


OCTAVIAN BÂSCĂ
LEON LIVOVSKI

ALGORITMI EURISTICI



Editura Universității din București

OCTAVIAN BÂSCĂ

LEON LIVOVSCI

bd 267 570

ALGORITMI EURISTICI



EDITURA UNIVERSITĂȚII DIN BUCUREȘTI
2003

III 476843

Referenți științifici: Prof. dr. Ion VĂDUVA
Prof. dr. Ioan TOMESCU

B.C.U. Bucuresti



C20035669

12/8/03

© Editura Universității din București
Șos. Panduri, 90–92, București – 76235; Telefon/Fax: 410.23.84
E-mail: editura@unibuc.ro
Internet: www.editura.unibuc.ro

Descrierea CIP a Bibliotecii Naționale a României
BĂSCĂ, OCTAVIAN

Algoritmi euristici / Băscă Octavian, Leon Livovschi –
București: Editura Universității din București, 2003
368 p.
Bibliografie
ISBN 973-575-785-0
I. Livovschi, Leon
51

INTRODUCERE

Așa cum se menționează în *Mic Dicționar Enciclopedic*, termenul *euristic* provine de la cuvântul grecesc *heurisko* ceea ce în traducere înseamnă *a descoperi*. Tot aici sunt date sensurile lui *euristic* cu funcțiile sintactice de adjectiv, substantiv și în combinație cu termenul *algoritm*. Ca adjectiv, *euristic* privește procedeele metodologice, fiind ceva care servește la obținerea unor cunoștințe noi sau care se aplică metodelor descoperirii și ale invenției. Sensul de substantiv al lui *euristică* desemnează o ramură de știință care are ca obiect studiarea activității creatoare, a metodologiei și tehnicii inovației intelectuale. Tot în același articol mai este menționat și termenul de *algoritm euristic* definit ca un algoritm verificat pe cazuri particulare dar nedemonstrat ca valabil pentru cazul general sau ca algoritm care dă o soluție aproximativă unei probleme.

Din cele de mai sus rezultă că noțiunile de euristică și algoritm euristic sunt noțiuni foarte des utilizate. Dar, cu toată răspândirea metodelor euristice, au fost elaborate până acum destul de puține lucrări în care să fie studiate și prezentate sistematic aceste metode.

Prin extindere, aproape orice teorie matematică și aplicațiile ei sunt în ultimă instanță procedee euristice. Pentru rezolvarea unei probleme practice cu ajutorul matematicii se parcurg în general următoarele etape:

1. Construirea unui model matematic.
2. Rezolvarea teoretică a problemei.
3. Interpretarea rezultatelor în cazul real.

În fiecare dintre aceste etape sunt efectuate aproximații datorate pe de o parte diferitelor abstractizări, pe de altă parte imperfecțiunii măsurătorilor și eventual subiectivității. Oricât de elaborat ar fi modelul matematic ales, se pot găsi elemente ale lumii reale care nu au fost luate în considerație în model și care eventual ar putea să determine calitatea soluției găsite. De foarte multe ori, deși se operează logic cu mulțimi infinite, implementarea calculelor se face prin mulțimi finite. O influență mare o are și modul de abordare a problemelor. Dăm în acest sens un exemplu.

S-a făcut un test privind aptitudinile casnice ale bărbaților. Una dintre întrebările testului era cea privind indicarea modului de preparare a unui ceai. Majoritatea lor a indicat următorul algoritm de preparare a unui ceai:

Algoritmul 0.1. (*Preparare ceai*)

1. [Apa] Se pune apă în ibric.
2. [Fierbere] Se fierbe apa din ibric.
3. [Finalizare] Se adaugă ceai, zahăr, lămâie și eventual rom, apoi STOP. ■

Deosebiri esențiale au apărut în răspunsul la următoarea întrebare în care se punea problema preparării ceaiului în cazul în care în ibric există deja apă. Astfel, o parte dintre bărbați a rezolvat problema prin adăugarea la începutul algoritmului precedent a pasului suplimentar:

0. [Verificare] Dacă în ibric este apă, atunci se merge la pasul 2.

Dar au fost și unii dintre bărbați care au găsit o soluție în care se adăuga la început:

0. [Verificare] Dacă în ibric este apă, atunci se varsă apa din ibric.

Ambele soluții sunt corecte din punct de vedere al rezultatului final. Dar ambele au atât calități cât și deficiențe. A doua soluție este în spiritul gândirii matematice de a reduce rezolvarea unei probleme la rezolvarea altei probleme pentru care se cunoaște soluția. Se poate lucra astfel *modular*, fiind suficient de a ști că un modul are o mulțime de date de intrare și o mulțime de date de ieșire fără a fi de interes procedeul cu care se găsește soluția. Prima soluție ține seama de structura algoritmului de rezolvare, speculând forma soluției. Acest mod de gândire poate să ducă la soluții mai eficiente. În cazul de față, nu numai că se economisesc unele operații, vărsarea apei și punerea altei ape în ibric, dar poate să ducă la soluție pentru unele situații care nu se pot rezolva prin a doua soluție, cum ar fi oprirea apei curente pentru o perioadă de timp din cauza unei defecțiuni la rețeaua de distribuție.

Scopul acestei cărți este identificarea și prezentarea diferitelor clase de algoritmi euristici și metodele de aplicare ale acestora. Trebuie să recunoaștem că este greu de inclus într-un singur volum toate clasele de algoritmi euristici, numărul lor fiind foarte mare, acest subiect fiind abordat într-o mulțime de lucrări apărute în reviste de specialitate.

După cunoștința autorilor, aceasta este prima monografie din țara noastră care abordează sistematic acest domeniu cu o mare aplicabilitate. Așa cum vom menționa în continuare, diferite tipuri de algoritmi euristici sunt studiate în lucrări din domenii foarte diverse cum ar fi cercetările operaționale, analiza numerică, teoria sistemelor, structuri de date, matematici financiare, fizică, chimie, biologie, arhitectură, teoria simulării, statistică, medicină și multe altele.

Structura lucrării este o reflectare a modului în care intervin metodele euristice în rezolvarea diferitelor probleme practice. Bazați pe o bogată experiență didactică și din dorința de a face o carte cu adevărat utilă, am selecționat pentru a prezenta metodele cu o cât mai mare aplicabilitate. În mod inevitabil, unele din aceste metode au primit o tratare mai amplă, fiind ilustrate cu exemple, iar altele au fost trecute numai în revistă. Pentru diferitele proprietăți enunțate am inclus și demonstrații numai în cazurile când acestea dau informații suplimentare sau pentru o mai bună înțelegere a noțiunilor.

Nu am inclus în carte metodele tratate în domeniul analizei numerice deși aceste metode sunt în cea mai mare parte algoritmi euristici. Pentru aceste metode există deja o literatură bogată. Pot fi consultate în acest domeniu cărți editate în țara noastră, elaborate de autori români sau traduceri, ([BUC73], [CRA82], [DOR76], [MAR87] etc.) și în străinătate, de referință fiind lucrarea [DEM81].

Am insistat asupra metodelor combinatoriale, a celor care utilizează teoria grafurilor și în special asupra metodelor de rezolvare a problemelor de planificarea activităților. Aceste metode au o foarte mare aplicabilitate în majoritatea domeniilor. Calitatea soluțiilor determinate și aproximarea cât mai bună a soluțiilor optime pot să fie hotărâtoare pentru obținerea unor beneficii materiale și morale în domeniul bancar, în transporturi, în comunicații, în servicii, în informatică, în electronică, în medicină și în multe alte domenii.

Cartea conține un număr de șapte capitole.

În Capitolul 1 se prezintă caracteristicile claselor de algoritmi euristici. Sunt definite diferitele tipuri de metode aproximative. Se dau metode de analiză a algoritmilor euristici prin care se determină calitățile lor și metode de sinteză pentru acești algoritmi prin care se pot ei elabora. Scopul acestui prim capitol este prezentarea unor instrumente de lucru pentru abordarea problemelor soluționate prin intermediul algoritmilor euristici. În ultima parte a acestui prim capitol sunt prezentați algoritmi genetici și evolutivi.

În Capitolul 2 se consideră câteva probleme din domeniul combinatoric. Sunt studiate probleme cum sunt: împerecherea minimală, problema rucsacului, probleme de aritmetică combinatorie, selectarea și ordonarea dispozitivelor de orientare, problema superșirului minimal, acoperirea unui set de mulțimi și minimizarea sumei maximele pe liniile unei matrici. De cele mai multe ori problemele de combinatorică presupun enumerarea unor elemente ale unor mulțimi și alegerea unor submulțimi ale acestor elemente drept soluții posibile. Euristicile aplicate în acest caz restrâng mulțimile inițiale la mulțimi cu mai puține elemente.

În Capitolul 3 sunt abordate probleme din teoria grafurilor. Dacă am tratat pe larg probleme de drumuri minime care sunt invocate în foarte multe aplicații, nu am tratat decât sumar probleme de fluxuri. Acestea din urmă sunt tratate în mai multe lucrări ce au apărut și în limba română. Sunt date metode de rezolvare pentru problema arborelui lui Steiner, pentru localizarea centrelor unui graf, pentru descompunerea unor grafuri, pentru plasarea facilităților într-o rețea, pentru drumuri hamiltoniene și pentru generarea unor separatori.

În Capitolul 4 se dau mai multe metode de rezolvare euristică a unei probleme particulare din teoria grafurilor și anume problema comisvoiajorului. Această problemă a permis construirea unor clase importante de euristici ce au putut să fie aplicate la soluționarea unui mare număr de probleme. Sunt tratate cazuri particulare cu restricții sau cu folosirea mai multor persoane, probleme de localizare a stațiilor de servire și diferite aplicații.

În Capitolul 5 este indicată o mare varietate de metode pentru rezolvarea problemei planificării activităților. Această problemă este una din cele mai frecvent întâlnite în practică. În plus, multe din metodele indicate în acest capitol pot fi adaptate pentru a obține soluții și pentru alte probleme din alte domenii. Am încercat să prezentăm metode cât mai variate și care să satisfacă diferite condiții suplimentare impuse planificărilor. Sunt indicate metode de soluționare polinomială (bazate pe drumuri critice, pe circuite critice și metode clasice), metode nepolinomială (bazate pe programare dinamică și metode arborescente), cazuri speciale de planificări (procesoare distincte, cu timpi de adaptare, cu profit maxim, minimizarea sumei întârzierilor, cu grafuri liniare, programări stohastice, planificări preemptive și cu divizarea procesorilor, minimizarea timpului mediu etc.). Sunt date o serie de aplicații ale acestor metode.

În Capitolul 6 se dau metode de soluționare a problemelor de programare liniară întreagă atât sub forma generală cât și cu variabile 0-1 și diferite aplicații care duc la rezolvarea unor probleme de același tip cum ar fi problema de depozitări și procesarea pe mai multe mașini paralele independente.

În Capitolul 7 au fost incluse alte probleme ce nu sunt de tipul celor prezentate în capitolele anterioare și care se rezolvă tot prin metode euristice. Au fost prezentate metode pentru ajustarea costurilor în cazul incertitudinii cererilor, localizarea deservirii, reprovizionarea comună, plasarea optimală a băncilor de conturi, descompunerea matricilor de trafic în comunicația prin sateliți, problema monezilor, organizarea memoriilor liniare, arbori binari optimi pentru căutare, problema șahului și alte probleme.

Modul de prezentare a algoritmilor este cel utilizat în multe lucrări de informatică. Execuția unui algoritm se realizează în felul următor. Se începe cu efectuarea operațiilor indicate în primul pas. Terminarea unui algoritm are loc dacă se ajunge la STOP sau se termină de efectuat operațiile din ultimul pas al algoritmului și nu se indică efectuarea operațiilor de la un alt pas. Dacă sunt efectuate operațiile unui pas și nu este prevăzută trecerea la un alt pas, atunci se trece la efectuarea operațiilor prevăzute la pasul următor, în afara cazului, menționat mai sus, în care s-au terminat de executat operațiile ultimului pas precum și în cazul în care în unii pași se indică executarea repetată a unor pași pentru diferite valori ale unor parametrii. Fiecare pas conține la început, incluse între paranteze drepte, un cuvânt sau o expresie care sintetizează operațiile prevăzute în acel pas.

Pentru marcarea terminării textului corespunzător unor teoreme, leme, definiții, algoritmi, exemple și altele am folosit semnul ■. Începerea textului ce definește aceste noțiuni se face prin **litere îngroșate** și sunt, în general, numerotate. Numerotarea se face prin numărul capitolului din care face parte și numărul curent de tipul respectiv. Au fost utilizate numere și pentru unele expresii, figuri, formule și tabele pentru a fi ușor de referit.

Noțiunile definite în text, corespondentul din diferite limbi străine a unor cuvinte sau expresii și majoritatea notațiilor sunt reprezentate prin *litere cursive* pentru a putea să fie mai ușor reperate.

Bibliografia plasată la sfârșitul cărții, cu toate că este bogată, este departe de a fi completă. Am inclus în special acele lucrări care sunt mai apropiate de aspectele tratate și care ajută cititorul să aprofundeze problematica algoritmilor euristici.

Prin modul de prezentare, prin enunțarea unor rezultate foarte puternice, explicarea folosirii acestora și posibilitatea implementării pe calculator, lucrarea se adresează studenților din facultățile de informatică, matematică, fizică, chimie și biologie, ai institutelor tehnice și economice, agronomice și de medicină, cercetătorilor din domeniile amintite, precum și personalului din compartimentele de conducere și control.

Sperăm ca această lucrare să se dovedească utilă și să se bucure de popularitate între specialiști și nespecialiști care utilizează metodele informatice pentru rezolvarea problemelor practice și pentru diferite alte aplicații posibile. Plecând de la deviza repetată foarte des de profesorul Grigore C. Moisil:

Cea mai scumpă știință este mult mai ieftină decât cea mai ieftină neștiință!

dorim și noi ca metodele prezentate aici să fie cunoscute și aplicate cât mai mult.

Mulțumim pe această cale tuturor celor care au contribuit la finalizarea acestei dorințe a noastre de a încheia o teorie a algoritmilor euristici plecând de la lucrări dispartate și bazându-ne pe experiența noastră la catedră și în utilizarea tehnicii de calcul. Ne referim în primul rând la colegii de muncă și prietenii noștri care ne-au încurajat mereu cu sfaturi și informații utile. Apoi ne referim la colectivul cu care am colaborat la Editura Academiei. Am găsit aici multă înțelegere și sollicitudine din partea doamnei SILVIA CÂNDEA, a domnului PETRE MOCANU, a domnului director IOAN GANEA și a multor alora pentru pregătirea și tipărirea acestei cărți. Nu în ultimul rând vrem să mulțumim soțiilor noastre și familiilor noastre pentru înțelegerea timpului sacrificat lor ca să putem realiza această lucrare. Ne-am bucura nespun să știm că aceste sacrificii nu au fost zadarnice și să putem să înregistrăm reacții, pozitive s-au critice, care să ne dovedească interesul pentru tratarea subiectului algoritmi euristici. În funcție de acestea vom ști dacă trebuie să continuăm sau nu să depunem eforturi noi pentru desțelenirea altor metode de tipul celor prezentate aici.

București 10.12.1997

AU? RII

CUPRINS

INTRODUCERE	3
CAPITOLUL 1. ANALIZA ȘI SINTEZA ALGORITMILOR EURISTICI	17
1.1. Algoritmi euristici și aproximativi	17
1.1.1. Definiții de bază	17
1.1.2. Algoritmi aproximativi	20
1.1.2.1. Algoritmi cu aproximare absolută	20
1.1.2.1.1. Problema memorării fișierelor pe două benzi	20
1.1.2.2. Algoritmi $f(n)$ -aproximativi	21
1.1.2.2.1. Problema comisvoiajorului	21
1.1.2.3. Algoritmi ε -aproximativi	21
1.1.2.3.1. Planificarea activităților independente	21
1.1.2.3.2. Problema împachetării	22
1.1.2.3.3. Problema rucsacului	24
1.1.2.4. Scheme aproximative în timp polinomial	27
1.1.2.4.1. Planificarea activităților independente	27
1.1.2.4.2. Problema comisvoiajorului	28
1.1.2.5. Scheme de aproximare complet polinomiale	29
1.1.2.5.1. Rotunjirea	30
1.1.2.5.2. Partiționarea pe intervale	32
1.1.2.5.3. Separarea	33
1.1.2.6. Algoritmi buni în sens probabilistic	35
1.1.3. Utilizarea teoriei NP-completitudinii pentru identificarea de algoritmi aproximativi	37
1.2. Analiza algoritmilor	38
1.2.1. Măsuri de comportare în cel mai rău caz a unui algoritm	38
1.2.2. Algoritmul A^*	42
1.2.2.1. Definiții și notații suplimentare	44

1.2.2.2. Căutarea unei soluții optimale cu algoritmul A^*	45
1.2.2.2.1. Proprietățile funcției f^*	45
1.2.2.2.2. Terminare și completitudine	46
1.2.2.2.3. Admisibilitate - garanția pentru o soluție optimală	47
1.2.2.2.4. Comportarea puterii de selectare a euristiciilor	48
1.2.2.2.5. Euristici monotone (consistente)	50
1.2.2.3. Relaxarea condițiilor de optimalitate	53
1.2.2.3.1. Ajustarea ponderilor lui g și h	53
1.2.2.3.2. Două versiuni ϵ -admisibile mai rapide ale lui A^*	54
1.2.2.3.2.1. Ponderarea dinamică	54
1.2.2.3.2.2. A_ϵ^* - algoritm ce utilizează estimări ale efortului căutării	55
1.2.2.3.2.3. Compararea celor doi algoritmi	55
1.2.3. Euristicile ca informație dată de modele simplificate	58
1.2.3.1. Utilizarea modelelor relaxate	58
1.2.3.1.1. Proveniența euristiciilor	58
1.2.3.1.2. Consistența euristiciilor bazate pe relaxare	60
1.2.3.2. Generarea mecanică a euristiciilor admisibile	61
1.2.3.2.1. Relaxarea sistematică	61
1.2.3.2.2. Observații și concluzii	63
1.2.4. Euristici bazate pe probabilitate	64
1.2.4.1. Euristici bazate pe cel mai plauzibil rezultat	64
1.2.4.2. Euristici bazate pe eșantionare	65
1.2.5. Modele abstracte pentru analiza cantitativă a performanței	66
1.2.5.1. Analiza matematică a performanței	66
1.2.5.2. Exemplul 1: Găsirea unui cel mai scurt drum într-o latice regulată	66
1.2.5.3. Exemplul 2: Găsirea unui cel mai scurt drum într-o rețea de orașe distribuite la întâmplare	71
1.2.5.4. Exemplul 3: Căutarea unui drum optim într-un arbore cu costuri aleatoare	74
1.2.5.4.1. Rezultate	76
1.2.6. Complexitatea și precizia euristiciilor admisibile	77
1.2.6.1. Euristicile interpretate drept surse de informație perturbate	77
1.2.6.1.1. Modelele simplificate - surse de semnale perturbate	77
1.2.6.1.2. Un model probabilistic pentru analiza performanței unei euristici	78
1.2.6.2. Dominanța stohastică pentru euristici admisibile aleatoare	81

1.3. Sinteza algoritmilor euristici	83
1.3.1. Clasificarea metodelor euristice	83
1.3.1.1. Morfologia metodelor de identificare a unei prime soluții	84
1.3.1.2. Morfologia metodelor iterative	85
1.3.2. Metode exacte pentru sinteza algoritmilor	85
1.3.2.1. Metoda Greedy	85
1.3.2.2. Metode arborescente	86
1.3.2.3. Metoda backtracking	88
1.3.2.4. Metoda branch and bound	89
1.3.2.5. Metoda divide et impera	90
1.3.2.6. Metoda programării dinamice	90
1.3.3. Metode generale de construire a unor euristici	92
1.3.3.1. Euristici folosind metoda Greedy	92
1.3.3.2. Euristici folosind metoda backtracking	93
1.3.3.3. Euristici folosind metoda branch and bound	93
1.3.3.4. Euristici folosind metoda divide et impera	95
1.3.3.5. Euristici folosind metoda programării dinamice	95
1.4. Algoritmi genetici și evolutivi	96
1.4.1. Introducere	96
1.4.2. Algoritm genetic pentru optimizarea unei funcții	97
1.4.2.1. Reprezentarea	98
1.4.2.2. Populația inițială	98
1.4.2.3. Funcția de evaluare	98
1.4.2.4. Operatori genetici	99
1.4.2.5. Parametri	99
1.4.2.6. Rezultate experimentale	100
1.4.2.7. Procesul de selectare	100
1.4.3. Algoritm evolutiv pentru rezolvarea problemei liniar-pătratică	101
1.4.3.1. Operatori specializați	102
1.4.4. Forma generală a algoritmilor genetici și evolutivi	105
1.4.5. Observații și comentarii	106
CAPITOLUL 2. PROBLEME COMBINATORIALE	107
2.1. Împerechere minimală	107
2.2. Problema rucsacului	110

2.2.1. Algoritm euristic eficient pentru problema rucsacului	110
2.2.2. Algoritm aproximativ polinomial pentru problema rucsacului	111
2.2.3. Teste de realizabilitate	111
2.2.4. Cazul densităților ordonate ale profitului	113
2.2.5. Algoritmi genetici pentru problema rucsacului	115
2.3. Algoritmi aproximativi pentru probleme de aritmetică combinatorie	118
2.3.1. Modul de prezentare al calculelor	119
2.3.2. Metoda condensării	120
2.4. Selectarea și ordonarea dispozitivelor de orientare	121
2.4.1. Ordonarea optimală a dispozitivelor în cazul unei singure piese	123
2.4.2. Selectarea și ordonarea dispozitivelor în cazul unei piese	125
2.4.3. Selectarea și ordonarea dispozitivelor pentru m tipuri de piese	127
2.4.4. Selectarea și ordonarea dispozitivelor în cazul a m tipuri de piese cu l orientări	127
2.5. Algoritmi aproximativi pentru problema superșirului minimal	127
2.5.1. Algoritmul împachetării	128
2.5.2. Algoritmul împachetării direcționate	129
2.5.3. Algoritmul de tip Greedy	130
2.6. Problema acoperirii unui set de mulțimi	131
2.6.1. Prezentarea algoritmului	132
2.7. Minimizarea sumei maxime pe liniile unei matrice	134
2.7.1. Algoritmul RDI pentru cazul general	135
2.7.2. Algoritmul $RLPT$ pentru cazul $m \times 3$	137
CAPITOLUL 3. PROBLEME ÎN TEORIA GRAFURILOR	139
3.1. O euristică pentru problema arborelui lui Steiner	139
3.2. Algoritm euristic pentru arbori Steiner rectiliniari	142
3.3. Algoritm euristic pentru identificarea drumurilor minime	146
3.3.1. Metoda corectării etichetelor	147
3.3.2. Algoritmul examinării topologice	147
3.4. Metodă euristică pentru identificarea clicilor de cardinalitate dată și de cost minimal	150
3.5. Localizarea mai multor centre într-un graf	153
3.6. Descompunerea unui graf	158
3.6.1. Identificarea clicilor (θ, α) maxime	158

3.6.2. Procedura contractării grafului	160
3.7. Așezarea facilităților într-o rețea planară	162
3.7.1. Euristică triumghiului	162
3.7.2. Euristică expandării roților	163
3.7.3. Euristică Greedy	164
3.7.4. Îmbunătățirea soluțiilor finale	164
3.7.5. Complexitatea euristicilor propuse	165
3.8. Drum hamiltonian într-un graf planar maximal	165
3.9. Algoritm euristic pentru generarea de separatori mici în grafuri arbitrare	168
CAPITOLUL 4. PROBLEMA COMISVOIAJORULUI	171
4.1. Metode euristice pentru problema comisvoiajorului	171
4.1.1. Metoda extinderii bilaterale	171
4.1.2. Metoda reducerii	172
4.1.3. Metoda proximității	174
4.1.4. Metode bazate pe pierderi	175
4.1.4.1. Pierdere simplă	176
4.1.4.2. Pierdere compusă	176
4.1.4.3. Folosirea distanțelor ajustate	182
4.1.4.4. Euristici mai rapide	182
4.1.5. Metoda ciclurilor crescătoare	183
4.1.6. Rectificarea turului	183
4.2. Problema restrictivă a comisvoiajorului	188
4.3. Problema comisvoiajorului cu k persoane	191
4.4. Localizarea stației de deservire în problema comisvoiajorului	193
4.5. Margini pentru problema transportului cu vehicule de capacitate limitată	197
4.5.1. Margini inferioare și superioare	197
4.5.2. Margini superioare pentru problema comisvoiajorului	198
4.6. Problema orientării	201
4.7. O aplicație a problemei comisvoiajorului	203
CAPITOLUL 5. PLANIFICAREA ACTIVITĂȚILOR	207
5.1. Modelarea problemelor de planificarea activităților	207
5.1.1. Notății utilizate	208

5.1.2. Modul de execuție	208
5.1.3. Resurse	209
5.1.4. Funcții obiectiv	210
5.1.5. Reprezentarea soluțiilor	211
5.1.6. Modelarea problemei principale de programare	212
5.1.7. Modelarea cu rețele Petri	213
5.2. Metode polinomiale de rezolvare a problemei planificării activităților	215
5.2.1. Algoritmi bazați pe metoda drumului critic	215
5.2.1.1. Mulțimi de potențiale pe un graf conjunctiv	215
5.2.1.2. Metoda potențiale-activități	216
5.2.1.3. Metode seriale de planificare folosind drumuri critice	218
5.2.1.4. Euristică Schrage pentru un singur procesor	220
5.2.1.5. Probleme cu resurse consumabile	222
5.2.1.6. Probleme cu termene de predare	224
5.2.1.7. Metoda PERT	225
5.2.2. Metoda circuitelor critice	226
5.2.2.1. Modelarea problemei centrale repetitive	227
5.2.3. Metode clasice	230
5.2.3.1. Metode de schimb	230
5.2.3.1.1. Programarea pe un procesor	230
5.2.3.1.1.1. Proprietăți ale soluțiilor optime pentru activități dependente	230
5.2.3.1.1.2. Dependente de tip antiarborescență	231
5.2.3.1.1.3. Euristică Greedy pentru activități cu termene de predare	232
5.2.3.1.2. Probleme de atelier cu două procesoare	233
5.2.3.1.3. Euristici de planificare pe două mașini cu timpi de accesibilitate	234
5.2.3.1.4. Algoritm euristic pentru procesare pe mai multe procesoare	237
5.2.3.1.5. Euristici bazate pe indicele de înclinare	239
5.2.3.1.6. Planificarea pe procesoare cu viteze diferite	241
5.2.3.2. Metode de planificare pe bază de listă	244
5.2.3.2.1. Margini pentru anomaliile din multiprocesare	246
5.2.3.2.2. Activități cu timpi egali și precedente tip antiarborescențe	249
5.2.3.2.3. Euristici bazate pe nivelurile nodurilor	250
5.2.3.2.4. Programare optimală pentru doi procesori și timpi egali	250
5.3. Metode nepolinomiale de programarea activităților	252
5.3.1. Algoritmi bazați pe programarea dinamică	252

5.3.1.1. Programarea activităților independente	253
5.3.1.2. Programarea activităților dependente	256
5.3.2. Metode arborescente	256
5.3.2.1. Minimizarea sumei întârzierilor	256
5.3.2.2. Minimizare durată totală pentru activități cu timp de latență	258
5.4. Alți algoritmi aproximativi pentru programarea activităților	261
5.4.1. Planificarea activităților pe procesoare distincte	261
5.4.2. Altă euristică pentru planificarea pe procesoare diferite	264
5.4.3. Minimizarea duratei totale cu timpi de adaptare	266
5.4.4. Planificări cu profit maxim	268
5.4.5. Minimizarea sumei întârzierilor	269
5.4.5.1. Căutarea locală și vecinătăți	270
5.4.5.2. Valorile maxime ale erorilor pentru $K-INT$ și ADJ	272
5.4.6. Planificarea activităților folosind grafuri liniare	273
5.4.7. Analiza euristicilor pentru programări stohastice	278
5.4.8. Planificări preemptive și cu divizarea procesorilor	281
5.4.9. Planificări cu minimizarea timpului mediu	286
5.5. Aplicații	290
5.5.1. Algoritm efectiv de asamblare a lucrărilor	290
5.5.1.1. Euristici pentru problema $SALB-I$	290
5.5.1.2. Euristici pentru problema $SALB-II$	292
5.5.2. Performanța unor euristici pentru linii de asamblare	293
5.5.3. Desvoltarea capacității cu mai multe tipuri de facilități	295
CAPITOLUL 6. PROGRAMARE LINIARĂ ÎNTREAGĂ	299
6.1. Algoritmi euristici pentru programarea liniară întreagă	299
6.1.1. Metodele fazei 1	300
6.1.2. Metodele fazei 2	301
6.1.3. Metodele fazei 3	303
6.1.4. Exemplu de programare liniară întreagă	303
6.2. Algoritm aproximativ pentru programarea 0-1	305

6.3. Programarea liniară a comenzilor cu variabile 0-1	309
6.4. Problema depozitării	314
6.5. Euristică liniară de procesare pe mașini paralele independente	317
CAPITOLUL 7. ALTE APLICAȚII	321
7.1. Euristici de ajustare a costurilor în cazul incertitudinii cererilor	321
7.2. Euristici pentru problema localizării deservirii	323
7.3. Problema reprovizionării comune	326
7.4. Plasarea optimală a băncilor de conturi	330
7.5. Descompunerea euristică a matricilor de trafic în comunicarea sateliților	333
7.6. Problema monedelor	337
7.7. Organizarea memoriilor liniare	342
7.8. Arbori binari optimi pentru căutare	351
7.9. Euristici în jocul de șah	354
BIBLIOGRAFIE	357

1 ANALIZA ȘI SINTEZA ALGORITMILOR

EURISTICI

Acest capitol cuprinde definirea euristiciilor și algoritmilor aproximativi, clasificări și principalele metode de analizare și elaborare ale acestor algoritmi. Pentru majoritatea metodelor sunt date exemple. Unele probleme sunt reluate și dezvoltate noi metode de soluționare ale lor în capitolele următoare.

1.1. Algoritmi euristici și aproximativi

1.1.1. Definiții de bază

Un algoritm se numește *algoritm aproximativ* dacă generează, pentru o problemă P dată, o *soluție corectă* având o valoare apropiată, într-un sens ce trebuie precizat, de valoarea *soluției optimale*.

De exemplu, metoda de extragere a rădăcinii pătrate a unui număr real în reprezentarea zecimală permite determinarea unui număr oricât de apropiat de valoarea reală, considerată valoare optimă. În unele cazuri, valoarea determinată de algoritmul aproximativ este chiar valoarea optimă. Pentru extragerea rădăcinii pătrate a unui număr zecimal aceasta se poate întâmpla acest lucru în cazul în care numărul zecimalelor rădăcinii pătrate este finit.

Un algoritm se numește *algoritm euristic* dacă, în contextul său, se folosesc anumite strategii de identificare a soluției care asigură obținerea unor rezultate *rezonabile*, în sensul că aceste rezultate sunt acceptabile conform unor criterii ce se presupun precizate. Cuvântul *euristică* desemnează una sau mai multe strategii folosite în cadrul unui algoritm euristic.

De exemplu, metoda prin care se poate face *acordarea creditelor la o bancă*, în care se urmărește obținerea unui profit cât mai bun, poate să utilizeze diferite *euristici* mai mult sau mai puțin eficiente cum ar fi:

- Acordarea creditelor în ordine descrescătoare a sumei cerute.
- Acordarea creditelor în ordine crescătoare a raportului dintre suma cerută și garanțiile date pentru rambursare.
- Acordarea creditelor în ordine crescătoare a timpului cerut pentru rambursare.
- Acordarea creditelor în ordine descrescătoare a timpului cerut pentru rambursare.
- Acordarea creditelor în ordinea de prioritate a unor investiții.

Un algoritm euristic pentru acordarea creditelor poate să combine mai multe euristici pentru a obține un rezultat cât mai apropiat de profitul maxim. Considerarea uneia sau a alteia dintre euristici se face în funcție de alți parametri, care pot să intervină în luarea deciziei, cum ar fi: modul de efectuare a plăților, cursul de schimb, valoarea depozitului disponibil etc.

Majoritatea algoritmilor aproximativi au la baza lor euristici, așa încât în literatura de specialitate nu se face o deosebire netă între aceste două noțiuni.

În continuare, se vor folosi următoarele notații și definiții:

A - pentru algoritm,

I - o mulțime de date particulare pentru un algoritm A (intrarea),

$A(I)$ - rezultatele furnizate de algoritmul A pentru mulțimea I (ieșirea),

OPT - algoritm optimal (care determină soluția optimală),

$OPT(I)$ - rezultatele furnizate de un algoritm optimal ce efectuează calcule în aceleași condiții ca și algoritmul A .

Se numește *performanță absolută* (în limba engleză *absolute performance ratio*) a unui algoritm de minimizare, respectiv maximizare mărimea:

$$R_A(I) = |A(I)| / |OPT(I)|, \text{ respectiv } R_A(I) = |OPT(I)| / |A(I)|.$$

Se observă din definiție că $R_A(I) \geq 1$.

Se numește *eroare a unui algoritm aproximativ* A mărimea R_r definită astfel:

$$R_r = \inf\{r \geq 0 \mid R_A(I) \leq r + 1, \text{ pentru toate problemele individuale ale algoritmului } A\}.$$

Se numește *eroare asimptotică* a unui algoritm aproximativ A mărimea:

$$R_A^\infty = \inf\{r \geq 0 \mid \text{există } N \in \mathbb{Z}^+ \text{ astfel încât, } R_A(I) \leq r + 1, \\ \text{pentru orice } I \text{ pentru care } |OPT(I)| \geq N\}.$$

Pentru o problemă de optimizare P , se numește *cea mai bună eroare asimptotică* mărimea:

$$R_{\text{MIN}}(P) = \inf\{r \geq 0 \mid \text{pentru rezolvarea problemei } P, \text{ există un algoritm aproximativ polinomial } A, \text{ astfel încât } R_A^\infty = r\}.$$

Algoritmul A , pentru determinarea soluției unei probleme P , se numește *algoritm de aproximare absolută* dacă și numai dacă există o constantă k astfel încât $|OPT(I) - A(I)| \leq k$, pentru orice I .

Algoritmul A se numește *algoritm $f(n)$ -aproximativ* dacă și numai dacă:

$$|OPT(I) - A(I)| / |OPT(I)| \leq f(n).$$

pentru orice I de mărime n . Prin *mărime* a unei mulțimii de date I se înțelege o măsură definită pe mulțimea I .

Algoritmul A_ε se numește o *schemă ε -aproximativă* dacă și numai dacă, pentru orice $\varepsilon > 0$, A_ε generează o soluție pentru care:

$$|OPT(I) - A(I)| / |OPT(I)| \leq \varepsilon.$$

O schemă aproximativă se numește *schemă aproximativă în timp polinomial* dacă și numai dacă, pentru orice $\varepsilon > 0$, timpul de calcul este polinomial în măsura definită pe mulțimea I .

O schemă de aproximare pentru care timpul de calcul este polinomial atât în măsura pe mulțimea I cât și în $1 / \varepsilon$ se numește *schemă de aproximare complet polinomială în timp*.

Fie P_1 și P_2 două probleme. Problema P_1 se reduce la problema P_2 , și se notează $P_1 \alpha P_2$, dacă și numai dacă există o metodă de rezolvare a lui P_1 cu un algoritm deterministic în timp polinomial utilizând un algoritm deterministic în timp polinomial care rezolvă problema P_2 .

Un rol esențial în studiul complexității algoritmilor îl are *problema satisfiabilității*. Această problemă constă în identificarea faptului dacă o *formulă booleană* este *adevărată* pentru o mulțime dată de valori ale variabilelor ei.

O problemă P este *NP-difilă* (în engleză *NP-hard*) dacă și numai dacă problema satisfiabilității se reduce la P .

Un algoritm este *algoritm pseudo-polinomial în timp* dacă are o complexitate polinomială în $LUNGIME(I)$ și $MAX(I)$, unde $LUNGIME(I)$ este numărul de biți în reprezentarea mulțimii I și $MAX(I)$ este valoarea celui mai mare număr din I .

Algoritmii euristici sunt preferați algoritmilor exacți în cazul când ei furnizează soluții suficient de apropiate de soluția optimală și pot fi implementați ușor, cu reduceri evidente în timp și spațiu.

1.1.2. Algoritmi aproximativi

În continuare vom prezenta mai mulți algoritmi ilustrativi pentru diferitele tipuri de aproximare. Pentru fiecare dintre probleme vom da algoritmi de soluționare și, eventual, exemple de aplicare ale acestor algoritmi. Pentru majoritatea algoritmilor, vom indica și alte posibile aplicații în diverse domenii de larg interes. Exemple mai complexe vor fi tratate în capitolele următoare.

1.1.2.1. Algoritmi cu aproximare absolută

1.1.2.1.1. Problema memorării fișierelor pe două benzi

Punerea problemei. Fiind date două benzi magnetice T_1 și T_2 , de lungimi b_1 și respectiv b_2 și n fișiere f_1, f_2, \dots, f_n de lungimi l_1, l_2, \dots, l_n , să se plaseze pe cele două benzi un număr cât mai mare din fișierele date. ■

Aplicații posibile: acordarea creditelor la bănci, umplerea containerelor.

Această problemă este *NP-difilă*. Un algoritm aproximativ pentru soluționarea ei este următorul:

Algoritmul 1.1. (*Benzi-magnetice*)

- [Ordonare] Se ordonează fișierele în ordinea crescătoare a lungimii lor; fișierele de aceeași lungime se pot lua în orice ordine.
- [Umplere banda 1] Se încarcă la maximum prima bandă cu fișiere în ordinea stabilită la pasul 1.
- [Umplere banda 2] Se încarcă la maximum a doua bandă cu fișierele rămase, considerate tot în ordinea stabilită la punctul 1, și apoi STOP. ■

Are loc următoarea proprietate, care dovedește că Algoritmul 1.1. este algoritm de aproximare absolută:

Teorema 1.1. [HOR78] Fie I mulțimea de fișiere ce urmează a fi memorate și $A(I)$ numărul de fișiere memorate în conformitate cu algoritmul 1.1. Atunci:

$$|OPT(I) - A(I)| \leq 1,$$

unde $OPT(I)$ este soluția optimală. ■

Algoritmul 1.1. poate fi generalizat la cazul a k benzi, cu un algoritm de aproximare absolută în care benzile sunt umplute pe rând de fișiere considerate în ordinea crescătoare a lungimii lor, aproximarea fiind în acest caz:

$$|OPT(I) - A(I)| \leq k - 1.$$

1.1.2.2. Algoritmi $f(n)$ -aproximativi

1.1.2.2.1. Problema comisvoiajorului

Punerea problemei. Se presupun m orașe legate între ele fiecare cu fiecare prin drumuri de lungime dată. Se caută un circuit de lungime minimă care să treacă o dată și numai o dată prin fiecare dintre orașe. ■

Aplicații posibile: stabilirea traseelor poștale sau de altă natură, aprovizionarea magazinelor, planificarea activităților.

Această problemă este *NP-dificilă*. În cazul în care distanțele dintre localitățile pe care le parcurge comisvoiajorul satisfac *regula triunghiului* adică:

$$d(a, c) \leq d(a, b) + d(b, c), \text{ pentru orice } a, b, c,$$

unde $d(a, b)$ reprezintă distanța între localitățile a și b , se poate elabora un algoritm euristic, numit *cel mai apropiat vecin*, și notat *NN* (din *Nearest Neighbor*).

Algoritmul 1.2. (*NN- Nearest Neighbor*)

1. [Inițializare] Se pleacă dintr-un oraș oarecare considerat drept oraș inițial.
2. [Continuarea drumului] Atâta timp cât mai sunt orașe neparcurse, se alege drept următoarea localitate cea mai apropiată dintre cele neparcurse încă.
3. [Închiderea circuitului] Se revine în orașul inițial apoi STOP. ■

Teorema 1.2. [GAR79] Pentru problema comisvoiajorului cu m orașe și în ipoteza regulii triunghiului, are loc inegalitatea:

$$(NN(I) - OPT(I)) / OPT(I) \leq 1/2 (\lceil \log_2 m \rceil - 1).$$

Mai mult, pentru orice valori ale lui m există probleme individuale pentru care:

$$(NN(I) - OPT(I)) / OPT(I) > 1/3 (\log_2(m + 1) - 5/3).$$

O demonstrație a acestei teoreme se poate găsi în [ROS77]. ■

Din teorema 1.2. rezultă că algoritmul *NN* este un algoritm de aproximare $1/2 \lceil \log_2 m \rceil$.

Problema comisvoiajorului va fi tratată pe larg în capitolul 4 unde vor fi indicate multe alte metode de rezolvare și aplicații ce se pot rezolva folosind soluții ale acestei probleme.

1.1.2.3. Algoritmi ε -aproximativi

1.1.2.3.1. Planificarea activităților independente

Punerea problemei. Se presupune existența a m ($m \geq 2$) procesoare de același tip. Se cere planificarea pe aceste procesoare a n activități independente care necesită

pentru execuție timpii t_1, t_2, \dots, t_n , astfel încât timpul total de lucru să fie cât mai mic posibil. ■

Aplicații posibile: tratarea programelor de către sistemele de operare, planificarea sistemelor de servicii, stabilirea planurilor de croire.

Problema obținerii unui timp minim de execuție a mai multor activități independente este *NP-dificilă*. Următoarea strategie de execuție asigură terminarea parcurgerii tuturor activităților într-un timp foarte apropiat de cel optim.

Definiția 1.1. O planificare *LPT* (*longest processing time*) este rezultatul unui algoritm care, ori de câte ori un procesor devine liber, alocă acestui procesor o activitate de durată maximă dintre activitățile nealocate încă. ■

Exemplul 1.1. Fie $m = 3, n = 7$ și $(t_1, t_2, t_3, t_4, t_5, t_6, t_7) = (5, 5, 4, 4, 3, 3, 3)$. Pe figura 1.1.a) este arătată soluția obținută utilizând planificarea *LPT* de durată totală 11 și pe figura 1.1.b) este dată soluția optimală pentru aceleași date de durată totală 9. ■




Fig. 1.1.

Teorema 1.3. [HOR78] Fie $OPT(I)$ timpul optimal și $LPT(I)$ timpul furnizat de un algoritm bazat pe planificarea *LPT* de efectuare a mai multor activități pe m procesoare. Atunci:

$$(LPT(I) - OPT(I)) / OPT(I) \leq 1/3 - 1/(3m).$$

O demonstrația a acestei teoreme se găsește în [GRA69]. ■

Există exemple pentru care are loc egalitatea în relația precedentă (vezi exemplul 1.1.)

Din teorema 1.3., rezultă că planificarea *LPT* este, pentru problema planificării activităților independente, o schemă $(1/3 - 1/(3m))$ -aproximativă.

1.1.2.3.2. Problema împachetării

Punerea problemei. Se consideră n obiecte ce urmează să fie încărcate în lăzi de capacitate egală cu L . Se cere o strategie care să asigure încărcarea celor n obiecte

într-un număr minim de lăzi, fiecare obiect fiind încărcat integral într-o singură ladă. Obiectul i necesită l_i unități de capacitate. Se presupune că $l_i \leq L$, pentru orice $i=1,2,\dots,n$. Altfel problema nu ar avea soluție pentru că ar exista obiecte care nu încăp în lăzi. ■

Aplicații posibile: alocarea memoriei, planificarea activităților pe clase de prioritate, colectărie.

Problema este *NP-dificilă*.

Pentru rezolvarea acestei probleme există mai multe euristici dintre care menționăm următoarele patru euristici simple:

1. *First Fit (FF)*. Lăzile se presupun numerotate și inițial sunt goale. Obiectele sunt parcurse în ordinea $1, 2, \dots, n$. Pentru a împacheta obiectul i , se caută cel mai mic indice j astfel încât lada j este completă pînă la nivelul r , $r \leq L - l_i$, și se introduce obiectul i în lada j .
2. *Best Fit (BF)*. Condițiile inițiale pentru obiecte și lăzi sunt aceleași ca mai sus. Pentru obiectul i , se caută cel mai mic indice j astfel încât lada j este umplută pînă la nivelul r , $r \leq L - l_i$, r fiind cât mai mare posibil, și se introduce obiectul i în lada j .
3. *First Fit Decreasing (FFD)*. Se ordonează obiectele în ordinea descrescătoare a lungimilor lor, $l_i \geq l_{i+1}$, pentru $i = 1, 2, \dots, n$, și se aplică euristica *FF*.
4. *Best Fit Decreasing (BFD)*. Se ordonează obiectele ca la euristica *FFD* și se aplică euristica *BF*.

Exemplul 1.2. Fie $L = 10$, $n = 6$ și $(l_1, l_2, l_3, l_4, l_5, l_6) = (5, 6, 3, 7, 5, 4)$. O soluție optimală a problemei este arătată în figura 1.2., fiind indicate numai dimensiunile obiectelor puse în lăzi. Aplicând metoda *FF* se obține o soluție cu 4 lăzi ce conțin în ordine elementele (1, 3), (2, 6), (4) și (5). Metoda *BF* dă o soluție tot cu 4 lăzi, care conțin elementele (1, 5), (2, 3), (4) și (6). Metodele *FFD* și *BFD* dau soluția optimală, abstracție făcând de o interschimbare între prima și ultima ladă la soluția prezentată în figura 1.2. ■




Fig. 1.2.

Se pot construi exemple pentru care euristicile *FFD* și *BFD* dau rezultate mai bune decât *FF* și *BF* dar și exemple în care *FF* sau *BF* sunt mai eficiente.

Teorema 1.4. [GAR79] Pentru toate problemele individuale de împachetare are loc inegalitatea:

$$FF(I) \leq 17/10 \text{ OPT}(I) + 2.$$

În afară de aceasta, există probleme pentru care $\text{OPT}(I)$ este oricât de mare și:

$$FF(I) \geq 17/10 (\text{OPT}(I) - 1).$$

O demonstrație a acestei teoreme se poate găsi în [JOH74a]. ■

Teorema 1.5. [GAR79] Pentru toate problemele individuale de împachetare are loc inegalitatea:

$$FFD(I) \leq 11/9 \text{ OPT}(I) + 4.$$

Există probleme individuale pentru care $\text{OPT}(I)$ este oricât de mare și:

$$FFD(I) \geq 11/9 \text{ OPT}(I).$$

O demonstrație a acestei teoreme se poate găsi în [JOH74a]. ■

Pentru metodele BF și BFD se pot demonstra proprietăți asemănătoare. Acestea dovedesc faptul că cele patru metode fac parte din clasa metodelor ε -aproximative.

1.1.2.3.3. Problema rucsacului

Punerea problemei. Fiind date mulțimile $P = \{p_1, p_2, \dots, p_r\}$ și $W = \{w_1, w_2, \dots, w_r\}$, unde P este mulțimea profiturilor obiectelor 1, 2, ..., r și W este mulțimea ponderilor acestor obiecte, se cere:

să se maximizeze $\sum p_i \delta_i$ cu condiția $\sum w_i \delta_i \leq M$ și $\delta_i \in \{0, 1\}$, pentru $i = 1, 2, \dots, r$, unde M reprezintă capacitatea rucsacului în care se încarcă obiectele. Cu alte cuvinte, să se determine o submulțime de obiecte, a căror pondere totală să nu depășească M , capacitatea rucsacului, și să dea un profit total maxim posibil. ■

Aplicații posibile: încărcarea containerelor, stabilirea rutelor pe calea ferată.

Se presupune că obiectele au fost ordonate în ordinea necrescătoare a densităților profitului, adică $p_i / w_i \geq p_{i+1} / w_{i+1}$, pentru $i = 1, 2, \dots, r - 1$. Fie $L(I, P, W, M)$ profitul obținut pe calea umplerii, în ordinea necrescătoare a rapoartelor p_i / w_i , a acelei părți din rucsacul de capacitate M care a rămas neocupată după ce obiectele din I au fost introduse în rucsac. P și W au semnificațiile de mai sus și se presupune că $r > 0$ și $\sum_{i \in I} w_i \leq M$.

Algoritmul 1.3. $L(I, P, W, M)$

1. [Inițializări] Se face $L = \sum_{i \in I} p_i$, $D = M - \sum_{i \in I} w_i$ și $i = 1$.

2. [Testare obiect] Dacă $i \notin I$ și $w_i \leq D$, atunci se face $I = I \cup \{i\}$, $L = L + p_i$ și $D = D - w_i$.
3. [Următorul obiect] Se face $i = i + 1$; dacă $i \leq r$, atunci se trece la pasul 2.
4. [Terminare] Furnizează L și STOP. ■

Este evident că acest algoritm are complexitatea $O(r)$.

Pentru rezolvarea problemei rucsacului se poate folosi următoarea euristică.

Pentru un k dat, se generează succesiv toate cele $\binom{r}{k}$ submulțimi de obiecte. Dacă submulțimea I curent generată satisface condiția $\sum_{i \in I} w_i > M$, unde M este capacitatea rucsacului, ea este eliminată. Altfel spațiul rămas liber în rucsac, adică $M - \sum_{i \in I} w_i$, este încărcat utilizând, în ordinea descrescătoare a raportului p_i / w_i , obiecte ce nu aparțin mulțimii I și fără a depăși pe M . Dintre toate aceste încărcări se alege aceea ce are valoarea profitului maximă.

În algoritmul următor, vom considera că r este numărul total de obiecte, ponderea unei combinații este suma ponderilor obiectelor ei și k este un întreg nenegativ care definește ordinul algoritmului.

Algoritm 1.4. ε -APROX(P, W, M, r, k)

1. [Inițializare] Se face $PMAX = 0$.
2. [Maximizare profit] Pentru toate combinațiile I de mărime cel mult $k \leq r$ și pondere cel mult M se face:

$$PMAX = \max\{PMAX, L(I, P, W, M)\}.$$

3. [Terminare] Furnizează $PMAX$ și STOP. ■

Exemplul 1.3. Fie problema rucsacului cu $r = 8$ obiecte, mărimea rucsacului fiind $M = 110$, profiturile $P = \{11, 21, 31, 33, 43, 53, 55, 65\}$ și ponderile $W = \{1, 11, 21, 23, 33, 43, 45, 55\}$. Obiectele sunt ordonate necrescător în raport cu p_i / w_i .

Soluția optimală este definită de obiectele 1, 2, 3, 5 și 6. Profitul optimal este $P^* = 159$ și ponderea este $D^* = 109$.

Pentru diferiți k se obțin următoarele soluții aproximative:

Pentru $k = 0$, $PMAX$ este chiar marginea inferioară $L(\emptyset, P, W, M)$; $PMAX = 139$; $\delta = (1, 1, 1, 1, 1, 0, 0, 0)$; $D = \sum \delta_i w_i = 89$; $100 (P^* - PMAX) / P^* = 2000 / 159 = 12.6\%$. Se analizează o singură combinație: $I = \emptyset$.

Pentru $k = 1$, $PMAX = 151$; $\delta = (1, 1, 1, 1, 0, 0, 1, 0)$; $D = 101$; $100 (P^* - PMAX) / P^* = 800 / 159 = 5.03\%$. Se analizează 9 combinații: $I = \emptyset, I = \{1\}, I = \{2\}, \dots, I = \{8\}$.

Pentru $k = 2$, $PMAX = P^* = 159$; $\delta = (1,1,1,0,1,1,0,0)$; $D = 109$. Se analizează 37 de combinații: $I = \emptyset$, $I = \{1\}$, $I = \{2\}$, ..., $I = \{8\}$, $I = \{1,2\}$, $I = \{1,3\}$, ..., $I = \{7,8\}$. Se determină chiar soluția optimală. ■

Teorema 1.6. [HOR78] Algoritmul ε -APROX este un algoritm ε -aproximativ pentru care $|(P^* - PMAX) / P^*| < 1 / (k + 1)$, pentru $k > 0$. Timpul de lucru are ordinul $O(k^{k+1})$ și memoria necesară este de ordinul $O(r)$.

Demonstrație. a) Să demonstrăm că $|(P^* - PMAX) / P^*| < 1 / (k + 1)$. Să presupunem că soluția optimală a fost obținută prin introducerea în rucsac a următoarelor j obiecte cu $\hat{p}_1, \hat{p}_2, \dots, \hat{p}_j$ și $\hat{w}_1, \hat{w}_2, \dots, \hat{w}_j$. Pentru $j \leq k$, algoritmul ε -APROX furnizează soluția P^* , deoarece toate combinațiile de mărime mai mică sau egală cu k sunt testate, printre ele fiind și soluția optimală. Fie $j > k$. Presupunem că variabilele din soluția optimală au fost ordonate astfel încât:

1. $\hat{p}_1, \hat{p}_2, \dots, \hat{p}_k$ sunt cele mai mari k valori \hat{p}_i din P^* și
2. celelalte $j-k$ obiecte rămase sunt ordonate necrescător după densitățile profitului:

$$\hat{p}_{k+1} / \hat{w}_{k+1} \geq \hat{p}_{k+2} / \hat{w}_{k+2} \geq \dots \geq \hat{p}_j / \hat{w}_j.$$

Condiția 1. implică $\hat{p}_{k+t} \leq P^* / (k + 1)$, pentru $t = 1, 2, \dots, j-k$. La o anumită etapă a pasului 2 al algoritmului ε -APROX, combinația I corespunde șirului $\hat{p}_1, \hat{p}_2, \dots, \hat{p}_k$. Să considerăm mai în detaliu această etapă. În procesul calculului marginii inferioare a soluției $L(I, P, W, M)$ fie (p_m, w_m) primul obiect din P^* , adică unul dintre obiectele ce au profiturile $\hat{p}_{k+1}, \dots, \hat{p}_j$ care nu este introdus în rucsac. Dacă un astfel de obiect nu există, atunci s-a obținut soluția optimală. Dacă acest obiect există, atunci se observă că:

1. Un spațiu mai mic decât w_m din capacitatea rucsacului este neocupat.
2. Partea din rucsac umplută până acum cu algoritmul marginii inferioare a fost ocupată cu o densitate a profitului mai mare sau egală cu cea utilizată pentru ocuparea părții rămase folosind obiecte din $\hat{p}_{k+1}, \hat{p}_{k+2}, \dots, \hat{p}_j$ în această ordine, deci
$$\sum_{i=k+1}^{j-1} \hat{p}_i \leq L(I, P, W, M).$$
3. Maximul densității la această etapă este p_m / w_m , așa încât spațiul rămas al rucsacului nu poate contribui cu mai mult decât p_m pentru obținerea lui P^* .

Rezultă că, în virtutea punctelor 2. și 3. de mai sus:

$$P^* = P_j + \sum_{i=k+1}^j \hat{p}_i = P_j + \sum_{i=k+1}^{m-1} \hat{p}_i + \sum_{i=m}^j \hat{p}_i < P_j + L(I, P, W, M) + p_m.$$

Deoarece $p_m \leq P^* / (k + 1)$, se obține $P^* - (P_j + L(I, P, W, M)) < P^* / (k + 1)$. Prin definiție, $PMAX \geq P_j + L(I, P, W, M)$. Prin urmare:

$$|(P^* - PMAX) / P^*| < 1 / (k + 1), \text{ pentru } k > 0.$$

b) Pentru orice k , algoritmul ε -APROX are o complexitate în timp polinomial.

Deoarece numărul de combinații de mărime j este $\binom{r}{j}$, rezultă că pasul 2 este executat de $\sum_{j=1}^k \binom{r}{j} < kr^k$ ori. Fiecare execuție a pasului 2 necesită un timp de ordinul cel mult r . Prin urmare, timpul total are ordinul $O(kr^{k+1})$.

Datele memorate sunt δ, I și valorile câtorva variabile simple. Rezultă că memoria necesară are $O(r)$. ■

Teorema ce urmează precizează cât de bună este marginea superioară menționată în teorema precedentă.

Teorema 1.7. [HOR78] Pentru fiecare k există probleme ale rucsacului pentru care $|OPT - PMAX| / OPT$ se apropie oricât de mult de $1 / (k + 1)$. ■

1.1.2.4. Scheme aproximative în timp polinomial

1.1.2.4.1. Planificarea activităților independente

Vom prezenta o altă metodă pentru rezolvarea problemei enunțată în paragraful 1.1.2.3.1. și anume vom folosi următoarea euristică:

1. Pentru k dat ($k < n$) se caută o soluție optimă de planificare a k activități cu cele mai mari durate de execuție.
2. Pentru cele $n - k$ activități rămase se aplică strategia LPT.

Exemplul 1.4. Fie $m = 2, n = 6; (t_1, t_2, t_3, t_4, t_5, t_6) = (8, 6, 5, 4, 4, 1)$ și $k = 4$. Cele mai mari 4 duratele de execuție sunt 8, 6, 5, 4. Pe figura 1.3.a) este arătată o planificare optimă ce necesită 12 unități de timp pentru aceste 4 activități. Utilizând strategia LPT pentru cele două activități rămase se obține soluția din figura 1.3.b) cu timpul total 15. Soluția optimă are timpul total 14 și este arătată pe figura 1.3.c). ■




Fig. 1.3.

Teorema 1.8. [HOR78] Fie o problemă de planificare a activităților cu m procesoare. Dacă $A(I)$ este timpul generat de euristica precedentă atunci:

$$|A(I) - OPT(I)| / OPT(I) \leq (1 - 1 / m) / (1 + \lfloor k / m \rfloor).$$

Timpul necesar pentru obținerea soluției are ordinul:

$$O(n \log n + m^{((m-1)/\varepsilon \cdot n)}), \text{ unde } \varepsilon \leq (1 - 1 / m) / (1 + \lfloor k / m \rfloor). \blacksquare$$

Teorema anterioară arată că euristica propusă este o schemă de aproximare în timp polinomial.

1.1.2.4.2. Problema comisvoiajorului

Vom prezenta o altă euristică pentru rezolvarea problemei comisvoiajorului enunțată în paragraful 1.1.2.2.1. Pentru această problemă pot fi elaborați algoritmi polinomiali care se bazează pe utilizarea noțiunilor din teoria grafurilor de *arbore parțial*, *graf eulerian* și *drum eulerian* pe care le definim în continuare.

Un *arbore parțial* al unui graf G neorientat este un subgraf conex, aciclic și care conține toate nodurile lui G . Un *arbore parțial minimal* este un arbore parțial pentru care suma lungimilor muchiilor este minimă. Pentru construirea unui arbore parțial minimal se cunosc algoritmi polinomiali.

Un graf se numește *eulerian* dacă este conex și toate nodurile lui au grad par. Se numește *ciclu eulerian* într-un graf un ciclu ce parcurge exact o singură dată fiecare muchie. Un ciclu eulerian poate fi identificat în timp polinomial.

O euristică ce permite elaborarea unui algoritm polinomial pentru problema comisvoiajorului, cu proprietatea inegalității triunghiului, este descrisă în continuare și ilustrată pe figura 1.4. Mai întâi se determină un arbore parțial minimal pentru graful dat (figura 1.4.a). Apoi se construiește un drum ce constituie dubla parcurgere în sensuri opuse a fiecărei muchii a arborelui (figura 1.4.b). În continuare, din acest drum se elimină localitățile deja parcurse (figura 1.4.c). Inegalitatea triunghiului asigură obținerea unui drum ce nu poate fi mai mare decât cel precedent.




Fig. 1.4.

Teorema 1.9. [GAR79] Pentru toate problemele comisvoiajorului în care este satisfăcută inegalitatea triunghiului, notând cu $MST(I)$ euristica anterioară, are loc inegalitatea:

$$MST(I) < 2 OPT(I). \blacksquare$$

Din cele de mai sus rezultă că euristica propusă este o schemă de aproximare în timp polinomial.

1.1.2.5. Scheme de aproximare complet polinomiale

În continuare se prezintă trei tehnici de aproximare complet polinomiale, exemplificate pentru problema cunoscută sub numele de *programare liniară booleană*.

Punerea problemei: Se cere identificarea valorii:

$$\max \sum_{i=1}^n p_i x_i,$$

cu condițiile:

$$\sum_{i=1}^n a_{ij} x_i \leq b_j, \text{ pentru } j = 1, 2, \dots, m,$$

$$x_i = 0 \text{ sau } 1, \text{ pentru } i = 1, 2, \dots, n,$$

$$p_i, a_{ij} \geq 0, \text{ pentru } i = 1, 2, \dots, n \text{ și } j = 1, 2, \dots, m. \blacksquare$$

Aplicații posibile: aprovizionare, dietă, încărcare vagoane, croire.

Fără a micșora generalitatea se poate presupune că $a_{ij} \leq b_j$, $i=1, \dots, n$ și $j=1, \dots, n$. Altfel valoarea lui x_i trebuie să fie 0 și deci variabila respectivă poate fi eliminată.

Dacă $1 \leq k \leq n$, atunci asignarea $x_i = y_i$, $i = 1, 2, \dots, k$, se numește *asignare efectuabilă* dacă și numai dacă există cel puțin o soluție astfel încât x_i să aibă valoarea y_i , pentru $i = 1, 2, \dots, k$. O *completare* a unei asignări efectuale $x_i = y_i$ este orice soluție y_1, \dots, y_n cu $x_i = y_i$, pentru $i = 1, 2, \dots, k$.

Fie $x_i = y_i$ și $x_i = z_i$, $i = 1, 2, \dots, k$, două asignări efectuale pentru care $y_j \neq z_j$ măcar pentru un j , $1 \leq j \leq k$. Dacă $\sum p_j y_j \geq \sum p_j z_j$, atunci y_1, \dots, y_k *domină* pe z_1, \dots, z_k dacă și numai dacă există o completare $y_1, \dots, y_k, y_{k+1}, \dots, y_n$ astfel încât $\sum_{i=1}^n p_i y_i \geq \sum_{i=1}^n p_i z_i$, pentru toate completările z_1, \dots, z_n ale lui z_1, \dots, z_k .

Un mod de rezolvare a problemei enunțate constă în generarea sistematică a tuturor asignărilor efectuale plecând de la asignarea nulă. Fie $S^{(0)}$ mulțimea tuturor asignărilor efectuale pentru x_1, x_2, \dots, x_n . Atunci $S^{(0)}$ este asignarea nulă și $S^{(n)}$ este mulțimea tuturor completărilor. Soluția problemei este dată de o asignare din $S^{(n)}$ care maximizează funcția obiectiv. Identificarea soluției constă în generarea lui $S^{(i+1)}$ din $S^{(i)}$, pentru $1 \leq i < n$. Dacă o mulțime $S^{(i)}$ conține două asignări efectuale y_1, \dots, y_k și z_1, \dots, z_j astfel încât $\sum p_j y_j \geq \sum p_j z_j$, atunci utilizarea unor reguli de dominare, dacă există, permite eliminarea asignărilor dominate.

Există cazuri în care regulile de dominare permit eliminarea unor asignări efectuale, chiar dacă $\sum p_j y_j \neq \sum p_j z_j$. Drept exemplu se poate vedea problema rucsacului (vezi paragraful 1.1.2.3.3. și Secțiunea 5.5. din [HOR78]).

În continuare vom descrie metode euristice de rezolvare a acestei probleme.

1.1.2.5.1. Rotunjirea

Ideea acestei euristici constă în schimbarea suficient de mică a valorilor lui p_i în q_i astfel încât noua problemă obținută să admită soluții destul de apropiate de soluțiile problemei inițiale și să fie ușor de calculat.

Exemplul 1.5. Fie $(p_1, p_2, p_3, p_4) = (1.1, 2.1, 1001.6, 1002.3)$ valorile problemei I date și valorile rotunjite $(q_1, q_2, q_3, q_4) = (0, 0, 1000, 1000)$ ale problemei I' aproximative. Diferența maximă de 7.1 dintre soluțiile problemelor I și I' are loc dacă $x_i = 1, 1 \leq i \leq 4$ este o soluție pentru I (și deci și pentru I'). Deoarece o soluție efectuabilă este $x_1 = x_2 = x_3 = 0, x_4 = 1$, rezultă că $OPT(I) \geq 1002.3$. Rezultă că $(OPT(I) - OPT(I')) / OPT(I) \leq 0.007$. Pentru problema I asignările efectuabile variabilelor (x_1, x_2, x_3, x_4) în mulțimile $S^{(0)}, \dots, S^{(4)}$ sunt următoarele:

$$S^{(0)} = \{(0000)\};$$

$$S^{(1)} = S^{(0)} \cup \{(1000)\};$$

$$S^{(2)} = S^{(1)} \cup \{(0100), (1100)\};$$

$$S^{(3)} = S^{(2)} \cup \{(0010), (1010), (0110), (1110)\};$$

$$S^{(4)} = S^{(3)} \cup \{(0001), (1001), (0101), (1101), (0011), (1011), (0111), (1111)\}.$$

Mulțimile $S^{(i)}$ determină următoarele mulțimi de valori:

$$S^{(0)} \rightarrow \{0\};$$

$$S^{(1)} \rightarrow \{0, 1.1\};$$

$$S^{(2)} \rightarrow \{0, 1.1, 2.1, 3.2\};$$

$$S^{(3)} \rightarrow \{0, 1.1, 2.1, 3.2, 1001.6, 1002.7, 1003.7, 1004.8\};$$

$$S^{(4)} \rightarrow \{0, 1.1, 2.1, 3.2, 1001.6, 1002.3, 1002.7, 1003.4, 1003.7, 1004.4, 1004.8, 1005.5, 2003.9, 2005, 2006, 2007.1\}.$$

În mod asemănător, pentru problema I' rezultă mulțimile:

$$S^{(0)} \rightarrow \{0\};$$

$$S^{(1)} \rightarrow \{0\};$$

$$S^{(2)} \rightarrow \{0\};$$

$$S^{(3)} \rightarrow \{0, 1000\};$$

$$S^{(4)} \rightarrow \{0, 1000, 2000\}.$$

Ținând seama că pentru problemele I , respectiv I' , sumele $\sum_{i=0}^n |S^{(i)}|$ au valorile 31, respectiv 8, rezultă că problema I' poate fi rezolvată într-un timp aproximativ de patru ori mai mic decât cel necesar pentru rezolvarea problemei I . ■

Teorema 1.10. [HOR78] Fie LB o estimare pentru $OPT(I)$ astfel încât $OPT(I) \geq LB$ și un ε dat. Atunci, utilizând euristica descrisă mai înainte, se poate obține o soluție a problemei I ce satisface condiția:

$$(OPT(I) - OPT(I^*)) / OPT(I) \leq \varepsilon$$

într-un timp de ordinul $O(n^3/\varepsilon)$. ■

Rotunjirea, așa cum a fost descrisă mai sus ca metodă generală, conduce la scheme aproximative în timp de $O(n^3/\varepsilon)$. Euristica propusă poate fi specializată însă în vederea obținerii unor soluții mai eficiente. Un exemplu ilustrativ îl constituie *problema rucsacului*.

Fie I datele problemei rucsacului, ε eroarea dorită și $OPT(I)$ valoarea soluției optime. Mai întâi se caută o estimare bună UB pentru $OPT(I)$. Pentru aceasta, cele n obiecte se ordonează astfel încât $p_i / w_i \geq p_{i+1} / w_{i+1}$, pentru $i = 1, 2, \dots, n$, p_i fiind profitul și w_i ponderea obiectului i . Apoi se caută cel mai mare j astfel încât $\sum_{i=1}^j w_i \leq M$. Dacă $j = n$, atunci soluția optimală este w_i , $i = 1, 2, \dots, n$ și $OPT(I) = \sum p_i$.

Fie $j < n$ și $UB = \sum_{i=1}^{j+1} p_i$. Se poate arăta că $1/2 UB \leq OPT(I) < UB$. Ținând seama de felul în care a fost ales j , rezultă inegalitatea $OPT(I) < UB$. Cealaltă inegalitate, $1/2 UB \leq OPT(I)$, rezultă din faptul că:

$$OPT(I) \geq \sum_{i=1}^j p_i \text{ și } OPT(I) \geq \max\{\sum_{i=1}^j p_i, p_{j+1}\}.$$

Prin urmare:

$$2 OPT(I) \geq \sum_{i=1}^{j+1} p_i = UB.$$

Fie $\delta = UB\varepsilon^2/9$. Cele n obiecte se împart în două clase MARI și MICI, unde MARI include toate obiectele cu $p_i > UB\varepsilon/3$ și MICI conține restul obiectelor. Fie r numărul obiectelor din MARI. Fiecare p_i din MARI se înlocuiește cu $q_i = \lfloor p_i/\delta \rfloor$, această înlocuire reprezentând o rotunjire. Urmează rezolvarea problemei rucsacului utilizând aceste r obiecte cu q_i -urile ce le corespund și aplicând metoda programării dinamice. Fie $S^{(r)}$ mulțimea perechilor (x, y) astfel obținute. Pentru fiecare pereche (x, y) din $S^{(r)}$, capacitatea $M - y$ rămasă liberă este încărcată cu obiecte din MICI în ordinea necrescătoare a rapoartelor p_i / w_i . Soluția este dată de umplerea cu valoare maximă posibilă.

Exemplul 1.6. Fie $n = 5$, $(p_1, p_2, p_3, p_4, p_5) = (w_1, w_2, w_3, w_4, w_5) = (1, 2, 10, 10, 1000)$, $M = 1112$ și $\varepsilon = 1/10$. Obiectele sunt în ordinea necrescătoare a rapoartelor p_i / w_i , $UB = \sum_{i=1}^5 p_i = 1113$, $\delta = 3.71 / 3$ și $\varepsilon UB / 3 = 37.1$. Rezultă că MICI include obiectele 1, 2 și 3 și MARI include elementele 4 și 5. Valorile q_4 și q_5 sunt respectiv $\lfloor p_4/\delta \rfloor = 94$ și $\lfloor p_5 / \delta \rfloor = 946$.

Pentru problema rucsacului cu $n = 2$, $M = 1112$, $(q_4, w_4) = (94, 100)$ și $(q_5, w_5) = (946, 1000)$, rezultă pentru $S^{(0)}$ valorile $\{(0, 0)\}$; pentru $S^{(1)}$ valorile $\{(0, 0), (94, 100)\}$ și pentru $S^{(2)}$ valorile $\{(0, 0), (94, 100), (946, 1000), (1040, 1100)\}$. Încercând $(0, 0)$ din MICI se obține perechea $(13, 13)$. Pentru perechile $(94, 100)$, $(946, 1000)$ și $(1040, 1100)$ se obține $(107, 113)$, $(959, 1013)$, respectiv $(1043, 1103)$. Răspunsul este dat de perechea $(1043, 1103)$, care corespunde mulțimii $\{x_1, x_2, x_3, x_4, x_5\} = (1, 1, 0, 1, 1)$ și $\sum p_i x_i = 1103$. ■

Teorema 1.11. [IBA75] Algoritmul descris anterior este ε -aproximativ pentru problema rucsacului. ■

Timpul necesar pentru ordonarea mărimilor p_i / w_i are ordinul $O(n \log n)$. Valoarea UB poate fi calculată într-un timp $O(n)$. Deoarece $OPT(I) \leq UB$, există cel mult $UB / \delta = 9 / \varepsilon^2$ perechi în $S^{(i)}$ în soluția pentru MARI și timpul necesar pentru obținerea lui $S^{(r)}$ este $O(r / \varepsilon^2) \leq O(n / \varepsilon^2)$. Completarea lui $S^{(r)}$ cu obiecte din MICI necesită un timp $O(|MICI|)$ și, deoarece $|S^{(r)}| \leq 9 / \varepsilon^2$, rezultă că MICI se încheie în cel mult $O(n / \varepsilon^2)$ unități de timp. Rezultă că timpul total al algoritmului descris este de $O(n (\log n + 1 / \varepsilon^2))$.

1.1.2.5.2. Partiționarea pe intervale

Această euristică constă în generarea unei clase restrânse de asignări, într-o succesiune $S^{(0)}, S^{(1)}, \dots, S^{(n)}$. Fie P_i maximul sumei $\sum_{j=1}^i p_j x_j$ al asignărilor generate pentru $S^{(i)}$. Intervalul $[0, P_i]$ este împărțit în subintervale de lungime $P_i \varepsilon / (n - 1)$, ultimul subinterval putând fi de lungime mai mică. Toate asignările efectuate în $S^{(i)}$ cu $\sum_{j=1}^i p_j x_j$ în același subinterval se consideră ca având același profit $\sum_{j=1}^i p_j x_j$ și se folosesc criteriile de dominare pentru reținerea uneia dintre aceste asignări. Cu $S^{(i)}$ astfel obținut, se generează $S^{(i+1)}$. Deoarece numărul de subintervale pentru fiecare $S^{(i)}$ este cel mult $\lceil n / \varepsilon \rceil + 1$, rezultă că $\sum_{i=1}^n |S^{(i)}| = O(n^2 / \varepsilon)$.

Eroarea introdusă în fiecare asignare efectuabilă în urma eliminării din $S^{(i)}$ a altor asignări este mai mică decât lungimea subintervalului. Această eroare se poate propaga aditiv de la $S^{(1)}$ până la $S^{(n)}$. Fie $PART(I)$ valoarea optimă obținută utilizând partiționarea pe intervale și $OPT(I)$ valoarea optimă a problemei de maximizare. Rezultă că:

$$OPT(I) - PART(I) \leq (\varepsilon \sum_{i=1}^{n-1} P_i) / (n - 1)$$

și, deoarece $P_i \leq OPT(I)$,

$$(OPT(I) - PART(I)) / OPT(I) \leq \varepsilon.$$

În multe cazuri, algoritmul propus poate fi accelerat plecând de la o estimare LB a lui $OPT(I)$ astfel încât $OPT(I) \geq LB$. Lungimea subintervalului poate fi luată egală cu $LB \varepsilon / (n - 1)$ în loc de $P_i \varepsilon / (n - 1)$. Pentru o asignare având o valoare mai mare ca LB , mărimea subintervalului se calculează în modul descris mai înainte.

Exemplul 1.7. Fie problema rucsacului enunțată în exemplul precedent. Mulțimile corespunzătoare de valori pentru $S^{(i)}$ sunt: pentru $S^{(0)}$ valoarea $\{ \cdot \}$, pentru $S^{(1)}$ valorile $\{0, 1\}$, pentru $S^{(2)}$ valorile $\{0, 1, 2, 3\}$, pentru $S^{(3)}$ valorile $\{0, 1, 2, 3, 10, 11, 12, 13\}$, pentru $S^{(4)}$ valorile $\{0, 1, 2, 3, 10, 11, 12, 13, 100, 101, 102, 103, 110, 111, 112, 113\}$, pentru $S^{(5)}$ valorile $\{0, 1, 2, 3, 10, 11, 12, 13, 100, 101, 102, 103, 110, 111, 112, 113, 1000, 1001, 1002, 1003, 1010, 1011, 1012, 1013, 1100, 1101, 1102, 1103, 1110, 1111, 1112\}$, cu mențiunea că, deoarece $p_k = w_k$, în $S^{(i)}$ au fost considerate numai valorile p_k . Pentru $\varepsilon = 1/10$ și $OPT(I) \geq LB \geq 1000$ se obține o lungime a subintervalului $LB \varepsilon / (n - 1) = 1000/40 = 25$. Intervalele sunt $[0, 25)$, $[25, 50)$, Toate valorile din $S^{(0)}$, $S^{(1)}$, $S^{(2)}$, $S^{(3)}$ fiind mai mici decât 25, rezultă că mulțimile valorilor corespunzătoare lor coincid, fiind toate $\{0\}$. În $S^{(4)}$ valorile mai mici ca 25 se înlocuiesc cu 0 și cele mai mari ca 100 se înlocuiesc cu 100. Rezultă că mulțimea valorilor pentru $S^{(4)}$ este $\{0, 100\}$. În mod asemănător se obține mulțimea valorilor pentru $S^{(5)}$ care este $\{0, 100, 1000, 1100\}$. Aplicând noii probleme metoda programării dinamice se obține soluția $PART(I) = 1100$, care corespunde mulțimii de valori $(x_1, x_2, x_3, x_4, x_5) = (0, 0, 0, 1, 1)$ al formulării inițiale. Această soluție se poate fi îmbunătățită utilizând o euristică prin care se schimbă unele valori x_i din 0 în 1. Eroarea soluției obținute mai sus este:

$$(OPT(I) - PART(I)) / PART(I) = 12/1112 < 0.011 < \varepsilon. \blacksquare$$

1.1.2.5.3. Separarea

Fie o problemă pentru care s-a obținut un $S^{(i)}$ cu soluții având valorile $\sum_{j=1}^i p_j x_j$: 0, 3.9, 4.1, 7.8, 8.2, 11.9, 12.1. În ipoteza unor intervale de lungime $P_i \varepsilon / (n - 1) = 2$, subintervalele sunt $[0, 2)$, $[2, 4)$, $[4, 6)$, $[6, 8)$, $[8, 10)$, $[10, 12)$ și $[12, 14)$. Fiecare din valorile precedente aparține unor intervale distincte, așa încât euristica partiționării nu poate fi aplicată. Există însă trei perechi de asignări care diferă prin mai puțin decât $P_i \varepsilon / (n - 1)$. Aplicând reguli de dominare, se pot reține numai patru asignări, eroarea introdusă fiind de cel mult $P_i \varepsilon / (n - 1)$. Mai precis, fie a_0, a_1, \dots, a_r valori distincte ale sumei $\sum_{j=1}^i p_j x_j$ din $S^{(i)}$. Fie $a_0 < a_1 < \dots < a_r$. O nouă mulțime I poate fi obținută din $S^{(i)}$

parcurgând șirul precedent de la stânga la dreapta și reținând un element numai dacă valoarea lui este mai mare decât ultimul reținut cu $P_i \varepsilon / (n - 1)$. Procedeu propus este descris de următorul algoritm:

Algoritmul 1.5. (*Separare*)

1. [Inițializare] Se face $I = \{\text{asignarea corespunzătoare lui } a_0\}$ și $XP = a_0$.
2. [Ciclare] Pentru $j = 1, 2, \dots, r$ se execută pasul 3, apoi STOP.
3. [Modificare asignare] Dacă $a_j > XP + P_j \varepsilon / (n - 1)$, atunci se introduce asignarea corespunzătoare lui a_j în I și se face $XP = a_j$. ■

Exemplul 1.8. Fie problema rucsacului cu profiturile $(p_1, p_2, p_3, p_4, p_5) = (3, 1, 5.1, 5.1, 5.1)$ și $LB\varepsilon / (n - 1) = 2$. Folosind algoritmul descris, se obțin următoarele mulțimi de valori: pentru $S^{(0)}$: $\{0\}$, pentru $S^{(1)}$: $\{0, 3\}$, pentru $S^{(2)}$: $\{0, 3\}$, pentru $S^{(3)}$: $\{0, 3, 5.1, 8.1\}$, pentru $S^{(4)}$: $\{0, 3, 5.1, 8.1, 10.2, 13.2\}$ și pentru $S^{(5)}$: $\{0, 3, 8.1, 10.2, 13.2, 15.3, 18.3\}$. ■

Observație. Pentru problema din acest exemplu, metoda partiționării furnizează o soluție mai simplă. Aplicând euristica partiționării, rezultă mulțimile de valori: pentru $S^{(0)}$: $\{0\}$, pentru $S^{(1)}$: $\{0, 3\}$, pentru $S^{(2)}$: $\{0, 3, 4\}$, pentru $S^{(3)}$: $\{0, 3, 4, 8.1\}$, pentru $S^{(4)}$: $\{0, 3, 4, 8.1, 13.2\}$ și pentru $S^{(5)}$: $\{0, 3, 4, 8.1, 13.2, 18.3\}$. Această secvență descrie o soluție mai simplă decât cea din exemplul precedent.

În încheierea acestei prezentări se poate pune întrebarea: Ce fel de probleme NP-dificile pot avea scheme de aproximare complet polinomiale? Răspunsul la această întrebare este dat în continuare.

Definiția 1.2. Fie L o problemă oarecare, I mulțimea de date, $LUNGIME(I)$ numărul de biți în reprezentarea mulțimii I și $MAX(I)$ valoarea celui mai mare număr din I . Fără a micșora generalitatea, se poate presupune că toate numerele din I sunt întregi. Pentru un polinom ales p , fie L_p problema L restrânsă la datele din I pentru care $MAX(I) \leq p(LUNGIME(I))$. Problema L este *tare NP-dificilă* dacă și numai dacă există un polinom p astfel încât L_p este NP-dificilă. ■

Drept exemple de probleme tare NP-dificile se pot cita: determinarea unui ciclu hamiltonian, problema comisvoiajorului, determinarea unei clici maxime etc.

Teorema 1.12. [HOR78, GAR79] Fie L o problemă de optimizare pentru care soluțiile corespunzătoare tuturor datelor au drept valoare un întreg pozitiv. Pentru toate datele din I ale lui L , se presupune că $OPT(I)$ este mărginit de o funcție polinomială p în variabilele $LUNGIME(I)$ și $MAX(I)$, adică au loc inegalitățile:

$$0 < OPT(I) < p(LUNGIME(I), MAX(I)).$$

Dacă L are o schemă de aproximare complet polinomială în timp, atunci L are și un algoritm exact de complexitate un polinom în $LUNGIME(I)$ și $MAX(I)$. ■

Consecință. Teorema precedentă nu este aplicabilă pentru probleme L tare NP-dificile. Într-adevăr, în acest caz ar rezulta că pentru L_p există *algoritmi corecți* de complexitate polinomială în $LUNGIME(I)$ și $MAX(I)$, ceea ce contrazice faptul că L_p este NP-dificilă. Rezultă că pentru L_p , deci și pentru L , nu există scheme de aproximare complet polinomiale în raport cu timpul.

1.1.2.6. Algoritmi buni în sens probabilistic

Există mulți algoritmi cu performanță nemărginită care pot rezolva *aproape întotdeauna* exact o problemă sau generează o soluție mult îndepărtată ca v.oare de cea a soluției optimale. Asemenea algoritmi sunt *buni în sens probabilistic*.

Pentru o problemă de mărime n , se definește mai întâi *spațiul eșantion* S_n . *Spațiul eșantion total* este produsul cartezian $S_1 \times S_2 \times \dots \times S_n \times \dots$. Un *element* al spațiului eșantion total este o secvență $X = x_1, x_2, \dots, x_n, \dots$ astfel încât $x_i \in S_i$.

Definiția 1.3. Un algoritm A rezolvă o problemă L *aproape întotdeauna* dacă, pentru fiecare eșantion X , numărul de x_i pentru care nu se rezolvă problema L este finit cu probabilitatea 1. ■

În continuare sunt prezentați doi algoritmi pentru probleme NP-dificile pe grafuri pentru care spațiul eșantion se construiește pornind de la o funcție $p(n)$, astfel încât $0 \leq p(n) \leq 1$ și $n \geq 0$. Un graf eșantion cu n noduri se construiește incluzând fiecare muchie (i, j) , $i \neq j$ cu probabilitatea $p(n)$.

Primul algoritm prezentat, elaborat de Posa [POS76], identifică un *ciclu hamiltonian* într-un graf nedirecționat. Euristică algoritmului începe cu alegerea arbitrară a unui nod, de exemplu 1, ca nod de start. În continuare, se construiește succesiv un drum P de lungime crescătoare, al cărui nod final se notează cu k . La fiecare iterație a algoritmului, se încearcă mărirea lungimii drumului P identificând o muchie (k, j) incidentă nodului final k . Pentru această muchie (k, j) au loc trei posibilități:

1. $j = 1$ și P include toate nodurile grafului. În acest caz, ciclul hamiltonian a fost găsit.
2. j nu aparține lui P . În acest caz drumului P i se adaugă muchia (k, j) , j devenind nodul final al lui P .
3. j se află deja pe drumul P . Există o singură muchie $e = (j, m)$ în P astfel încât eliminarea lui e și includerea lui (k, j) în P are drept rezultat un drum simplu. Muchia e este eliminată și (k, j) se adaugă la P , nodul final fiind acum m .

Se mai pune condiția ca la pasul 3 să nu fie generate două drumuri de aceeași lungime având același nod final, pentru a nu se intra într-un ciclu infinit. Pentru o alegere convenabilă a reprezentării datelor, algoritmul descris are un timp de lucru de $O(n^2)$, unde n este numărul de noduri din graf.

Teorema 1.13. [POS76] Pentru $p(n) \approx (\alpha \ln n / n)$, $\alpha > 1$, algoritmul precedent identifică un ciclu hamiltonian (aproape întotdeauna). ■




Fig. 1.5.

Exemplul 1.9. Fie graful din figura 1.5. Inițial drumul P conține nodul 1. Presupunând că a fost aleasă muchia $(1,4)$, drumul P este extins (vezi cazul 2) la $\{1,4\}$. Dacă se alege în continuare muchia $(4,5)$, rezultă drumul $\{1,4,5\}$. Singura alegere în continuare o constituie muchia $(1,5)$, adică are loc cazul 3 și P devine $\{1,5,4\}$. În continuare se consideră muchiile $(4,3)$ și $(3,2)$ și se obține drumul $\{1,5,4,3,2\}$. Considerând în continuare muchia $(2,1)$ se obține ciclul hamiltonian $\{1,5,4,3,2,1\}$. ■

Definiția 1.4. O mulțime N de noduri ale grafului $G(V, E)$ se numește *independentă* dacă și numai dacă nodurile din orice pereche din N nu sunt adiacente în G . O mulțime de noduri este *independentă maximală* dacă este independentă și are cel mai mare număr de noduri dintre mulțimile independente. ■

Un algoritm de tip Greedy pentru determinarea unei mulțimi independente maxime a unui graf este:

Algoritmul 1.6. INDEP(V, E)

1. [Inițializare] Se face $N = \emptyset$.
2. [Explorare] Atâta timp cât există un nod $i \in V - N$ care nu este adiacent cu noduri din N , se face $N = N \cup \{i\}$.
3. [Terminare] Se furnizează N și STOP. ■




Fig. 1.6.

Exemplul 1.10. Un exemplu pentru care algoritmul descris se dovedește neeficient este arătat în figura 1.6. Dacă se pleacă de la $N = \emptyset$ și se alege $i = 1$, atunci algoritmul furnizează rezultatul $N = \{1\}$ cu toate că mulțimea independentă maximală este, în acest caz $\{2, 3, \dots, n\}$. ■

Totuși, pentru anumite distribuții de probabilitate are loc următoarea proprietate:

Teorema 1.14. [KAR77] Dacă $p(n) = c$, pentru o anumită constantă c , atunci pentru orice $\varepsilon > 0$ are loc inegalitatea:

$$(OPT(I) - A(I)) / OPT(I) \leq 0.5 + \varepsilon. \blacksquare$$

1.1.3. Utilizarea teoriei NP-completitudinii pentru identificarea de algoritmi aproximativi

Există probleme pentru care teoria NP-completitudinii permite demonstrarea inexistenței soluțiilor aproximative. Câteva dintre aceste rezultate sunt menționate în teoremele ce urmează.

Teorema 1.15. [HOR78] În ipoteza $P \neq NP$, problema aproximării soluției de încărcării rucsacului este NP-dificilă. ■

Un rezultat asemănător are loc în cazul problemei aproximării absolute a clicii maxime.

Teorema 1.16. [HOR78] Problema clicii maxime se reduce la problema aproximării absolute a clicii maxime. ■

Rezultate asemănătoare au loc pentru probleme de ε -aproximare.

Teorema 1.17. [HOR78] Problema ciclului hamiltonian se reduce la problema ε -aproximativă a comisvoiajorului. ■

Teorema 1.18. [HOR78] Problema partiției se reduce la problema ε -aproximativă a programării întregi. ■

Teorema 1.19. [HOR78] Problema ciclului hamiltonian se reduce la problema ε -aproximativă a asignării pătratice. ■

Teorema 1.20. [GAR79] Dacă $P \neq NP$, atunci pentru problema aproximării absolute a unei mulțimi maxime independente nu există un algoritm aproximativ polinomial. ■

Teorema 1.21. [GAR79] Fie MIN o problemă de minimizare, valorile soluției problemei fiind numere întregi nenegative. Să presupunem că pentru un $k \in \mathbb{Z}^+$ dat, problema: “Fiind dată o problemă individuală I din MIN , este adevărat că $OPT(I) \leq k$?” este NP-dificilă. Atunci, dacă $P \neq NP$, nu există un algoritm aproximativ

polinomial A pentru rezolvarea problemei MIN cu o eroare $R_A < 1/k$ și problema MIN nu poate fi rezolvată cu o schemă aproximativă polinomială. ■

Teorema 1.22. [GAR79] Dacă $P \neq NP$, atunci pentru problema colorării grafurilor nu există un algoritm aproximativ polinomial cu eroarea asimptotică $R_A^\infty < 1/3$. ■

Teorema 1.23. [GAR79] Dacă $P \neq NP$, atunci pentru problema colorării grafurilor nu există un algoritm aproximativ polinomial cu eroarea asimptotică $R_A^\infty < 1$.

Demonstrația acestei teoreme se face prin metoda creșterii erorii. ■

Teorema 1.24. [GAR79] Dacă $P \neq NP$, atunci pentru problema comisvoiajorului nu există un algoritm aproximativ polinomial cu eroarea asimptotică $R_A^\infty < \infty$. ■

1.2. Analiza algoritmilor

Fiind dat un algoritm euristic pentru rezolvarea unei clase de probleme, identificarea unor proprietăți formale ale acestui algoritm, numită *analiza algoritmului*, constituie un aport esențial pentru cunoașterea eficienței lui. În analiza unui algoritm se determină resursele utilizate pentru executarea lui (în special memoria ocupată), timpul de execuție (în cazul cel mai defavorabil, mediu etc.) exprimat adesea prin numărul de operații necesare, determinarea calităților soluțiilor furnizate cum ar fi eroarea față de soluția optimă, determinarea unei soluții în timp finit și alte calități care vor fi definite în continuare. Analiza algoritmilor este făcută, în primul rând, pentru a furniza criterii de alegere între mai multe metode de soluționare și, în al doilea rând, pentru a evalua oportunitatea folosirii lor. De exemplu, obținerea soluției după un număr mare de operații poate face algoritmul practic inaplicabil.

1.2.1. Măsuri de comportare în cel mai rău caz a unui algoritm

În acest paragraf vom studia comportarea în cel mai rău caz a unor algoritmi, prezentând exemple ilustrative.

Problema acoperirii I. Fiind dată o familie finită $F = \{S_1, S_2, \dots, S_p\}$ de mulțimi finite, se cere identificarea unei subfamilii $F' \subseteq F$ astfel încât $\bigcup_{S \in F'} S = \bigcup_{S \in F} S$. ■

Cu $SC(k)$ se notează subproblema cu familii în care orice mulțime nu conține mai mult de k elemente. Algoritmul propus, de $O(n \log n)$, este următorul.

Algoritm 1.7. (*Acoperire*)

1. [Inițializări] Se face $SUB = \emptyset$, $UNCOV = \bigcup_{S \in F} S$, $N = |F|$, $SET(i) = S_i$, $i = 1, 2, \dots, N$.

2. [Terminare] Dacă $UNCOV = \emptyset$, atunci furnizează SUB și STOP.
3. [Alegere] Se alege $j \leq N$ astfel încât $|SET(j)|$ este maxim.
4. [Modificări] Se face $SUB = SUB \cup \{S_j\}$, $UNCOV = UNCOV - SET(j)$, $SET(i) = SET(i) - SET(j)$, pentru $i = 1, 2, \dots, N, i \neq j$, apoi se face $SET(j) = \emptyset$.
5. [Ciclare] Se trece la pasul 2. ■




Fig. 1.7.

Exemplul 1.11. Fie problema ilustrată pe figura 1.7., în care mulțimea T ce trebuie acoperită constă din $k \bullet k!$ puncte, grupate în k segmente de câte $k!$ puncte și numerotate de la 1 la k . Mulțimea F constă din mulțimi de câte k puncte, fiecare mulțime care conține un punct din segmentul i conține cel puțin câte un punct din segmentul ce urmează după i . Subacoperirea optimală F_0 constă din l mulțimi disjuncte, fiecare conținând câte un punct din fiecare dintre cele k segmente. Subacoperirea identificată de algoritm este constituită din $k! / k$ mulțimi disjuncte cu câte k elemente care acoperă segmentul k , $k! / (k - 1)$ mulțimi, cu câte $k - 1$ elemente din segmentul $k - 1$ și un punct din segmentul k , prin care se acoperă segmentul $k - 1, \dots$ și $k!$ mulțimi ce conțin câte un punct din fiecare segment, prin care se acoperă segmentul 1. Algoritm *Acoperire* identifică mai întâi $k! / k$ mulțimi ce acoperă segmentul k , deoarece ele au indice maxim și pot fi alese în virtutea pasului 3. În continuare, se alege $k! / (k - 1)$ mulțimi care acoperă segmentul $k - 1$. Acest proces continuă până când se realizează subacoperirea F_1 care conține

$$k!(1/k + 1/(k-1) + \dots + 1) = k!(\sum_{j=1}^k (1/j))$$

mulțimi. Subacoperirea optimală F_0 cuprinde $k!$ mulțimi, de unde rezultă că $r(A, F_0) \geq \sum_{j=1}^k (1/j)$, unde cu $r(A, F_0)$ s-a notat măsura comportării relative a algoritmului *Acoperire* în cel mai rău caz. Se poate demonstra că suma din dreapta inegalității reprezintă chiar marginea superioară a comportării algoritmului C_1 , adică

$$r(A, OPT(SC(k))) \leq \sum_{j=1}^k (1/j). \blacksquare$$

Problema colorării grafurilor. Pentru un graf $G(N, A)$ cu N noduri și A arce, se cere determinarea unei atribuirii de culori nodurilor grafului astfel încât oricare două noduri adiacente să aibă culori diferite. ■

Pentru rezolvare se propune următorul algoritm:

Algoritmul 1.8. (Colorare)

1. [Inițializare] Se face $NECOLORAT = N$, $COLORAT(i) = \emptyset$, $i = 1, 2, \dots, |N|$, $I = 1$.
2. [Terminare] Dacă $NECOLORAT = \emptyset$, furnizează $COLORAT(i)$, $i = 1, 2, \dots, I$ și STOP.
3. [Culoare nouă] Dacă fiecare nod din $NECOLORAT$ este conectat cu un nod din $COLORAT(I)$, atunci se face $I = I + 1$.
4. [Alegere] Se alege nodul x din $NECOLORAT$ de grad maximal printre nodurile ce nu sunt conectate la nici-un nod din $COLORAT(I)$.
5. [Colorare] Se face $COLORAT(I) = COLORAT(I) \cup \{x\}$ și $NECOLORAT = NECOLORAT - \{x\}$.
6. [Ciclare] Se trece la pasul 2. ■

Acest algoritm se comportă rezonabil pentru exemple de complexitate mică. Există însă și exemple pentru care algoritmul este neeficient.

Exemplul 1.12. Fie graful $G_k = (N_k, A_k)$ cu nodurile și arcele:

$$N_k = \{a_1, \dots, a_k, b_1, \dots, b_k\}, A_k = \{(a_i, b_j) \mid i \neq j\}.$$

Pentru cazul $k = 3$, graful corespunzător este arătat în figura 1.8. Acest graf este 2-colorabil, cele două culori fiind atribuite nodurilor a_i , respectiv b_i . Deoarece toate nodurile au același grad, algoritmul 1.8. le colorează în ordinea $a_1, b_1, a_2, b_2, \dots, a_k, b_k$ atribuindu-le culorile $h(a_1) = h(b_1) = 1, h(a_2) = h(b_2) = 2, \dots, h(a_k) = h(b_k) = k$. Rezultă că $r(A, G_k) = k / 2$, unde $r(A, G_k)$ este raportul dintre numărul de culori furnizat de algoritmul 1.8. și numărul optimal (= 2). ■




Fig. 1.8.

Un mod de ameliorare a acestui algoritm constă în alegerea altui criteriu de identificare a lui x în pasul 4. Fie *Colorare-nou* algoritmul obținut din algoritmul *Colorare* prin folosirea următoarei forme a pasului 4:

4. Fie POS submulțimea lui $NECOLORAT$ ce cuprinde nodurile neconectate la nici-un nod din $COLORAT(I)$. Fie x nodul din POS conectat cu cel mai mic număr de alte noduri din POS .

Exemplul 1.13. Există o secvență de grafuri $\{H_k\}$ 2-colorabile astfel încât H_k are 2^k noduri și numărul culorilor dat de algoritmul *Colorare-nou* este $k + 1$. Secvența $H_1 - H_4$ este arătată în figura 1.9. Graful H_{k+1} se obține din graful H_k prin adăugarea a 2^k noduri și arce, pe figura 1.9. aceste noduri fiind încercuite. Algoritmul *Colorare-nou* aplicat lui H_{k+1} atribuie mai întâi o aceeași culoare nodurilor încercuite și apoi trece la colorarea grafului H_k . Deoarece H_1 necesită două culori, rezultă că H_k se colorează cu $k + 1$ culori și $r(A, H_k) = (k + 1) / 2$. ■




Fig. 1.9.

Problema clicii maximele. Se numește *clică* a unui graf neorientat $G(N, A)$ un subgraf pentru care oricare două noduri sunt adiacente. Problema *clicii maximele* constă în determinarea unei clici cu cel mai mare număr de noduri conținută într-un graf nedirecționat. ■

Un algoritm euristic simplu pentru rezolvarea ei este descris în continuare.

Algoritmul 1.9. (Clică-maximală)

1. [Inițializări] Se face $SUB = \emptyset, REST = N$.
2. [Terminare] Dacă $REST = \emptyset$, atunci furnizează SUB și STOP.
3. [Alegere] Se alege $y \in REST$ nodul conectat cu cele mai multe alte noduri din $REST$.
4. [Modificări] Se face $SUB = SUB \cup \{y\}, REST = REST - \{\text{nodurile neconectate cu } y\}$.
5. [Ciclare] Se trece la pasul 2. ■




Fig. 1.10.

Exemplul 1.14. Pe figura 1.10. este ilustrat un graf cu $2k + 1$ noduri, ce conține o clică cu k noduri, pentru care algoritmul 1.9. identifică numai clici cu două noduri. Nodul p_0 este primul identificat, deoarece este singurul conectat cu alte k noduri și, drept consecință, este identificată o clică cu două noduri și anume muchia (p_0, p_1) . Rezultă că $r(A, G) = k / 2$. ■

O altă variantă, în cadrul căreia se pleacă de la N și se elimină succesiv noduri până ce rămâne o clică, poate uneori să aibă, de asemenea, un comportament ineficient. Algoritmul construit folosind principiul enunțat mai sus, pe care l-am numit *Clică-maximală-nou*, are forma următoare.

Algoritmul 1.10. (*Clică-maximală-nou*)

1. [Inițializare] Se face $SUB = N$.
2. [Terminare] Dacă SUB este clică, atunci furnizează SUB și STOP.
3. [Alegere] Se alege $y \in SUB$ un nod conectat cu cel mai mic număr de noduri din SUB .
4. [Modificare și reluare] Se face $SUB = SUB - \{y\}$ și se trece la pasul 2. ■




Fig. 1.11.

Exemplul 1.15. Figura 1.11. ilustrează un graf cu $3k$ noduri ce conține o clică de mărime k și pentru care algoritmul 1.10. dă următorul rezultat. În virtutea pasului 3, algoritmul elimină cele k vîrfuri ale clicii și identifică în graful din dreapta o clică cu două vîrfuri. În concluzie $r(A, G) = k / 2$. ■

1.2.2. Algoritmul A^*

Un exemplu remarcabil privind problema analizei algoritmilor îl constituie algoritmul A^* elaborat de N. J. Nilsson (1982) și prezentat conform cu J. Pearl (1984).

În cele ce urmează se presupune că pentru o problemă dată se pot specifica următoarele trei componente: *stările*, *mutările* și *soluțiile*. Mulțimea stărilor se numește *spațiul stărilor* problemei sau *spațiul problemei*. Fiecărei probleme, pentru care sunt specificate stările și mutările, i se poate asocia un *graf al spațiului stărilor*, ale cărui noduri, respectiv, arce corespund stărilor, respectiv, mutărilor. Stării inițiale, adică cele din care începe căutarea soluției, îi corespunde un nod numit *start* și soluțiilor le corespund *drumuri soluție* ce se încheie cu noduri *finale*, numite prin abuz de limbaj și *noduri soluție*.

În prezentarea algoritmului A^* se folosesc următoarele notații și termeni:

- s - nodul start,
- n - nod oarecare,
- n' - succesorul nodului n ,
- $g(n)$ - costul drumului de la s la n ,
- $h(n)$ - o estimare (evaluare) a costului drumului de la n la un nod soluție,
- $f(n) = g(n) + h(n)$ - estimarea (evaluarea) costului unei soluții,
- $c(n, n')$ - costul arcului de la n la n' ,
- *generarea unui nod* - calculul codului nodului pe baza codului nodului *tată* despre care se spune că a fost *explorat*,
- *expandarea unui nod* - generarea tuturor succesorilor direcți ai unui nod *tată*,
- *DESCHIS* - mulțimea nodurilor generate ce urmează a fi expandate,
- *ÎNCHIS* - mulțimea nodurilor expandate (adică ai căror succesori sunt accesibili procedurii de căutare a soluției).

Ideea de bază a algoritmului A^* constă în folosirea unei *funcții euristice de evaluare* $f(n)$ în vederea identificării nodului n din graful spațiului stărilor ce urmează a fi expandat în vederea continuării identificării unui drum soluție. Se presupune că nodul ales pentru expandare este unul pentru care $f(\bullet)$ are o valoare minimă și, dacă există două drumuri orientate către acest nod, cel cu o valoare mai mare a lui $f(\bullet)$ este eliminat. Algoritmul A^* face parte dintr-o familie de algoritmi numiți în lim' engleză *best-first* și este aplicabil numai grafurilor SAU. În procesul de căutare a soluției are loc uneori *reluarea* parcurgerii unor ramuri ale arborelui de traversare T (vezi mai jos) generat de algoritm. Mai precis, dacă la o anumită etapă un drum în T s-a dovedit puțin promițător în ceea ce privește eficiența soluției, parcurgerea lui este întreruptă și se trece la generarea și parcurgerea altui drum. Dacă se constată că parcurgerea acestui nou drum este inutilă, are loc *reluarea* parcurgerii drumului anterior. Această strategie se numește *inspectarea grafului (graph-search)*.

Algoritmul 1.11. (A^*)

1. [Inițializare] Se include nodul start s în *DESCHIS*.
2. [Terminare] Dacă *DESCHIS* este vidă, atunci STOP.
3. [Alegere] Se elimină din *DESCHIS* și se include în *ÎNCHIS* un nod n pentru care valoarea funcției f este minimă.
4. [Soluție] Dacă n este nod soluție, atunci se furnizează soluția obținută ... a listă a pointerilor de la n la nodul inițial s .

5. [Nod care nu e soluție] Altfel se parcurge nodul n generând toți succesorii săi și se asociază pointeri de la aceștia către n . Pentru fiecare succesor n' al lui n :
- Dacă n' nu este în *DESCHIS* sau *ÎNCHIS*, atunci se estimează $h(n')$ (o estimare a costului celui mai bun drum de la n' la un nod soluție) și se calculează $f(n') = g(n') + h(n')$, unde $g(n') = g(n) + c(n, n')$ și $g(s) = 0$.
 - Dacă n' este deja în *DESCHIS* sau *ÎNCHIS*, atunci se orientează pointerii săi dealungul drumului ce furnizează un cel mai mic $g(n')$.
 - Dacă n' necesită o reajustare a pointerului și este în *ÎNCHIS*, atunci se introduce n' în *DESCHIS*.
6. [Ciclare] Se trece la pasul 2. ■

1.2.2.1. Definiții și notații suplimentare

În continuare se presupune, dacă nu este precizat altfel, că spațiul căutării soluțiilor este un graf SAU, identificarea unei soluții constând în găsirea unui drum între nodul s și un nod soluție. De asemenea, se presupune că estimarea euristică $h(n)$ este calculabilă în orice nod al grafului. În locul formulării *nodul n_j este succesorul nodului n_i* se folosește notația $n_j \in SCS(n_i)$, *SCS* fiind *operatorul succesiune*. Se presupune că grafurile au un singur nod start s . Mulțimea nodurilor soluție este notată cu Γ și elementele ei cu γ . Orice arc are un cost $c(n_i, n_j) \geq \delta > 0$, cu δ dat, și costul unui drum este egal cu suma costurilor arcelor componente. Dacă un nod n_j este accesibil dintr-un nod n_i , atunci mulțimea tuturor drumurilor de la n_i la n_j este notată cu $P_{n_i-n_j}$ și cu $P_{n-\gamma}$ se notează orice drum de la n la γ , adică $F \in P_{n-\Gamma}$. Mulțimea celor mai ieftine drumuri de la n_i la n_j este notată cu $P_{n_i-n_j}^*$ și costul celui mai ieftin drum, cu $k(n_i, n_j)$.

Costurilor drumurilor optimale conținând pe s sau un element din Γ li se atribuie următoarele nume:

- $f^*(n)$ - costul celui mai ieftin drum soluție ce trece prin nodul n ,
- $g^*(n)$ - costul celui mai ieftin drum de la s la un nod n , adică:

$$g^*(n) = k(s, n),$$

- $h^*(n)$ - costul celui mai ieftin drum de la n la Γ , adică:

$$h^*(n) = \min_{\gamma \in \Gamma} k(n, \gamma),$$

- C^* - cel mai ieftin cost al drumului de la s la Γ , adică:

$$C^* = h^*(s).$$

Cu Γ^* este notată mulțimea nodurilor *soluții optimale*, adică submulțimea nodurilor accesibile din s pe o cale sau mai multe căi de cost C^* . Această mulțime poate eventual să fie vidă sau să conțină mai multe elemente, dar în cele mai multe cazuri ea conține un singur element care ar trebui determinat.

Algoritmul A^* explorează graful G al spațiului stărilor utilizând un arbore de traversare T . La fiecare etapă a căutării, arborele T este definit de pointerii pe care A^* îi atribuie nodurilor generate, ramificațiile din T având sens opus pointerilor. Ori de câte ori este necesară evidențierea faptului că un drum dat face parte din T , la o anumită etapă a căutării, acest drum este notat cu PP , de exemplu $PP_{n_1-n_2} \in T$, indicii fiind nodurile între care se consideră drumul dat. De asemenea, se face distincție între un nod aflat *dealungul* unui drum P , dacă P este în T , de un nod situat *pe* P , dacă P nu este în T .

Uniunea tuturor ramificațiilor din arborii de traversare construiți în timpul căutării reprezintă subgraful *explorat* al lui G și este notat G_e . De notat că un drum P poate aparține lui G_e dar să nu aparțină nici unui arbore de traversare din G_e .

În continuare sunt studiate câteva proprietăți de bază ale algoritmului A^* .

Completitudine. Un algoritm este *complet* dacă se încheie cu o soluție, atunci când există cel puțin una.

Admisibilitate. Un algoritm este *admisibil* atunci când garantează furnizarea unei soluții *optimale*, atunci când există o astfel de soluție.

Dominanță. Un algoritm A_1 *domină* algoritmul A_2 dacă orice nod expandat de A_1 este de asemenea expandat de A_2 . Algoritmul A_1 *domină strict* pe A_2 dacă A_1 domină pe A_2 dar A_2 nu domină pe A_1 . Un sinonim al termenului *domină* îl constituie expresia: *mai eficient decât*. Aceasta deoarece, în general, A_1 evaluează un număr mai mic de noduri decât A_2 , deci se obțin costuri mai mici pentru A_1 .

Optimalitate. Un algoritm se numește *optimal* într-o clasă de algoritmi dacă el domină toate elementele acestei clase.

1.2.2.2. Căutarea unei soluții optimale cu algoritmul A^*

1.2.2.2.1. Proprietățile funcției f^*

Funcția f de selectare (evaluare) a nodurilor utilizată în A^* este suma a două funcții $g(n)$ și $h(n)$, unde:

- $g(n)$ - este costul drumului *curent* PP_{s-n} de la s la n , cu $g(s) = 0$, s fiind nodul start,
- $h(n)$ - este o estimare a lui $h^*(n)$, astfel încât $h(\gamma) = 0$, γ fiind nod soluție.

Pentru specificarea costurilor *actuale* P_{s-n} și $P_{n-\gamma}$ dealungul unui drum P , se folosește notația $g_P(n)$ respectiv $h_P(n)$. Evident că pentru orice drum P au loc:

$$g_P(n) \geq g^*(n) \text{ și } h_P(n) \geq h^*(n). \quad (1.1)$$

Atunci când g și h coincid cu valorile lor optimale, suma lor:

$$f^*(n) = g^*(n) + h^*(n)$$

măsoară *costul optimal pe toate drumurile soluție ce trec prin n* . În particular, pentru nodul inițial s și orice nod soluție $\gamma \in I^*$ au loc relațiile:

$$f^*(s) = h^*(s) = g^*(\gamma) = f^*(\gamma) = C^*$$

și, în plus, dacă $n^* \in P_{s-I}^*$ este un nod oarecare de pe un drum optimal, atunci este satisfăcută relația:

$$f^*(n^*) = C^*. \quad (1.2)$$

Pentru demonstrarea validității relației (1.2), se observă că $n^* \in P_{s-I}^*$ implică existența unui drum soluție P trecând prin n și având costul C^* . Deci pe acest drum $g_P(n) + h_P(n) = C^*$. În virtutea optimalității lui g^* și h^* din (1.1), rezultă că $g^*(n) + h^*(n) \leq C^*$, dar această inegalitate nu poate fi strictă. În caz contrar ar exista un drum P' pentru care $g_{P'}(n) + h_{P'}(n) < C^*$, ceea ce ar contrazice optimalitatea lui C^* .

Importanța funcției $f^*(n)$ rezultă din comportarea ei în noduri ce nu aparțin unui drum soluție optimal. Pentru un asemenea nod n trebuie satisfăcută condiția:

$$f^*(n) > C^*, n \notin P_{s-I}^*. \quad (1.3)$$

Într-adevăr, presupunând că $g^*(n) + h^*(n) \leq C^*$, ar rezulta că există un drum soluție P' trecând prin n pentru care $g_{P'}(n) + h_{P'}(n) \leq C^*$, deci P' ar fi o soluție optimală, ceea ce contrazice ipoteza că n nu aparține unui drum soluție optimal.

1.2.2.2. Terminare și completitudine

Algoritmul A^* se termină întotdeauna pentru grafuri finite. Afirmatia rezultă din faptul că numărul de drumuri aciclice în asemenea grafuri este finit și algoritmul A^* adaugă noi legături în arborele de traversare al grafului la orice expansiune a unui nod. Orice nouă legătură reprezintă un nou drum aciclic astfel încât până la urmă mulțimea de drumuri este epuizată.

Algoritmul A^* este de asemenea complet pe grafuri finite. Un eșec are loc numai atunci când mulțimea *DESCHIS* este găsită vidă și dacă există un drum soluție $P_{s-\gamma}$, atunci mulțimea *DESCHIS* nu poate fi vidă înainte ca $P_{s-\gamma}$ să fie depistată. Altfel ar exista măcar un nod $n' \in P_{s-\gamma}$ în *DESCHIS* care este expandat fără a genera un nou succesori. Aceasta contrazice presupunerea că n' aparține drumului soluție. Orice astfel de nod, în afară de nodul soluție, are cel puțin un succesori aflat pe drumul soluție.

1.2.2.2.3. *Admisibilitate - garanția pentru o soluție optimală*

Definiția 1.5. O funcție euristică h este *admisibilă* dacă, pentru orice nod n :

$$h(n) \leq h^*(n). \blacksquare \tag{1.4}$$

În cele ce urmează, se presupune că relația (1.4) este satisfăcută.

Lema 1.1. La orice moment, înainte ca A^* să se încheie, există un nod n' în *DESCHIS* situat pe $P_{s-\gamma}^*$ cu $f(n') \leq C^*$.

Demonstrație. Fie un drum optimal $P_{s-\gamma}^* \in P_{s-\Gamma}^*$:

$$P_{s-\gamma}^* = s, n_1, n_2, \dots, n', \dots, \gamma,$$

unde n' este primul nod de pe $P_{s-\Gamma}^*$ aparținând mulțimii *DESCHIS*. Există cel puțin un nod din *DESCHIS* situat pe $P_{s-\Gamma}^*$ deoarece γ nu este în *ÎNCHIS* înainte de încheiere. Deoarece toți predecesorii lui n' sunt în *ÎNCHIS* și drumul s, n_1, n_2, \dots, n' este optimal, rezultă că pointerii atribuiți lui n' sunt dealungul drumului $P_{s-n'}^*$, deci $g(n') = g^*(n')$. Din admisibilitatea lui h se deduce inegalitatea:

$$f(n') = g^*(n') + h(n') \leq g^*(n') + h^*(n') = f^*(n')$$

și, deoarece $n' \in P_{s-\gamma}^*$, rezultă că (vezi (1.2)) $f^*(n') = C^*$, deci $f(n') \leq C^*$. ■

Lema 1.2. (Corolar al lemei 1.1.) Fie n' primul nod de pe drumul optimal $P_{s-n''}^*$ către nodul n'' , nu neapărat din Γ , aparținând mulțimii *DESCHIS*. Atunci $g(n') = g^*(n')$, adică A^* a identificat deja un drum optimal de pointeri către n' (deci n' aparține lui $P_{s-n''}^*$) și acest drum rămâne neschimbat în procesul căutării.

Demonstrație. Afirmația rezultă direct din lema 1.1., unde egalitatea $g(n') = g^*(n')$ a fost dedusă fără să se țină seama de faptul că γ este nod soluție. ■

Teorema 1.25. A^* este admisibil.

Demonstrație. Să presupunem că A^* se încheie cu un nod soluție $t \in \Gamma$ pentru care $f(t) = g(t) > C^*$. Algoritmul A^* inspectează satisfacerea de către noduri a criteriului de terminare numai după ce au fost selectate pentru expandare. Rezultă că, dacă nodul t a fost ales pentru expandare, este satisfăcută condiția:

$$f(t) \leq f(n), \text{ pentru orice } n \in \text{DESCHIS.}$$

De aici se deduce că, imediat înainte de încheiere, pentru toate nodurile din *DESCHIS* are loc inegalitatea $f(n) > C^*$, în contradicție cu lema 1.1. care garantează existența măcar a unui nod n' cu $f(n') \leq C^*$. Prin urmare, pentru nodul terminal t , are loc relația $g(t) = C^*$, cu semnificația că A^* furnizează un drum optimal. ■

1.2.2.2.4. Comportarea puterii de selectare a euristiciilor

Puterea estimării $h(\bullet)$ a unei euristici este definită de valoarea selecției induse de h și depinde evident de *acuratețea* acestei estimări. Dacă $h(\bullet)$ estimează costul căutării în mod exact (adică $h = h^*$), atunci A^* explorează numai noduri situate pe drumuri optimale. Pe de altă parte, dacă nu este folosită nici o euristică ($h = 0$), rezultă o căutare în lățime, drept rezultat având loc expandarea tuturor nodurilor accesibile din s pe un drum de cost mai mic decât C^* . Cazurile cele mai des întâlnite sunt situate între aceste două extreme. Este evidentă proprietatea următoare: cu cât h este mai apropiat de h^* , cu condiția să rămână admisibilă, cu atât este mai eficientă căutarea soluției.

Definiția 1.6. O euristică h_2 este *euristică mai informată* decât h_1 , dacă ambele sunt admisibile și $h_2(n) > h_1(n)$, pentru orice nod n nonsoluție. Similar, un algoritm A^* ce utilizează h_2 se consideră mai informat decât altul ce utilizează h_1 . ■

Teorema 1.26. (Condiție necesară pentru expandarea unui nod) Orice nod expandat de A^* nu poate avea o valoare a lui f mai mare ca C^* , adică $f(n) \leq C^*$ pentru toate nodurile n expandate.

Demonstrație. Să presupunem contrariul, adică n este selectat din *DESCHIS* dacă $f(n) > C^*$. Această ipoteză contrazice lema 1.1. în virtutea căreia mulțimea *DESCHIS* conține un nod n' astfel încât $f(n') \leq C^*$. Deci nodul n' va fi ales pentru expandare în locul lui n . ■

Teorema 1.27. (Condiție suficientă pentru expandarea unui nod) Orice nod din *DESCHIS*, pentru care $f(n) < C^*$, va fi până la urmă expandat de A^* .

Demonstrație. Să presupunem că la o anumită etapă, nodul n cu $f(n) < C^*$ este găsit în *DESCHIS*. Algoritmul A^* se încheie cu $f(t) = C^*$ după ce l-a selectat pe t pentru expandare din *DESCHIS*. Faptul că nodul t și nu n a fost selectat, înseamnă că, ori n a fost selectat înaintea lui t , ori valoarea $f(n)$ a fost între timp modificată astfel încât depășește pe C^* . Dar valoarea lui f nu poate fi modificată decât prin deplasarea în adâncime, astfel încât numai prima alternativă, adică expandarea lui n , este singura posibilitate. ■

De notat că nici una din teoremele 1.26. sau 1.27. nu conține o condiție necesară și suficientă, deoarece soarta nodurilor din *DESCHIS* pentru care are loc egalitatea $f(n) = C^*$ nu este menționată de nici una dintre teoreme și rămâne să fie decisă de regulile *tie-breaking* utilizate în implementarea algoritmului A^* . O regulă *tie-breaking* este un criteriu de alegere a uneia dintre mai mult de două alternative, echivalente din punct de vedere al continuării căutării soluției.

Condițiile de expandare din teoremele 1.26. și 1.27., chiar dacă sunt utile, nu furnizează criterii adecvate pentru determinarea eficienței unui algoritm A^* . Aceasta se datorește faptului că în aceste teoreme sunt invocați doi parametri locali, care pot varia o dată cu etapa de evoluție a algoritmului și nu sunt, prin urmare, detectabili direct din datele externe. Primul este funcția $g(n)$, care nu este în realitate o proprietate a nodului n , dar depinde de drumul către n depistat de A^* la un moment dat. Al doilea este condiția din teorema 1.27. că n se află în *DESCHIS* înainte de a fi selectat pentru expandare. Faptul că un nod dat n este în *DESCHIS* depinde nu de n însuși, ci de comportarea lui A^* în procesul de explorare a drumurilor care duc la n . Următoarele două rezultate rectifică aceste dificultăți.

Definiția 1.7. Un drum P este *C-mărginit* dacă orice nod n dealungul acestui drum satisface condiția $g_P(n) + h(n) \leq C$. Similar, dacă în relația precedentă are loc inegalitatea strictă pentru orice n de pe P , atunci P este *strict C-mărginit*. Dacă este necesară menționarea euristicii folosită pentru afirmarea inegalității precedente, se folosește notația *C(h)-mărginit*. ■

Teorema 1.28. O condiție suficientă pentru A^* în vederea expandării unui nod n este existența unui drum P strict C^* -mărginit de la s la n .

Demonstrație. Presupunem contrariul, adică existența unui drum P strict C^* -mărginit de la s la n și că, la încheierea căutării, nodul său final n nu a fost încă expandat. Fie n' primul nod din *DESCHIS* de pe P (la încheierea căutării). Deoarece toți predecesorii lui n' sunt în *ÎNCHIS*, valoarea lui g pe care A^* o atribuie lui n' nu poate fi mai mare decât $g_P(n')$; deci:

$$f(n') = g(n') + h(n') \leq g_P(n') + h(n') < C^*.$$

Dar, dacă $f(n') < C$ la încheierea căutării, atunci n' trebuie să fi fost ales pentru expandare în locul nodului soluție, care este candidat a încheia căutarea cu $f = C^*$. Acest fapt contrazice ipoteza că un nod n' din *DESCHIS* există pe P și, prin urmare, n trebuie expandat. ■

Teorema 1.29. O condiție necesară pentru ca A^* să expandeze un nod n este existența unui drum C^* -mărginit de la s la n .

Demonstrație. Dacă A^* expandează un nod n , atunci n trebuie să fie în *DESCHIS* și, de asemenea, $f(n) \leq C^*$ (teorema 1.26.). Fie acum drumul PP al pointerilor atribuiți lui n la momentul expandării lui. Fiecare predecesor n' al lui n dealungul lui PP este în *ÎNCHIS* și, prin urmare, a fost ales pentru expandare, poate mai mult decât o dată, la un moment precedent, moment la care, cum rezultă din teorema 1.26., este satisfăcută inegalitatea $g^*(n') + h(n') \leq C^*$. Valoarea curentă a lui

$g(n')$ dealungul lui PP nu poate fi mai mare decât valoarea lui $g'(n')$ în momentul expansiunii. Prin urmare, fiecare nod n' de pe PP satisface condiția $f(n') \leq C^*$, cu semnificația că PP este și el C^* -mărginit. ■

Teoremele 1.28. și 1.29. joacă un rol major în analiza performanțelor lui A^* . Teorema următoare confirmă intuiția noastră privind tendința de a alege pe h , posibil, cât mai ridicat.

Teorema 1.30. Dacă A_2^* este mai informat decât A_1^* , atunci A_2^* domină pe A_1^* .

Demonstrație. Fie h_2 și h_1 euristicile utilizate de A_2^* , respectiv, A_1^* astfel încât $h_2(n) > h_1(n)$ pentru orice nod n care nu este soluție și să presupunem că A_2^* expandează un nod oarecare n . Din teorema 1.29. se știe că există un drum C^* -mărginit de la s la n ales cu ajutorul lui h_2 . Deoarece $h_2(n') > h_1(n')$, pentru orice nod n' de pe P , rezultă că P este strict mărginit dacă a fost ales de h_1 . ■

1.2.2.2.5. Euristici monotone (consistente)

În secțiunea precedentă s-a presupus, implicit, că eficiența lui A^* poate fi măsurată cu numărul de noduri neexpandate. În realitate, un nod poate fi expandat de mai multe ori și, prin urmare, nu numărul de noduri expandate ci numărul de operații de expansiune trebuie avut în vedere la aprecierea eficienței. În continuare se arată că, în anumite condiții, algoritmul A^* nu parcurge, în vederea introducerii în *DESCHIS*, unele noduri din *ÎNCHIS* și, prin urmare, timpul necesar reexpansiunii poate fi în acest fel micșorat.

Condiția care permite evitarea redeschiderilor este o anumită proprietate a lui h ce este satisfăcută de orice funcție h^* , adică o *consistență*. În secțiunile precedente s-a văzut că orice funcție h^* , în afară de estimarea corectă a costurilor optime către Γ , satisface anumite relații între $h^*(n)$ și evaluările lui h^* ale descendenților lui n . Relațiile (1.2) și (1.3) implică faptul că cel mai ieftin drum constrâns să treacă prin n nu poate fi mai puțin costisitor decât cel mai ieftin drum generat fără această restricție, adică $g^*(n) + h^*(n) \geq h^*(s)$, pentru orice n , sau $k(s, n) + h^*(n) \geq h^*(s)$, unde $k(s, n)$ este costul celui mai ieftin drum de la s la n .

Această formă a *inegalității triunghiului* pentru geodezice este valabilă pentru orice pereche de noduri, nu neapărat conținând pe s . Așadar, dacă n' este un descendent al lui n , are loc relația:

$$h^*(n) \leq k(n, n') + h^*(n'), \text{ pentru orice } (n, n'),$$

care este automat satisfăcută și pentru nodurile n' pentru care $k(n, n') = \infty$ și care nu sunt descendente ale lui n .

Rezultă că este rezonabil să se considere că, dacă procesul de estimare a lui $h(n)$ este consistent, el trebuie să moștenească proprietatea geodezică a lui $h^*(n)$ și să satisfacă condiția:

$$h(n) \leq k(n, n') + h(n'), \text{ pentru orice } (n, n'). \quad (1.5)$$

Definiția 1.8. O funcție euristică $h(n)$ este *consistentă* dacă relația (1.5) este satisfăcută pentru orice pereche de noduri n și n' . ■

Definiția 1.9. O funcție euristică $h(n)$ este *monotonă* dacă satisface relația:

$$h(n) \leq c(n, n') + h(n'), \text{ pentru orice } (n, n'), n' \in SCS(n), \quad (1.6)$$

unde $c(n, n')$ este costul arcului de la n la n' . ■

Monotonia pare, la prima vedere, mai puțin restrictivă decât consistența, deoarece ea se referă la două noduri succesive. Se poate însă arăta, prin inducție după adâncimea k a descendenților lui n , că (1.6) implică (1.5). Prin urmare are loc următoarea teoremă.

Teorema 1.31. Monotonia și consistența sunt proprietăți echivalente. ■

Se poate de asemenea deduce legătura dintre consistență și admisibilitate.

Teorema 1.32. Orice euristică consistentă este și admisibilă.

Demonstrație. Înlocuind pe n' din (1.5) cu orice nod soluție $\gamma \in \Gamma$, se obține:

$$h(n) \leq k(n, \gamma) + h(\gamma), \text{ pentru orice } n.$$

Deoarece $h(\gamma) = 0$ și $k(n, \gamma) = h^*(n)$ pentru orice nod $\gamma \in \Gamma^*$, rezultă că are loc condiția de admisibilitate (vezi (1.4)):

$$h(n) \leq h^*(n). \quad \blacksquare$$

Vom demonstra avantajele utilizării euristiciilor consistente sau monotone.

Teorema 1.33. Un algoritm A^* ce utilizează o euristică monotonă găsește drumurile optimale pentru toate nodurile expandate, adică:

$$g(n) = g^*(n), \text{ pentru orice } n \in \hat{INCHIS}.$$

Demonstrație. Să presupunem că A^* alege pentru expandare un nod pentru care $g(n) > g^*(n)$. Fie un drum optimal P_{s-n}^* de la s la n . Dacă n este singurul nod din *DESCHIS* de pe drumul P_{s-n}^* , atunci este evident că toți predecesorii lui n pe P_{s-n}^* au fost expandați și, prin urmare, $g(n) = g^*(n)$ (Lema 1.2.). Presupunerea $g(n) > g^*(n)$ implică faptul că P_{s-n}^* conține măcar un nod adițional în *DESCHIS* și, ca de obicei, fie n' primul nod din *DESCHIS* de pe P_{s-n}^* . Se poate arăta că n' și nu n trebuie ales pentru expandare. Lema 1.2. menționează că $g(n') = g^*(n')$ și, prin urmare, în virtutea consistenței, rezultă că:

$$f(n') = g^*(n') + h(n') \leq g^*(n') + k(n', n) + h(n),$$

unde $k(n', n)$ este costul celui mai ieftin drum de la n' la n . Suma $g^*(n') + k(n', n)$ este egală cu $g^*(n)$ deoarece n' este un predecesor al lui n dealungul lui P_{s-n}^* și, de aceea,

$$f(n') \leq g^*(n) + h(n).$$

Rezultă că ipoteza $g(n) > g^*(n)$ implică:

$$f(n') < f(n),$$

fapt care împiedică alegerea lui n în loc de n' . Prin urmare, rezultă că $g(n) = g^*(n)$, ceea ce completează demonstrația teoremei. ■

Teorema 1.34. Monotonia implică faptul că secvența valorilor lui f corespunzătoare nodurilor expandate de A^* este nedescrescătoare.

Demonstrație. Fie n_2 nodul expandat imediat după n_1 . Dacă n_2 este în *DESCHIS*, atunci, când n_1 a fost expandat, din regula de selectare a nodurilor rezultă că $f(n_1) \leq f(n_2)$. În caz contrar, n_2 trebuie să fie noul venit în *DESCHIS*, adică un succesori al lui n_1 pentru care:

$$g(n_2) = g(n_1) + c(n_1, n_2)$$

și pentru care, în virtutea monotoniei:

$$f(n_2) = g(n_1) + c(n_1, n_2) + h(n_2) \geq g(n_1) + h(n_1) = f(n_1).$$

Rezultă că secvența valorilor lui f nu poate fi descrescătoare. ■

Monotonia simplifică semnificativ condițiile de expandare a nodurilor.

Teorema 1.35. Dacă f este monotonă, atunci condiția necesară pentru expandare este:

$$g^*(n) + h(n) \leq C^*$$

și condiția suficientă este definită de inegalitatea strictă:

$$g^*(n) + h(n) < C^*.$$

Demonstrație. Condiția necesară rezultă din teoremele 1.26. și 1.31. Condiția suficientă se bazează pe natura nedescrescătoare a lui $g^* + h$ dealungul unui drum optimal de la s la un nod arbitrar n . Afirmatia este adevărată, deoarece, dacă n' este un predecesor al lui n dealungul unui drum optimal P_{s-n}^* , el trebuie să satisfacă relația:

$$g^*(n) = g^*(n') + c(n', n),$$

care, împreună cu monotonia lui h , implică:

$$g^*(n) + h(n) = g^*(n') + c(n', n) + h(n) \geq g^*(n') + h(n').$$

Rezultă că dacă n satisface condiția:

$$g^*(n) + h(n) < C^*,$$

atunci și toți predecesorii lui de pe P_{s-n}^* trebuie să o satisfacă. Prin urmare P_{s-n}^* este strict C^* -mărginit și, în virtutea teoremei 1.28., n va fi expandat de A^* . ■

1.2.2.3. Relaxarea condițiilor de optimalitate

Rezultatele precedente arată că A^* posedă unele proprietăți utile privind folosirea euristicii alese. În particular, dacă euristica utilizată este admisibilă, atunci A^* garantează obținerea unui drum optimal.

Experiența arată, totuși, că în multe cazuri A^* utilizează un timp mare în procesul de discriminare a drumurilor a căror cost nu variază mult de la unul la altul. În acest caz, proprietatea de admisibilitate devine un cusur în loc de o virtute. Ea forțează pe A^* să consume un timp disproporționat de mare în selectarea celui mai bun dintre candidații aproape egali și împiedică pe A^* să încheie căutarea unui drum suboptimal, dar, pe de altă parte, acceptabil.

În continuare se prezintă două forme de reprezentare a lui f ca funcție de g și h și efectele lor asupra eficienței algoritmului A^* .

1.2.2.3.1. Ajustarea ponderilor lui g și h

În vederea obținerii unor versiuni mai rapide ale algoritmului A^* , care nu asigură neapărat generarea unor soluții optimale, este indicat să se examineze separat efectele lui g și h .

În ipoteza că $f(n) = g(n)$, strategia căutării coincide cu cea a *costului uniform*, care este o variantă a căutării în lățime. În această variantă, în loc să se parcurgă nivele de adâncime egală, sunt parcurse nivele de cost egal. Procedura *cost uniform* se realizează pe calea selectării pentru expandare a unui nod din *DESCHIS* de cost minimal, unde costul fiecărui nod este definit ca fiind costul drumului de la nodul start la acest nod.

În ipoteza că $f(n) = h(n)$, strategia căutării coincide cu cea a căutării în lățime (*BF*). În acest caz, dacă alegerea lui $h(n)$ nu este suficient de consistentă, adică nu reflectă suficient de bine particularitățile problemei studiate, atunci este posibilă atribuirea de valori mici ale lui $h(n)$ unor drumuri prea lungi, drumuri care, datorită lipsei criteriului furnizat de g , nu pot fi evitate.

În vederea echilibrării particularităților menționate, se poate utiliza o funcție de evaluare ponderată:

$$f_w(n) = (1 - w)g(n) + wh(n),$$

care, pentru $w = 0, 1/2, 1$ corespunde strategiilor cost uniform, A^* și *BF*. Prin variația continuă a lui w între 0 și 1 se pot obține diferite variante ale algoritmului A^* , în vederea rezolvării convenabile a unor probleme.

Rezultatele empirice obținute pentru *jocul 15* (15 plăcuțe pe un tabel 4×4 care trebuie aduse dintr-o stare inițială într-o stare finală prin mutări admise a câte unei plăcuțe pe locul liber dacă acesta este vecin ei) arată că f_w asigură o performanță optimală (număr mediu minim de noduri expandate) în banda $1/2 < w < 1$. Simulări mai extensive pentru *jocul 8* (8 plăcuțe pe un tabel 3×3) au arătat că f_w atinge o performanță optimală în vecinătatea lui $w = 1/2$ și creșterea lui w dincolo de $1/2$ poate provoca o creștere a numărului de noduri expandate.

1.2.2.3.2. Două versiuni ε -admisibile mai rapide ale lui A^*

Deteriorarea performanței lui $f_w = (1 - w)g + wh$ pentru $w > 1/2$, cuplată cu riscul permanent de încheiere cu o soluție de cost mai mare decât cel acceptabil, a determinat încercările de a răspunde la întrebarea: poate fi asigurată o creștere a vitezei cu prețul unei descreșteri mărginite a calității soluției? În continuare sunt prezentate două abordări ale acestei probleme: *ponderarea dinamică* și A_ε^* . Un algoritm este considerat ε -admisibil dacă furnizează un rezultat diferit de cel optimal prin factorul $1 + \varepsilon$.

1.2.2.3.2.1. Ponderarea dinamică

În locul menținerii lui w constant dealungul căutării, este natural să se varieze dinamic valoarea lui astfel încât valoarea lui h să fie ponderată mai mult atunci când adâncimea căutării crește. Pentru aceasta se poate utiliza funcția de evaluare:

$$f(n) = g(n) + h(n) + \varepsilon(1 - d(n)/N)h(n)$$

unde $d(n)$ este adâncimea nodului n și N este adâncimea (anticipată) a nodului soluție dorit. La nivele mici ale arborelui de căutare ($d \ll N$), h are o pondere de ordinul $1 + \varepsilon$, fapt care încurajează căutarea în adâncime. La nivele adânci, atunci când terminarea se apropie, căutarea presupune o ponderare egală a lui g și h , fapt care evită o încheiere prematură.

Nu este greu de văzut că dacă $h(n)$ este admisibilă, algoritmul este ε -admisibil, adică se găsește un drum de cost cel mult $(1 + \varepsilon)C^*$. Afirmatia se bazează pe faptul că înaintea terminării, pentru primul nod n' din *DESCHIS* de pe orice soluție optimală are loc egalitatea $g(n') = g^*(n')$ (vezi lema 1.2.) și prin urmare:

$$f(n') \leq g^*(n') + h^*(n') + \varepsilon(1 - d(n')/N)h^*(n') \leq C^* + \varepsilon h^*(n') \leq (1 + \varepsilon)C^*.$$

Rezultă că algoritmul nu se poate încheia cu un nod soluție al cărui cost este mai mare decât $(1 + \varepsilon)C^*$.

1.2.2.3.2.2. A_ε^* - algoritm ce utilizează estimări ale efortului căutării

Algoritmul A_ε^* utilizează două liste: *DESCHIS* și *FOCAR*. *FOCAR* este o sublistă a lui *DESCHIS* ce conține numai acele noduri pentru care f nu deviază față de valoarea cea mai mică a lui f printr-un factor mai mare decât $1 + \varepsilon$, adică:

$$FOCAR = \{n \mid f(n) \leq (1 + \varepsilon) \min_{n' \in OPEN} f(n')\}.$$

Operațiile lui A_ε^* sunt identice cu cele ale lui A^* , cu excepția că A_ε^* selectează din *FOCAR* nodul cu valoarea h_F minimă, unde $h_F(n)$ este o a doua funcție euristică care estimează efortul computațional necesar completării căutării plecând din n .

Rățiunea acestei variante este simplă. În acord cu estimările disponibile ale lui $f(\bullet)$, toate nodurile din *FOCAR* au aproximativ drumuri soluție egale. Dec. în loc să se consume timp pentru identificarea celui mai bun dintre ele, este mai indicat să se genereze porțiunea rămasă a soluției și nodul care oferă cel mai mic efort de completare este unul cu valoare minimă a lui h_F . Este clar că pentru $\varepsilon = 0$, A_ε^* se reduce la A^* .

Euristica h pentru formarea mulțimii *FOCAR* este de natură total diferită față de euristica h_F utilizată pentru selectarea nodurilor din *FOCAR*. Prima euristică anticipează reducerea calității soluției datorită efortului necesar continuării căutării ei. A doua euristică estimează efortul computațional pentru completarea căutării.

Teorema 1.36. A_ε^* este ε -admisibil, adică el găsește întotdeauna o soluție al cărui cost nu depășește costul optimal printr-un factor mai mare decât $1 + \varepsilon$.

Demonstrație. Adoptând următoarele notații:

n_0 = un nod în *DESCHIS* având o valoare f optimală,

t = nod terminal (căutat pentru expansiune și găsit a fi nod soluție),

n_1 = primul nod din *DESCHIS* de pe o soluție optimală,

$C(t) = f(t) = g(t)$ = costul soluției găsite,

rezultă:

$f(n_1) \leq C^*$	deoarece h este admisibilă,
$f(n_0) \leq f(n_1)$	deoarece <i>DESCHIS</i> este f -ordonată,
$f(t) \leq f(n_0) (1 + \varepsilon)$	deoarece t este ales din <i>FOCAR</i> .

Prin urmare:

$$C(t) = f(t) \leq f(n_1) (1 + \varepsilon) \leq C^* (1 + \varepsilon). \blacksquare$$

1.2.2.3.2.3. Compararea celor doi algoritmi

Ponderarea dinamică este un algoritm ușor de implementat; acest algoritm memorează doar o singură listă și folosește o singură funcție euristică. A_ε^* oferă pe de

altă parte multe alte avantaje. În timp ce ponderarea dinamică este limitată la probleme în care adâncimea soluției optimale (N), sau măcar o bună margine superioară a ei, este cunoscută *a priori*, A_ϵ^* își menține ϵ -admisibilitatea chiar când valoarea N este complet necunoscută. Mai mult, separarea totală a celor două euristici utilizate de A_ϵ^* îi asigură un mecanism în vederea incorporării unor estimări sofisticate a costului computațional necesar completării căutării. Acest fapt implică elaborarea unor funcții de drumul de la s la n , nu întotdeauna descriptibile de g și h . De exemplu, dacă problema comisvoiajorului este considerată în cazul unei rețele cu localități rar distribuite, numărul de arce din porțiunea neexplorată a grafului constituie uzual o mai validă estimare a efortului computațional rezidual decât proporția $1 - \text{depth}(n) / N$ a orașelor neexplorate, ce reprezintă ghidul algoritmului ponderare dinamică.

Compararea performanțelor celor doi algoritmi pe mai multe exemple arată comportarea ceva mai bună a algoritmului A_ϵ^* . Ambii algoritmi au o cea mai mare utilitate în probleme *hard* asigurând o economie cuprinsă între 60% și 90%.

Exemplul 1.16. În cartea lui Nilsson, ideea reluării parcurgerii unor ramuri anterioare ale arborelui generat în procesul căutării soluției este ilustrată pe următorul exemplu. Fie o bază de date inițială DB1, căreia îi sunt aplicate regulile de transformare R1 și R3, având drept rezultat bazele DB2 și DB3 (vezi figura 1.12.). Dacă sistemul de control decide că această cale este nepromițătoare, înregistrările DB2 și DB3 sunt șterse și are loc întoarcerea, urmată de aplicarea regulii R2 având drept rezultat baza DB4. Dacă însă sistemul de control menține înregistrările bazelor DB2 și DB3 și baza DB4 se dovedește inutilă, atunci se poate relua căutarea imediat după DB2 sau DB3. ■




Fig. 1.12.

Exemplul 1.17. Strategia de inspectare a grafului, menționată mai înainte și utilizată în algoritmul A^* , este ilustrată pe exemplul ce urmează [NIL82, pag. 67].

Să presupunem că procesul de căutare a generat graful de căutare din figura 1.13.a) în care arborele de traversare T este definit de pointerii reprezentați de săgețile

paralele cu arcele grafului. Nodurile marcate cu cercuri pline sunt în *ÎNCHIS* și cele marcate cu cercuri goale sunt în *DESCHIS*, în momentul când algoritmul a ales pentru expandare nodul 1. Arcele grafului se presupun de cost unitar. Atunci când nodul 1 este expandat, este generat nodul 2, unicul său succesori. Dar nodul 2, care are tată nodul 3 în arborele de căutare (traversare), a fost deja generat, este în *ÎNCHIS* și are succesori 4 și 5. De asemenea, trebuie notat faptul că tatăl nodului 4 în arborele de căutare este nodul 6, deoarece cel mai scurt drum (de cost minim) de la nodul s către nodul 4 trece prin nodul 6. Deoarece algoritmul a identificat un drum către nodul 2 ce trece prin nodul 1, de cost mai mic decât drumul anterior prin nodul 3, nodul tată al nodului 2 în arborele de căutare este schimbat din 3 în 1. Costurile drumurilor către descendenții nodului 2 în graful de căutare, adică drumurile către nodurile 4 și 5, sunt recalulate. Aceste costuri sunt acum mai mici decât anterior și tatăl nodului 4 este schimbat din nodul 6 în nodul 2. Arborele de căutare (traversare), ajustat este definit de arcele din figura 1.13.b). ■




Fig. 1.13.

Exemplul 1.18. Un exemplu ilustrativ simplu privind semnificația și nivelul de utilizare al funcției de evaluare f îl constituie *jocul 8* [NIL82, pag. 73]. Fiind date opt plăcuțe pătrate numerotate de la 1 la 8 și plasate pe o tablă pătrată de latură trei ca în figura 1.14.a) se cere rearanjarea lor ca în figura 1.14.b), mutând succesiv orice plăcuță pe un loc neocupat.




Fig. 1.14.

Drept funcție de evaluare se consideră $f(n) = d(n) + w(n)$, unde $d(n)$ este adâncimea unui nod n în arborele de căutare și $w(n)$ este numărul plăcuțelor incorect

plasate pe tabla corespunzătoare nodului n . De exemplu, pentru configurația din figura 1.14.a) valoarea lui f este egală cu $0 + 4 = 4$.

Rezultatul aplicării strategiei *inspectarea grafului* în cazul exemplului considerat este ilustrat în figura 1.15. Valoarea lui f pentru fiecare nod este încercuită; numerele neîncercuite arată ordinea în care nodurile sunt expandate.

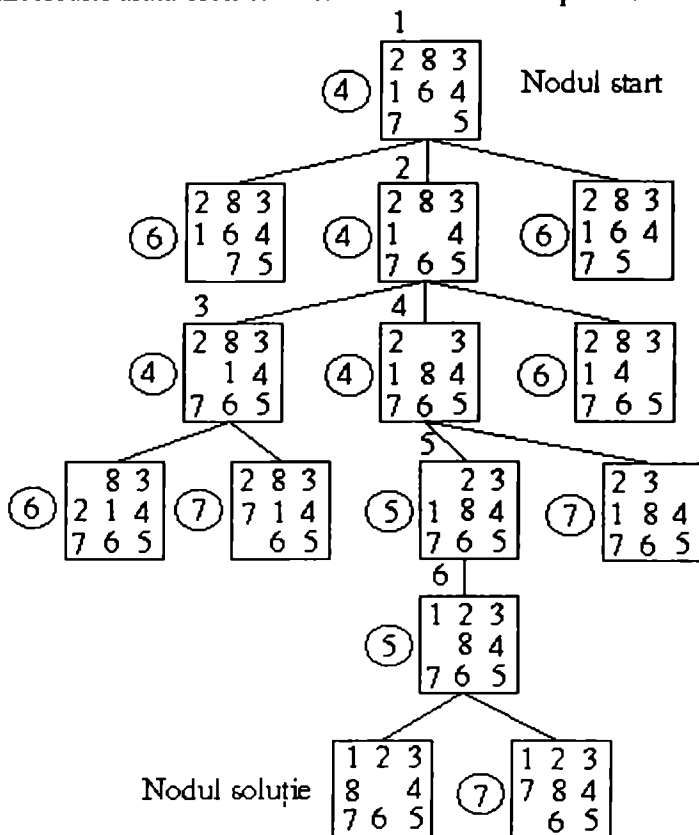


Fig. 1.15.

Soluția problemei studiate poate fi obținută și cu ajutorul altor metode de căutare, dar utilizarea funcției de evaluare are drept rezultat expandarea unui număr mai mic de noduri. ■

1.2.3. Euristicile ca informație dată de modele simplificate

1.2.3.1. Utilizarea modelelor relaxate

1.2.3.1.1. Proveniența euristicilor

Fie exemplul jocului 8, care constă în rearanjarea a 8 plăcuțe, numerotate de la 1 la 8, pe un tabel (tăbliță) 3×3 astfel încât să fie așezate ca în figura 1.16., dreapta.

Rearanjarea plăcuțelor este permisă numai prin deplasarea ortogonală, adică orizontală sau verticală, a plăcuțelor de pe o poziție adiacentă pătratului liber. Plecând de la configurația (s) și procedând în modul descris, se obțin configurațiile A, B și C. Care dintre aceste trei alternative este mai promițătoare? Utilizarea *căutării exhaustive* este nepractică în cazul când configurația inițială este mult deosebită de cea finală. Decizia privind alegerea celei mai promițătoare alternative, evitând căutarea exhaustivă, necesită utilizarea unei *estimări* a eficienței căutării. În cazul jocului 8 există două euristici de estimare a proximității dintre două stări. Prima este numărul de plăcuțe incorect așezate prin care diferă două stări (configurații) și este notată h_1 . A doua este suma distanțelor (orizontale și verticale) dintre plăcuțele așezate diferit în două configurații și este notată cu h_2 . Pentru stările A, B, C din figură, proximitățile lor la starea soluție sunt:

$$h_1(A) = 2, h_1(B) = 3, h_1(C) = 4,$$

$$h_2(A) = 2, h_2(B) = 4, h_2(C) = 4.$$

Evident, ambele euristici decid că starea A este cea mai apropiată de soluție și, prin urmare, ea va fi explorată înaintea stărilor B și C.

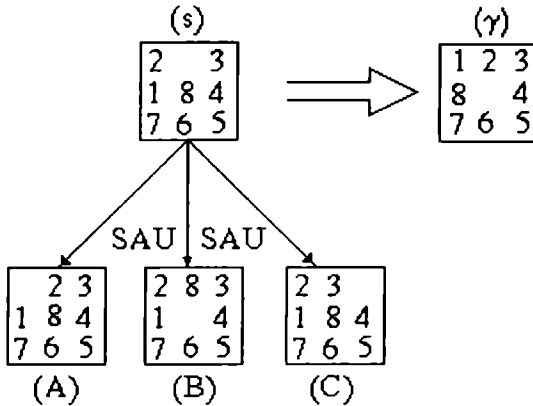


Fig. 1.16.

În cadrul încercării de motivare a raționalității alegerii euristici h_2 drepturistică admisibilă, se pot întâlni argumente cum sunt cele ce urmează:

1. Fie o soluție a problemei, nu neapărat optimă. Pentru a satisface condițiile stării soluție, fiecare plăcuță trebuie să parcurgă o traiectorie de la poziția inițială la cea finală, costul total al soluției (număr de pași) fiind suma costurilor traiectoriilor individuale. Orice traiectorie trebuie să conțină măcar atâția pași câți sunt dați de distanța h_2 (numită și *distanță Manhattan*) dintre configurația inițială și cea finală și, prin urmare, suma acestor distanțe nu poate depăși costul total al soluției.

2. Dacă este posibilă deplasarea fiecărei plăcuțe *independent* de celelalte, atunci se poate muta plăcuța 1 dealungul celei mai scurte traiectorii în poziția sa finală, apoi se poate proceda la fel cu plăcuța 2 și așa mai departe până la obținerea configurației soluției. În total sunt efectuați măcar atâția pași câți dă suma distanțelor. În consecință, suma acestor distanțe nu poate depăși costul total al soluției.

Primul argument este analitic. În cadrul său este selectată o proprietate ce trebuie satisfăcută de orice soluție astfel încât să fie asigurată o traiectorie a fiecărei plăcuțe către poziția ei finală. Deci se caută costul minimal ce satisface această proprietate. Al doilea argument are o natură operațională. El descrie o procedură pentru rezolvarea unei probleme auxiliare similare, în cadrul căreia regulile jocului au fost *relaxate* astfel încât plăcuțele pot fi așezate una peste alta. În locul căutării unei *funcții* $h(n)$ ce aproximează pe $h^*(n)$, se completează soluția obținută pe calea relaxării, se *numără* pașii necesari și numărul obținut se folosește drept o estimare a lui $h^*(n)$.

Această a doua schemă de căutare ilustrează modelul (paradigma) menționată în continuare: Euristicile sunt descoperite consultând modele simplificate ale domeniului problemei studiate.

1.2.3.1.2. Consistența euristicilor bazate pe relaxare

Este interesant de notat că euristicile generate de optimizări pe modele relaxate sunt garantate a fi *consistente* (sau monotone). Această proprietate este ușor de verificat după cum se vede din figura 1.17., unde $h(n)$ și $h(n')$ sunt euristicile atribuite respectiv nodurilor n și n' . Aceste euristici descriu costul minim al completării soluției din aceste noduri, în cadrul unui model relaxat comun ambelor noduri. Soluția optimă $h(n)$ trebuie să satisfacă condiția $h(n) \leq c'(n, n') + h(n')$, unde $c'(n, n')$ este costul relaxat al arcului (n, n') . Altfel $c'(n, n') + h(n')$ ar constitui, în locul lui $h(n)$, costul optimă al drumului din n . Costul relaxat $c'(n, n')$ nu poate depăși, prin definiție, costul original $c(n, n')$. Rezultă că:

$$h(n) \leq c(n, n') + h(n'),$$

care, împreună cu condiția tehnică $h(\text{nod soluție}) = 0$, completează condițiile de consistență (vezi 1.2.2.2.5.).




Fig. 1.17.

Această proprietate are implicații computaționale și psihologice. Din punct de vedere computațional, ea garantează că A^* , dirijat de euristicele unui model relaxat, va evita efortul de a redeschide noduri din *ÎNCHIS* și a redirecționa pointerii lor. Pointerii atribuiți oricărui nod expandat de algoritm sunt deja direcționați dealungul drumului optimal către acest nod.

Din punct de vedere psihologic, dacă se presupune că oamenii descoperă euristici pe calea consultării unui model relaxat, se poate explica faptul că majoritatea euristicilor elaborate sunt admisibile și consistente.

1.2.3.2. Generarea mecanică a euristicilor admisibile

1.2.3.2.1. Relaxarea sistematică

Eliminarea restricțiilor în cadrul relaxării poate fi sistematizată astfel încât euristicele naturale, cum sunt cele prezentate în paragraful 1.2.3.1.1., să fie generate în mod mecanic. Pentru aceasta este convenabilă reprezentarea domeniului problemei prin restricțiile ce guvernează aplicabilitatea și impactul diferitelor transformări în acest domeniu. Fie, de exemplu, jocul 8. Este total nepractic să se specifice mulțimea mutărilor legale cu ajutorul listei perechilor de stări, dinaintea și după efectuarea fiecărei mutări. O reprezentare mai naturală a jocului constă în specificarea mutărilor permise cu ajutorul a două mulțimi de condiții, o condiție fiind adevărată înaintea unei mutări și a doua după efectuarea acestei mutări. De exemplu, acțiunile pot fi reprezentate prin trei liste:

1. **Lista precondițiilor** - reprezentând conjuncția predicatelor adevărate înaintea efectuării unei acțiuni.
2. **Lista adăugare** - lista predicatelor ce trebuie adăugate în vederea descrierii mulțimii stărilor în urma aplicării unei acțiuni.
3. **Lista ștergere** - lista predicatelor ce nu mai sunt adevărate după ce o acțiune a fost aplicată și, în consecință, sunt eliminate.

În continuare această reprezentare este folosită în formalizarea schemei de relaxare pentru jocul 8.

Mai întâi se definesc trei predicate primitive:

$PE(x, y)$ - plăcuța x se află pe căsuța (locația) y ,

$LIBER(y)$ - căsuța y nu conține plăcuțe (e liberă),

$AD(y, z)$ - căsuța y este adiacentă cu căsuța z ,

unde variabila x reprezintă plăcuțele X_1, X_2, \dots, X_8 și variabilele y și z parcurg mulțimea locațiilor C_1, C_2, \dots, C_9 . Cu toate că predicatul *LIBER* poate fi definit în termeni de *PE*:

$$LIBER(y) \Leftrightarrow \forall x \sim PE(x, y),$$

unde \sim notează negația, este convenabil să se folosească acest predicat în mod explicit, drept un predicat independent. Folosind aceste primitive, orice stare este reprezentată printr-o listă de nouă predicate de forma:

$$PE(X_1, C_1), PE(X_2, C_2), \dots, PE(X_8, C_8), LIBER(C_9),$$

împreună cu descrierea tabelului:

$$AD(C_1, C_2), AD(C_1, C_4), \dots$$

Mișcarea corespunzătoare transferării plăcuței x din locația y în locația z este descrisă prin trei liste:

MUTĂ(x, y, z):

lista precondițiilor: $PE(x, y), LIBER(z), AD(y, z)$;

lista adăugare: $PE(x, z), LIBER(y)$;

lista ștergere: $PE(x, y), LIBER(z)$,

care descrie detaliile mutării plăcuței x din locația y în locația z . Problema constă în găsirea unei secvențe aplicabile de atribuire variabilelor din operatorul de bază *MUTĂ*(x, y, z), care să transforme starea inițială într-o stare care să satisfacă criteriile ce asigură o stare soluție.

În continuare se examinează efectul relaxării problemei pe calea eliminării condițiilor *LIBER*(z) și *AD*(y, z) din lista precondițiilor. Jocul rezultat permite deplasarea printr-o singură mișcare a unei plăcuțe de pe poziția curentă în poziția dorită. O problemă dată poate fi ușor rezolvată utilizând următoarea strategie de control. În orice stare, se alege o plăcuță neșezată pe locația dorită. Fie X_1 această plăcuță, Y_1 locația ei curentă și Z_1 locația dorită. Se aplică operatorul *MUTĂ*(X_1, Y_1, Z_1) și se repetă procedura stării următoare până când toate plăcuțele ajung să fie corect plasate, deci se obține soluția.

Este evident că numărul de mutări necesare pentru a rezolva o asemenea problemă este egal exact cu numărul de plăcuțe plasat greșit în configurația inițială. Dacă pentru rezolvarea acestei probleme se folosește un program de rezolvare mecanică (*mechanical problem-solver*) și se numără mutările necesare, se constată că soluția corespunde euristicii h_1 .

Să presupunem acum că se elimină doar condiția *LIBER*(z) pe când *AD*(y, z) se păstrează. Modelul rezultat permite mutarea oricărei plăcuțe într-o locație adiacentă, independent de faptul că această locație este ocupată. Rezultă euristica h_2 (*): suma distanțelor Manhattan.

O altă schimbare urmează în mod natural și constă în reținerea condiției *LIBER*(z) și eliminarea lui *AD*(y, z). Modelul obținut permite mutarea oricărei plăcuțe pe locația liberă, chiar dacă locațiile participante nu sunt vecine. Problema obținerii configurației soluție este echivalentă cu cea a sortării prin *interschimbare* a unei liste de elemente, adică schimbarea simultană a locațiilor a două elemente, fiecare pas trebuind să schimbe un element marcat *blank* cu un alt element. Soluția optimală a problemei sortării prin interschimbare se poate obține utilizând următorul algoritm de tip *Greedy*:

Algoritm 1.12. (*Jocul 8*)

1. [Mutare] Dacă locația curentă vidă y trebuie ocupată de plăcuța x , mută pe x în y . Altfel, adică dacă y trebuie să fie vidă în starea soluție, mută în y orice plăcuță necorect plasată.
2. [Ciclare] Dacă mai sunt plăcuțe necorect plasate repetă 1, altfel STOP. ■

Euristica h_3 obținută în modul descris mai sus este apropiată, ca eficiență, de euristica h_1 . Acest rezultat ilustrează faptul că metoda eliminării sistematice a precondițiilor este capabilă să genereze euristici netriviale.

În general, problemele rezultate prin eliminarea precondițiilor nu permit obținerea, întotdeauna, a unor soluții mai simple și uneori pot deveni mai dificile decât problema dată. Prin urmare, căutarea unui model în spațiul eliminărilor trebuie abordată cu precauție.

1.2.3.2.2. *Observații și concluzii*

Am prezentat o schemă naturală pentru a elabora euristici pentru probleme combinatoriale. Mai întâi, domeniul problemei este formulat în termeni de 'rei liste de operatori ce descriu transformarea stărilor din domeniu și condițiile ce definesc stările soluție. Apoi, precondițiile ce limitează aplicabilitatea operatorilor sunt parțial eliminate, generând un meta-spațiu de căutare a modelului relaxat obținut în modul descris. Căutarea începe ori pe modelul inițial, în care operanzii precondițiilor sunt eliminați câte unul, ori plecând de la un model trivial ce nu conține precondiții și căruia i se adaugă succesiv restricții. Modelul generat de un număr mai mic de restricții are proprietatea de *decompozabilitate*, în sensul că operatorii ce descriu evoluția modelului devin mai independenți între ei, fapt ce permite rezolvarea problemei studiate prin strategii de tip *Greedy*, fără *backtracking*.

Cu toate că efortul investit în căutarea unui model relaxat pare a fi dificil, el este de obicei răsplătit de eficiența algoritmului elaborat.

1.2.4. Euristici bazate pe probabilitate

Metodele probabiliste specifică o mulțime de configurații ale unui mediu împreună cu gradul lor de probabilitate. În problema comisvoiajorului, de exemplu, tabelul distanțelor dintre localități specifică o configurație a mediului pe care trebuie să îl parcurgă comisvoiajorul. Dacă, în loc să se specifice distanțele, sunt furnizate marginile inferioare și superioare între care se află fiecare distanță, atunci acest tabel de date definește o mulțime de probleme posibile. În sfârșit, dacă se specifică distribuțiile distanțelor dintre localități, devine posibilă determinarea faptului dacă o configurație este mai credibilă decât alta și cu cât mai mult credibilă. Cu alte cuvinte, distribuția cuantifică probabilitatea cu care se realizează configurațiile.

Este de remarcat faptul că oamenii își însușesc și invocă considerații probabiliste drept parte a codificării mintale a experiențelor lor. Astfel, în mod normal, un eveniment este apreciat ca fiind probabil dacă posedă particularități considerate *prototipice* unei populații largi.

Deoarece testul fundamental pentru succesul metodelor euristice constă în faptul că ele funcționează bine *de cele mai multe ori* și din cauză că teoria probabilităților este principalul formalism de cuantificare a noțiunii *de cele mai multe ori*, rezultă că modelele probabiliste pot furniza un fundament formal pentru evaluarea cantitativă a metodelor euristice. Mai mult, este de asemenea natural ca modelele probabiliste, atunci când sunt disponibile, să fie consultate în procesul elaborării metodelor euristice, ori în selectarea parametrilor care definesc aceste metode, astfel încât să se poată garanta că numai unei fracțiuni mici din variantele problemei studiate nu i se poate asigura o tratare adecvată.

1.2.4.1. Euristici bazate pe cel mai plauzibil rezultat

Metodele euristice sunt adesea bazate pe estimări ale valorilor necunoscute ale unor variabile. De exemplu, algoritmul A^* este ghidat de funcția h care estimează valoarea necunoscută a lui h^* , costul minimal de completare a unui drum soluție. Dacă domeniul problemei este caracterizat de un model probabilistic, uneori este posibil să se calculeze cea mai probabilă valoare a unei variabile necunoscute și să se utilizeze această valoare în construirea funcției euristice.

Fie, de exemplu, problema găsirii celui mai ieftin drum într-un graf în care toate costurile arcelor sunt extrase independent dintr-o funcție comună de distribuție cu valoarea medie μ . Dacă N este numărul de arce rămase între nodul n și nodul soluție, atunci pentru un N mare legea numerelor mari afirmă că pentru costul unui

drum soluție se poate lua o valoare în vecinătatea lui μN . Prin urmare, dacă este sigur că există doar un singur drum între n și nodul soluție, atunci valoarea μN poate fi acceptată drept o estimare a lui h^* și în A^* se poate utiliza funcția $f = g + \mu N$.

Prin natura lor, estimările bazate pe probabilitate nu sunt garantate ca fiind admisibile. Uneori aceste estimări pot depăși cu mult costul h^* și pot cauza încheierea prematură a lui A^* cu o soluție suboptimală. Pe de altă parte, dacă nu se caută întotdeauna o soluție optimală exactă și se acceptă găsirea cât mai frecvent a unei soluții *bune*, euristicele bazate pe probabilitate sunt perfect acceptabile.

1.2.4.2. Euristici bazate pe eșantionare

Eșantionarea este poate cea mai veche și cea mai des practică metodă euristică. Ea constă în deducerea unei proprietăți a unei mulțimi mari de elemente din proprietățile unei submulțimi de elemente, alese la întâmplare.

Fie, de exemplu, o bază de date imensă conținând N cifre binare pentru care trebuie calculată *proporția* cifrelor 1. Evident că răspunsul exact nu poate fi identificat decât dacă se inspectează toate cele N cifre, adică parcurgând N pași. Dacă însă se admite o eroare mică, este suficient un număr de pași funcție de eroarea acceptată. Este suficient să se aleagă la întâmplare n cifre și să se calculeze proporția de cifre egale cu 1. Pentru valori mari ale lui N , celebra teoremă a lui Bernoulli garantează că dacă proporția exactă este π și proporția eșantionării este γ , atunci abaterea dintre ele este mărginită de următoarea relație:

$$P(|\pi - \gamma| \geq \varepsilon) \leq 2 e^{-n\varepsilon^2/2}.$$

Rezultă că numărul de observații necesar pentru a garanta o probabilitate η suficient de mare astfel încât eroarea $|\pi - \gamma|$ să fie mai mică decât ε este dată de:

$$n = 2 / \varepsilon^2 \log (2 / (1 - \eta)).$$

Acest număr depinde numai de ε și η , nu și de N , astfel încât rezultă o reducere a efortului de calcul de la o valoare liniară, egală cu N în cazul parcurgerii integrale a mulțimii date de cifre, la o valoare constantă.

Mai mult, dacă N crește indefinit, se poate alege drept mărime a eșantionării orice funcție divergentă de N , $n = g(N)$, ceea ce garantează că abaterea dintre γ și π tinde către zero cu o probabilitate apropiată de 1, adică:

$$P(|\pi - \gamma| < \varepsilon) \rightarrow 1, \text{ pentru } \forall \varepsilon > 0.$$

În felul acesta, complexitatea se reduce de la N la $g(N)$, unde funcția $g(N)$ poate crește foarte încet, de exemplu ca $\log N$, $\log \log N$ sau chiar mai încet.

1.2.5. Modele abstracte pentru analiza cantitativă a performanței

1.2.5.1. Analiza matematică a performanței

Utilizarea unor modele abstracte în analiza performanței algoritmilor constituie o abordare naturală a acestei probleme în cadrul căreia se folosesc structuri simplificate, modele probabilistic abordabile, jocuri sintetice și alte tipuri de modele. Aplicabilitatea acestor investigații este limitată, evident, la acele probleme care au o structură similară cu modelele matematice elaborate, dar, ca și în cazul cercetărilor de laborator, ele sunt utile în identificarea factorilor care au o influență decisivă asupra analizei problemei studiate.

Modelele probabilistice sunt eficient aplicabile în studiul problemelor practice în care se urmărește optimizarea unei măsuri a performanței constând într-o combinație a calității soluției și efortul de căutare, *mediat* pe toate problemele *frecvent* întâlnite. Teoria probabilităților constituie un limbaj foarte potrivit pentru formalizarea descrierii acelor aspecte ale performanței ce urmează a fi ameliorate. În acest scop, se pleacă de la un model abstract simplificat, conținând un număr minim de parametri necesari pentru reprezentarea particularităților mai deosebite ale domeniului problemei, după care se analizează performanța diferiților algoritmi de căutare pe acest model ca funcție de parametrii modelului. Dacă drept rezultat al acestei analize, apare evident că valoarea unui anumit parametru are o influență mare asupra performanțelor metodei, acest parametru devine focarul atenției în eforturile empirice de caracterizare a domeniului problemei. Alternativ, dacă o metodă dată de căutare se dovedește a avea o performanță înaltă pentru un număr mare de parametri, această metodă devine un prim candidat în vederea testării pe diferite variante ale problemei.

1.2.5.2. Exemplul 1: Găsirea unui cel mai scurt drum într-o latică regulată

Punerea problemei. Fie graful latică infinit din figura 1.18., în care fiecare nod este identificat cu perechea de coordonate întregi (x, y) și fiecare arc are lungimea unitate. Trebuie găsit un cel mai scurt drum între nodul start $s = (0, 0)$ și nodul soluție $\gamma = (m, n)$ folosind distanța aeriană:

$$h(x, y) = \sqrt{(x - m)^2 + (y - n)^2},$$

drepturistică ghid. Se cere estimarea, pentru valori mari m și n , a numărului Z de noduri expandate de A^* , folosind următoarele funcții de evaluare:

- a) $f = g$,
- b) $f = g + h$,
- c) $f = h$. ■

Aplicații posibile: organizarea memoriilor bidimensionale.




Fig. 1.18.

Soluția. Funcția h este o euristică admisibilă și consistentă, deoarece este o geodezică în modelul relaxat în care orice deplasare este permisă în orice direcție. Prin urmare în toate nodurile expandate $g^* = g^*$. În plus, expresiile exacte pentru g^* și h^* sunt:

$$g^*(x, y) = |x| + |y|,$$

$$h^*(x, y) = |m - x| + |n - y|.$$

Prin urmare, presupunând că $m \geq 0, n \geq 0$, rezultă:

$$f^*(s) = f^*(0, 0) = m + n.$$

Cazul a): $f = g$.

Pentru $f = g$, algoritmul A^* devine un algoritm de căutare în lățime, în care fiecare nod ce satisface inegalitatea:

$$g^*(x, y) < f^*(s),$$

sau:

$$|x| + |y| < m + n,$$

va fi expandat. Mulțimea acestor noduri este circumscrisă de conturul pătrat din figura 1.19., a cărei arie are expresia:

$$I_a = 2(m + n)^2.$$

Deoarece densitatea nodurilor este unitară și frontiera poate conține cel mult $O(m+n)$ noduri, numărul de noduri Z_u expandate fără informația euristică este:

$$Z_u = 2(m+n)^2 + O(m+n). \quad (1.7)$$




Fig. 1.19.

Cazul b): $f = g + h$.

Mulțimea nodurilor expandate este inclusă în frontiera satisfăcând ecuația:

$$g(x, y) + h(x, y) = m + n,$$

sau:

$$|x| + |y| + \sqrt{(x-m)^2 + (y-n)^2} = m + n. \quad (1.8)$$

Forma frontierei este reprezentată de conturul interior din figura 1.19. Aria delimitată de acest contur poate fi determinată ca sumă a următoarelor patru componente:

1. $x \geq 0, y \geq 0$. Ecuația (1.8) devine:

$$2(m-x)(n-y) = 0,$$

care circumscrie dreptunghiul $0 \leq x \leq m, 0 \leq y \leq n$ de arie:

$$J_1 = m \cdot n.$$

2. $x \geq 0, y < 0$. Ecuația (1.8) devine:

$$4ny + 2(m-x)(n+y) = 0,$$

sau:

$$y = 2n^2 / (m + 2n - x) - n,$$

care include aria:

$$I_2 = - \int_0^m [2n^2 / (m + 2n - x) - n] dx = m n - 2n^2 \ln(1 + m / (2n)).$$

3. $x < 0, y \geq 0$. Acest caz este simetric cu cel precedent, valorile lui m și n schimbându-se între ele. Rezultă că:

$$I_3 = m n - 2m^2 \ln(1 + n / (2m)).$$

4. $x < 0, y < 0$. În acest caz $|x| = -x, |y| = -y$ și ecuația (1.8) devine:

$$4m x + 4n y + 2(m + x)(n + y) = 0,$$

sau:

$$y = 2(m + n)^2 / (m + 2n + x) - (n + 2m).$$

Rezultă că:

$$I_4 = - \int_{\frac{-mn}{n+2m}}^0 [2(m + n)^2 / (m + 2n + x) - (n + 2m)] dx =$$

$$= m n - 2(m + n)^2 \ln(1 + m n / (2(m+n)^2)).$$

Însumând cele patru arii se obține:

$$Z_b = 4mn - 2n^2 \ln(1+m/(2n)) - 2m^2 \ln(1+n/(2m)) - 2(m+n)^2 \ln(1+mn/(2(m+n)^2)). \quad (1.9)$$

Pentru cazul special $m = n$ din (1.9) rezultă că:

$$Z_b \approx 1.436 m^2,$$

ceea ce reprezintă 18% din numărul de noduri expandate prin căutarea în lă; ne (vezi (1.7)). Pentru $n = 0$, nodurile sunt situate pe axa x și numărul lor este mărginit de m . Figura 1.20. ilustrează performanța relativă Z_b / Z_a ca funcție de raportul n / m . Această curbă arată că euristica distanță aeriană asigură o eficiență mare pentru $m \ll n$, respectiv $n \ll m$, ținând seama de simetria funcțiilor Z_a și Z_b în m și n . Acest rezultat era de așteptat deoarece cea mai mică eroare relativă dintre distanța optimală h^* și distanța aeriană h este atinsă când punctul soluție este aproape de axe.




Fig. 1.20.

Cazul c): $f = h$.

Structura particulară a grafului problemei date arată că în acest caz se poate obține un drum optimal, expandând numai $m + n$ noduri situate pe acest drum optimal. Motivul acestei eficiențe constă în faptul că orice nod are un fiu pe drumul optimal către nodul soluție pentru care valoarea lui h este strict mai mică decât valoarea corespunzătoare nodului tată. Deoarece nodul tată avea o valoare h minimă în *DESCHIS*, rezultă că și fiul va avea o valoare minimă a lui h și va fi imediat selectat, fără ca algoritmul să intre în *backtracking*.

O motivare de natură geometrică a afirmației precedente se poate deduce urmărind modul de generare al unui drum optimal pe graful din figura 1.18., în care $m > 0$, $n > 0$. Fie dreptunghiul definit de punctele O , γ , $(0, n)$ și $(m, 0)$. Orice încercare de a trasa un drum optimal printr-un punct exterior acestui dreptunghi eșuează, deoarece distanța h a acestui punct la γ este sigur mai mare decât distanța la γ a nodului său tată, situat pe conturul dreptunghiului. De asemenea, orice drum al cărui ultim arc are un sens invers axei x , respectiv y , nu poate fi optimal. Rezultă că un drum optimal nu poate cuprinde decât arce orientate în sensurile pozitive ale axelor și nu trece prin noduri din afara dreptunghiului, deci are lungimea $m + n$.

Sumar. Acest exemplu demonstrează mai multe particularități ale algoritmului A^* dintre care semnalăm următoarele.

1. Cea mai mare parte a nodurilor expandate se află pe drumuri optimale. În exemplul precedent, toate $m \cdot n$ noduri situate în dreptunghiul $0 \leq x \leq m$, $0 \leq y \leq n$ sunt situate pe drumuri optimale și sunt expandate de A^* chiar dacă funcția empirică ajunge aproape perfectă. Dacă graful conține mai multe drumuri aproape optimale, A^* le explorează complet înainte de terminare. Metode de evitare a acestui dezavantaj al algoritmului A^* au fost prezentate în paragraful 1.2.2.3.
2. Luând $f = h$ se poate asigura ocazional o căutare mai eficientă decât cu $f = g + h$. În general însă, în acest caz rezultă soluții suboptimale și, mai semnificativ, pot exista forme ale lui h care cresc efortul de căutare sau împiedică încheierea algoritmului A^* . De exemplu, dacă în exemplul precedent se utilizează euristica:

$$h_1 = \begin{cases} \sqrt{(m-x)^2 + (n-y)^2}, & \text{pentru } y \neq y_0 \\ 0, & \text{pentru } y = y_0, y_0 < n, \end{cases}$$

atunci A^* nu se încheie niciodată cu $f = h_1$, deoarece are loc expandarea continuă a nodurilor de pe drumul $y = y_0$.

1.2.5.3. Exemplul 2: Găsirea unui cel mai scurt drum într-o rețea de orașe distribuite la întâmplare

Punerea problemei. Fie o hartă de drumuri caracterizată printr-o rețea densă de orașe, distribuite la întâmplare cu o densitate ρ pe unitatea de suprafață. Se cere să se estimeze complexitatea identificării unui cel mai scurt traseu între orașul start s , situat în originea $(0, 0)$ și orașul destinație γ situat în punctul $(0, c)$, utilizând algoritmul A^* și aplicând euristica distanței aeriene. ■

Aplicații posibile: turism, aviație, marină.

Soluția. Fie $k(n_1, n_2)$ distanța minimă dintre orașele n_1 și n_2 și $d(n_1, n_2)$ distanța aeriană dintre ele. În particular:

$$d(s, \gamma) = h(s) = c,$$

$$k(s, \gamma) = h^*(s) = a.$$

Raportul c / a măsoară acuratețea estimării distanței start-destinație și poate fi, în general, o funcție de ρ și c . Mărimea problemei depinde de asemenea de ρ și de c . Căutarea în lățime expandează, estimativ, toate cele $M = \rho\pi c^2$ noduri situate în cercul de rază c cu centrul în s și de aceea acest număr este ales drept standard în evaluarea euristicii distanță aeriană. Mai precis, eficiența selectării η_h a lui $h(\bullet)$ este definită drept raport între numărul de noduri expandat cu și fără utilizarea lui $h(\bullet)$, adică:

$$\eta_h = M / Z_h = \rho\pi c^2 / Z_h, \tag{1.10}$$

unde Z_h este numărul de noduri expandate de A^* utilizând pe h . Problema de rezolvat constă în calculul lui η_h ca funcție de mărimea M și acuratețea parametrului c / a .

Condiția necesară pentru ca A^* să expandeze un nod n implică faptul că (vezi teorema 1.27.) numai nodurile satisfăcând condiția:

$$g^*(n) + h(n) \leq f^*(s) = a \tag{1.11}$$

sunt candidați pentru expandare. Deoarece $h(n)$ este egală cu distanța $d(n, \gamma)$ și $g^*(n)$ este margine superioară pentru $d(s, n)$, orice nod ce satisface (1.11) trebuie să satisfacă de asemenea condiția:

$$d(s, n) + d(n, \gamma) \leq a. \tag{1.12}$$

Inegalitatea (1.12) definește o elipsă cu focarele s și γ și axele a și $\sqrt{a^2 - c^2}$. Aria acestei elipse este egală cu $\pi a \sqrt{a^2 - c^2} / 4$ și, deoarece fiecare nod din afara elipsei este exclus de la expandare, se poate deduce marginea superioară a numărului de noduri expandate:

$$Z_h \leq \rho \pi a \sqrt{a^2 - c^2} / 4. \tag{1.13}$$

Atunci când acuratețea c a distanței aeriene crește, eroarea $a - c$ scade, excentricitatea elipsei crește și o fracțiune mare de noduri nu este expandată. Raportul dintre artele elipsei și cercului (vezi figura 1.21.) definește eficiența căutării funcției h . În figura 1.21., cercul R delimitează regiunea în care nodurile sunt până la urmă expandate de căutarea în lățime. Orice nod din afara elipsei E este sigur neexpandat de A^* . Conturul C_1 conține acele noduri care sunt sigur expandate de A^* .

Definind:

$$\alpha = (a / c) - 1,$$

din ecuațiile (1.10) și (1.13) rezultă:

$$\eta_h \geq 4 / [(1 + \alpha) \alpha^{1/2} (2 + \alpha)^{1/2}] \quad (1.14)$$

și, presupunând că $\alpha \ll 1$, rezultă că o fracțiune de cel mult $(\alpha / 8)^{1/2}$ de noduri expandate de căutarea în lățime este de asemenea expandată de A^* .




Fig. 1.21.

Deoarece harta drumurilor a fost presupusă omogenă, este de asemenea rezonabil să se presupună că raportul a / c rămâne constant pentru distanțe mari. Prin urmare, marginea inferioară (1.14) rămâne un factor constant indiferent de cât de departe este γ de s .

Pentru a arăta că η_k este de asemenea superior mărginită, este necesară acceptarea unor presupuneri privind regularitatea interconectărilor în harta drumurilor. Mai întâi se presupune că, în afara unei mulțimi de noduri de măsură nulă, estimarea relativă a erorii X este mărginită deasupra lui zero, adică:

$$X(n) = k(s, n) / d(s, n) - 1 \geq \beta > 0.$$

Cu această presupunere se poate utiliza condiția suficientă de expansiune (vezi teorema 1.35.):

$$g^*(n) + h(n) < a \tag{1.15}$$

și conchide că toate nodurile ce satisfac condiția:

$$(1 + \beta) d(s, n) + d(n, \gamma) < (1 + \alpha) d(s, \gamma) \tag{1.16}$$

vor fi expandate. Aici s-a făcut caz și de consistența lui h , care face ca ecuația (1.15) să fie aplicabilă tuturor nodurilor, nu neapărat celor din *DESCHIS*. Inegalitatea (1.16) definește conturul C_1 din figura 1.21., ce conține toate nodurile care sunt sigur expandate.

Mai general, probabilitatea P ca un nod situat în afara lui C_1 să fie expandat de A^* este egală cu probabilitatea ca $X(n)$ să satisfacă inegalitatea:

$$(1 + X(n)) d(s, n) + d(n, \gamma) < (1 + \alpha) d(s, \gamma).$$

Rezultă că, dacă $X(n)$ este caracterizată de o singură funcție de distribuție $F_X(x)$, conturul isoprobabilitate ce conectează toate punctele de probabilitate P este definit de ecuația:

$$(1 + F_X^{-1}(P)) d(s, n) + d(n, \gamma) = (1 + \alpha) d(s, \gamma).$$




Fig. 1.22.

Unele dintre aceste contururi sunt arătate pe figura 1.22. De notat faptul că ramurile de căutare sunt mai concentrate în vecinătatea nodului soluție, indicând că A^* contribuie cu mai mult efort în jurul nodului start, unde acuratețea lui $h(\bullet)$ relativ la mărimea lui g este mai redusă.

Nodurile din interiorul conturului C_1 (figura 1.21.) sunt sigur expandate și, deoarece aria mărginită de C_1 este proporțională cu a^2 , rezultă că eficiența selectării η_h obținută prin utilizarea euristicii distanță aeriană este cel mult o constantă multiplicativă. Cu alte cuvinte, dacă N este numărul de noduri dealungul unui drum optimal ($N \approx \rho^{1/2} a$) atunci, pentru un ρ dat, complexitatea lui A^* rămâne de ordinul

$\Theta(N^2)$. Se poate de asemenea argumenta că, în cazul în care densitatea ρ crește, nu există o garanție a creșterii acurateții lui h cât timp nu se formulează ipoteze adiționale privind statisticile ce corelează distanțele cu conexiunile drumurilor.

1.2.5.4. Exemplul 3: Căutarea unui drum optim într-un arbore cu costuri aleatoare

Punerea problemei. Se cere să se găsească un cel mai ieftin drum din rădăcina unui arbore către oricare dintre frunzele sale. Arborele este binar și de înălțime N . Fiecare ramură poate avea costul 1 sau 0 cu probabilitatea p sau $1-p$. ■

Aplicații posibile: sisteme distribuite, energetică, telefonie.

Sunt folosite două metode de căutare. Prima este de tip *cost uniform* (vezi paragraful 1.2.2.3.) și nu folosește euristici privind partea neexplorată a arborelui de căutare. A doua constituie o căutare în etape și constă în folosirea periodică a informației în vederea eliminării acelor noduri *rele*, care nu au o performanță în acord cu așteptările.

Enunțul problemei definește o căutare ce urmează a fi executată pe o mulțime de *variante*. În fiecare variantă a problemei, trebuie găsit un cel mai ieftin drum către un nod terminal într-un arbore T , din spațiul de variante $T(N, p)$, conținând arbori binari uniformi de înălțime N cu arce de cost 0 sau 1. Probabilitatea ca un arbore T , având o anumită asignare a costurilor, să facă parte din $T(N, p)$ este egală cu $p^{N_1}(1-p)^{N_0}$ unde N_1 și N_0 sunt respectiv numerele de arce din T de cost 1 și 0 și $N_1 + N_0 = 2^{N+1} - 2$.

Un nod J din arbore are *costul* c dacă c este suma costurilor arcelor de pe drumul din rădăcină la nodul J . Un interes special în cadrul problemei studiate îl au costurile frunzelor (nodurilor terminale) și în special costul celei mai ieftine frunze, care urmează să fie identificată. Fie variabila aleatoare $C(N, p)$ descriind *numărul minim de 1* de pe un drum rădăcină - frunză într-un arbore T din mulțimea $T(N, p)$. După cum se va vedea mai departe, distribuția $C(N, p)$ variază în mod semnificativ cu p și are caracteristici diferite în următoarele trei regiuni: $p < 1/2$, $p = 1/2$ și $p > 1/2$. Mai mult, natura acestei distribuții decide care algoritm este mai potrivit pentru căutare. Din acest motiv aceste trei regiuni sunt analizate separat.

Un nod J' este un *fiu* (α, L) al nodului J dacă au loc următoarele condiții:

1. J' este situat cu L nivele mai jos decât J .
2. Costul drumului de la J la J' nu depășește pe αL .

O familie de t fii succesivi (α, L) reprezintă un drum în T ce constă din t segmente consecutive, fiecare de cost cel mult αL . Un asemenea drum se numește *drum regulat* (α, L) și familii de asemenea drumuri se numesc *familii regulate* (α, L) . Pentru simplificarea notației, un drum încheiat la un nod frunză se numește tot *regulat* (α, L) , chiar dacă ultimul său segment conține mai puțin de L noduri și costul său este cel mult αL . Evident că orice drum rădăcină - frunză care este un drum regulat (α, L) nu poate avea un cost mai mare decât $\alpha(N + L)$.

În continuare este prezentată analiza a doi algoritmi de căutare A_1 și A_2 . A_1 este un algoritm de cost uniform și este analizat pentru cazurile: $p < 1/2$ și $p = 1/2$. A_2 este un algoritm hibrid de căutare locală și globală în adâncime și este analizat pentru $p > 1/2$.

Ambii algoritmi încep de la un subarbore conținând rădăcina lui T și, ca pas general, expandează un nod de pe frontiera subarborului. Expanderea unui nod J constă în crearea a doi urmași și a arcelor de la J la acești urmași.

Algoritmul A_1 . La fiecare pas, se expandează cel mai din stânga nod dintre nodurile frontieră de cost minim. Algoritmul se încheie când se încearcă expanderea unei frunze a lui T . Această frunză reprezintă o soluție optimală.

Algoritmul A_2 . Se efectuează o căutare în adâncime în vederea găsirii unui drum regulat (α, L) de la un nod de nivel d la o frunză, unde d , α și L sunt trei parametri exteriori aleși. Cu alte cuvinte, A_2 este o strategie de căutare în adâncime care se oprește la intervale de L nivele în vederea aprecierii progresării căutării. Dacă creșterea costului după ultima apreciere este de cel mult αL , căutarea continuă; în cazul când creșterea costului este mai mare decât αL , nodul curent este eliminat, programul efectuează un *backtracking* la un nivel mai înalt și căutarea este reluată. Dacă este identificat un drum regulat (α, L) , A_2 furnizează acest drum drept soluție, costul ei fiind cel mult $d + \alpha(N - d + L)$. Dacă are loc o eșuare, căutarea este reluată de la alt nod de nivel d . Dacă toate 2^d noduri de la nivelul d eșuează să devină rădăcină a unui drum regulat (α, L) către o frunză, A_2 se încheie cu un eșec. Probabilitatea unui eșec poate fi totuși făcută foarte mică pe calea alegerii convenabile a parametrilor d , α și L .

Schema căutării este arătată în figura 1.23. și constă din două componente:

1. Căutarea locală în adâncime, cu marginea adâncimii L , a unor fii (α, L) .
2. Căutarea globală în adâncime a membrilor familiei (α, L) , căutând un drum ce atinge nivelul N .

Analiza probabilistă a algoritmului A_2 arată (vezi mai jos teorema 1.39.) că, pentru $p > 1/2$ și valori N mari, costul optimal $C(n, p)$ este foarte apropiat de $\alpha^* N$, unde α^* este o constantă dată de p . În cazul când se caută o soluție aproape optimală,




Fig. 1.23.

căutarea poate fi încheiată de îndată ce s-a găsit o frunză cu cost sub αN ($\alpha > \alpha^*$), unde α este ales suficient de aproape de α^* . Din fericire, există mai multe frunze cu costuri între $\alpha^* N$ și αN , așa încât căutarea poate fi limitată la o submulțime de asemenea frunze, ușor de identificat. O alegere convenabilă o constituie mulțimea frunzelor accesibile pe drumuri regulate (α, L) , dealungul cărora costul crește cu nu mai mult decât αL , pe fiecare segment succesiv de lungime L . Asemenea drumuri constituie obiective convenabile deoarece violările condiției de creștere gradată a costului, spre deosebire de violările condițiilor impuse costului total al drumului, sunt detectabile printr-o analiză locală. Într-adevăr, după cum se va vedea mai departe (vezi teorema 1.42.) algoritmul A_2 are o complexitate temporară liniară în medie și, dacă parametrii d și L sunt convenabil aleși, atunci A_2 identifică o soluție aproape optimală cu o probabilitate apropiată de unu.

1.2.5.4.1. Rezultate

Proprietățile esențiale ale algoritmilor A_1 și A_2 sunt sintetizate în continuare.

Teorema 1.37. [PEA84] Dacă $p < 1/2$, atunci:

$$P[C(N, p) > k] \leq (2p)^{2^{k+1}-2}, \text{ pentru } k = -1, 0, 1, \dots \blacksquare$$

Prin urmare costul optimal este aproape sigur mărginit atunci când $N \rightarrow \infty$.

Teorema 1.38. Dacă $p = 1/2$, atunci pentru orice funcție H monotonă și mărginită are loc:

$$P[|C(N, 1/2) - \log_2 \log_2 M| > H(N)] \rightarrow 0. \blacksquare$$

Aceasta implică faptul următor: costul optimal tinde către $\log_2 \log_2 N$.

Teorema 1.39. Fie $p > 1/2$ și $G(\alpha, p) = \left(\frac{p}{\alpha}\right)^\alpha \left(\frac{1-p}{1-\alpha}\right)^{1-\alpha}$. Fie α^* mărimea definită de ecuația $G(\alpha^*, p) = 1/2$.

Pentru $\alpha < \alpha^*$:

$$P[C(N, p) \leq \alpha N] = O(c_\alpha^{-N}) \text{ cu } c_\alpha > 1.$$

Pentru $\alpha > \alpha^*$:

$$P[C(N, p) \geq \alpha N] = O(d_\alpha^{-N}) \text{ cu } d_\alpha > 1. \blacksquare$$

Această teoremă stabilește proprietățile: costul optimal crește proporțional cu N și factorul de proporționalitate este apropiat de α^* cu o probabilitate ridicată.

Fie variabilele aleatoare $t_1(N, p)$ și $t_2(N, p)$ descriind numărul de noduri expandate respectiv de algoritmi A_1 și A_2 pe un arbore T din mulțimea $T(N, p)$.

Teorema 1.40. Dacă $p < 1/2$, atunci $E[t_1(N, p)] = O(N)$, adică A_1 găsește o frunză de cost optimal într-un timp mediu liniar. ■

Teorema 1.41. Dacă $p = 1/2$, atunci $E[t_1(N, 1/2)] = O(N^2)$, adică A_1 găsește o frunză de cost optimal într-un timp mediu pătratic. ■

Teorema 1.42. Dacă $p > 1/2$, atunci orice algoritm ce garantează găsirea unui drum mai ieftin decât $(1 + \varepsilon) C(N, p)$ operează în timp exponențial. Totuși, pentru orice $\varepsilon > 0$, parametrii d și L pot fi aleși astfel încât algoritmul A_2 găsește o soluție de cost cel mult $(1 + \varepsilon) C(N, p)$ cu o probabilitate apropiată de 1 și operează în timp mediu liniar, adică $E[t_2(N, p)] = O(N)$. ■

Observație. Algoritmul A_1 este o variantă a căutării în lățime, cu deosebirea că în locul parcurgerii nodurilor de aceeași adâncime, căutarea se efectuează pe nivele de noduri de cost egal a drumurilor ce le conectează cu rădăcina.

1.2.6. Complexitatea și precizia euristiciilor admisibile

1.2.6.1. Euristiciile interpretate drept surse de informație perturbate

1.2.6.1.1. Modelele simplificate - surse de semnale perturbate

Metodele euristice se bazează, de obicei, pe modele simplificate ale problemelor studiate. Este deci natural să se accepte că utilizarea unei euristici depinde de proximitatea dintre model și problema reală studiată. Algoritmul A^* este un model convenabil pentru studiul acestei relații în termeni cantitativi, deoarece atât scopul său, minimizarea costului, cât și euristica sa pot fi exprimate cantitativ. În acest scop, euristiciile sunt interpretate drept surse de informații perturbate care generează în fiecare

nod al grafului de căutare informația $h(n)$, în locul informației corecte $h^*(n)$. Din acest motiv, diferența $h - h^*$ este interpretată drept *eroare* asociată cu funcția euristică h .

1.2.6.1.2. *Un model probabilistic pentru analiza performanței unei euristici*

În paragraful 1.2.5.3. a fost prezentată analiza performanței medii a euristicii distanță aeriană, presupunând că nodurile sunt distribuite aleator și uniform în spațiul euclidian definit de funcția euristică h . Cu alte cuvinte, se consideră că h și g definesc o mulțime de coordonate și se presupune că topologia grafului localităților variază aleator, în conformitate cu regularitatea dir. rețelele tipice de localități.

În multe cazuri, nu este accesibilă formularea unei interpretări fizice atât de clare a euristicii h . Drept consecință, poate fi mult mai convenabil să se construiască un model probabilistic dintr-un sens opus și anume: acceptarea topologiei grafului de căutare drept o entitate dată și tratarea funcțiilor $h(n)$ drept variabile aleatoare distribuite întâmplător în nodurile grafului, dar corelate într-un anumit grad cu distanțele actuale $h^*(n)$.

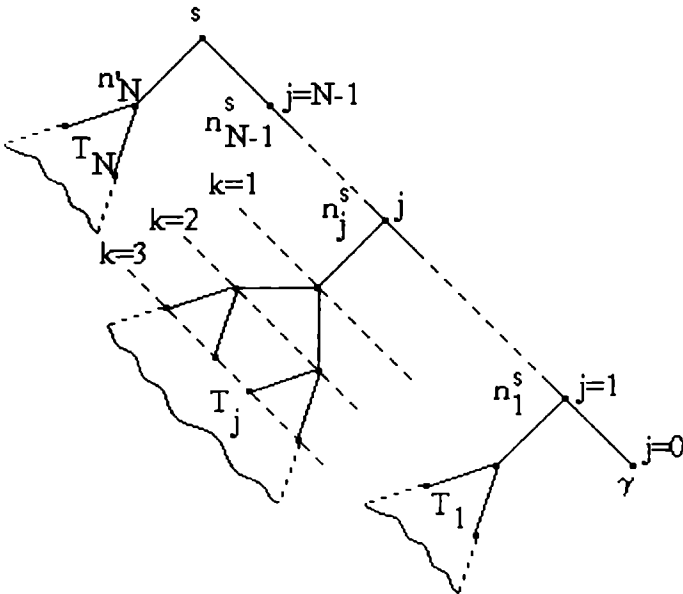


Fig. 1.24.

În acest scop, spațiul căutărilor este modelat printr-un arbore T nedirecționat, cu gradul nodurilor egal cu b , având un unic nod start s și un unic nod soluție γ , situat la distanța N de s . Arborele poate fi finit, de adâncime N , sau infinit, fiecare arc având

un cost simetric unitar. Un arbore de căutare tipic este arătat în figura 1.24., unde, fără a restrânge generalitatea, drumul soluție $(s, n_{N-1}^s, \dots, n_j^s, \dots, n_1^s, \gamma)$ este reprezentat în dreapta. Arborii $T_1, \dots, T_j, \dots, T_N$ sunt subarbori ai lui T , cu rădăcini pe drumul soluție. Fiecare subarbore T_j este identificat prin rădăcina sa n_j^s de pe drumul soluție, unde n_j^s este singurul nod din T_j ce are $b - 1$ urmași.

Identificarea nodului γ se efectuează folosind următoarea variantă a algoritmului A^* pentru căutarea pe arbori.

Algoritmul 1.13. (A^* pentru arbori)

1. [Inițializări] Se marchează s ca aparținând lui *DESCHIS* și se calculează $f(s)$.
2. [Alegere nod] Se caută un nod n în *DESCHIS* cu valoare minimală a lui f ; în cazul mai multor valori egale ale lui f , alegerea nodului căutat este arbitrară.
3. [Terminare] Dacă n este nodul soluție γ , atunci STOP.
4. [Modificări și ciclare] Se marchează n ca aparținând lui *ÎNCHIS* și se calculează $f(n'_i)$ pentru fiecare fiu n'_i al lui n . Se marchează fiecare asemenea nod n'_i care nu se află în *ÎNCHIS* sau pentru care $f(n'_i)$ este mai bună ca aparținând lui *DESCHIS*. Se trece la pasul 2. ■

Algoritmul A^* caută nodul soluție fără a ști locația sa și nici distanța N , dar este ghidat de funcția euristică $h(n)$ care estimează distanța oricărui nod la nodul soluție. Deoarece toate arcele se presupun de cost unitar, funcția f este definită de:

$$f(n) = g(n) + h(n),$$

unde $g(n)$ este adâncimea lui n și $h(n)$ este estimarea euristică a lui $h^*(n)$, adică numărul de arce ce separă pe n de γ . Se mai presupune că funcția $h(n)$ este admisibilă, adică $h(n) \leq h^*(n)$, pentru orice n , fapt ce garantează că nodurile de adâncime mai mare decât N nu vor fi expandate.

Modelul probabilistic descris presupune că fiecare $h(n)$ poate fi tratată ca o variabilă aleatoare cu valori în $[0, h^*(n)]$ și caracterizată prin funcția de distribuție:

$$F_{h(n)}(x) = P[h(n) \leq x].$$

Fiind dată o caracterizare a funcțiilor de distribuție $F_{h(n)}(x)$, problema de rezolvat constă în cercetarea modului în care aceste funcții influențează relația dintre $E(Z)$, numărul mediu de noduri expandate de A^* , și lungimea N a drumului soluție, tratată ca parametru ce definește dificultatea problemei.

↳ Procesul de expandare este structurat sub forma arborelui din figura 1.25. Numărul de succesori dintr-o generație $d + 1 > 1$ este egal cu suma descendenților tuturor părinților de la nivelul $d - 1$. Prin urmare, mărimea w_{d+1} a generației $d + 1$ este

suma a w_d variabile aleatoare $X_{i,d}$, $1 \leq i \leq w_d$ reprezentând numărul de fii fertili ai generației $d + 1$, adică:

$$w_{d+1} = X_{1,d} + \dots + X_{i,d} + \dots + X_{w_d,d}.$$




Fig. 1.25.

Presupunând că $X_{i,d}$ și w_d sunt independente, rezultă că media variabilei w_{d+1} este definită de produsul:

$$\bar{w}_{d+1} = E(w_{d+1}) = E(w_d) E(X_{i,d}) = \bar{w}_d E(X_{i,d}).$$

Dacă se notează cu q_d probabilitatea supraviețuirii unui descendent oarecare al generației d , atunci:

$$E(X_{i,d}) = q_d c_d,$$

unde c_d este numărul de descendenți ai generației d ce nu fac parte din drumul soluție.

Observând că $c_1 = b - 1$ și $c_d = b$, pentru $d > 1$, rezultă:

$$E(X_{i,d}) = \begin{cases} (b-1)q_1, & \text{pentru } d=1, \\ bq_d, & \text{pentru } d \geq 2. \end{cases}$$

Ținând seama de expresiile lui \bar{w}_{d+1} și $E(X_{i,d})$ și de faptul că $E(w_0) = \bar{w}_0 = 1$ deoarece generația 0 are cu certitudine un singur descendent, se obține:

$$\bar{w}_1 = (b-1)q_1, \bar{w}_0 = (b-1)q_1, \bar{w}_2 = b q_2 \bar{w}_1, \bar{w}_3 = b q_3 \bar{w}_2, \dots, \bar{w}_d = b q_d \bar{w}_{d-1}.$$

Urmărind șirul precedent se obține succesiv:

$$\bar{w}_d = b q_d b q_{d-1} \dots b q_2 (b-1) q_1 = (b-1) b^{d-1} q_d q_{d-1} \dots q_2 q_1 = \frac{b-1}{b} b^d \prod_{k=1}^d q_k.$$

Numărul mediu al nodurilor expandate de A^* trebuie calculat aplicând analiza precedentă tuturor subarborilor din afara drumului soluție din figura 1.26. Numărul mediu de noduri expandate la adâncimea $d \geq 1$ a unui subarbor T_j este dat de produsul:

$$(b-1) b^{d-1} q_{j,d} q_{j,d-1} \dots q_{j,1},$$

unde $q_{j,k}$ reprezintă probabilitatea ca un nod $n_{j,k}$ de adâncime k în T_j să fie expandat o dată intrat în *DESCHIS*, adică:

$$P[f(n_{j,k}) \leq N] \geq q_{j,k} \geq P[f(n_{j,k}) \leq N - 1]. \quad (1.17)$$

Însumând produsele de mai sus pentru toate nivelele d și toți subarborii respectivi și adăugând și cele N noduri expandate dealungul drumului soluție se obține expresia numărului mediu de noduri expandate:

$$E(Z) = N + \frac{b-1}{b} \sum_{j=1}^N \sum_{d=1}^{\infty} b^d \prod_{k=1}^d q_{j,k}, \quad (1.18)$$

unde $q_{j,k}$ este mărginit conform relației (1.17). Ținând seamă de presupunerea că funcția $h(n)$ este admisibilă, deci că nodurile de adâncime mai mare decât N nu sunt expandate, rezultă că adâncimea maximă a inspectării subarborelui T_j (vezi figura 1.24.) nu depășește adâncimea sa care este egală cu j , deci sumarea după d în (1.18) poate fi efectuată în intervalul $1 \leq d \leq j$. Rezultă o formă alternativă a lui $E(Z)$ și anume:

$$E(Z) = N + \frac{b-1}{b} \sum_{j=1}^N \sum_{d=1}^j b^d \prod_{k=1}^d q_{j,k}.$$

1.2.6.2. Dominanța stohastică pentru euristici admisibile aleatoare

Problema deciderii faptului că o euristică este mai bună decât alta se pune destul de frecvent. Este evident că, dacă o euristică asigură o estimare mai precisă a lui h^* , ea este preferată. Aceasta este ideea teoremei 1.30. care stabilește că, dacă pentru fiecare nod nonsoluție al grafului de căutare $h_1(n) < h_2(n)$ și ambele euristici sunt admisibile, atunci orice nod expandat de A_2^* este expandat de asemenea și de A_1^* , deci euristica $h_2(n)$ este preferabilă. Totuși sunt rare cazurile când se dispune de o cunoaștere *a priori* suficientă, ceea ce garantează că $h_1(n) < h_2(n)$ are loc pentru orice nod al arborelui de căutare. Chiar atunci când acuratețea mai bună a lui h_2 este rezultatul utilizării unor proceduri de calcul mai sofisticate decât ale lui h_1 , îmbunătățirea este rar garantată a avea loc în fiecare nod al spațiului problemei. În general, atunci când $h(n)$ este mai exactă pentru unele noduri, ea poate deveni mai puțin exactă pentru altele. Este natural atunci să se pună problema identificării condițiilor în care inegalitatea $h_1 < h_2$ este rezonabil probabilă, dar nesatisfăcătoare ocazional. Formalizarea acestei probleme este prezentată în continuare:

Definiția 1.10. Fiind date două variabile aleatoare X_1 și X_2 , se zice că X_2 este *sturistic mai mare* decât X_1 , proprietate notată $X_1 \tilde{<} X_2$, dacă și numai dacă:

$$P(X_2 > x) \geq P(X_1 > x), \text{ pentru orice } x \in R,$$

sau, echivalent:

$$F_{X_1}(x) \geq F_{X_2}(x), \text{ pentru orice } x \in R. \blacksquare$$

Definiția 1.11. Fie A_1^* și A_2^* doi algoritmi ce folosesc respectiv funcțiile h_1 și h_2 . A_2^* este *mai mult informat stohastic* decât A_1^* dacă și numai dacă $h_1(n) \tilde{<} h_2(n)$, pentru

orice $n \in T$. Similar, A_2^* se consideră a fi *stochastic mai eficient decât* A_1^* dacă și numai dacă $Z_2 \tilde{<} Z_1$, unde Z_1 și Z_2 sunt numerele de noduri expandate de A_1^* , respectiv, A_2^* . ■

Examinarea relațiilor (1.17) și (1.18) arată că, dacă pentru fiecare nod n , $h_2(n)$ este mai mare decât $h_1(n)$, atunci h_2 introduce o valoare $E(Z)$ mai mică. Aceasta se datorește faptului că fiecare $q_{j,k}$ în cazul lui h_2 este mai mic sau cel mult egal cu factorul corespunzător din h_1 . Totuși, se poate demonstra o proprietate mai tare și anume: $h_1(n) \tilde{<} h_2(n)$ implică nu numai preferința în medie ci și *preferința stochastică*.

Teorema 1.43. Pentru orice distribuție de erori, dacă A_2^* este stochastic mai informat decât A_1^* , atunci A_2^* este stochastic mai eficient decât A_1^* .

Demonstrație. Fiind dată o mulțime de variabile aleatoare independente, ordinea $\tilde{<}$ este conservată de adunarea pe această mulțime. Cu alte cuvinte, dacă X_1, Y_1, X_2 și Y_2 sunt mutual independente, atunci $X_1 \tilde{<} X_2$ și $Y_1 \tilde{<} Y_2$ implică $X_1 + Y_1 \tilde{<} X_2 + Y_2$. Fie $Z_1(n)$ și $Z_2(n)$ numerele de noduri expandate de A_1^* , respectiv, A_2^* în sub-arborii de rădăcină n . Se poate demonstra că $Z_2(s) \tilde{<} Z_1(s)$. Echivalent, deoarece numerele de noduri expandate în arborii T_j (vezi figura 1.24.) sunt independente, folosind proprietatea de conservare a adunării pentru variabile aleatoare independente, este suficient să se arate că $Z_2(n'_j) \tilde{<} Z_1(n'_j)$ pentru un arbore arbitrar T_j . Fie n orice nod la adâncimea d a arborelui; este suficient să se arate că $Z_2(n) \tilde{<} Z_1(n)$, pentru orice asemenea n . Demonstrația se efectuează pe calea inducției după d , de jos în sus.

Pentru valori suficient de mari ale lui d afirmația este adevărată deoarece $Z_2(n) = Z_1(n) = 0$, pentru toate nodurile n de la nivelul d . Presupunând că $Z_2(n) \tilde{<} Z_1(n)$, pentru toate nodurile n de la nivelul d , rămâne de arătat că relația precedentă are loc și pentru toate nodurile n de la nivelul $d - 1$. Fie $n_1, \dots, n_k, \dots, n_b$ descendenții direcți ai nodului n la nivelul $d - 1$, conform figurii 1.26. Pentru toți întregii $x \geq 0$ are loc relația:

$$P(Z(n) \leq x) = \begin{cases} 1, & \text{dacă } A^* \text{ nu expandează pe } n \\ P\left(\sum_k Z(n_k) \leq x - 1\right), & \text{dacă } A^* \text{ expandează pe } n, \end{cases}$$




Fig. 1.26.

sau:

$$F_{Z(n)}(x) = P(Z(n) \leq x) = [1 - P(n \text{ exp})] + P(n \text{ exp}) P[(\sum_k Z(n_k) \leq x-1) \mid n \text{ exp}], \quad (1.19)$$

unde *exp* este prescurtarea lui *expandat*.

Deoarece $h_1(n) \lesssim h_2(n)$, pentru orice *n* și drumul de la *s* la *n* este unic, rezultă că:

$$P(A_1^* \text{ expandează pe } n) \geq P(A_2^* \text{ expandează pe } n). \quad (1.20)$$

Într-adevăr, în acest caz $f_1(n) \lesssim f_2(n)$ și atunci:

$$P(f_1(n) \leq N) \geq P(f_2(n) \leq N).$$

În virtutea inducției:

$$Z_2(n_k) \lesssim Z_1(n_k), \text{ pentru toți } k,$$

și deoarece $Z(n_1), \dots, Z(n_k), \dots, Z(n_b)$ sunt condițional independente:

$$\sum_k Z_2(n_k) \lesssim \sum_k Z_1(n_k),$$

sau:

$$P[\sum_k Z_2(n_k) \leq x-1] \leq P[\sum_k Z_1(n_k) \leq x-1]. \quad (1.21)$$

Ținând seama de (1.20) și (1.21) în (1.19) se poate arăta că $F_{Z_1(n)}(x) \leq F_{Z_2(n)}(x)$ sau că:

$$\left. \begin{matrix} u_1 \geq u_2 \\ v_1 \leq v_2 \end{matrix} \right\} \Rightarrow 1 - u_1 + u_1 v_1 \leq 1 - u_2 + u_2 v_2, \quad (1.22)$$

unde: $u_j = P(A_j^* \text{ expandează pe } n), \quad j = 1, 2,$

$$v_j = P[\sum_k Z_j(n_k) \leq x-1] \quad j = 1, 2.$$

Implicația (1.22) se poate reduce la:

$$\left. \begin{matrix} u_1 \geq u_2 \\ v_1 \leq v_2 \end{matrix} \right\} \Rightarrow (u_1 - u_2)(1 - v_1) + (v_2 - v_1)u_2 \geq 0,$$

care este ușor de verificat ținând seama că u_2 și v_1 sunt probabilități și, prin urmare, $v_1 \leq 1$ și $u_2 \geq 0$.

Rezultă că $F_{Z_1(n)}(x) \leq F_{Z_2(n)}(x)$, pentru toate nodurile și nivelele unui subarbore oarecare al lui *T*. În concluzie, $Z_1(s) \lesssim Z_2(s)$, fapt ce demonstrează teorema. ◀

1.3. Sinteza algoritmilor euristici

În acest paragraf vom descrie principalele tipuri de abordare ale unor probleme care, pentru soluționare, conduc la elaborarea unor algoritmi euristici.

1.3.1. Clasificarea metodelor euristice

Metodele euristice pot fi clasificate, în general, în două clase: metode de identificare a unei prime soluții, respectiv, metode iterative, de îmbunătățire pas cu pas a unei soluții cunoscute. O clasificare *în mare* a metodelor euristice poate fi:

1. Metode de identificare a unei prime soluții:

1.1. cu grad de libertate descrescător:

1.1.1. și procedee de alegere prioritară;

1.1.2. și procedee de relaxare a alegerii;

1.2. cu grad de libertate crescător;

2. Metode iterative:

2.1. cu alegere necondiționată;

2.2. cu alegere condiționată.

Metodele de identificare a unei prime soluții utilizează arborii de decizie, dar nu asigură faptul că mulțimea soluțiilor identificate conține eventual și soluția optimală. Parcurgerea metodei de identificare este reprezentabilă printr-un arbore, în cadrul căruia nodurile reprezentând mulțimi de soluții sunt ramificate succesiv. În multe metode de identificare a unei prime soluții, numărul de ramificații ale nodurilor arborelui scade succesiv. Aceste metode se numesc cu *grad de libertate descrescător*.

Cele mai simple metode de identificare cu grad de libertate descrescător utilizează reguli de prioritate pe baza cărora are loc selecționarea ramurilor ce urmează a fi parcurse. Asemenea metode sunt foarte rapide, dar au desavantajul că adesea generează parcurgeri ce conduc la soluții puțin eficiente.

Soluții mai bune se pot obține frecvent dacă există posibilități de relaxare a problemei date care să permită reducerea complexității arborelui de identificare.

În cadrul metodelor de identificare cu grad de libertate crescător, numărul de ramificații crește o dată cu adâncimea arborelui de decizie. Creșterea numărului de ramificări permite, după parcurgerea lor, corectarea deciziilor precedente. Drept consecință metodele cu grad de libertate crescător asigură frecvent obținerea de soluții esențial mai bune decât cele furnizate de metodele cu grad de libertate descrescător.

Metoda de iterație cu alegere necondiționată constă în continuarea succesivă a căutării soluțiilor, fără utilizarea vreunui criteriu de apreciere a eficienței căutării. Caracteristic pentru această metodă este numărul mare de soluții identificate cu ajutorul unei proceduri eficiente în ceea ce privește timpul de calcul.

În cadrul metodei cu alegere condiționată, sunt utilizate teste (sau filtre) care evită generarea de noi soluții care nu pot fi mai eficiente decât o soluție precedentă.

1.3.1.1. Morfologia metodelor de identificare a unei prime soluții

În procesul de identificare a unei prime soluții participă o mulțime de decizii ce pot fi împărțite în următoarele patru grupe:

- Decizia privind ce submulțimi de soluții urmează să fie scindate primele și decizia privind ordinea în care urmează să fie parcurse nodurile arborelui de decizie.
- Decizia privind modul în care submulțimea de soluții urmează a fi scindată și identificarea ramificării, adică numărul de noduri următoare și conținutul lor.
- Decizia privind modul în care se evaluează un nod unic din submulțimea de soluții, adică felul în care se stabilește calitatea nodului unic.
- Decizia, luată pe baza evaluării, privind submulțimile de soluții care ar urma să fie examinate ce pot fi ignorate, deci nodurile aferente eliminate; de asemenea alegerea acelor submulțimi de soluții ce pot participa la o următoare scindare.

1.3.1.2. Morfologia metodelor iterative

Destul de frecvent, soluțiile identificate cu metoda precedentă nu satisfac condițiile impuse, adică se abat prea mult de la soluțiile căutate. Dacă nu se poate ori nu se dorește ameliorarea metodei anterioare, rămâne varianta folosirii metodelor iterative. Cu ajutorul lor se încearcă îmbunătățirea unei soluții anterioare, fără garantarea obținerii soluției dorite, eventual optimale.

Esența metodelor iterative constă în căutarea unei soluții mai bune într-o vecinătate (definită) a unei soluții cunoscute. Deciziile din cadrul metodelor iterative frecvent întâlnite sunt cele relative la definiția vecinătății soluțiilor sau la organizarea metodelor de căutare.

În lucrarea [MÜL76] sunt prezentate pe larg cele două metodologii și multiplele proceduri folosite în cadrul metodelor euristice, fapt ce permite identificarea multiplelor variante ale algoritmilor euristici de rezolvare a unei probleme.

1.3.2. Metode exacte pentru sinteza algoritmilor

În acest paragraf, vom prezenta metode *clasice* pentru generarea algoritmilor, cu specificarea caracteristicilor algoritmilor obținuți. Aceste metode sunt utile în elaborarea algoritmilor euristici atât în determinarea unor metode de determinare a soluției unei subprobleme cât și în determinarea unor soluții aproximative, plecare, pentru relaxările problemelor pentru care se caută soluții euristice.

1.3.2.1. Metoda Greedy

Această metodă se aplică, în general, la probleme pentru care se caută determinarea unei submulțimi a unei mulțimi cu anumite caracteristici. Dintre diferitele submulțimi ce îndeplinesc anumite condiții, numite *soluții posibile*, se alege una singură, numită *soluție optimală*. Metoda Greedy se aplică în cazul în care orice

submulțime a unei soluții posibile este o soluție posibilă. În particular, se consideră că mulțimea vidă este o soluție posibilă. Presupunând că mulțimea elementelor pentru care se aplică metoda Greedy este $A = \{a_1, a_2, \dots, a_n\}$ și că rezultatul este mulțimea B , metoda corespunde la algoritmul următor:

Algoritmul 1.14. GREEDY(A, n, B)

1. [Inițializare] Se face $B = \emptyset$.
2. [Terminare] Dacă $A = \emptyset$, atunci furnizează B și STOP.
3. [Alegere] Se alege un element $x \in A$ și se face $A = A - \{x\}$.
4. [Adăugare] Dacă sunt verificate condițiile pentru a fi soluție, se face $B = B \cup \{x\}$.
5. [Ciclare] Se merge la pasul 2. ■

În această metodă sunt de rezolvat două probleme și anume problema determinării unor condiții pe care trebuie să le îndeplinească mulțimea B pentru a fi siguri că, prin completarea ei, se ajunge la soluția optimă și definirea unor criterii de alegere pentru determinarea unei soluții eficiente.

Exemple de aplicare a metodei Greedy: metoda simplex din programarea liniară, problema rucsacului, interclasarea mulțimilor ordonate de elemente, memorarea fișierelor pe benzi magnetice, programarea activităților independente etc.

1.3.2.2. Metode arborescente

Aplicarea metodei arborescente se face pentru probleme de determinare a elementelor $x \in S$, unde S este o mulțime de elemente posibile, care minimizează o funcție $f(x)$. Se consideră o limită superioară F_1 a valorilor $f(x)$ care restrânge mulțimea elementelor soluție. Vom nota cu X mulțimea soluțiilor, adică $X = \{x \in S \mid f(x) < F_1\}$, cu f^* valoarea optimă dată de expresia $f^* = \min_{x \in X} f(x)$ și cu X^* mulțimea soluțiilor optimale, $X^* = \{x \in X \mid f(x) = f^*\}$. Dacă nu există soluții, deci $X = \emptyset$, atunci se consideră $f^* = +\infty$. Vom nota cu \hat{f} o evaluare prin exces pentru f^* . Inițial se poate lua $\hat{f} = F_1$.

Numim *arborescență validă* pentru \hat{f} o structură arborescentă care are rădăcina $R = X$, unde X este mulțimea soluțiilor, nodurile sunt submulțimi ale lui X , succesorii direcți S_1, S_2, \dots, S_p ai unui nod S sunt astfel încât $S = S_1 \cup S_2 \cup \dots \cup S_p$, unele noduri sunt marcate cu "eliminată" și dacă se elimină un nod, atunci se elimină toți descendenții aceluși nod, dacă există o soluție optimă și dacă $\hat{f} > f^*$, atunci cel puțin o soluție optimă nu aparține nodurilor eliminate și pentru fiecare nod S se determină o evaluare $g(S)$ prin lipsă față de elementele lui S care verifică relația $g(S) \leq f(x)$ pentru orice $x \in S$.

Restricția unei arborescențe valide la nodurile neeliminate este tot o arborescență validă care se numește *arborescența curentă*.

Se poate demonstra următoarea proprietate: dacă există o soluție optimală și dacă $\hat{f} > f^*$, atunci soluția optimală va aparține nodurilor terminale ale arborescenței curente.

Pe mulțimea arborescențelor valide definim următoarele operații:

- *Trunchiere (eliminare)*: Se pleacă de la o arborescență A_1 validă pentru \hat{f} și, prin eliminarea unui nod și a descendenților lui, se determină o arborescență A_2 . Trunchierea este definită numai dacă arborescența rezultată este validă pentru \hat{f} .
- *Separare*: Se pleacă de la o arborescență A_1 și se obține o arborescență A_2 prin introducerea la un nod terminal S a succesorilor direcți S_1, S_2, \dots, S_p astfel încât $S = S_1 \cup S_2 \cup \dots \cup S_p$ și se face $g(S_1) = g(S_2) = \dots = g(S_p) = g(S)$. Se demonstrează că, dacă A_1 este o arborescență validă pentru \hat{f} , atunci și A_2 este validă pentru \hat{f} .
- *Evaluare*: Se calculează pentru un nod S din arborele curent o evaluare prin lipsă $h(S)$ și dacă $h(S) < g(S)$, atunci se face $g(S) = h(S)$.
- *Ajustare*: La o arborescență validă pentru \hat{f} , dacă se găsește o soluție de valoare $\hat{g} < \hat{f}$, atunci se face $\hat{f} = \hat{g}$. Se demonstrează că arborescența este validă pentru \hat{g} .

Metoda arborescentă pentru o problemă P este algoritmul prin care se pleacă de la arborescența ce conține un singur nod, rădăcina, cu estimarea $\hat{f} = F_1$ și aplicând operații de trunchiere, separare, evaluare și ajustare se obține un șir de arborescențe valide. Algoritmul se termină când toate nodurile sunt eliminate.

Dacă la terminarea aplicării metodei arborescente se obține $\hat{f} = F_1$, atunci problema $\min f(x)$ pentru $x \in S$ și $f(x) < F_1$ nu are soluție. Altfel, ultima valoare \hat{f} este egală cu valoarea f^* a unei soluții optimale.

Pentru a obține o *evaluare prin lipsă*, se ține seamă de următoarele proprietăți:

Teorema 1.44. Dacă A este o arborescență validă pentru \hat{f} și dacă un nod S este astfel încât $g(S) \geq \hat{f}$, atunci arborescența obținută plecând de la A prin eliminarea lui S și a descendenților săi este o arborescență validă pentru \hat{f} . ■

Teorema 1.45. Dacă A este o arborescență validă pentru \hat{f} și dacă se demonstrează că soluția optimală a unui nod S are o valoare superioară lui \hat{f} sau că S este vidă, atunci arborescența obținută eliminând pe S și descendenții săi este tot validă pentru \hat{f} . ■

Se poate obține o *evaluare prin exces* dacă se obține o valoare inițială aplicând o *uristică* și apoi se ameliorează această valoare prin tehnici de vecinătăți.

În luarea deciziilor de trunchiere și eliminare se aplică criterii date de proprietățile următoare numite *proprietăți de dominanță*.

Teorema 1.46. Fie S un nod terminal și $S' \subset S$; dacă S' conține o soluție optimală de fiecare dată când S conține o asemenea soluție, atunci se aplică o separare a lui S în S' și $S - S'$ și apoi se poate elimina $S - S'$. ■

Teorema 1.47. Dacă S_1 și S_2 sunt două noduri neeliminate și dacă are loc relația $\min_{x \in S_1} f(x) \leq \min_{x \in S_2} f(x)$, atunci se poate elimina S_2 . ■

Pentru separare se pot utiliza două tipuri de strategii:

- *strategia de separare în adâncime* în care se consideră un nivel curent de pe care se selectează un nod din care se trece la un nod de pe nivelul imediat următor care nu a fost evaluat; în cazul când nu mai există astfel de noduri, se revine la nodul din nivelul anterior și se explorează o nouă variantă; această metodă utilizează pentru gestionare o stivă;
- *strategia de separare în lățime* în care se consideră pentru un nod curent toți succesorii lui direcți, parcurgerea arborescenței făcându-se nivel cu nivel; această metodă utilizează pentru gestionare o coadă.

La nivelul fiecărui nod S al arborescenței se poate defini problema P' derivată din P care se enunță astfel: să se minimizeze valoarea $f(x)$ pentru $x \in S$ și $f(x) < \hat{f}$. Această problemă o mai numim *problemă locală* pentru nodul S . Problema locală corespunzătoare rădăcinii coincide cu problema P .

Dacă problema locală P' corespunzătoare lui S nu are soluție, atunci se elimină S . Dacă soluția optimală a problemei locale este \hat{g} , atunci se elimină S cu eventuale operații de ajustare. Dacă problema locală P' nu se poate rezolva, atunci se aplică o separare a lui S .

O condiție suficientă pentru convergența metodei arborescente este existența unei funcții h cu valori numere naturale astfel încât $h(X)$ să fie un număr finit și dacă S_1 este un succesori direct al lui S , atunci $0 < h(S_1) < h(S)$ și oricare nod are un număr de cel mult k succesori direcți pentru un k dat.

1.3.2.3. Metoda backtracking

Această metodă de elaborare a unui algoritm se aplică problemelor în care soluția se poate pune sub forma unui vector, fiecare element al vectorului putând să ia o mulțime finită de valori. Între elementele din vectorul soluție se stabilesc relații numite *condiții interne*, prin care se poate stabili dacă o anumită combinație poate fi acceptată drept soluție sau nu. O problemă poate să admită, eventual, mai multe soluții rezultat. În metoda backtracking se încearcă evitarea generării tuturor combinațiilor posibile pentru a determina soluțiile rezultat. Pentru a determina o soluție (x_1, x_2, \dots, x_n) , presupunând că au fost determinate valori pentru x_1, x_2, \dots, x_{k-1} ,

se atribuie o valoare pentru x_k și sunt verificate condiții prin care se determină că s-a obținut o soluție, în cazul $k = n$, sau se poate completa cu valorile x_{k+1}, \dots, x_n pentru a obține o soluție. Aceste condiții se numesc, în cazul când nu s-a obținut deja o soluție, *condiții de continuare*. Dacă valoarea dată lui x_k nu este acceptabilă, se încearcă o altă valoare și, dacă nu mai sunt valori posibile pentru x_k , se revine la x_{k-1} și se încearcă o nouă valoare. Algoritmul se termină când nu se mai poate atribui nici o valoare posibilă lui x_1 . Metoda backtracking se poate descrie sub forma următoare:

Algoritmul 1.15. BACKTRACK(x, n)

1. [Inițializare] Se face $k = 1$.
2. [Verificare soluție] Dacă $k > n$, atunci se prelucrează soluția (x_1, x_2, \dots, x_n) și se merge la pasul 5.
3. [Testare continuare] Dacă nu mai sunt valori posibile neexplorate pentru x_k , atunci se merge la pasul 5.
4. [Atribuire și continuare] Se atribuie o valoare posibilă pentru x_k , apoi se face $k = k + 1$ și se merge la pasul 2.
5. [Revenire și continuare] Se face $k = k - 1$. Dacă $k > 0$, atunci se trece la pasul 3, altfel STOP. ■

Prin prelucrarea unei soluții, la pasul 2, se înțelege mulțimea de operații care se fac pentru o soluție găsită cum ar fi tipărirea, numărarea, memorarea, calculul valorii unei funcții particulare etc. Prin valori posibile neexplorate, la pasul 3, se înțeleg acele valori ale lui x_k , ce nu au fost încă folosite cu combinația curentă a elementelor x_1, \dots, x_{k-1} și pentru care sunt îndeplinite condițiile interne.

Exemple de aplicare a metodei backtracking: determinarea unor submulțimi de elemente de sumă dată, partiționarea unui întreg, problema celor 8 dame, colorarea grafurilor, generarea submulțimilor unei mulțimi etc.

1.3.2.4. Metoda branch and bound

Această metodă este asemănătoare cu metoda backtracking. Deosebirea constă în faptul că, în această metodă sunt limitate valorile posibil de atribuit elementelor pe baza informațiilor obținute anterior luării deciziei. Astfel mulțimea elementelor explorate pentru determinarea soluțiilor devine mai mică și eficacitatea algoritmului crește. Determinarea dacă pentru o valoare a unui element este necesară continuarea completării ei sau nu pentru a ajunge la soluție se face prin calculul valorii unei funcții, numită *criteriu de evaluare*, și verificarea apartenenței acestei valori la o mulțime posibilă de valori pentru soluție.

Exemple de aplicare a metodei branch and bound: determinarea drumurilor minime ale unui graf, jocul " $n^2 - 1$ " ($n = 3, 4, \dots$).

1.3.2.5. Metoda divide et impera

Metoda divide et impera constă în împărțirea unei probleme în două sau mai multe subprobleme de dimensiuni mai mici, care la rândul lor sunt divizate eventual în alte subprobleme, procesul continuând până în momentul în care se ajunge la o mulțime de subprobleme suficient de mici pentru a obține soluțiile corespunzătoare lor și apoi se assemblează soluțiile subproblemelor pentru a obține o soluție pentru problema inițială urmând calea inversă descompunerilor.

Exemple de aplicare a metodei divide et impera: sortarea prin interclasare, căutarea în fișiere, căutarea în arbori de sortare, problema turnurilor din Hanoi etc.

1.3.2.6. Metoda programării dinamice

Metoda de programare dinamică a fost concepută de Bellman, fiind publicată în anul 1957. Această metodă a fost aplicată pentru rezolvarea unor probleme privind procesele industriale, gestionarea stocurilor, probleme de investiții, planificări economice și alte probleme de optimizări combinatoriale.

Metoda programării dinamice se aplică problemelor în care soluția se obține ca rezultat al unui șir de decizii, fiecare decizie depinzând de deciziile luate anterior, în fiecare moment de decizie pot fi explorate mai multe variante de decizie posibile. În luarea deciziilor se ține seama de *principiul optimalității* care stabilește că orice subșir de decizii al unui șir optimal de decizii este optimal. În linii mari, metoda programării dinamice constituie determinarea unui șir de stări s_0, s_1, \dots, s_n , unde s_0 este starea inițială și s_n este starea finală, din care rezultă soluția optimală, și o lțime de decizii d_1, d_2, \dots, d_n . Fiecare decizie d_i determină modul de tranziție din starea s_{i-1} în starea s_i . Deciziile pot fi determinate în ordinea d_n, \dots, d_1 (*metoda înainte*) sau în ordinea d_1, \dots, d_n (*metoda înapoi*). Vom preciza în cele ce urmează acest proces.

Metoda programării dinamice constă în determinarea unui șir de decizii, numit *politică*, prin care se asigură evoluția unui proces. Determinarea unei decizii a unei probleme de dimensiune N se face în funcție de deciziile ce sunt luate pentru probleme de dimensiuni $N - 1, N - 2, \dots, 2, 1$. De fiecare dată se consideră cea mai bună decizie, aceasta asigurând o soluție optimă. Deciziile sunt luate secvențial. Definim formal acest proces de decizie în continuare.

Numim *proces de decizie secvențială* o tripletă de forma (X, U, g) , unde X este spațiul stărilor, U este o mulțime numită *spațiul deciziilor* și

$$g: X \times U \times N \rightarrow X \cup \{\varepsilon\}$$

este *funcția de tranziție*. Vom nota cu $\Delta(x, k) = \{u \mid g(x, u, k) \neq \varepsilon\}$ mulțimea deciziilor posibile la momentul k pentru starea x . *Traectoria unei particule* se definește în felul

următor: se consideră o stare inițială $x(0)$ și dacă se cunoaște starea $x(k)$ la momentul k , se consideră o decizie $u \in \Delta(x(k), k)$ și se obține $x(k + 1) = g(x(k), u, k)$ starea la momentul $k + 1$. Se presupune că la fiecare etapă există un număr finit de decizii posibile care nu depășește o valoare N . Aceasta se numește *ipoteza Markov* și un sistem care verifică această ipoteză se numește *orizont de procese de decizie secvențială* și se notează (X, U, g, N) .

Mulțimea stărilor accesibile la momentul k , notată X_k , se definește astfel: $x \in X_k$ dacă și numai dacă există un șir de decizii $(u(0), \dots, u(k-1))$ astfel încât $u(0) \in \Delta(x(0), 0)$, $x(1) = g(x(0), u(0), 0)$, $u(1) \in \Delta(x(1), 1)$, $x(2) = g(x(1), u(1), 1)$, ..., $u(k-1) \in \Delta(x(k-1), k-1)$, $x(k) = g(x(k-1), u(k-1), k-1)$.

Se numește *subpolitică de ordin $n \leq N$* a orizontului de procese de decizie secvențială (X, U, g, N) pentru starea x a lui X_{N-n} perechea $(x, (d_0, d_1, \dots, d_{n-1}))$, cu $d_0 \in \Delta(x, N-n)$, $d_1 \in \Delta(x, N-n+1)$, cu $x_1 = g(x, d_0, N-n)$, $d_2 \in \Delta(x, N-n+2)$, cu $x_2 = g(x_1, d_1, N-n+1)$, ..., $d_{n-1} \in \Delta(x_{n-1}, N-1)$, cu $x_{n-1} = g(x_{n-2}, d_{n-2}, N-2)$. Numim *politică* o subpolitică de ordin N .

Pentru compararea politicilor se consideră un *criteriu* care este o funcție $J(x, (d_0, d_1, \dots, d_{n-1}))$. Vom spune că $(x, (d_0^*, \dots, d_{n-1}^*))$ este *subpolitică optimală* dacă pentru orice subpolitică $(x, (d_0, d_1, \dots, d_{n-1}))$ are loc inegalitatea:

$$J(x, (d_0^*, \dots, d_{n-1}^*)) \leq J(x, (d_0, d_1, \dots, d_{n-1})).$$

Un criteriu J se numește *criteriu separabil* dacă există o funcție $r_k(x, u)$, pentru $x \in X_k$ și $u \in \Delta(x, k)$, $0 \leq k \leq N-1$, numită *funcție de cost imediat*, funcțiile R_n de n variabile reale, $1 \leq n \leq N$ și funcții φ_n de două variabile reale, monoton nedescrescătoare în raport cu a doua variabilă, $2 \leq n \leq N$, astfel încât pentru orice n , $1 \leq n \leq N-1$ și orice subpolitică de ordin n $(a, (d_0, d_1, \dots, d_{n-1}))$ au loc relațiile $J(a, (d_0, d_1, \dots, d_{n-1})) = R_n(\rho_0, \dots, \rho_{n-1}) = \varphi_n(\rho_0, R_{n-1}(\rho_1, \dots, \rho_{n-1}))$, cu $\rho_0 = r_{N-n}(a, d_0)$, $\rho_1 = r_{N-n+1}(x_1, d_1)$, $\rho_2 = r_{N-n+2}(x_2, d_2), \dots, \rho_{n-1} = r_{N-1}(x_{n-1}, d_{n-1})$, $x_1 = g(a, d_0, N-n)$, $x_2 = g(x_1, d_1, N-n+1), \dots, x_{n-1} = g(x_{n-2}, d_{n-2}, N-2)$.

Exemple de criterii separabile cel mai des utilizate sunt următoarele: $\sum_{i=0}^{N-1} r_i$, $\prod_{i=0}^{N-1} r_i$, cu $r_i \in \mathbb{R}^+$, $\max\{r_i \mid i = 0, 1, \dots, N-1\}$ și $\min\{r_i \mid i = 0, 1, \dots, N-1\}$.

Se numește *principiul optimalității* proprietatea că orice subpolitică a unei politici optimale este optimală.

Vom nota în continuare cu $\bar{u}(n, x)$ o subpolitică asociată unei stări inițiale $x \in X_{N-n}$ și orizont n , $\bar{u}(n, x) = (u(N-n), u(N-n+1), \dots, u(N-1))$ și cu $\bar{u}^*(n, x)$ o subpolitică optimală în raport cu un criteriu J și având valoarea $J(x, \bar{u}^*(n, x))$. Din definițiile anterioare rezultă următoarea relație:

$$\bar{u}(n, x) = (u(N-n), \bar{u}(n-1, g(x, u(N-n), N-n))).$$

Algoritmul de programare dinamică poate să fie descris în felul următor.

Algoritmul 1.16. PROGDM(X, U, g, J)

1. [Ciclare k] Pentru $k = N - 1, N - 2, \dots, 0$ se execută pasul 2, apoi STOP.
2. [Ciclare stare] Pentru orice stare x din X_k se execută pasul 3.
3. [Calculare] Dacă $\Delta(x, k) \neq \emptyset$, atunci se face:

$$f^*(x, k) = \min_{u \in \Delta(x, k)} \{J(x, u, \bar{u}^*(N - k - 1, g(x, u, k)))\}; v^*(x, k) = u,$$

unde $u \in \Delta(x, k)$ este o decizie pentru care se realizează minimul precedent; (dacă există mai multe și traiectoria optimală trece prin x la nivelul k , atunci există mai multe politici optimale); se face:

$$\bar{u}^*(N - k, x) = (v^*(x, k), \bar{u}^*(N - k - 1, g(x, v^*(x, k), k))). \blacksquare$$

Exemple de aplicare a metodei programării dinamice: determinarea drumurilor de lungime minimă în grafuri, determinarea arborilor optimi și căutare. programarea activităților etc.

1.3.3. Metode generale de construire a unor euristici

Una din metodele cele mai frecvente de elaborare a algoritmilor euristici se poate descrie pe scurt în felul următor. Se descompune procesul de căutare a soluțiilor în mai multe etape succesive pentru care sunt determinate soluții pe care le numim *soluții locale*. Pe baza soluțiilor locale se determină soluțiile problemei inițiale. Prin exemple, se poate vedea că nu întotdeauna se obțin soluțiile optimale ale problemei inițiale. Dacă procedeu rezultat produce întotdeauna soluția optimală, se obține un *algorithm exact*. Altfel, dacă se găsește un contraexemplu sau nu s-a găsit o demonstrație prin care se arată optimalitatea algoritmului propus, se obține un *algorithm euristic*.

În elaborarea algoritmului euristic, sunt detectate mai întâi toate condițiile pe care trebuie să le îndeplinească o soluție optimală, după care, în funcție de anumite criterii (facilitatea de verificare, necesitatea verificării pentru soluții posibile, posibilitatea unor relaxări etc.), se determină o mulțime de clase de condiții.

1.3.3.1. Euristici folosind metoda Greedy

Cea mai mare parte a algoritmilor euristici se poate încadra în această clasă. Prima idee care este exploatată în soluționarea unei probleme este determinarea unor etape în care *câștigul* să fie cât mai mare posibil. Intuitiv aceasta duce la obținerea unei soluții acceptabile într-un număr mai mic de pași. Riscurile sunt de două feluri: ori o traiectorie care să aibă câștiguri mari la început dar mult mai mici decât alte traiectorii de la un moment dat, ori să fie o traiectorie falsă, prin care să nu ne putem

aproșia oricât de mult de o soluție optimală. În primul caz, riscul este de a obține un timp mai mare de lucru, dar în al doilea caz riscul este mult mai mare deoarece cu toate eforturile făcute nu se obține o soluție satisfăcătoare. De o importanță deosebită este alegerea funcției de calcul a câștigului.

Exemple de algoritmi euristici bazați pe metoda Greedy: metoda gradientului, metoda tangentei în determinarea soluțiilor unor ecuații, metoda calculului adresei în căutarea în mulțimi ordonate, metoda de soluționare a problemei rucsacului (vezi algoritmul 1.4.), metoda de soluționare a problemei comisvoiajorului (vezi algoritmul 1.2.), *LPT*-planificarea (vezi definiția 1.1.) etc.

1.3.3.2. Euristici folosind metoda backtracking

Acest tip de euristici se folosesc în cazul în care determinarea aproximării soluției pentru o problemă dată se determină dintr-o mulțime finită de elemente ce trebuie explorat în totalitatea lor. Prin anumite criterii aplicate spațiului în care se lucrează sau prin localizarea unor stări inițiale se poate face această reducere a posibilităților de variație a variabilelor. Procesul de explorare este analog metodei exacte de tip backtracking.

Exemple de algoritmi euristici bazați pe metoda backtracking: metoda de soluționare a problemei de programare liniară întreagă, metoda înjumătățirii intervalului și metoda coardei pentru determinarea soluției unei ecuații etc.

1.3.3.3. Euristici folosind metoda branch and bound

În algoritmul *branch and bound* o *problemă parțială*, referită și ca *nod*, P_i este descompusă într-o mulțime $S(P_i)$ cu $|S(P_i)| < \infty$. O problemă $P_j \in S(P_i)$ se numește *fiu* al lui P_i . Fie o problemă de *minimizare* în care $f(P_i)$ este valoarea optimală a lui P_i . De obicei $f(P_i)$ nu se cunoaște a priori, dar pentru fiecare P_i se calculează o margine inferioară $g(P_i)$. În afară de proprietatea $g(P_i) \leq f(P_i)$ se mai presupune că:

$$g(P_i) \leq g(P_j), \text{ pentru } P_j \in S(P_i).$$

La calculul lui $g(P_i)$ se poate uneori conchide că $g(P_i) = f(P_i)$. Mulțimea acestor P_i se notează cu G și descompunerea ei nu mai trebuie continuată, conform cu *testul G* în algoritmul prezentat mai departe. Dacă z este valoarea minimă a lui $f(P_i)$, pentru toate $P_i \in G$ testate, atunci P_i poate fi terminată dacă $g(P_i) \geq z$, deoarece P_i nu poate furniza o valoare mai mică decât z . Acest test se numește *testul marginii inferioare*. Dacă se cunoaște o *relație de dominanță D*, atunci în algoritm se poate introduce și un *test de dominanță D* de forma:

$$P_k D P_i \text{ implică } f(P_k) \leq f(P_i),$$

unde D are semnificația unei relații de ordine parțială. Problema P_i poate fi în acest caz încheiată, deoarece P_k va furniza o soluție cel puțin la fel de bună ca orice soluție furnizată de P_i . Relația de dominanță D este *consistentă cu g* dacă:

$$P_k D P_i \text{ implică } g(P_k) \leq g(P_i).$$

O problemă parțială generată într-un calcul Branch and Bound dar netestată încă se numește *activă*. Mulțimea curentă a nodurilor active se notează cu A și mulțimea problemelor parțial generate se notează cu H . O *funcție de căutare s* care selectează o problemă parțială $P_i = s(A)$ din A determină ordinea testării problemelor parțiale generate în timpul calculului.

O funcție $s = s_h$ se numește *funcție de căutare euristică* bazată pe *funcția euristică h* și care selectează o problemă parțială din A cu cele mai mici valori ale lui h . *Adâncimea* problemei P_i reprezintă numărul de descompuneri necesar generării problemei P_i din problema inițială P_0 . O funcție $s = \bar{s}_k$ se numește *funcție de căutare în adâncime* bazată pe h , care selectează problema cu cea mai mică valoare a lui h dintre problemele având adâncimea maximă. Funcția $s = s_g$ se numește *funcție de căutare cu cea mai bună margine*, adică marginea inferioară g este utilizată în locul lui h din s_h . Se poate folosi de asemenea funcția de căutare în adâncime bazată pe g și 1 (tă $s = \bar{s}_g$).

În continuare este prezentat un algoritm *BB* pentru rezolvarea unei probleme de minimizare P_0 .

Algoritm 1.17. (BB)

1. [Inițializări] Se face $H = \{P_0\}$, $A = \{P_0\}$ și $z = \infty$.
2. [Căutare] Dacă $A = \emptyset$, atunci se trece la pasul 9; altfel se face $P_i = s(A)$ și se trece la pasul 3.
3. [Testul G] Dacă $P_i \in G$, atunci se trece la pasul 7; altfel se trece la pasul 4.
4. [Testul marginii inferioare] Dacă $g(P_i) \geq z$, atunci se trece la pasul 8; altfel se trece la pasul 5.
5. [Testul de dominanță] Dacă o anumită $P_k (\neq P_i) \in H$ satisface $P_k D P_i$, atunci se trece la pasul 8; altfel se trece la pasul 6.
6. [Ramificare] Se generează $S(P_i)$ descompunând pe P_i , se face $A = A \cup S(P_i) - \{P_i\}$ și $H = H \cup S(P_i)$, apoi se trece la pasul 2.
7. [Îmbunătățire] Se face $z = \min[z, f(P_i)]$.
8. [Încheie P_i] Se face $A = A - \{P_i\}$ și se trece la pasul 2.
9. [Terminare] Se face $z = f(P_0)$ (dacă $z = \infty$, P_0 nu are soluție) și STOP. ■

Performanța algoritmului *BB* este uneori măsurată cu următoarele valori:

- T : numărul de probleme parțiale descompuse în pasul 6 înainte ca algoritmul să se oprească la pasul 9.

- M : mărimea maximă a mulțimii A atinsă în timpul parcurgerii algoritmului.

În continuare, sunt discutate trei tipuri de modificări care asigură accelerarea calculelor și/sau reducerea spațiului de memorare.

1. Metoda ε -reducerii (ε -allowance method) constă în înlocuirea testului din pasul 4 cu $g(P_i) + \varepsilon(z) \geq z$, unde $\varepsilon(z) \geq 0$. Funcțiile de reducere utilizate în practică sunt $\varepsilon(z) = \varepsilon$ (constantă) și $\varepsilon(z) = \gamma z$ cu $\gamma \geq 0$.
2. Metoda T -tăieturii (T -cut method). Această metodă constă în întreruperea calculelor de îndată ce numărul de probleme parțiale descompuse în pasul 6 atinge o margine specificată T_0 . Valoarea z_f a variabilei z în acest moment reprezintă valoarea soluției suboptimale. Pentru aplicarea acestei metode este suficient să se introducă în algoritmul BB un procedeu de contorizare a numărului problemelor parțial descompuse. În acest fel se asigură satisfacerea de către T a condiției $T \leq T_0$.
3. Metoda M -tăieturii (M -cut method). Această metodă constă în eliminarea necondiționată în pasul 6 a unui număr de $|A = A \cup S(P_i) - \{P_i\}| - M_0$ probleme parțiale, unde M_0 este o margine a capacității (capacity bound M_0). În felul acesta se asigură satisfacerea de către M a condiției $M \leq M_0$.

În metodele de tip branch and bound, de o importanță deosebită este modul de evaluare a unui nod.

Exemple de algoritmi euristici bazați pe metoda branch and bound: programarea activităților, probleme combinatoriale etc.

1.3.3.4. Euristici folosind metoda divide et impera

Principiul de construire al acestor algoritmi coincide cu cel descris pentru algoritmi exacti de tip divide et impera. Deosebirea constă numai în eventualele relaxări luate în considerație la rezolvarea problemelor considerate simple.

Algoritmii de acest tip sunt foarte utili mai ales în calculul paralel.

Exemple de algoritmi euristici bazați pe metoda divide et impera: programarea activităților, determinarea extremelor unei funcții, integrarea prin metoda Monte-Carlo, metode statistice pentru concordanță și omogenitate etc.

1.3.3.5. Euristici folosind metoda programării dinamice

Acești algoritmi euristici se obțin prin relaxarea condițiilor de optimalitate. Această relaxare poate fi făcută fie în scopul unor calcule mai simple, fie în scopul satisfacerii principiului optimalității, făcând astfel posibilă aplicarea metodei programării dinamice.

Exemple de algoritmi euristici bazați pe metoda programării dinamice: metode de alocare a memoriei (prima potrivire, cea mai bună potrivire, metoda camarazilor), programarea activităților etc.

1.4. Algoritmi genetici și evolutivi

1.4.1. Introducere

Idea de bază a algoritmilor genetici și evolutivi constă în modificarea succesivă a unor soluții inițiale sau generate anterior folosind, de obicei, doi operatori: *mutație* și *încrucișare*. Dacă noua soluție este mai bună decât cele precedente, procesul de modificare continuă. Altfel, dacă nu este posibilă ameliorarea soluției sau numărul de modificări a depășit o anumită limită, algoritmul se încheie. Un algoritm se numește *genetic clasic* dacă soluțiile sale sunt reprezentate sub formă de *cromozomi*, adică șiruri de biți 0 și 1. Problemele în care soluțiile sunt reprezentate sub formă de cromozomi sunt însă rare. Pentru probleme obișnuite, implementarea conceptelor de *mutație* și *încrucișare* (vezi 1.4.2.4.), așa cum sunt gândite în cadrul algoritmilor genetici clasici, se poate realiza în două moduri, ilustrate în figurile 1.27. și 1.28.. Algoritmii realizați în modurile descrise în aceste figuri se numesc *algoritmi genetici*, respectiv *evolutivi*. În cele ce urmează adjectivul *clasic* va fi omis.




Fig. 1.27.




Fig. 1.28.

Un algoritm genetic, ca și orice program evolutiv, pentru o problemă particulară trebuie să cuprindă următoarele cinci componente:

- o reprezentare genetică a soluțiilor potențiale ale problemei studiate,
- un mod de creare a populației inițiale de soluții potențiale,
- o funcție de evaluare, care joacă rol de mediu și evaluează calitatea soluțiilor,
- operatori genetici ce alterează structura copiilor,
- valorile diferiților parametri pe care le utilizează algoritmii genetici cum sunt mărimea populației, probabilitățile de aplicare a operatorilor genetici etc..

1.4.2. Algoritm genetic pentru optimizarea unei funcții

În cadrul exemplului ce urmează sunt ilustrate ideile de bază ale algoritmilor genetici, pe un exemplu de identificare a maximumului unei funcții. Funcția dată este (vezi figura 1.29.):




Fig. 1.29.

problema de rezolvat fiind identificarea lui x_0 aparținând intervalului $[-1, 2]$ pentru care funcția dată are o valoare maximă, adică $f(x_0) \geq f(x)$ pentru toți $x \in [-1, 2]$. Anulând derivata funcției f se obține:

$$f'(x) = \sin(10\pi x) + 10\pi x \cdot \cos(10\pi x) = 0,$$

de unde rezultă:

$$\operatorname{tg}(10\pi x) = -10\pi x.$$

Ecuția precedentă are o infinitate de soluții și anume:

$$x_i = (2i - 1) / 20 + \varepsilon_i, \text{ pentru } i = 1, 2, \dots,$$

$$x_0 = 0,$$

$$x_i = (2i + 1) / 20 - \varepsilon_i, \text{ pentru } i = -1, -2, \dots,$$

unde ε_i reprezintă secvențe descrescătoare de numere reale, pentru $i = 1, 2, \dots$ și $i = -1, -2, \dots$, ce tind către zero. Funcția f are maxime locale pentru x_i , dacă i este un întreg impar, și minime locale pentru x_i , dacă i este un întreg par. Deoarece domeniul este $[-1, 2]$, rezultă că maximum global se realizează pentru $x_{19} = 37/20 + \varepsilon_{19} = 1.85 + \varepsilon_{19}$, unde $f(x_{19})$ este puțin mai mare decât $f(1.85) = 1.85 \cdot \sin(18\pi + \pi/2) + 1.0 = 2.85$.

Componentele necesare pentru elaborarea algoritmului genetic de identificare a soluției problemei enunțate sunt prezentate în continuare.

1.4.2.1. Reprezentarea

Pentru reprezentarea valorilor variabilei x se folosește un vector binar x , în presupunerea că precizia soluției este de șase cifre după punctul zecimal. Domeniul variabilei x are lungimea 3 și precizia acceptată implică împărțirea intervalului $[-1, 2]$ în cel puțin $3 \cdot 10^6$ subintervale egale. Rezultă că vectorul asociat variabilei x trebuie să conțină 22 biți, deoarece:

$$2\,097\,152 = 2^{21} < 3\,000\,000 < 2^{22} = 4\,194\,304.$$

Transformarea șirului binar $\langle b_{21} b_{20} \dots b_0 \rangle$ într-un număr real din intervalul $[-1..2]$ se poate efectua în două etape:

- convertirea șirului binar $\langle b_{21} b_{20} \dots b_0 \rangle$ din baza 2 în baza 10:

$$(\langle b_{21} b_{20} \dots b_0 \rangle)_2 = \left(\sum_{i=0}^{21} b_i \cdot 2^i \right)_{10} = x',$$

- identifică numărul real corespunzător:

$$x = -1.0 + x' \cdot 3 / (2^{22} - 1),$$

unde -1.0 este marginea inferioară a domeniului și 3 este lungimea domeniului. De exemplu, cromozomul:

$$(1000101110110101000111)$$

reprezintă numărul:

$$x' = (1000101110110101000111)_2 = 2\,288\,967,$$

și

$$x = -1.0 + 2\,288\,967 \cdot 3 / 4\,194\,303 = 0.637197.$$

Evident, cromozomii:

$$(0000000000000000000000) \text{ și } (1111111111111111111111)$$

reprezintă marginile domeniului adică pe -1.0 , respectiv 2.0 .

1.4.2.2. Populația inițială

Populația inițială constă din mai mulți cromozomi, fiecare dintre ei fiind un vector de 22 de biți. Cei 22 de biți ai fiecărui cromozom sunt inițializați aleator.

1.4.2.3. Funcția de evaluare

Funcția de evaluare *eval* a vectorilor binari v este echivalentă cu funcția f :

$$\text{eval}(v) = f(x),$$

unde cromozomul v reprezintă valoarea reală x . De exemplu, următorii trei cromozomi:

$$v_1 = (1000101110110101000111),$$

$$v_2 = (0000001110000000010000),$$

$$v_3 = (1110000000111111000101),$$

corespund valorilor $x_1 = 0.637197$, $x_2 = -0.958973$ și, respectiv, $x_3 = 1.627888$.

Funcția de evaluare generează valorile:

$$eval(v_1) = f(x_1) = 1.586345,$$

$$eval(v_2) = f(x_2) = 0.078878,$$

$$eval(v_3) = f(x_3) = 2.250650.$$

Cromozomul v_3 este evident cel mai bun dintre cei trei cromozomi, deoarece furnizează cea mai mare valoare.

1.4.2.4. Operatori genetici

În faza de modificare a soluției deja generate se folosesc doi operatori clasici: *mutație* și *încrucișare*. Operatorul *mutație* alterează una sau mai multe *gene* (biți ai cromozomilor). Presupunând că a cincea genă a cromozomului v_3 a fost aleasă pentru mutație și ținând seama că ea este 0, rezultă că va fi transformată în 1. Noul cromozom obținut este:

$$v'_3 = (1110100000111111000101).$$

Acest cromozom reprezintă valoarea $x'_3 = 1.721638$ și $f(x'_3) = -0.082257$, ceea ce arată că această mutație particulară produce o descreștere a valorii cromozomului v_3 .

Dacă însă a 10-a genă a fost selectată pentru mutație în cromozomul v_3 , atunci:

$$v''_3 = (1110000001111111000101).$$

Valoare corespunzătoare este $x''_3 = 1.630818$ și $f(x''_3) = 2.343555$, ceea ce reprezintă o îmbunătățire a valorii $f(x_3) = 2.250650$.

Pentru ilustrarea operatorului de încrucișare se consideră cromozomii v_2 și v_3 , cu presupunerea că punctul de încrucișare a fost ales (aleator) după a cincea genă:

$$v_2 = (00000|01110000000010000),$$

$$v_3 = (11100|00000111111000101).$$

Cei doi descendenți generați sunt:

$$v'_2 = (00000|00000111111000101),$$

$$v'_3 = (11100|01110000000010000).$$

Evaluările acestor doi descendenți sunt:

$$f(v'_2) = f(-0.998113) = 0.940865,$$

$$f(v'_3) = f(1.666028) = 2.459245.$$

Se observă că al doilea descendent are o evaluare mai bună decât cei doi părinți. Aceste observații pot fi utilizate în continuare pentru a obține soluții mai bune prin operații succesive de mutație și încrucișare din valori deja studiate.

1.4.2.5. Parametri

Pentru problema studiată au fost aleși următorii parametri: mărimea populației $pop_dim = 50$, probabilitatea încrucișării $p_c = 0.25$, probabilitatea mutației $p_m = 0.01$.

Numărul generației	Funcția de evaluare
1	1.441942
6	2.250003
8	2.250283
9	2.250284
10	2.250363
12	2.328077
39	2.344251
40	2.345087
51	2.738930
99	2.849246
137	2.850217
145	2.850227

Tabelul 1.1.

1.4.2.6. Rezultate experimentale

În tabelul 1.1. sunt prezentate rezultatele aplicării procedurilor descrise pentru problema studiată, după 150 de generații. Cel mai bun cromozom obținut este:

$$v_{\max} = (1111001101000100000101)$$

și îi corespunde valoarea $x_{\max} = 1.850773$. După cum era de așteptat $x_{\max} = 1.85 + \varepsilon$ și (x_{\max}) este puțin mai mare decât 2.85.

1.4.2.7. Procesul de selectare

Pentru selectarea unei noi populații, folosind o distribuție de probabilități bazată pe funcția de evaluare, se folosește modelul ruletei. O asemenea ruletă se construiește în modul următor:

- Se calculează evaluarea $eval(v_i)$ a fiecărui cromozom v_i ($i = 1, \dots, pop_dim$).
- Se calculează evaluarea totală a populației:

$$F = \sum_{i=1}^{pop_dim} eval(v_i).$$

- Se calculează probabilitatea p_i a selectării pentru fiecare cromozom v_i , $i = 1, 2, \dots, pop_dim$):

$$p_i = eval(v_i) / F.$$

- Se calculează probabilitatea cumulativă q_i pentru fiecare cromozom v_i , $i = 1, 2, \dots, pop_dim$):

$$q_i = \sum_{j=1}^i p_j.$$

Selecția se realizează pe calea rotirii ruletei de un număr de pop_dim ori. De fiecare dată, se alege un singur cromozom pentru noua populație în modul următor:

- Se generează un număr aleator real r din intervalul $[0..1]$.
- Dacă $r < q_1$, atunci se selectează primul cromozom (v_1); altfel se selectează cromozomul v_i , $2 \leq i \leq pop_dim$, astfel încât $q_{i-1} < r \leq q_i$.

Evident că unii cromozomi vor fi selectați mai mult decât o singură dată și alții nu vor fi selectați. Vom nota în continuare cu p_m probabilitatea de mutație și cu p_c probabilitatea de încrucișare.

Pentru aplicarea operatorului *mutație* se consideră șirul de biți generat de toți cromozomii populației curente. Numărul de biți ai unei populații este egal cu $m \cdot pop_dim$, unde m este numărul (actual) de cromozomi. Pentru toți biții populației se procedează în modul următor:

- Se generează un număr aleator r (real) din intervalul $[0, 1]$;
- Dacă $r < p_m$, atunci se schimbă bitul examinat.

Numărul așteptat al biților ce se schimbă este egal cu $p_m \cdot m \cdot pop_dim$.

Pentru operatorul *încrucișare* se procedează astfel:

- Se generează un număr aleator r (real) din intervalul $[0, 1]$;
- Dacă $r < p_c$, atunci se selectează cromozomul considerat pentru încrucișare.

În continuare, pentru fiecare pereche succesivă de cromozomi selectați pentru încrucișare, se generează un număr întreg pos din intervalul $[1, m - 1]$. Acest număr indică poziția punctului ce definește încrucișarea. Doi cromozomi:

$$(b_1 \ b_2 \ \dots \ b_{pos} \ b_{pos+1} \ \dots \ b_m) \text{ și} \\ (c_1 \ c_2 \ \dots \ c_{pos} \ c_{pos+1} \ \dots \ c_m)$$

sunt înlocuiți cu perechea de descendenți:

$$(b_1 \ b_2 \ \dots \ b_{pos} \ c_{pos+1} \ \dots \ c_m) \text{ și} \\ (c_1 \ c_2 \ \dots \ c_{pos} \ b_{pos+1} \ \dots \ b_m).$$

Numărul așteptat al cromozomilor ce participă la încrucișare este egal cu $p_c \cdot pop_dim$.

Observație. Dacă numărul de cromozomi selectați pentru încrucișare este impar, atunci ori se adaugă aleator încă un cromozom, ori se elimină tot aleator unul dintre cromozomii existenți.

1.4.3. Algoritm evolutiv pentru rezolvarea problemei liniar-pătratică

Exemplul precedent ilustrează concepțiile de bază ale algoritmilor genetici în cazul în care problema studiată este suficient de simplă pentru a permite codificarea binară a soluției. În cazul problemelor întâlnite de obicei, se poate adopta aceeași

strategie, cu prețul creșterii foarte mari a lungimii cromozomilor și măririi timpului de calcul. În acest caz, este convenabilă utilizarea reprezentării cromozomilor în termeni de valori reale, eventual întregi, și adaptarea operatorilor *mutație* și *încrucșare* la acest mod de reprezentare. Algoritmul formulat în acest mod este de tip evolutiv și utilizează de obicei și alte modalități de efectuare a mutației și încrucșării după cum vom arăta în continuare.

Drept exemplu ilustrativ, fie problema determinării minimumului:

$$\min q \cdot x_N^2 + \sum_{k=0}^{N-1} (s \cdot x_k^2 + r \cdot u_k^2), \quad (1.23)$$

cu condițiile:

$$x_{k+1} = a \cdot x_k + b \cdot u_k, \quad k = 0, 1, \dots, N-1, \quad (1.24)$$

unde x_0 este dat, a, b, q, s, r sunt constante date, $x_k \in \mathbb{R}$ are semnificație de stare și $u_k \in \mathbb{R}$ reprezintă controlul sistemului.

Valoarea performanței optime a procesului de minimizare a expresiei (1.23) cu condiția (1.24) este:

$$J^* = K_0 x_0^2, \quad (1.25)$$

unde K_k este soluția ecuației Riccati:

$$K_k = s + r a^2 K_{k+1} / (r + b^2 K_{k+1}), \quad K_N = q.$$

Problema (1.23) este rezolvată în continuare pentru mulțimile de parametrii din tabelul 1.2.

Cazul	N	x_0	s	r	q	a	b
I	45	100	1	1	1	1	1
II	45	100	10	1	1	1	1
III	45	100	1000	1	1	1	1
IV	45	100	1	10	1	1	1
V	45	100	1	1000	1	1	1
VI	45	100	1	1	10	1	1
VII	45	100	1	1	1000	1	1
VIII	45	100	1	1	1	0.01	1
IX	45	100	1	1	1	1	0.01
X	45	100	1	1	1	1	100

Tabelul 1.2.

1.4.3.1. Operatori specializați

Operatorii utilizați sunt diferiți de cei clasici, deoarece ei operează în spațiul valorilor reale. Totuși, datorită asemănărilor intuitive, ei sunt atribuiți claselor standard, adică *mutație* și *încrucșare*. În plus, unii operatori sunt neuniformi, adică acțiunea lor depinde de vârsta populației.

Grupul mutațiilor:

- *mutația uniformă* este definită în mod similar versiunii clasice: dacă $x_t^l = \langle v_1, v_2, \dots, v_n \rangle$ este un cromozom, atunci fiecare element v_k are aceeași șansă de a fi modificat. Rezultatul unei mutații unice a operatorului este vectorul $\langle v_1, v_2, \dots, v_k, \dots, v_n \rangle$, cu $1 \leq k \leq n$ și v_k este o valoare aleatoare din domeniul respectiv, *domeniu_k*.
- *mutația neuniformă* este un operator responsabil pentru capacitatea tratării mai fine a problemei. Operatorul de mutație neuniformă este definit astfel: dacă vectorul $s_v^l = \langle v_1, v_2, \dots, v_m \rangle$ este un cromozom și a fost ales elementul v_k pentru mutație, domeniul lui v_k fiind $[l_k, u_k]$, atunci, rezultatul este vectorul $s_v^{l+1} = \langle v_1, v_2, \dots, v_k, \dots, v_m \rangle$, cu $k \in \{1, \dots, n\}$ și:

$$v_k = \begin{cases} v_k + \Delta(t, u_k - v_k), & \text{dacă valoarea aleatoare este } 0, \\ v_k - \Delta(t, v_k - l_k), & \text{dacă valoarea aleatoare este } 1, \end{cases}$$

unde, $\Delta(t, y)$ furnizează o valoare din $[0, y]$ astfel încât probabilitatea ca $\Delta(t, y)$ să fie aproape de 0 și crește o dată cu t . Această proprietate are drept consecință faptul că, inițial, acest operator parcurge spațiul în mod uniform (când t este mic) și foarte local la etapele următoare. Un exemplu de funcție $\Delta(t, y)$ este:

$$\Delta(t, y) = y \cdot (1 - r^{(1-t/T)^b}),$$

unde r este un număr aleator din $[0, 1]$, T este numărul generațiilor și b este un parametru al sistemului ce determină gradul de neuniformitate. Valorile lui Δ pentru două momente distincte, sunt descrise de figurile 1.30. și 1.31.




Fig. 1.30.




Fig. 1.31.

Grupul încrucișărilor:

- *încrucișarea simplă* este definită în mod obișnuit dar cu condiția ca punctul de încrucișare să figureze între doi v_i și v_j consecutivi ai unui cromozom dat x .
- *încrucișarea aritmetică* este definită drept combinație liniară a doi vectori și anume, dacă s_v^l și s_w^l urmează să fie încrucișați, atunci descendenții generați sunt $s_v^{l+1} = a \cdot s_w^l + (1-a) s_v^l$ și $s_w^{l+1} = a \cdot s_v^l + (1-a) s_w^l$. În acest operator, a reprezintă fie o

constantă (*încrucișare aritmetică uniformă*), fie o variabilă a cărei valoare depinde de vârsta populației (*încrucișare aritmetică neuniformă*).

Rezultatele aplicării algoritmului evolutiv problemei enunțate mai sus sunt prezentate în tabelul 1.3. Pentru toate cele 10 cazuri, mărimea populației a fost egală cu 70 și au fost generate 40 000 de generații. Vectorul $\langle u_0, \dots, u_{69} \rangle$ a fost inițializat cu valori aleatoare aparținând domeniului de control. În tabelul 1.3. sunt menționate atât valorile finale obținute după 40 000 de generații cât și valorile obținute după diferite generații intermediare. În ultima coloană a tabelului este menționat factorul cu care trebuie multiplicat valorile din coloanele 1-7 în vederea obținerii valorii soluției.

Cazul	Generații						Factor	
	1	100	1000	10000	20000	30000	40000	
I	17904.4	3.87385	1.73682	1.61859	1.61817	1.61804	1.61804	10^4
II	13572.3	5.56187	1.35678	1.11451	1.09201	1.09162	1.09161	10^5
III	17024.8	2.89355	1.06954	1.00952	1.00124	1.00102	1.00101	10^7
IV	15082.1	8.74213	4.05532	3.71745	3.70811	3.70162	3.70160	10^4
V	5968.42	12.2782	2.69862	2.85524	2.87645	2.87571	2.87569	10^5
VI	17897.7	5.37447	2.09334	1.61863	1.61837	1.61805	1.61804	10^4
VII	2690258	18.6685	7.23567	1.73564	1.65413	1.61842	1.61804	10^4
VIII	123.942	72.1958	1.95783	1.00009	1.00005	1.00005	1.00005	10^4
IX	7.28165	4.82740	4.39091	4.42524	4.31021	4.31004	4.31004	10^5
X	9971341	148233	16081.0	1.48445	1.00040	1.00010	1.00010	10^4

Tabelul 1.3.

Rezultatele furnizate de soluția exactă a problemei studiate (vezi (1.25)) sunt date în tabelul 1.4.

Cazul	Soluția exactă
I	16180.3399
II	109160.7978
III	10009990.0200
IV	37015.6212
V	287569.3725
VI	16180.3399
VII	16180.3399
VIII	10000.5000
IX	431004.0987
X	10000.9999

Tabelul 1.4.

1.4.4. Forma generală a algoritmilor genetici și evolutivi

Algoritmii evolutivi pot fi construiți conform schemei următoare:

Algoritmul 1.18. (*Evolutiv*)

1. [Inițializări] Se face $t = 0$ și se inițializează $P(0)$.
2. [Evaluare] Se evaluează $P(t)$.
3. [Terminare] Dacă sunt îndeplinite condițiile de terminate, atunci STOP.
4. [Generație nouă] Se face $t = t + 1$ și se selectează $P(t)$ din $P(t - 1)$.
5. [Adaptare] Se adaptează $P(t)$.
6. [Ciclare] Se trece la pasul 2. ■

În acest algoritm am notat prin $P(t)$ populația din generația t , prin evaluarea din pasul 2 se stabilesc măsuri elementelor populației, selectarea din pasul 4 presupune alegerea elementelor utilizate pentru construirea unei noi generații care se determină în pasul 5 prin aplicarea regulilor de derivare. Condițiile de terminare din pasul 3 stabilesc situațiile în care calculele nu mai trebuiesc făcute în continuare fie din cauza imposibilității îmbunătățirii soluției, fie prin atingerea numărului maxim de generații stabilit inițial.

Un model de algoritm genetic în care populațiile sunt puse în corespondență cu vectori cu m elemente 0 și 1 este următorul.

Algoritmul 1.19. (*Iterated Hillclimber*)

1. [Inițializări] Se face $t = 0$.
2. [Terminare] Dacă $t > MAX$, atunci STOP.
3. [Inițializare iterație] Se selectează aleator vectorul curent v_c și se evaluează v_c .
4. [Explorare] Se generează cei m vecini ai lui v_c obținuți prin schimbarea câte unui bit în vectorul v_c și se alege unul dintre ei v_n care are cea mai mare valoare pentru funcția obiectiv f .
5. [Progresare] Dacă $f(v_c) < f(v_n)$, atunci se face $v_c = v_n$ și se trece la pasul 4.
6. [Ciclare] Se face $t = t + 1$ și se trece la pasul 2. ■

Algoritmul anterior asigură determinarea unui maxim local dar soluțiile furnizate pot să fie foarte depărtate de maximul absolut. O variantă a acestui algoritm care de cele mai multe ori dă o aproximație a soluției problemei este următoarea.

Algoritmul 1.20. (*Simulated Annealing*)

1. [Inițializări] Se face $t = 0$, se inițializează T , se alege la întâmplare un vector curent v_c și se evaluează v_c .
2. [Terminare] Dacă $T < \varepsilon$, atunci STOP.

3. [Explorare] Se alege dintre cei m vecini ai lui v_c unul v_n care diferă de v_c printr-un singur bit.
4. [Progresare] Dacă $f(v_c) < f(v_n)$, atunci se face $v_c = v_n$; altfel se generează un număr aleator r din intervalul $[0, 1)$ și dacă $r < \exp((f(v_n) - f(v_c))/T)$, atunci se face $v_c = v_n$.
5. [Reluare] Dacă v_c poate să fie îmbunătățită, atunci se trece la pasul 3.
6. [Ciclare] Se face $T = g(T, t)$ și $t = t + 1$ și se trece la pasul 2. ■

Funcția g din pasul 6 are proprietatea $g(T, t) < T$, pentru orice T și t . Variabila T limitează posibilitățile de *întoarcere*, adică posibilitatea de a considera combinații mai puțin performante decât cele cunoscute la momentul curent. Întoarcerea devine din ce în ce mai limitată pe măsură ce se consideră o generație de ordin mai mare. Când nu mai sunt posibilități de întoarcere ($T < \varepsilon$) explorarea se termină.

1.4.5. Observații și comentarii.

1. În unele probleme, datele au un caracter estimativ. În asemenea cazuri este indicat să se găsească o soluție euristică apropiată de cea optimală, obținută mai ușor decât una optimală (vezi de exemplu [SAH77]).

2. În [FIS80] sunt citate trei metode de analiză a algoritmilor: testul empiric, comportarea în cel mai rău caz și analiza probabilistă. Principalul avantaj al testării empirice constă în acuratețea ei. Măcar pentru problemele testate, performanța algoritmului este cert cunoscută. Pe de altă parte, testarea empirică este costisitoare și furnizează numai o informație de natură statistică a performanței euristicii.

Analiza comportării în cel mai rău caz are avantajul furnizării unei garanții privind abaterea maximală a euristicii față de soluția optimală, pentru *orice* problemă din clasa studiată. Această analiză furnizează de asemenea exemple pentru care euristica studiată se comportă în modul cel mai rău. Desavantajul major al analizei în cazul cel mai rău constă în faptul că nu este de obicei predictivă privind performanța în medie.

Analiza probabilistă corectează deficiența de mai sus, arătând cum se comportă euristica pentru probleme *tipice*. Limitarea majoră a analizei probabiliste constă în faptul că nu furnizează o funcție de densitate pentru datele problemei, alese de obicei sub o formă simplă. În afară de aceasta, cele mai multe rezultate probabiliste sunt asimptotice în mărimea problemei și nu sunt strict aplicabile problemelor de mărime finită.

O observație cu caracter general privind marginile în cazul cel mai rău, este că valorile lor sunt prea mari în comparație cu performanța medie sau cu o performanță considerată ca fiind acceptabilă.

2 PROBLEME COMBINATORIALE

2.1. Împerechere minimală

Punerea problemei. Fiind dat un număr par N de puncte situate într-un plan, se cere identificarea unei împărțiri în $N / 2$ perechi a acestor puncte astfel încât suma distanțelor dintre punctele perechilor să fie minimă. ■

Aplicații posibile: construirea circuitelor electrice și electronice, gruparea informațiilor în baze de date.




Fig. 2.1.

Euristica propusă se bazează pe următoarea procedură. Se aleg la întâmplare $2n$ puncte ce formează un ciclu de perechi alternativ conectate respectiv neconectate (vezi figura 2.1.a). Apoi se calculează suma lungimilor muchiilor ce conectează, respectiv, nu conectează puncte și care sunt desenate cu linii pline, respectiv, punctate. Dacă suma lungimilor muchiilor pline este mai mică decât suma lungimilor celor punctate, atunci se acceptă împerecherea construită. Altfel muchiile pline se

consideră întrerupte și reciproc (vezi figura 2.1.b), obținând astfel o valoare inițială mai bună pentru perechile considerate. Această operație se numește, în continuare, *rotirea* (engl. *rotation*) unui ciclu de perechi alternative.

Mai precis, alegerea ciclurilor se efectuează astfel. După ce a fost obținută o configurație de conexiuni, se elimină în mod arbitrar o conexiune după care unul dintre cele două puncte se notează cu “-” și se numește *coadă* și celălalt se notează cu “+” și se numește *cap* (vezi figura 2.2.).




Fig. 2.2.

În continuare se încearcă identificarea unui ciclu corect construit, adică format din muchii alternativ pline și punctate, pe calea conectării capului cu unul dintre nodurile anterioare, situate pe drumul coadă-cap. Un asemenea ciclu este arătat pe figura 2.3.a). Două exemple de cicluri necorect construite sunt arătate pe figurile 2.3.b) și 2.3.c). Într-o versiune mai eficientă, construirea ciclului se efectuează pe calea extinderii drumului inițial identificat în două direcții, atât dinspre capul cât și dinspre coada drumului.

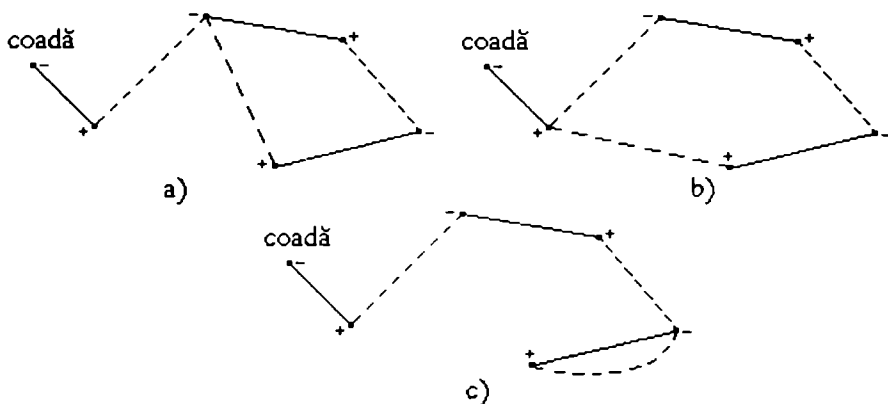


Fig. 2.3.

În cadrul algoritmului există mai multe detalii expuse în continuare.

1. La elaborarea configurației inițiale se poate adopta o strategie mai mult sau mai puțin *Greedy*, dar s-a constatat că viteza convergenței depinde foarte puțin de

acest factor. Din acest motiv, este acceptabil ca mulțimea inițială a perechilor să fie elaborată pe calea parcurgerii la întâmplare a punctelor (nodurilor) și identificarea succesivă a celui mai apropiat vecin. Dacă nu există vre-un vecin liber, atunci se alege la întâmplare un nod liber.

2. În testările efectuate, numărul de vecini a fost $K = 17$. Această alegere e motivată de faptul că în acest fel au putut fi analizate latices cu câte 20 000 de noduri.
3. Fiecărui nod din lista vecinilor i se atribuie o pondere care descrește cu distanța:

$$p_k = \text{const} \cdot e^{-\mu l_k},$$

unde, l_k este distanța la vecinul k , μ o constantă pozitivă și:

$$\sum_{k=1}^K p_k = 1.$$

Pentru selectarea nodului pereche au fost utilizate următoarele două metode:

- a) Folosind un generator (pseudo-)aleator, se identifică un k cu probabilitatea p_k . Dacă eticheta acestui nod este nepozitivă și dacă acest nod nu a fost mai înainte legat cu capul actual, atunci el este acceptat. Altfel căutarea este reluată până se identifică un nod acceptabil.
 - b) Se începe la fel ca mai sus. Dacă însă nodul are eticheta “+” sau este deja conectat cu capul, atunci se caută *Greedy* cel mai apropiat nod acceptabil. Testările efectuate au demonstrat că metoda b) este mai eficientă (mai rapidă) decât metoda a), dar nu într-un mod esențial.
4. După cum s-a mai amintit, continuarea căutării poate avea loc la ambele capete sau numai la capul drumului anterior identificat. Rezultatele obținute arată că prima strategie este ceva mai eficientă.
 5. Prima pereche ce este desfăcută (*brocken*) poate fi aleasă aleator, sau astfel încât lungimea muchiei corespunzătoare să fie mai scurtă sau mai lungă decât lungimea medie. Cu toate că s-ar părea că este mai eficientă alegerea unei muchii mai lungi, experiențele au demonstrat că prima pereche poate fi aleasă aleator.
 6. După construirea unui ciclu, se poate continua de la aceeași pereche inițială de noduri sau se caută altă pereche. A doua variantă s-a dovedit ceva mai eficientă decât prima.
 7. După ce a fost construit un ciclu, se poate trece la rotirea lui dacă această operație micșorează lungimea sau la identificarea altui ciclu. A doua variantă poate fi mai convenabilă, deoarece evită consumul de timp necesar identificării optimalității.

Algoritmul prezentat s-a dovedit foarte robust deoarece s-a comportat foarte bine în majoritatea testărilor. Folosind o structură de date adecvată programele ce corespund diferitelor variante ale algoritmului pot fi ușor construite și se dovedesc foarte eficiente.

2.2. Problema rucsacului

Problema rucsacului a mai fost abordată în în paragrafele 1.1.2.3.3. și 1.1.2.5.1. În continuare vom da alte metode de rezolvare și caracteristici ale soluțiilor ei.

2.2.1. Algoritm euristic eficient pentru problema rucsacului

Algoritmul 1.3. prezentat anterior poate avea o comportare arbitrar de neeficientă după cum se vede din exemplul următor.

Exemplul 2.1. Fie un număr întreg $x > 2$ oricât de mare și o problemă a rucsacului cu capacitatea $M = x$ și două obiecte ale căror ponderi sunt $w_1 = 1$ și $w_2 = x$ și cu profiturile $p_1 = 2$ și $p_2 = x$. Obiectele sunt deja ordonate necrescător în raport cu densitatea profitului deoarece $p_1 / w_1 = 2$ este mai mare decât $p_2 / w_2 = 1$. Prin aplicarea algoritmului 1.3. se plasează mai întâi primul obiect în rucsac deoarece $w_1 < M$ și algoritmul se termină cu profitul 2. Al doilea obiect nu se mai poate pune deoarece s-ar depăși capacitatea rucsacului. Evident că valoarea optimă se obține prin plasarea celui de al doilea obiect în rucsac, în acest caz obținând profitul x . Deci algoritmul Greedy furnizează o valoare de $x / 2$ ori mai mică decât cea optimă. ■

Algoritmul 1.3. poate fi modificat ușor pentru a obține o soluție mai bună în cazul în care nici un obiect nu are o pondere mai mare decât capacitatea rucsacului. De altfel astfel de obiecte ar putea să fie ignorate pentru că ele nu pot fi puse în rucsac în nici o soluție. Algoritmul transformat este următorul:

Algoritmul 2.1. $AL(I, p, w, M)$

1. [Profit maxim] Se determină valoarea maximă p_i a profitului dat de un obiect.
2. [Profit dat de L] Se determină valoarea v furnizată de algoritmul 1.3.
3. [Terminare] Se furnizează cea mai mare dintre valorile determinate în pașii 1 și 2, apoi STOP. ■

Teorema 2.1. Soluția furnizată de algoritmul 2.1. este cel puțin jumătate din soluția optimală.

Demonstrație. Fie opt soluția optimală și sol cea furnizată de algoritm. Fie l cel mai mic întreg astfel încât $\sum_{i=1}^l w_i > M$ în ipoteza că rucsacul nu poate conține toate obiectele. Fie apoi o problemă modificată care folosește aceleași obiecte dar capacitatea rucsacului are valoarea $M' = \sum_{i=1}^l w_i$. În acest caz, algoritmul Greedy furnizează soluția optimală (vezi [HOR78]) având valoarea $opt' = \sum_{i=1}^l p_i$. Este evident că soluția problemei originale nu poate fi mai mare decât cea a problemei modificate,

deci $opt \leq opt'$. Pe de altă parte $v \geq \sum_{i=1}^{l-1} p_i$, unde v este valoarea din pasul 2, deoarece algoritmul 1.3. va introduce sigur primele $l - 1$ obiecte în rucsac înainte de a eșua plasarea obiectului l . În plus $p_i \geq p_l$, unde p_i este cea mai mare valoare a profitului determinată în pasul 1 al algoritmului. Ținând seama de cele menționate mai sus și de inegalitatea:

$$\max\{x, y\} \geq (x + y) / 2,$$

rezultă că:

$$sol = \max\{p_l, v\} \geq (p_l + v) / 2 \geq (p_l + \sum_{i=1}^{l-1} p_i) / 2 = \sum_{i=1}^l p_i / 2 = opt' / 2 \geq opt / 2,$$

adică algoritmul 2.1. dă o soluție egală cu cel puțin jumătate din cea optimală. ■

2.2.2. Algoritm aproximativ polinomial pentru problema rucsacului

Algoritmul ce urmează furnizează o soluție ε -aproximativă pentru problema rucsacului cu n obiecte, unde: $E_n = \{1, 2, \dots, n\}$ este mulțimea obiectelor, $w_i \in \mathbb{Z}^+$ sunt greutatea, $p_i \in \mathbb{Z}^+$ sunt profiturile obiectelor și $M \in \mathbb{Z}^+$ este capacitatea rucsacului. Se presupune că $w_i \leq M$, pentru $i = 1, 2, \dots, n$. Acest algoritm este *polinomial aproximativ* în sensul că necesită un timp polinomial în mărimea l a datelor problemei rezolvate.

Algoritmul 2.2. (Rucsac)

- [Inițializări] $P_{\max} = 0, k = \lceil 1 / \varepsilon \rceil - 1$.
- [Ordonare] Se sortează obiectele după densitatea profiturilor astfel încât $p_1 / w_1 \geq p_2 / w_2 \geq \dots \geq p_n / w_n$.
- [Ponderi] Pentru fiecare submulțime $S \subseteq E_n$ cu $|S| \leq k$ și $\sum_{i \in S} w_i \leq M$ se face:

$$P = \sum_{i \in S} p_i; W = \sum_{i \in S} w_i.$$

- [Ciclare] Pentru $j = 1, 2, \dots, n$: Dacă $j \notin S$ și $W + w_j \leq M$, atunci, se face:

$$P = P + p_j; W = W + w_j; P_{\max} = \max(P_{\max}, P).$$

- [Terminare] Se furnizează P_{\max} și STOP. ■

Algoritmul enumeră toate submulțimile cu k ori mai puține elemente, după care o procedură greedy este aplicată fiecărei asemenea submulțimi. Se poate arăta că, pentru $k = \lceil 1 / \varepsilon \rceil - 1 \leq n$, acest algoritm este polinomial.

2.2.3. Teste de realizabilitate

Punerea problemei. Să se deducă margini inferioare pentru timpul necesar găsirii de soluții aproximative ale problemei rucsacului pentru algoritmi ce folosesc oracole în vederea efectuării testelor de realizabilitate (*feasability*) și dominanță. ■

În teorema ce urmează se deduce o margine inferioară a programelor ce folosesc teste de realizabilitate dar nu și teste de dominanță, și nu se utilizează ordonarea obiectelor după densitatea profitului. O submulțime $S \subseteq E_n$ este realizabilă dacă satisface condiția, folosită în programul de mai înainte, $\sum_{i \in S} w_i \leq M$. În caz contrar, mulțimea S se numește nerealizabilă. Pentru orice $S \subseteq E_n$, se definesc mărimile $w(S) = \sum_{i \in S} w_i$ și $p(S) = \sum_{i \in S} p_i$. Cu $R_{w,M}$ se notează un oracol în care sunt memorate w_1, w_2, \dots, w_n și M . Oracolul de realizabilitate folosit în continuare este definit astfel:

$$R_{w,M}(S) = \begin{cases} <, & \text{dacă } w(S) < M, \\ =, & \text{dacă } w(S) = M, \\ >, & \text{dacă } w(S) > M. \end{cases}$$

Un asemenea oracol este mai riguros decât oracolele “da-nu” folosite în schemele aproximative. Mai jos se folosește notația $\gamma = \lceil 1 / \varepsilon \rceil - 1$.

Teorema 2.2. Orice algoritm ε -aproximativ, adică un algoritm care furnizează o soluție realizabilă cu eroarea ε , $0 < \varepsilon < 1$, pentru problema rucsacului, care are acces la w_i și M numai prin intermediul unui oracol de realizabilitate, folosește cel puțin $\binom{n}{\gamma}$ apelări ale oracolului.

Demonstrație. Pentru $n \geq 2$ și $0 < \varepsilon < 1$, fie $m \in \mathbb{Z}^+$, astfel încât $1 \leq m < 1 / \varepsilon$ și $|n / 2 - m|$ să fie minimală. Dacă $2 / (n + 2) \leq \varepsilon < 1$, adică $n / 2 + 1 \geq 1 / \varepsilon > 1$, atunci $m = \gamma$. Dacă $0 < \varepsilon < 2 / (n + 2)$, atunci $m = \lceil n / 2 \rceil$. În ambele cazuri, $\binom{n}{m} \geq \binom{n}{\gamma}$.

Demonstrația teoremei constă în a arăta că nici un algoritm care are acces numai la w_i și M , prin intermediul oracolului descris, nu poate garanta faptul că eroarea relativă a soluției furnizate este mărginită de ε , dacă acest algoritm folosește mai puțin de $\binom{n}{m}$ apeluri la oracol.

Fie A un algoritm ε -aproximativ care apelează oracolul său de $r < \binom{n}{m}$ ori. Fie o problemă a rucsacului cu $p_i = 1$; $w_i = 2$; pentru $i = 1, 2, \dots, n$ și $M = 2m - 1$. Evident că $R_{w,M}$ furnizează răspunsul “<” pentru orice $S \subseteq E_n$ cu $|S| < m$ și răspunsul “>” pentru orice $S \subseteq E_n$ cu $|S| \geq m$. Pentru intrarea I , algoritmul A apelează pe $R_{w,M}$ pentru mulțimile S_1, S_2, \dots, S_r , unde $S_i \subseteq E_n$, și furnizează răspunsul realizabil S_{r+1} . Deoarece $\binom{n}{m} > r$ și $|S_{r+1}| < m$, pentru că S_{r+1} este realizabil, rezultă că există o submulțime $S_0 \subseteq E_n$ astfel încât $|S_0| = m$ și $S_0 \neq S_i$, $1 \leq i \leq r + 1$. Fie acum intrarea I' definită prin:

$$w'_i = \begin{cases} m, & \text{dacă } i \in S_0, \\ m + 1, & \text{dacă } i \notin S_0, \end{cases} \quad M' = w'(S_0) = m^2 \text{ și } p'_i = p_i, \text{ pentru } i = 1, 2, \dots, n.$$

Pentru fiecare S_i , $1 \leq i \leq r$,

$$|S_i| < m \text{ implică } w'(S_i) \leq (m+1) \cdot |S_i| \leq (m+1)(m-1) = m^2 - 1 \leq M'$$

și, deoarece fiecare S_i , $1 \leq i \leq r$, cu $|S_i| \geq m$, diferă de S_0 măcar cu un obiect,

$$|S_i| \geq m \text{ implică } w'(S_i) \geq (m+1) + m \cdot (|S_i| - 1) \geq (m+1) + m(m-1) = m^2 + 1 > M'.$$

Prin urmare, pentru fiecare S_i , $1 \leq i \leq r$, $R_{w',M}(S_i) = R_{w,M}(S_i)$. Deoarece oracolele $R_{w,M}$ și $R_{w',M}$ se comportă la fel pentru fiecare S_i , $1 \leq i \leq r$ și $p_i = p'_i$, $1 \leq i \leq n$, rezultă că algoritmul A nu poate distinge pe I de I' în r apeluri ale oracolului și furnizează același răspuns S_{r+1} pentru ambele probleme. Deoarece S_{r+1} este realizabil pentru I , rezultă că $|S_{r+1}| < m$, astfel încât $p'(S_{r+1}) \leq m - 1$. Atunci eroarea relativă a lui S_{r+1} pentru problema I' este:

$$\frac{p'(S_0) - p'(S_{r+1})}{p'(S_0)} \geq \frac{m - (m-1)}{m} = \frac{1}{m} > \varepsilon,$$

ceea ce contrazice ipoteza că A este un algoritm cu oracole ε -aproximativ. Deoarece m a fost ales astfel încât $\binom{n}{m} \geq \binom{n}{\gamma}$, rezultă că $\binom{n}{\gamma}$ este o margine inferioară pentru numărul de apeluri ale oracolului în vederea garantării unei erori nu mai mari decât ε . ■

2.2.4. Cazul densităților ordonate ale profitului

În ipoteza că densitățile profiturilor sunt preordonate, adică ordonate înainte de aplicarea algoritmului, ca în paragraful 2.2., are loc teorema ce urmează.

Teorema 2.3. Orice algoritm ε -aproximativ pentru problema rucsacului, care are acces la w_i și M numai prin intermediul unui oracol de realizabilitate, folosește cel puțin $\binom{n}{\gamma}$ apelări ale oracolului, chiar dacă obiectele la intrare sunt sortate astfel încât $p_i / w_i \geq p_{i+1} / w_{i+1}$, pentru $i = 1, 2, \dots, n - 1$.

Demonstrație. Pentru $n \geq 2$ și $0 < \varepsilon < 1$ se identifică un $m \in \mathbb{Z}^+$ astfel încât $1 \leq m < 1/\varepsilon$ și $|n/2 - m|$ este minimală (ca în teorema 2.2.). Să presupunem că A este un algoritm cu oracole ε -aproximativ care apelează oracolul său de realizabilitate de $r < \binom{n}{m}$ ori. Fie x cel mai mic întreg astfel încât:

$$x > \frac{(n-1)(m-1)}{1-m\varepsilon} \geq 0.$$

Fie apoi I problema rucsacului cu $p_i = x + n + i$, $w_i = 2$, pentru $i = 1, 2, \dots, n$ și $M = 2m - 1$. Deoarece $p_i > p_{i+1}$ și $w_i = w_{i+1}$, pentru $1 \leq i < n$, rezultă $p_i / w_i \geq p_{i+1} / w_{i+1}$, pentru $1 \leq i < n$, așa cum se presupune în enunțul teoremei. Ca și în teorema 2.2., $R_{w,M}$ furnizează răspunsul “<” pentru orice $S \subseteq E_n$ cu $|S| < m$ și răspunsul “>” pentru orice

$S \subseteq E_n$ cu $|S| \geq m$. Algoritmul A apelează pe $R_{w,M}$ pentru mulțimile S_1, S_2, \dots, S_r , unde $S_i \subseteq E_n$, și furnizează soluția realizabilă S_{r+1} . Deoarece $\binom{n}{m} > r$ și $|S_{r+1}| < m$, există o submulțime $S_0 \subseteq E_n$ astfel încât $|S_0| = m$ și $S_0 \neq S_i, 1 \leq i \leq r + 1$. Fie acum altă problemă P cu:

$$w'_i = \begin{cases} x+n-2, & \text{dacă } i \in S_0, \\ x+n-1, & \text{dacă } i \notin S_0, \end{cases} \quad M' = w'(S_0) = m(x+n-2) \text{ și } p'_i = p_i = x+n-1, 1 \leq i \leq n.$$

Pentru orice $1 \leq i \leq r$ au loc relațiile:

$$\frac{p'_i}{w'_i} \geq \frac{x+n-i}{x+n-1} \text{ și } \frac{p'_{i+1}}{w'_{i+1}} \geq \frac{x+n-i-1}{x+n-2},$$

de unde, așa cum s-a cerut,

$$\frac{p'_i w'_{i+1}}{w'_i p'_{i+1}} \geq 1 \text{ și } \frac{p'_i}{w'_i} \geq \frac{p'_{i+1}}{w'_{i+1}}, 1 \leq i \leq n.$$

Pentru fiecare $S_i, 1 \leq i \leq r$:

$$|S_i| < m \text{ implică } w'(S_i) \leq (x+n-1) \cdot |S_i| \leq (x+n-1)(m-1) = M' - ((x+n) - (m+1)).$$

În continuare, $m > 0, \varepsilon > 0$ și $m < 1 / \varepsilon$ implică $0 < m \varepsilon < 1$, de unde:

$$x > \frac{(n-1)(m-1)}{1-m\varepsilon} > (n-1)(m-1) \text{ și } (x+n) - (m+1) > nm - 2m \geq 0, \text{ pentru orice } n \geq 2.$$

Rezultă că $|S_i| < m$ implică $w'(S_i) < M'$. Deoarece fiecare $S_i, 1 \leq i \leq r$, cu $|S_i| \geq m$ diferă de S_0 măcar cu un obiect, $|S_i| \geq m$ și $S_0 \neq S_i$ implică:

$$\begin{aligned} w'(S_i) &\geq (x+n-1) + (x+n-2)(|S_i| - 1) \\ &\geq (x+n-1) + (x+n-2)(m-1) = m(x+n-2) + 1 > M'. \end{aligned}$$

Prin urmare, pentru fiecare $S_i, 1 \leq i \leq r, R_{w',M'}(S_i) = R_{w,M}(S_i)$. Deoarece oracolele $R_{w,M}$ și $R_{w',M'}$ se comportă la fel pentru orice $S_i, 1 \leq i \leq r$, și $p_i = p'_i$, pentru $1 \leq i \leq n$, și ambele mulțimi de obiecte sunt sortate conform densității profiturilor, algoritmul A nu poate distinge problemele I și P în r apeluri ale oracolului și furnizează aceeași soluție S_{r+1} .

Deoarece S_{r+1} este realizabilă pentru I , rezultă că $|S_{r+1}| < m$. Rezultă că o margine slabă (engl. *loose bound*) pentru $p'(S_{r+1})$ este:

$$p'(S_{r+1}) \leq (m-1) \max_{1 \leq i \leq n} p'_i = (m-1)(x+n-1).$$

Faptul că S_0 este o soluție realizabilă pentru P și $|S_0| = m$, implică:

$$p'(S_0) \geq m \min_{1 \leq i \leq n} p'_i = m x.$$

Eroarea relativă a lui S_{r+1} ca soluție pentru problema P este, prin urmare, cel puțin egală cu:

$$\frac{p'(S_0) - p'(S_{r+1})}{p'(S_0)} \geq \frac{mx - (m-1)(x+n-1)}{mx} = \frac{1}{m} - \frac{(n-1)(m-1)}{mx} > \frac{1}{m} - \frac{1-m\varepsilon}{m} = \varepsilon.$$

Acest rezultat contrazice ipoteza că A este un algoritm ε -aproximativ cu oracole și, prin urmare, marginea inferioară este egală cu $\binom{n}{\nu}$. ■

2.2.5. Algoritmi genetici pentru problema rucsacului

Vom considera trei tipuri de probleme ale rucsacului și anume:

1. *Problema necorelată*, în care atât w_i cât și p_i , pentru $i = 1, 2, \dots, n$, iau valori aleatoare din intervalul $[1, \nu]$, unde ν este un număr natural dat.
2. *Problema cu corelație slabă*, în care w_i , pentru $i = 1, 2, \dots, n$, iau valori aleatoare din intervalul $[1, \nu]$, unde ν este un număr natural dat, și $p_i = w_i + u_i$, unde u_i este un număr aleator din intervalul $[-r, r]$, cu r număr natural dat, pentru $i = 1, 2, \dots, n$.
3. *Problema cu corelație tare*, în care w_i , pentru $i = 1, 2, \dots, n$, iau valori aleatoare din intervalul $[1, \nu]$, unde ν este un număr natural dat, și $p_i = w_i + r$, unde r este un număr natural dat, pentru $i = 1, 2, \dots, n$.

Cu cât corelația este mai mare, cu atât este mai mică diferența:

$$\max_i p_i / w_i - \min_i p_i / w_i,$$

de unde rezultă că o problemă cu o corelație mai mare este, în general, mai dificilă.

În experimentările făcute s-a considerat $\nu = 10$ și $r = 5$. Pentru teste au fost folosite câte trei rânduri de date pentru fiecare tip de problemă având un număr de elemente $n = 100, 250$ și, respectiv, 500 . Se pot considera două tipuri de probleme:

- *rucsac de capacitate restrictivă* în care capacitatea rucsacului este $M_1 = 2\nu$; în acest caz soluția optimă conține numai câteva elemente;
- *rucsac de capacitate aleatoare* în care capacitatea rucsacului este $M_2 = \frac{1}{2} \sum_{i=1}^n w_i$; în acest caz soluția optimă conține circa jumătate dintre elemente.

Au fost concepute trei tipuri de algoritmi: algoritmi $A_p(i)$ bazați pe funcții de penalitate, algoritmi $A_r(i)$ bazați pe metode de rectificare și algoritmi $A_d(i)$ bazați pe decodificatori. Vom prezenta în continuare aceste tipuri de algoritmi.

Algoritmii $A_p(i)$. În acești algoritmi, soluțiile sunt reprezentate sub forma unor vectori x cu n elemente cu valori 0 și 1 ; se selectează al i -lea element pentru a fi pus în rucsac dacă și numai dacă $x_i = 1$. Evaluarea unui vector x se face după formula:

$$eval(x) = \sum_{i=1}^n x_i p_i - pen(x),$$

unde funcția de penalitate $pen(x)$ este 0 pentru orice soluție corectă x , adică acelea pentru care $\sum_{i=1}^n x_i w_i \leq M$, și fiind strict pozitivă în caz contrar. Se pot folosi mai multe

strategii pentru calculul penalităților. Următoarele trei exemple consideră creșterea penalității logaritmice, liniară și, respectiv pătratic, în raport de măsura depășirii:

$$A_p(1): \text{pen}(x) = \log_2(1 + \rho(\sum_{i=1}^n x_i w_i - M)),$$

$$A_p(2): \text{pen}(x) = \rho(\sum_{i=1}^n x_i w_i - M),$$

$$A_p(3): \text{pen}(x) = (\rho(\sum_{i=1}^n x_i w_i - M))^2.$$

În formulele anterioare s-a notat $\rho = \max_i p_i / w_i$.

Algoritmii $A_p(i)$. În acești algoritmi, soluțiile sunt reprezentate tot sub forma unor vectori x cu n elemente cu valori 0 și 1; se selectează al i -lea element pentru a fi pus în rucsac dacă și numai dacă $x_i = 1$. Evaluarea unui vector x se face după formula:

$$\text{eval}(x) = \sum_{i=1}^n x'_i p_i,$$

unde x' este versiunea rectificată a vectorului original x . Sunt două probleme de rezolvat în acest caz. În primul rând trebuie să fie stabilită o strategie de rectificare și în al doilea rând trebuie stabilită probabilitatea cu care vectorul rectificat înlocuiește vectorul din care provine în populație. Această probabilitate poate fi cuprinsă între 0 și 1. Orvosh și Davis au stabilit *regula 5%* prin care se stabilește că cele mai bune rezultate se obțin dacă se consideră probabilitatea de înlocuire de 0.05.

Procesul de rectificare se desfășoară după următorul algoritm:

Algoritm 2.3. (Rectificare)

1. [Inițializare] Se face $x' = x$.
2. [Terminare] Dacă $\sum_{i=1}^n x'_i w_i \leq M$, atunci STOP.
3. [Alegere] Se alege un element i din rucsac, adică un indice cu $x'_i = 1$.
4. [Eliminare] Se elimină elementul i din rucsac, adică se face $x'_i = 0$.
5. [Ciclare] Se merge la pasul 2. ■

Dintre strategiile de alegere din pasul 3 se pot menționa următoarele două care duc la două tipuri de algoritmi prin rectificare:

- $A_p(1)$ (*rectificare aleatoare*): alegerea se face aleator.
- $A_p(1)$ (*rectificare Greedy*): alegerea se face prin luarea în considerare a elementului cu cel mai mic profit dintre cele din rucsac; dacă sunt mai multe cu același profit se alege oricare dintre ele.

Algoritmii $A_p(i)$. Cei mai naturali decodificatori pentru problema rucsacului se bazează pe reprezentarea întreagă. Fiecare cromozom este un vector de n întregi,

cel de al i -lea element al vectorului fiind un întreg cuprins între 1 și $n - i + 1$. Reprezentarea aceasta se pune în legătură cu o listă de elemente L . Vectorul se decodifică prin considerarea și eliminarea din lista curentă a elementului respectiv. De exemplu, începând cu lista $L = (1, 2, 3, 4, 5, 6)$, vectorul $x = (4, 3, 4, 1, 1)$ se decodifică astfel: se consideră 4 obținând lista $L = (1, 2, 3, 5, 6)$, se consideră 3 obținând lista $L = (1, 2, 5, 6)$, se consideră 6 obținând lista $L = (1, 2, 5)$, se consideră 1 obținând lista $L = (2, 5)$, se consideră 2 obținând lista $L = (5)$ și, în final, se consideră 5 obținând lista $L = ()$. Deci decodificarea vectorului este $(4, 3, 6, 1, 2, 5)$.

Fiecare cromozom poate fi interpretat ca o strategie de introducere a elementelor în rucsac. În plus, aplicarea unei încrucișeri între doi cromozomi fezabili produce tot cromozomi fezabili. Operatorul mutație se definește similar ca pentru cazul binar: se alege la întâmplare pentru poziția i orice număr cuprins între 1 și $n - i + 1$. Algoritmul de decodificare este următorul:

Algoritmul 2.4. (Decodificare)

1. [Inițializare] Se construiește o listă de elemente L , se face $i = 1$, $W = 0$ și $P = 0$.
2. [Terminare] Dacă $i > n$, atunci STOP.
3. [Eliminare] Se face $j = L(x_i)$ și se elimină al x_i -lea element din lista L .
4. [Adăugare] Dacă $W + w_j \leq M$, atunci se face $W = W + w_j$ și $P = P + p_j$ (se adaugă elementul j la rucsac).
5. [Ciclare] Se face $i = i + 1$ și se merge la pasul 2. ■

Algoritmii bazați pe decodificare diferă doar prin modul de construire a listei L . Pot fi considerate, de exemplu următoarele două strategii:

- $A_d(1)$ (decodificarea aleatoare): se consideră o ordine aleatoare a elementelor, de exemplu ordinea de intrare.
- $A_d(1)$ (decodificarea Greedy): se pun în lista L în ordinea descrescătoare a profiturilor; dacă sunt mai multe elemente cu același profit se consideră o ordine oarecare.

S-au făcut experimentări pe populații de 100 de cromozomi cu probabilitatea de mutație 0.05 și probabilitatea de încrucișare 0.65. Măsurarea performanțelor a fost făcută prin reținerea celor mai bune soluții obținute din câte 500 de generații. S-a observat că pentru un număr mai mare de generații se produc, în general, puține modificări. Rezultatele prezentate în tabelul 2.1. reprezintă valorile medii din câte 25 de experimente. Datele nu au fost sortate în raport de profit. Tipul de capacitate M_1 este cazul capacității restrictive și M_2 este cazul cu capacitate aleatoare. Rezultatele din metodele $A_d(1)$ și $A_d(2)$ s-au obținut aplicând regula 5%. Orice alte probabilități de alegere a înlocuirii prin vector rectificat dau diferențe nesemnificative.

Corelație	Număr elem.	Tip capac.	metoda						
			$A_p(1)$	$A_p(2)$	$A_p(3)$	$A_r(1)$	$A_r(2)$	$A_d(1)$	$A_d(2)$
deloc	100	M_1	X	X	X	62.9	94.0	63.5	59.4
		M_2	398.1	341.3	342.6	344.6	371.3	354.7	353.3
	250	M_1	X	X	X	62.6	135.1	58.0	60.4
		M_2	919.6	837.3	825.5	842.2	894.4	867.4	857.5
	500	M_1	X	X	X	63.9	156.2	61.0	61.4
		M_2	1712.2	1570.8	1565.1	1577.4	1663.2	1602.8	1597.0
slab	100	M_1	X	X	X	39.7	51.0	38.2	38.4
		M_2	408.5	327.0	328.3	330.1	358.2	333.6	332.3
	250	M_1	X	X	X	43.7	74.0	42.7	44.7
		M_2	920.8	791.3	788.5	798.4	852.1	804.4	799.0
	500	M_1	X	X	X	44.5	93.8	43.2	44.5
		M_2	1729.0	1531.8	1532.0	1538.6	1624.8	1548.4	1547.1
tare	100	M_1	X	X	X	61.6	90.0	59.5	59.5
		M_2	741.7	564.5	564.4	566.5	577.0	576.2	576.2
	250	M_1	X	X	X	65.5	117.0	65.5	64.0
		M_2	1631.9	1339.5	1343.4	1345.8	1364.4	1366.4	1359.0
	500	M_1	X	X	X	67.5	120.0	67.1	64.1
		M_2	3051.6	2703.8	2700.8	2709.5	2748.1	2738.0	2744.0

Tabelul 2.1.

Principalele concluzii ce se pot trage din experimentări sunt următoarele:

- Algoritmii bazați pe penalități nu determină rezultate fezabile pentru problemele cu capacitate restrictivă (M_1) oricare ar fi numărul de elemente sau corelația.
- Pentru problemele cu capacitatea aleatoare a rucsacului (M_2) cele mai bune rezultate au fost obținute prin algoritmul cu penalitate logaritmică $A_p(1)$.
- Pentru problemele cu capacitatea rucsacului restrictivă (M_1) cele mai bune rezultate au fost obținute prin algoritmul cu rectificare Greedy $A_r(2)$.

2.3. Algoritmi aproximativi pentru probleme de aritmetică combinatorie

Punerea problemei. Se prezintă o tehnică generală de aproximare pentru o clasă largă de probleme NP-dificile în cadrul cărora se efectuează calcule aritmetice. Drept probleme reprezentative cunoscute se menționează problema rucsacului și cea a produsului submulțimilor. ■

Aplicații posibile: compilatoare de limbaje de programare, programarea calculatoarelor.

În continuare vom folosi notațiile:

$P_0(A)$ - mulțimea submulțimilor finite ale lui A ;

t - funcție cu valori în $P_0(\mathbb{Z}^+)$ calculată în timp polinomial cu algoritm nedeterminist;

$(A, t)_{Ext}$ - problemă de optimizare NP, unde $Ext = \max$ sau $Ext = \min$.

$sol(a)$ - soluție a problemei $(A, t)_{Ext}$.

$op(a)$ - soluție optimă a problemei $(A, t)_{Ext}$.

Ap - algoritm aproximativ.

2.3.1. Modul de prezentare al calculelor

Fie dată $(a_1, a_2, \dots, a_k) \in (\mathbb{Z}^+)^k$ și $k - 1$ operații binare $\beta_1(x, y), \dots, \beta_{k-1}(x, y)$, nu neapărat distincte, definite pe întregi. Fiecărei secvențe $(a_1, \beta_1, a_2, \beta_2, \dots, a_{k-1}, \beta_{k-1}, a_k)$ i se asociază o secvență de calcule (m_1, m_2, \dots, m_k) definită astfel:

a) $m_1 = a_1$.

b) pentru $i = 1, \dots, k - 1, m_{i+1} = \beta_i(m_i, a_{i+1})$.

De exemplu, pentru secvența de calcule $(3, x^y, 2, x + y, 1)$, secvența rezultatelor succesive este $(3, 9, 10)$. Valoarea lui m_k se numește *rezultatul calculelor*.

Definiția 2.1. Pentru o mulțime dată B de operații binare, *problema Pr1(B)* este următoarea: fiind dată secvența (a_1, \dots, a_n, b) , să se găsească cel mai mare întreg k pentru care sunt satisfăcute condițiile:

1. pentru un $i_0 \in \{1, 2, \dots, n\}$, k este rezultatul calculului efectuat cu secvența $(a_{i_0}, a_{i_0+1}, \dots, a_n)$ pe B , și
2. $k \leq b$. ■

Fie operația binară u_1 definită astfel: $u_1(x, y) = x$. În acest caz, $Pr1(u_1, x, y)$ este o versiune a problemei rucsacului numită *problema submulțimii de sumă maximă* și care se formulează astfel: fiind dată secvența (a_1, \dots, a_n, b) , să se maximizeze $\sum \varepsilon_i p_i$ cu $\varepsilon_i \in \{0, 1\}$ astfel încât $\sum \varepsilon_i a_i \leq b$.

Definiția 2.2. Operația $\beta \in B$ este *crescătoare* dacă $\beta(x, y) \geq x$ pentru toți $x, y > 0, x, y \in \mathbb{Z}$. ■

Operațiile $x + y, xy, x^y, y^x, u_1$ sunt crescătoare, pe când $x - y$ și $y - x$ nu sunt crescătoare.

În continuare, se prezintă un algoritm care, pentru fiecare secvență $a = (a_1, a_2, \dots, a_n, b)$ furnizează valoarea lui $op(a)$ într-un timp de ordinul $O(n \cdot op(a) \log op(a))$.

Algoritmul 2.4. (Calcul-optim) Intrare : $a = (a_1, \dots, a_m, b)$. Ieșire : $op(a)$.

- [Inițializări] Se face $i = 1$ și $T = \emptyset$.
- [Completare T] Dacă $T \neq \emptyset$, atunci, pentru fiecare s din T , se face:

$$T = T \cup \{\beta(s, a_i) \mid \beta \in B \text{ și } \beta(s, a_i) \leq b\}.$$
- [Adăugare element nou] Se face $T = T \cup \{a_i\}$.
- [Terminare] Dacă $i = n$, atunci STOP (furnizează $\max(T)$).
- [Ciclare] Se face $i = i + 1$ și se merge la pasul 2. ■

Este ușor de văzut că la terminarea parcurgerii algoritmului 2.4. valoarea lui $\max(T)$ este $op(a)$. Utilizând o structură convenabilă pentru reprezentarea lui T (de exemplu, arborii 2-3 din paragrafele 4.9-4.10 din [AHO74]) se poate arăta că timpul de execuție al pașilor 2-5 este de ordinul $O(|B| |T| \log|T|)$. Timpul de execuție al celorlalți pași este constant. $|B|$ este constant, deoarece T conține numai întregi pozitivi mai mici sau egali cu $op(a)$ pe tot parcursul executării algoritmului. Rezultă că timpul de execuție al algoritmului este de ordinul $O(n op(a) \log op(a))$.

2.3.2. Metoda condensării

Definiția 2.3. Fie (m_1, m_2, \dots, m_k) secvența rezultatelor obținute după efectuarea calculelor descrise de $(a_1, \beta_1, a_2, \beta_2, \dots, a_{k-1}, \beta_{k-1}, a_k)$ și fie $0 < \delta \leq 1$. O secvență $(m'_1, m'_2, \dots, m'_k)$ este o δ -condensare a secvenței (m_1, m_2, \dots, m_k) dacă există o secvență $(h_1, h_2, \dots, h_k) \in \mathbb{R}^k$ cu $0 \leq h_i \leq \delta$, astfel încât:

$$a) m'_i = m_i (1 - h_i) = a_i (1 - h_i),$$

$$b) m'_{i+1} = \left[\beta_i(m'_i, a_{i+1}) \right] (1 - h_{i+1}), \text{ pentru } i = 1, 2, \dots, k - 1. \blacksquare$$

Definiția 2.4. Un algoritm A_p este ε -aproximativ pentru probleme $(A, t)_{\max}$, dacă pentru toți $a \in A$, $A_p(a) \in t(a)$ și $A_p(a) \geq (1 - \varepsilon) op(a)$. ■

Definiția 2.5. Un algoritm $(A, t)_{\max}$ este *complet aproximativ* dacă pentru orice $\varepsilon > 0$ există un algoritm ε -aproximativ al lui $(A, t)_{\max}$ având complexitatea $Q(l(a), 1/\varepsilon)$, unde Q este un polinom în două variabile și $l(a)$ este lungimea lui a . ■

Algoritmul 2.3. descris în continuare este un algoritm complet polinomial pentru $Pr1(B)$, unde B este orice submulțime a lui $\{x + y, xy, u_1\}$.

Algoritmul 2.5. (Calcul-limită): Intrare : $a = (a_1, \dots, a_m, b) \in (\mathbb{Z}^+)^{m+1}$, $\varepsilon > 0$.

Ieșire: un întreg $k \in t(a)$ astfel încât $op(a) \geq k \geq op(a) (1 - \varepsilon)$.

- [Inițializare] Se face $r = \max(1/\varepsilon, n)$, $\delta = 1 / r^2$ (δ este parametrul de condensare), $i = 1$ și $T = \emptyset$.

2. [Completare] Dacă $T \neq \emptyset$, atunci se face: $T = T \cup \{\beta(s, a_i) \mid \beta \in B \text{ și } \beta(s, a_i) \leq b\}$, pentru fiecare s din T .
3. [Adăugare element nou] Se face $T = T \cup \{a_i\}$.
4. [Sortare] Se sortează T (se presupune că $T = (s_1, \dots, s_k)$, $s_i < s_{i+1}$).
5. [Terminare] Dacă $i = n$, atunci STOP (furnizează S_i).
6. [Inițializare condensare] Se face $j = 1, k = 2$.
7. [Eliminări] Atâta timp cât $k \leq t$ și $s_j / s_k > 1 - \delta$, se face $T = T - \{s_k\}$ și $k = k + 1$.
8. [Ciclare eliminări] Dacă $k < t$, atunci se face $j = k$ și $k = k + 1$ și se merge la pasul 7.
9. [Ciclare] Se face $i \leftarrow i + 1$ și se merge la pasul 2. ■

Teorema 2.4. Pentru fiecare $\varepsilon > 0$, algoritmul 2.5. dă o ε -aproximare pentru $Pr1(B)$, unde $B \subset \{x + y, xy, u_i\}$ de complexitate $O(\max\{l^A(a), l^2(a) / \varepsilon\})$ în timp. ■

Exemplul 2.2. Modul în care operează algoritmul 2.4. poate fi ilustrat pe următorul exemplu al problemei rucsacului: $(a_1, a_2, a_3, a_4, b) = (1, 3, 4, 6, 7)$.

i	a_i	T
1	1	$T = \emptyset, T = \{1\}$
2	3	$T = \{1\} \cup \{1 + 3\}, T = \{1, 1 + 3, 3\}$
3	4	$T = \{1, 1 + 3, 3, 1 + 4, 3 + 4\}, T = \{1, 1 + 3, 3, 1 + 4, 3 + 4, 4\}$
4	6	$T = \{1, 1 + 3, 3, 1 + 4, 3 + 4, 4, 1 + 6\}$

Tabelul 2.2.

Modul de efectuare a calculelor este prezentat în tabelul 2.2. Rezultă soluțiile: $3 + 4 = 7$ și $1 + 6 = 7$. Mulțimea T a elementelor distincte este $T = \{1, 4, 3, 5, 7\}$ și se vede că $|T| = 5 \leq op(a)$.

2.4. Selectarea și ordonarea dispozitivelor de orientare

Punerea problemei. Pentru asamblarea automată a unor aparate este necesară alimentarea mașinilor de montaj cu piesele componente corect orientate. Orientarea acestor piese se realizează cu ajutorul unor dispozitive conectate în serie, fiecare dispozitiv efectuând o anumită operație de orientare. Problema de rezolvat constă în calculul eficienței unui șir de dispozitive de orientare, adică a probabilității unei orientări corecte a unei piese după parcurgerea dispozitivelor. ■

Aplicații posibile: fluxuri de producție, formarea garniturilor de tren.

Enunțul problemei pentru două orientări. Pentru cazul, cel mai simplu, a două orientări, o mulțime $N = \{1, 2, \dots, n\}$ de dispozitive și o mulțime $M = \{1, 2, \dots, m\}$ de piese, eficiența unui dispozitiv este definită, pentru fiecare $i \in N, j \in M$, de o matrice 2×2 de forma:

$$P_{ij} = \begin{bmatrix} a_{ij} & b_{ij} \\ c_{ij} & d_{ij} \end{bmatrix},$$

cu condițiile $0 \leq a_{ij}, b_{ij}, c_{ij}, d_{ij} \leq 1$, $a_{ij} + b_{ij} \leq 1$, $c_{ij} + d_{ij} \leq 1$. Fie η_j probabilitatea ca o piesă de tip j să fie corect orientată înainte de a intra în dispozitivul i și Q_j numărul de piese de tip j . Atunci $I_j = [\eta_j, 1 - \eta_j]$ este distribuția orientărilor inițiale ale piesei j și $S_j = Q_j / \sum_{j=1}^n Q_j$ proporția pieselor de tip j . Dacă se notează cu η_{jk} probabilitatea orientării corecte a piesei j după ce a trecut prin dispozitivul k , atunci orientarea la ieșire $\sigma_{jk} = [\eta_{jk}, 1 - \eta_{jk}]$ este egală cu produsul $I_j \cdot P_{ij}$, și η_{jk} are valoarea $\eta_j a_{ij} + (1 - \eta_j) c_{ij}$ și se numește *eficiența dispozitivului k pentru piesa j având orientarea inițială I_j* .

Un sistem serial de orientare poate fi definit ca fiind o permutare pe mulțimea celor N dispozitive. Fiind dată o permutare $\psi = \{i_1, i_2, \dots, i_n\}$, sistemul poate fi definit drept o colecție de mulțimi ordonate de matrici:

$$\left\{ P_j(\psi) = P_{i_1 j}, P_{i_2 j}, \dots, P_{i_m j}, j \in M \right\},$$

unde $P_j(\psi)$ este mulțimea ordonată a matricilor P_{ij} pentru piesa j . Eficiențele corespunzătoare, adică $\eta_j(\psi)$, $j \in M$, sunt date de:

$$[\eta_j(\psi), 1 - \eta_j(\psi)] = I_j P_j(\psi) = [\eta_j, 1 - \eta_j] P_j(\psi).$$

Eficiența ponderată a sistemului este:

$$\eta(\psi) = \sum_{j \in M} S_j \eta_j(\psi),$$

unde S_j sunt date.

Ipoteze. În continuare sunt enunțate trei ipoteze privind P_{ij} în vederea simplificării analizei euristiciilor propuse. Aceste ipoteze sunt satisfăcute în multe situații reale.

1. $0 \leq a_{ij}, c_{ij} \leq 1$.
2. Piesele nu sunt respinse de nici un dispozitiv, adică $a_{ij} + b_{ij} = c_{ij} + d_{ij} = 1$.
3. Piesele corect orientate sunt preferate de dispozitivul folosit, adică $a_{ij} \geq c_{ij}$.

Teorema 2.5. Dacă matricile P_{ij} satisfac ipotezele 1,2,3, atunci matricile mulțimii $P_j(\psi)$ satisfac aceleași ipoteze pentru fiecare $j \in M$ și fiecare permutare ψ a mulțimii N .

Demonstrația fiind simplă este omisă. ■

Problema selecției și orientării dispozitivelor. Fie m piese și n dispozitive, nu neapărat distincte. Fiind dată distribuția orientărilor tuturor pieselor și caracteristicile fiecărui dispozitiv, pentru fiecare piesă în parte, este interesantă problema selectării a k sau mai puține dispozitive ($k \leq n$) și ordonarea lor în vederea maximizării eficienței ponderate a sistemului rezultat. Pentru formalizarea problemei este necesară definirea

mulțimii sistemelor seriale realizabile. Dacă se pot selecta maximum k dispozitive ($k \leq n$), atunci mulțimea G_k a sistemelor realizabile constă din toate permutările fiecărei submulțimi a lui N conținând k sau mai puține dispozitive. Problema de rezolvat constă în:

$$\text{maximizarea lui } \eta(\psi), \text{ unde } \psi \in G_k \text{ fiind date } I_j, P_{ij}, i \in N, j \in M \text{ și } k \leq n. \quad (2.1)$$

2.4.1. Ordonarea optimală a dispozitivelor în cazul unei singure piese

În acest paragraf, se studiază cazul particular al problemei enunțate mai înainte pentru $k = n$ și $m = 1$. Indicele j poate fi suprimat, orientarea este definită prin $I = [\eta, 1 - \eta]$ și eficiența dispozitivului i , cu $1 \leq i \leq n$, este:

$$P_i = \begin{bmatrix} a_i & b_i \\ c_i & d_i \end{bmatrix}.$$

Matricea de tranziție limită este definită prin:

$$P_i^\infty = \lim_{L \rightarrow \infty} (P_i)^L.$$

Ținând seama de ipotezele 1 și 2, se poate arăta că:

$$P_i^\infty = \begin{bmatrix} \frac{c_i}{b_i + c_i} & \frac{b_i}{b_i + c_i} \\ \frac{c_i}{b_i + c_i} & \frac{b_i}{b_i + c_i} \end{bmatrix}.$$

Calculând produsul $I \cdot P_i^\infty$ se obține vectorul:

$$[\eta, 1 - \eta] = [c_i / (b_i + c_i), b_i / (b_i + c_i)],$$

adică are loc:

Teorema 2.6. Eficiența asimptotică a dispozitivului P_i este $c_i / (b_i + c_i)$. ■

Teorema 2.7. Într-un sistem cu două dispozitive:

$$b_1 / c_1 > (=, \text{ respectiv } <) b_2 / c_2 \Rightarrow \eta(1, 2) > (=, \text{ respectiv } <) \eta(2, 1).$$

Demonstrație. Este suficient să se demonstreze prima implicație, adică $b_1/c_1 > b_2/c_2$ implică $\eta(1, 2) > \eta(2, 1)$. Presupunând implicația neadevărată, adică $\eta(1, 2) \leq \eta(2, 1)$ și efectuând calculele ce furnizează pe $\eta(1, 2)$ și $\eta(2, 1)$ rezultă că $\eta(a_1 a_2 + b_1 c_2) + (1 - \eta)(c_1 a_2 + d_1 c_2) \leq \eta(a_1 a_2 + b_2 c_1) + (1 - \eta)(c_2 a_1 + d_2 c_1)$, unde $[\eta, 1 - \eta]$ este o distribuție arbitrară a orientării inițiale. Efectuând reducerile se obține $c_1 / b_1 \geq c_2 / b_2$ deci se ajunge la o contradicție. Rezultă că prima implicație este adevărată. În mod similar se demonstrează celelalte implicații. ■

În cele ce urmează, se presupune, fără a micșora generalitatea, că dispozitivele satisfac condiția:

$$c_1 / b_1 \leq c_2 / b_2 \leq \dots \leq c_n / b_n. \quad (2.2)$$

Teorema 2.8. În ipoteza (2.2), ordinea optimală a unui sistem cu n dispozitive este $\psi^* = \{1, 2, \dots, n\}$.

Demonstrație. Fie ψ o permutare diferită de ψ^* . Atunci există două dispozitive P_r și P_s , astfel încât P_r este primul predecesor al lui P_s în ψ și $c_r / b_r \geq c_s / b_s$. Se poate arăta că schimbând între ele dispozitivele P_r și P_s , rezultă o ordonare ψ' astfel încât $\eta(\psi) \geq \eta(\psi')$. Fie η' și η'' orientările piesei considerate pe P_r , respectiv P_s . În virtutea teoremei 2.7., orientarea η''' a piesei la ieșirea din P_r în ordonarea ψ' satisface relația $\eta''' = \eta'' + \delta$, cu $\delta \geq 0$. Dar în ambele ordonări ψ și ψ' dispozitivele ce urmează după P_r și P_s , pot fi reprezentate printr-un dispozitiv compus:

$$P_0 = \begin{bmatrix} a_0 & b_0 \\ c_0 & d_0 \end{bmatrix},$$

unde $a_0 \geq c_0$ conform teoremei 2.5. Rezultă că au loc relațiile:

$$\eta(\psi') = (\eta''' + \delta) a_0 + (1 - \eta''' - \delta) c_0 \text{ și } \eta(\psi) = \eta'' a_0 + (1 - \eta'') c_0.$$

Deoarece $\delta \geq 0$ și $a_0 \geq c_0$, $\eta(\psi') \geq \eta(\psi)$. Un număr finit de asemenea schimbări transformă pe ψ în ψ^* , eficiența nedescrând la fiecare schimbare. Prin urmare ψ^* este o succesiune optimală. ■

Teorema 2.9. Fiind date condițiile (2.2) și o orientare inițială η , soluția optimală a problemei (2.1), cu $k = n$, adică soluția optimală a problemei ordonării a n sau mai puține dispozitive, este dată de $\psi_0^* \in G_n$, unde ψ_0^* se obține din ψ^* eliminând fiecare dispozitiv cu o eficiență:

$$c_i / (b_i + c_i) \leq \eta. \quad (2.3)$$

Demonstrație. Este ușor de dedus că (2.2) implică:

$$c_1 / (b_1 + c_1) \leq c_2 / (b_2 + c_2) \leq \dots \leq c_n / (b_n + c_n).$$

Fie $N' \subset N$ o mulțime de dispozitive ce satisface (2.3), cu $N' \neq \emptyset$. Evident că $N' = \{1, 2, \dots, r\}$ pentru un $r \leq n$. În cele ce urmează se arată că eficiența sistemului crește dacă se elimină dispozitivul $i = 1$.

În $\psi^* = \{1, 2, \dots, n\}$ dispozitivele ce urmează după P_1 pot fi reprezentate printr-un dispozitiv compus P_0 pentru care $a_0 \geq c_0$ în virtutea teoremei 2.5. Fie η_1 orientarea la ieșirea din dispozitivul P_1 și ordonarea $\psi_1^* = \{2, 3, \dots, n\}$. Au loc relațiile $\eta(\psi_1^*) = \eta a_0 + (1 - \eta) c_0$ și $\eta(\psi^*) = \eta_1 a_0 + (1 - \eta_1) c_0$. Din (2.3) rezultă că $\eta_1 \leq \eta$ și, deoarece $a_0 \geq c_0$, $\eta(\psi_1^*) \geq \eta(\psi^*)$.

Procedura descrisă se repetă pentru $i = 2, 3, \dots, r$. Sistemul rămas este efinit de ordonarea $\psi_0^* = \{r + 1, r + 2, \dots, n\}$, cu $\eta(\psi_0^*) \geq \eta(\psi^*)$. Dacă $r = n$, atunci $\psi_0^* = \emptyset$. Rămâne de arătat că eliminarea oricărui dispozitiv $i \geq r + 1$ nu poate îmbunătăți eficiența sistemului. Acest lucru se demonstrează în mod analog celui descris mai sus. Aceasta completează demonstrația teoremei. ■

Teorema 2.10. Să presupunem că în ordonarea ψ_0^* din teorema 2.9. există un dispozitiv P_i cu proprietatea $a_i = c_i$. Atunci eliminarea tuturor dispozitivelor care preced pe P_i în ψ_0^* nu schimbă eficiența sistemului și, în consecință, reprezintă o altă soluție optimală.

Demonstrație. Afirmația rezultă din observația că eficiența lui P_i este a_i independent de orientarea η la intrare. Evident că un sistem optimal cu număr minim de dispozitive se obține pe calea identificării celui mai din dreapta dispozitiv P_i din ψ_0^* și eliminarea tuturor dispozitivelor din stânga lui P_i . ■

Corolarul 1. Fiind date (2.2), $c_i / (b_i + c_i) > \eta$, orientarea inițială și $a_i > c_i$, $i \in N$, unica soluție optimală a problemei (2.1) este $\psi^* = \{1, 2, \dots, n\}$.

Demonstrație. Concluzia rezultă din teoremele 2.9 și 2.10. ■

2.4.2. Selectarea și ordonarea dispozitivelor în cazul unei piese

În acest paragraf, se consideră problema (2.1), cu $1 \leq k \leq n$, $m = 1$. În virtutea corolarului 1 se presupune că $c_i / (b_i + c_i) > \eta$ și $a_i > c_i$, pentru $i \in N$, și că are loc ordonarea (2.2). De asemenea se presupune că $a_i > c_i$, pentru toate dispozitivele din mulțimea N .

Formularea în termeni de programare dinamică. Fie $F_t(p)$ eficiența maximă la ieșirea din dispozitivul t , dacă exact $p=1,2,\dots,\min(t,k)$ dispozitive au fost selectate dintre primele t dispozitive ale unui n , sistem optimal. Relația recursivă are forma:

$$F_t(p) = \max\{F_{t-1}(p), a_t F_{t-1}(p-1) + c_t(1 - F_{t-1}(p-1))\}, \quad (2.4)$$

unde:

$$F_t(0) = \eta, \text{ pentru toți } t = 1, 2, \dots, n \text{ și } F_1(1) = \eta_1 a_1 + (1 - \eta_1) c_1. \quad (2.5)$$

Cu ajutorul relațiilor (2.4) și (2.5) se poate elabora selectarea și ordonarea optimală a $k < n$ dispozitive.

Proceduri euristice. În continuare se presupune că ordonarea optimală a n dispozitive este $\psi^* = \{1, 2, \dots, n\}$.

Euristica 1. În această euristică, cele k dispozitive se aleg la întâmplare din ψ^* . Această euristică nu are o motivare rațională și este folosită numai pentru compararea cu euristicile ce urmează.

Euristica 2. Această metodă selectează ultimile k dispozitive din ordonarea ψ^* , adică dispozitivele $P_{n-k+1}, P_{n-k+2}, \dots, P_n$. Aceste dispozitive au eficiențe asimptotice mari și din acest motiv se consideră bine alese.

Exemplul 2.3. Fie $n = 3$, $k = 2$ și $m = 1$. Matricile dispozitivelor sunt:

$$P_1 = \begin{bmatrix} 0.8 & 0.2 \\ 0.7 & 0.3 \end{bmatrix} \quad P_2 = \begin{bmatrix} 0.9 & 0.1 \\ 0.6 & 0.4 \end{bmatrix} \quad P_3 = \begin{bmatrix} 0.9 & 0.1 \\ 0.8 & 0.2 \end{bmatrix}.$$

Orientarea inițială este $\eta = 0.15$ și $\psi^* = \{1, 2, 3\}$. Ieșirile asimptotice ale celor trei dispozitive sunt respectiv 0.78, 0.86 și 0.89. Euristică 2 generează soluția $P_2 P_3$ având eficiența 86.45% și sistemul optimal este $P_1 P_3$ cu eficiența 87.15%. ■

Euristică 3. Metoda acestei euristici constă în selectarea a k dispozitive în conformitate cu performanța lor relativ la orientarea inițială η , adică în conformitate cu valorile maxime ale lui $\eta_i = \eta a_i + (1 - \eta) c_i$, $1 \leq i \leq n$. Apoi ele se ordonează ca în ψ^* . În cazul exemplului precedent, euristica 3 selectează pe P_1 și P_3 , care reprezintă soluția optimală.

Exemplul 2.4. Fie $n = 5$, $k = 4$, $m = 1$ și matricile P_1, P_2, P_3, P_4, P_5 sunt.

$$P_1 = P_2 = P_3 = \begin{bmatrix} 0.8 & 0.2 \\ 0.7 & 0.3 \end{bmatrix} \quad P_4 = \begin{bmatrix} 0.9 & 0.1 \\ 0.6 & 0.4 \end{bmatrix} \quad P_5 = \begin{bmatrix} 0.9 & 0.1 \\ 0.8 & 0.2 \end{bmatrix}.$$

Orientarea inițială este $\eta = 0.15$ și $\psi^* = \{1, 2, 3, 4, 5\}$. Euristică 3 identifică soluția $P_1 P_2 P_3 P_5$ cu eficiența 88.22%. Soluția optimală este $P_1 P_2 P_4 P_5$ și are eficiența 88.31%. ■

Euristică 4. Această euristică selectează k dispozitive în ordinea definită de ψ^* schimbând valoarea lui η în modul descris mai jos. Fie $\psi^* = \{0, 1, \dots, n\}$, unde 0 este indicele unui dispozitiv neutru cu matricea $P_0 = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$ utilizat pentru inițializarea procesului.

- [Inițializări] Se face $P = P_0$, $k_0 = k$, $\psi = \emptyset$, $\eta_0 = \eta$ (orientarea inițială).
- [Construcție inițială] Se construiește $\psi^* = \{0, 1, 2, \dots, n\}$, pentru un sistem optimal D_n cu n dispozitive, unde $D_n = P_0 P_1 P_2 \dots P_n$.
- [Calcul eficiență] Se calculează eficiența tuturor dispozitivelor ce urmează după P_0 în D_n , adică $\eta_i = \eta_0 a_i + (1 - \eta_0) c_i$, pentru $i = 1, \dots, n$.
- [Alegere] Se identifică k dispozitive ce corespund la cele mai mari k valori ale lui η_i . În cazul egalității a două valori ale eficienței, se alege dispozitivul situat la stânga în ψ^* .
- [Selectare] Se identifică cel mai din stânga dispozitiv f identificat în pasul 4. Fie $P = P_f$ și $\psi = \{\psi, f\}$.
- [Ajustare] Se face $\eta_0 = \eta_0 a_f + (1 - \eta_0) c_f$ ținând seama că $P_f = \begin{bmatrix} a_f & b_f \\ c_f & d_f \end{bmatrix}$.
- [Ciclare] Se face $k_0 = k_0 - 1$. Dacă $k_0 \geq 1$, atunci se trece la pasul 3.
- [Terminare] Eficiența sistemului cu k dispozitive este η_0 și ordinea dispozitivelor este definită de ψ . STOP. ■

2.4.3. Selectarea și ordonarea dispozitivelor pentru m tipuri de piese

Într-un sistem cu m tipuri de piese, matricea asociată piesei de tip j este de forma:

$$P_{ij} = \begin{bmatrix} a_{ij} & b_{ij} \\ c_{ij} & d_{ij} \end{bmatrix}, \text{ pentru } i = 1, 2, \dots, n \text{ și } j = 1, 2, \dots, m.$$

În acest caz se efectuează o conversie a problemei date într-una cu $m = 1$ folosind matrici de forma:

$$P_i = \begin{bmatrix} \sum_{j=1}^m S_j a_{ij} & \sum_{j=1}^m S_j b_{ij} \\ \sum_{j=1}^m S_j c_{ij} & \sum_{j=1}^m S_j d_{ij} \end{bmatrix}, \text{ pentru } i = 1, 2, \dots, n,$$

unde $S_j, 1 \leq j \leq m$ sunt ponderi asociate tipurilor pieselor. După efectuarea acestei conversii se aplică euristicele precedente.

2.4.4. Selectarea și ordonarea dispozitivelor în cazul a m tipuri de piese cu l orientări

În acest caz, matricea de tranziție este o matrice $l \times l$ ($l > 2$) de forma $P_{ij} = [e_{ij}^{pq}]_{l \times l}$, $i \in N, j \in M$ unde e_{ij}^{pq} este probabilitatea ca piesa de tip j intrată în dispozitivul i cu orientarea p părăsește dispozitivul i cu orientarea q . Elementele matricii P_{ij} satisfac condiția $0 \leq e_{ij}^{pq} \leq 1$.

Euristica propusă are la bază ideea conversiei matricilor $l \times l$ în matrice 2×2 . O matrice convertită P'_{ij} are forma:

$$P'_{ij} = \begin{bmatrix} a_{ij} & b_{ij} \\ c_{ij} & d_{ij} \end{bmatrix}, \text{ unde } a_{ij} = e_{ij}^{11}, b_{ij} = \sum_{k=2}^l e_{ij}^{1k},$$

$$c_{ij} = \sum_{k=2}^l \frac{\eta_j^k}{k-2 \eta_j^2 + \eta_j^3 + \dots + \eta_j^l} \cdot e_{ij}^{k1}, d_{ij} = \sum_{k=2}^l \frac{\eta_j^k}{k-2 \eta_j^2 + \eta_j^3 + \dots + \eta_j^l} \times \sum_{l=2}^l e_{ij}^{kl}.$$

În felul acesta problema studiată este redusă la cea precedentă (paragraful 2.4.3) care la rândul ei se reduce la problema studiată în paragraful 2.4.2.

2.5. Algoritmi aproximativi pentru problema superșirului minimal

Punerea problemei. Fiind date mai multe șiruri de caractere, se cere identificarea unui șir de lungime minimală care să acopere toate șirurile date, adică este un superșir, în sensul că oricare dintre șiruri este un subșir al șirului determinat. ■

Aplicații posibile: codificări date, proiectarea unor fluxuri industriale.

Exemplul 2.5. Fie $S = \{\text{egiach, bfgiak, hfdegi, iakfd, fgiakh}\}$ o mulțime de cinci șiruri. Șirul bfgiakhfdegiach este un superșir al șirurilor din S . ■

În continuare se presupune că șirurile din mulțimea studiată satisfac condiția că nici unul dintre ele nu este *subșir* al altuia. Fie $s_1 = a_1 \dots a_r$ și $s_2 = b_1 \dots b_s$ două șiruri ce satisfac condiția precedentă. Acoperirea maximală a acestor două șiruri are lungimea definită prin:

$$\Psi(s_1, s_2) = \max\{k \geq 0 \mid a_{r-k+i} = b_i, 1 \leq i \leq k\}.$$

Dacă $\Psi(s_1, s_2) = k$, atunci șirul $s_1 \circ s_2$ este definit prin $a_1 \dots a_r b_{k+1} \dots b_s$. Operația \circ este asociativă, adică $s_1 \circ (s_2 \circ s_3) = (s_1 \circ s_2) \circ s_3$.

Problema superșirului maxim (*PSM*) este legată, într-un sens ce urmează să fie precizat, cu problema drumului maxima! (*PDM*) într-un graf. Fiind dat un graf orientat complet $G = (V, E)$ în care fiecare arc (u, v) are o lungime întreagă nenegativă $l(u, v)$, lungimea unui drum p în G este definită ca sumă a lungimilor arcelor sale și se notează cu $\lambda_p(G, l)$. Problema drumului maximal constă în identificarea unui drum hamiltonian p (adică un drum care include orice nod) în G care maximizează pe $\lambda_p(G, l)$. Lungimea unui asemenea drum este notată cu $\lambda^*(G, l)$.

Fie $S = (s_1, \dots, s_n)$ datele unei probleme *PSM*. $PDM(S)$ definește datele (G, l) ale problemei *PDM* cu:

$$V = \{u_1, \dots, u_n\}, E = V \times V, l(u_i, u_j) = \Psi(s_i, s_j), 1 \leq i, j \leq n, i \neq j.$$

Un exemplu ce ilustrează această transformare este arătat în figura 2.4.




Fig. 2.4.

În continuare vom prezenta câțiva algoritmi aproximativi pentru rezolvarea problemei *PDM*.

2.5.1. Algoritmul împachetării

O *împachetare* într-un graf $G = (V, E)$ este o mulțime de muchii ce nu au un nod comun. O împachetare M este maximă dacă lungimea ei, adică suma lungimilor

arcelor respective, notată $l(M)$, este maximă. Valoarea unei împachetări maxime este dată de formula $\mu^*(G, l) = \max_M l(M)$. Există algoritmi pentru identificarea unei împachetări maxime având o complexitate temporală de $O(n^3)$ unde $n = |V|$. Pentru problema PDM se poate folosi următoarea procedură numită *MATCH*.

Algoritmul 2.6. (MATCH).

1. [Împachetare] Se identifică o împachetare maximală M în G și se calculează valoarea ei.
2. [Eliminări arce] Pentru $(u, v) \in M$, se elimină din G toate arcele de forma (u, x) sau (y, v) .
3. [Unificare] Se unifică u și v într-un singur nod.
4. [Ciclare] Dacă există arce neparcuse, atunci se trece la pasul 1, altfel STOP. ■




Fig. 2.5.

Exemplul 2.6. Un exemplu ilustrativ este arătat în figura 2.5.a). Prima împachetare maximală este $(b, a), (c, f), (e, d)$ și are valoarea $8 + 9 + 7 = 24$. Eliminând arcele divergente din b, c, e respectiv cele convergente în a, f, d , unificând vârfurile $(b, a), (c, f), (e, d)$ se obține graful din figura 2.5.b). Reluând pasul 1, rezultă împachetarea (cf, ba) ce are valoarea 6. În continuare se obține graful din figura 2.5.c) pentru care se obține împachetarea $(ed, cfba)$ de cost 5. Rezultă că drumul maxim identificat are lungimea 35. ■

2.5.2 Algoritmul împachetării direcționate

O împachetare direcționată într-un digraf $G = (V, E)$ este o mulțime de arce ce satisfac condiția că nici o pereche din ele nu converge într-un același nod și nici nu diverge dintr-un același nod. Altfel spus, o împachetare direcționată este o colecție de

drumuri și cicluri disjuncte. Algoritmul prin care se determină o împachetare direcționată are următoarea structură.

Algoritmul 2.7. (Împachetare direcționată)

1. [Împachetare] Se identifică o împachetare maximală direcționată M în G .
2. [Eliminare cicluri] Se construiește $M := M -$ un arc de cost minimal din fiecare ciclu al lui M .
3. [Transformări graf] Pentru fiecare drum $(u_1, u_2, \dots, u_n) \in M$ se elimină din G :
 - a) arcele de forma (u_i, x) , $2 \leq i \leq n$;
 - b) arcele de forma (x, u_i) , $1 \leq i \leq n - 1$;
 - c) arcul (u_n, u_1) , dacă există;
 - d) se compactează drumul într-un singur vârf.
4. [Ciclare] Dacă există arce neparcuse, atunci se trece la pasul 1, altfel STOP. ■

Exemplul 2.7. Pentru graful din figura 2.5, împachetarea maximală direcționată (pasul 1) este arătată pe figura 2.6.a). Eliminând arcele (a, c) , respectiv (d, e) , (pasul 2) rezultă drumurile din figura 2.6.b) care au costurile 23 respectiv 7. După parcurgerea pasului 3 se obține graful din figura 2.6.c). Împachetarea maximă direcționată corespunzătoare este: $(ed, cfba)$, $(cfba, ed)$. După parcurgerea pasului 2 se obține perechea $(ed, cfba)$ de cost 5. Drumul căutat are costul (lungimea) 35 și coincide cu cel din exemplul precedent. ■




Fig. 2.6.

2.5.3. Algoritmul de tip Greedy

În cadrul acestui algoritm, arcele sunt parcurse în ordinea nedescrescătoare a lungimii, un arc (u, v) fiind selectat dacă anterior nu a fost selectat un arc de forma (u, x) sau (y, v) și dacă mulțimea arcelor selecționate nu include un drum de la v la u .

Exemplul 2.8. Pentru graful din figura 2.5.a), algoritmul selectează arcele (c, f) , (b, a) , (e, d) , (f, b) , (d, c) , în această ordine. Aceste arce definesc drumul (e, d, c, f, b, a) de lungime: $7 + 5 + 9 + 6 + 8 = 35$. ■




Fig. 2.7.

Acest algoritm nu furnizează întotdeauna o soluție apropiată de cea optimă, după cum rezultă din figura 2.7. pentru care soluția optimă are valoarea 300 și cea furnizată de algoritm, valoarea 101.

Algoritm Greedy pentru PSM. Algoritm Greedy pentru PDM poate fi reformulat pentru PSM după cum urmează.

Fiind dată o mulțime nevidă de șiruri S , se repetă pasul următor până când S va conține un singur șir:

Se selectează o pereche de șiruri $s_1, s_2 \in S$ ce maximizează $\Psi(s_1, s_2)$, apoi se elimină s_1 și s_2 din S înlocuindu-le cu $s_1 \circ s_2$.

Teorema 2.11. Fie S o mulțime de șiruri. Are loc următoarea inegalitate: $\Psi^*(S) \leq 2 \Psi_{SGREEDY}$, unde $SGREEDY$ este valoarea din algoritmul precedent. ■

Complexitatea algoritmului $SGREEDY$ este de cel puțin $O(n^2)$. În continuare se prezintă un algoritm ce utilizează reprezentarea datelor prin arbori sufix *trie* și care are o complexitate logaritmică.

Problema PSM și problema comisvoiajorului. Fie $S = (s_1, s_2, \dots, s_n)$ o problemă PSM. O problemă a comisvoiajorului asociată problemei PSM se poate defini considerând o mulțime $C = (c_1, c_2, \dots, c_n, c_{n+1})$ de localități și mulțimea distanțelor:

$$d(c_i, c_j) = \begin{cases} |s_i| - \Psi(s_i, s_j) & 1 \leq i \leq n, 1 \leq j \leq n, i \neq j, \\ |s_i| & 1 \leq i \leq n, j = n+1, \\ ||S|| & i = n+1, 1 \leq j \leq n \end{cases}$$




Fig. 2.8.

Exemplul 2.9. Un exemplu ilustrativ este arătat pe figura 2.8., unde $S = \{cbadef, fcbade, adefcd\}$ și vârfurile 1, 2, 3 reprezintă șirurile $cbadef, fcbade, adefcd$. Ținând seama de felul în care au fost definite distanțele $d(c_i, c_j)$, localitatea finală a drumului comisvoiajorului este c_{n+1} . Drumul minimal este (2, 1, 3, 4) și are lungimea 9. Acestui drum îi corespunde supersșirul $scabdefadefcd$. ■

2.6. Problema acoperirii unui set de mulțimi

Punerea problemei. Problema acoperirii unui set de mulțimi (SCP) constă în acoperirea rândurilor unei matrici zero-unu (0-1), având m linii și n coloane, cu o

submulțime de coloane astfel încât costul acoperirii să fie minimal. Dacă $x_j = 1$, în cazul când coloana j , de cost $c_j > 0$, figurează în soluție, în caz contrar $x_j = 0$, problema SCP se enunță astfel:

$$\text{să se minimizeze } \sum_{j=1}^n c_j x_j, \quad (2.6)$$

cu condițiile:

$$\sum_{j=1}^n a_{ij} x_j \geq 1, \text{ pentru } i = 1, 2, \dots, m, \quad (2.7)$$

$$x_j \in \{0, 1\}, \text{ pentru } j = 1, 2, \dots, n. \blacksquare \quad (2.8)$$

Aplicații posibile: aprovizionarea cu piese de schimb, obținerea unor împrumuturi.

2.6.1. Prezentarea algoritmului

Fără a micșora generalitatea, se presupune că anterior coloanele au fost ordonate în ordinea crescătoare a costului, coloanele cu cost egal fiind ordonate în ordinea descrescătoare a numerelor rândurilor pe care le acoperă. Aceasta înseamnă că pentru orice rând i , coloana $\min\{j \mid a_{ij} = 1, j = 1, 2, \dots, n\}$ este cea mai "bună" coloană ce acoperă rândul i .

Notând cu $t_i (\geq 0)$, $i = 1, \dots, m$, multiplicatorii lui Lagrange asociați cu ecuațiile (2.7), se obține următoarea problemă (LLBP) pentru marginea inferioară a problemei, deci pentru cazul semnelui "=" în (2.7):

$$\text{să se minimizeze } \sum_{j=1}^n \left(c_j - \sum_{i=1}^m t_i a_{ij} \right) x_j + \sum_{i=1}^m t_i, \quad (2.9)$$

cu condițiile:

$$x_j \in \{0, 1\}, \text{ pentru } j = 1, 2, \dots, n. \quad (2.10)$$

Notând cu C_j coeficientul lui x_j în (2.9) și cu X_j valorile soluției pentru x_j , rezultă că $X_j = 1$, dacă $C_j \leq 0$ (altfel $X_j = 0$) și valoarea marginii inferioare Z_{LB} a soluției optime date de:

$$Z_{LB} = \sum_{j=1}^n C_j X_j + \sum_{i=1}^m t_i.$$

Pentru maximizarea marginii inferioare obținute în urma rezolvării problemei LLBP se folosește o formă particulară a metodei gradientului (*subgradient optimisation*) prezentată în continuare.

Fie Z_{\max} valoarea maximă identificată a marginii inferioare, Z_{UB} cea mai bună soluție găsită la un moment dat și P_k marginea inferioară în cazul când coloana k , $k = 1, 2, \dots, n$, este obligată să aparțină soluției. Se poate obține o soluție pentru problema SCP aplicând algoritmul următor.

Algoritmul 2.8. (SCP)

1. [Inițializări] Se face $Z_{\max} = -\infty$, $Z_{\text{UB}} = \infty$, $P_k = c_k$, pentru $k = 1, 2, \dots, n$, și $t_i = \min \{c_j \mid a_{ij} = 1, j = 1, 2, \dots, n\}$, pentru $i = 1, 2, \dots, m$.
2. [Soluție LLBP] Se rezolvă problema LLBP cu mulțimea curentă a multiplicatorilor t_i , soluția obținută fiind notată cu Z_{LB} , X_j , $j = 1, 2, \dots, n$. Se efectuează atribuirea $Z_{\max} = \max\{Z_{\max}, Z_{\text{LB}}\}$.
3. [Soluție SCP] Se construiește o soluție S a problemei originale SCP în modul următor:

a) Fie $S = \{j \mid X_j = 1, j = 1, 2, \dots, n\}$.

b) Pentru fiecare rând i neacoperit, adică pentru care $\sum_{j=1}^n a_{ij} X_j = 0$, se adaugă

la S coloana corespunzătoare lui $\min\{j \mid a_{ij} = 1, c_j < \infty, j = 1, 2, \dots, n\}$.

c) Se parcurg coloanele $j \in S$ în ordinea descrescătoare a indicelui j și, dacă $S - \{j\}$ este o soluție a SCP, se efectuează atribuirea $S = S - \{j\}$.

d) Se înlocuiește Z_{UB} cu $Z_{\text{UB}} = \min\{Z_{\text{UB}}, \sum_{j \in S} c_j\}$.

Pasul b) poate fi efectuat într-un mod eficient, din punct de vedere computațional, observând că, neglijând coloanele eliminate, se poate identifica aceeași coloană ce acoperă un rând neacoperit.

4. [Terminare] Dacă $Z_{\max} = Z_{\text{UB}}$, atunci STOP (Z_{UB} este soluția optimală).
5. [Eliminare coloane] Din examinarea problemei originale SCP (ecuațiile (2.6) - (2.8)) și a problemei LLBP (ecuațiile (2.9) și (2.10)) rezultă că, impunând constrângerea adițională ca o coloană particulară k să figureze în soluția optimală, adică $x_k = 1$, rezultă o margine inferioară egală cu $Z_{\text{LB}} + C_k$ dacă $X_k = 0$, altfel Z_{LB} nu se schimbă ($X_k = 1$). Rezultă că valoarea lui P_k poate fi schimbată în conformitate cu:

$$P_k = \max(P_k, Z_{\text{LB}} + C_k), \text{ dacă } X_k = 0, \text{ pentru } k = 1, 2, \dots, n$$

$$P_k = \max(P_k, Z_{\text{LB}}), \text{ dacă } X_k = 1, \text{ pentru } k = 1, 2, \dots, n.$$

Deci din problema de rezolvat pot fi eliminate coloane considerând:

$$c_k = \infty, \text{ dacă } P_k > Z_{\text{UB}}, \text{ pentru } k = 1, 2, \dots, n,$$

deoarece reținerea unei coloane k cu P_k mai mare ca Z_{UB} nu poate furniza o soluție îmbunătățită.

6. [Calcul subgradienți] Se calculează subgradienții G_i conform definiției:

$$G_i = 1 - \sum_{j=1}^n a_{ij} X_j, \text{ pentru } i = 1, 2, \dots, m.$$

În cazul când gradienții astfel calculați nu contribuie în mod efectiv la schimbarea valorilor multiplicatorilor, ei sunt ajustați astfel:

$$G_i = 0, \text{ dacă } t_i = 0 \text{ și } G_i < 0, \text{ pentru } i = 1, 2, \dots, m.$$

7. [Terminare] Dacă $\sum_{i=1}^m (G_i)^2 = 0$, atunci STOP (deoarece în acest caz nu se poate defini o valoare convenabilă a pasului (conform definiției (2.11) de mai jos).

8. [Calcul pas] Calculează valoarea pasului în conformitate cu:

$$T = f(1.05 Z_{UB} - Z_{LB}) / \left(\sum_{i=1}^m (G_i)^2 \right), \quad (2.11)$$

unde inițial $f = 2$. Dacă Z_{\max} nu crește în ultimile 30 de iterații ale procedurii calculului subgradientului, plecând de la valoarea curentă a lui f , atunci f se înjumătățește. Expresia lui T din (2.11) are forma standard folosită în metoda subgradientului, cu excepția factorului 1.05 care s-a dovedit, în urma testărilor pe calculator, util pentru a evita micșorarea prea mare a lui T atunci când valorile Z_{UB} și Z_{LB} devin apropiate.

9. [Terminare] Dacă $f \leq 0.005$, atunci STOP (Criteriu arbitrar de încheiere a calculelor).

10. [Schimbare multiplicatori] Se schimbă valorile multiplicatorilor Lagrange în conformitate cu:

$$t_i = \max(0, t_i + T G_i), \text{ pentru } i = 1, 2, \dots, m,$$

adică în conformitate cu definiția standard a modificării multiplicatorilor Lagrange negativi, și se trece la pasul 2. ■

La încheierea euristicii descrise, Z_{UB} este valoarea celei mai bune soluții identificate și Z_{\max} este valoarea celei mai bune margini inferioare.

Calitatea soluției este apreciată cu criteriul:

$$(Z_{UB} - Z_{\max}) / Z_{\max}.$$

Structura euristicii Lagrange este:

- Se identifică o relaxare Lagrange a problemei ușor de rezolvat.
- Se folosește optimizarea subgradientului în vederea maximizării marginii inferioare obținută în urma relaxării.
- La fiecare iterație a pasului b) se ajustează, dacă este posibil, marginea inferioară curentă într-o soluție a problemei date.

2.7. Minimizarea sumei maxime pe liniile unei matrice

Punerea problemei. Fiind dată o matrice cu elemente nenegative de dimensiuni $m \times n$ se studiază problema permutării independente a elementelor din fiecare coloană în vederea minimizării sumei maxime pe linii.

Aplicații posibile: planificarea activităților.

Această problemă este NP-completă.

2.7.1. Algoritmul *RDI* pentru cazul general

Înainte de a prezenta algoritmul *RDI* se descrie un algoritm exact ce rezolvă cazul particular $m \times 2$, numit *DI*.

Algoritm 2.9. (*DI*)

- [Coloana 1] Se aranjează elementele coloanei 1 în ordine crescătoare începând de la rândul 1 la m .
- [Coloana 2] Se aranjează elementele coloanei 2 în ordine descrescătoare. ■

Complexitatea temporală a algoritmului *DI* este $O(m \log m)$.

Lema 2.1. Algoritm *DI* este optimal pentru cazul $m \times 2$ al problemei studiate.

Demonstrație. Să presupunem că există un cel mai scurt contraexemplu. Dacă, într-o soluție optimală, a_1 este cuplat cu b_m , atunci a_1 și b_m pot fi eliminați, deoarece atât în soluția optimală cât și în cea furnizată de algoritmul *DI* a_1 și b_m aparțin aceluiași rând, după rezultat obținându-se un contraexemplu mai scurt decât cel presupus. Să presupunem atunci că într-o soluție optimală a_1 , b_m sunt cuplați cu b' , a' , adică matricea transformată este de forma:

$$\begin{bmatrix} a_1 & b' \\ \vdots & \vdots \\ a' & b_m \end{bmatrix},$$

cu

$$a_1 + b' \leq \omega_{OPT} \text{ și } a' + b_m \leq \omega_{OPT}.$$

Deoarece $a' \leq a_1$ și $b_m \leq b'$, se deduce că:

$$a_1 + b_m \leq a_1 + b' \leq \omega_{OPT} \text{ și } a' + b' \leq a' + b_m \leq \omega_{OPT}.$$

Rezultă că, interschimbând între ele elementele b' și b_m în soluția examinată, se obține o nouă soluție optimală în care au loc cuplările (a_1, b_m) și (a', b') . Eliminând pe a_1 și b_m se obține un contraexemplu mai scurt decât cel acceptat inițial și prin urmare ipoteza că algoritmul *DI* nu este optimal se respinge. ■

Pe baza algoritmului *DI* se poate obține un algoritm aproximativ numit *RDI* pentru cazul general $m \times n$, în modul descris în continuare. În cadrul algoritmului se calculează suma finală pe rânduri adunând succesiv câte o coloană.

Algoritmul 2.10. (RDI)

1. [Aplicare *DI*] Se aplică algoritmul *DI* la primele două coloane ale matricei și se face $j = 2$.
2. [Terminare] Dacă $j = n$, se obțin permutările corespunzătoare elementelor coloanelor parcurgând în sens invers procedurile de generare ale coloanelor și apoi STOP.
3. [Însumări] Se însumează coloanele $(j - 1)'$ cu j obținând coloana auxiliară j' (se consideră în loc de coloana $1'$ coloana 1 în cazul $j = 1$) și se face $j = j + 1$.
4. [Aplicare *DI*] Se aplică algoritmul *DI* coloanelor $(j - 1)'$ și j apoi se merge la pasul 2. ■

Algoritmul descris are complexitatea $O(m n \log m)$.

Teorema 2.12. $\omega_{RDI} \leq (2 - 1/m) \omega_{OPT}$ pentru matrici $m \times n$.

Demonstrație. Fie d_j cel mai mare element din coloana j , pentru $j = 1, \dots, n$. Fie γ_1 și γ_2 elementele maxim, respectiv minim, din coloana n' și $d^* = \max\{d_j\}$.

Aserțiune. $\gamma_1 - \gamma_2 \leq d^*$.

Demonstrația se efectuează prin inducție. Mai întâi se consideră parcurgerea coloanelor 1 și 2. Fie $a + c$, respectiv $b + l$, elementul maxim, respectiv minim, din coloana $2'$, unde a și b aparțin coloanei 1 și c și l aparțin coloanei 2. Au loc două situații:

i) $a > b$. În acest caz, în virtutea algoritmului *DI*, $c < l$ și prin urmare:

$$(a + c) - (b + l) = (a - b) + (c - l) \leq a - b \leq d_1.$$

ii) $a \leq b$. Atunci:

$$(a + c) - (b + l) = (a - b) + (c - l) \leq c - l \leq d_2.$$

Rezultă că diferența dintre $a + c$ și $b + l$ este mărginită superior de $\max(d_1, d_2)$ care este cel mult d^* . Aplicând succesiv argumentele precedente coloanelor $(k - i)'$ și k , rezultă că diferența dintre cel mai mare și cel mai mic element din coloana k' este cel mult $\max(d^*, d_k) = d^*$, rezultat adevărat și pentru coloana n' . Cu aceasta, demonstrația aserțiunii este încheiată.

În continuare, se observă că:

$$\omega_{RDI} = \gamma_1, \omega_{OPT} \geq \gamma_2 + \frac{1}{m}(\gamma_1 - \gamma_2) \text{ și } \omega_{OPT} \geq \max(d_1, d_2, \dots, d_n) = d^*,$$

de unde rezultă:

$$\omega_{RDI} - \omega_{OPT} \leq \gamma_1 - \gamma_2 + \frac{1}{m}(\gamma_1 - \gamma_2) = \left(1 - \frac{1}{m}\right)(\gamma_1 - \gamma_2) \leq \left(1 - \frac{1}{m}\right)d^* \leq \left(1 - \frac{1}{m}\right)\omega_{OPT}.$$

Prin urmare $\omega_{RDI} \leq (2 - 1/m) \omega_{OPT}$. ■

Exemplul 2.10. Următorul exemplu ilustrează situația în care marginea superioară este atinsă.

$$A_{\text{OPT}} = \begin{bmatrix} 1 & m-1 & 0 \\ 2 & m-2 & 0 \\ \vdots & \vdots & \vdots \\ m-2 & 2 & 0 \\ m-1 & 1 & 0 \\ 0 & 0 & m \end{bmatrix} \quad A_{\text{RDI}} = \begin{bmatrix} m-1 & 0 & m \\ m-2 & 1 & 0 \\ \vdots & \vdots & \vdots \\ 2 & m-3 & 0 \\ 1 & m-2 & 0 \\ 0 & m-1 & 0 \end{bmatrix}.$$

În soluția optimă maximul sumelor pe linii este m pe când aplicând algoritmul euristic se obține maximul sumei pe linii $2m - 1$. ■

2.7.2. Algoritmul *RLPT* pentru cazul $m \times 3$

În continuare se prezintă un algoritm, care furnizează în cel mai rău caz o soluție mai bună decât cea a algoritmului *RDI*, pentru cazul matricilor $m \times 3$.

Algoritmul 2.11. (*RLPT*)

1. [Ordonare elemente] Se ordonează descrescător toate elementele matricei.
2. [Terminare] Dacă toate elementele au fost plasate, atunci STOP.
3. [Alegere] Se identifică cel mai mare element curent $a_{i,j}^*$, din lista ordonată.
4. [Plasare] Se atribuie acest element rândului cu cea mai mică sumă, dintre rândurile a căror locuri din coloana j^* nu sunt încă ocupate, prin schimbarea celor două elemente între ele.
5. [Ciclare] Se merge la pasul 2. ■

Complexitatea algoritmului *RLPT* este $O(m \log m)$.

Teorema 2.13. $\omega_{\text{RLPT}} \leq 3/2 \omega_{\text{OPT}}$ pentru matrici $m \times 3$.

Demonstrație. Presupunând că afirmația nu este adevărată, fie un cel mai scurt contraexemplu, adică unul cu r minim, cu elementele t_1, t_2, \dots, t_r , considerate în ordinea descrescătoare. Evident că, în virtutea euristicii *RLPT*, elementul t trebuie introdus într-un rând a cărui sumă finală este ω_{RLPT} , adică obținută pe baza aplicării algoritmului *RLPT*. În caz contrar, elementul t_r poate fi eliminat, ω_{RLPT} și ω_{OPT} rămân neschimbate, drept rezultat obținându-se un contraexemplu mai scurt. Rezultă că rămâne de demonstrat inconsistența ipotezei existenței unui contraexemplu cu r elemente. Fără a micșora generalitatea, se presupune că t_r este plasat în coloana 3.

Pentru aceasta se consideră soluția euristică după ce au fost plasate elementele t_1, t_2, \dots, t_{r-1} și înaintea plasării lui t_r . Fie i_1, i_2, \dots, i_k locurile neocupate din coloana 3. Concluzia teoremei rezultă drept consecință a următoarelor două aserțiuni:

Aserțiunea 1. Locurile i_1, i_2, \dots, i_k din coloanele 1 și 2 sunt ocupate.

Demonstrație. În virtutea *RLPT*, cele mai mari m elemente sunt plasate în rânduri distincte. Rezultă că $r > m$ și că pentru o soluție optimală $\omega_{\text{OPT}} \geq \hat{c}_r$. Fie d suma minimală pentru rândurile $\{i_1, i_2, \dots, i_k\}$. Atunci t_r va trebui plasat într-unul dintre rândurile i_1, i_2, \dots, i_k pentru care suma este d . Dacă $d \leq \omega_{\text{OPT}}$ atunci:

$$\omega_{\text{RLPT}} - \omega_{\text{OPT}} = (d + t_r) - \omega_{\text{OPT}} \leq t_r, \text{ deci } \frac{\omega_{\text{RLPT}}}{\omega_{\text{OPT}}} \leq 1 + \frac{t_r}{\omega_{\text{OPT}}} \leq 1 + \frac{1}{2} = \frac{3}{2},$$

în contradicție cu ipoteza, privind existența contraexemplului. Prin urmare, $d > \omega_{\text{OPT}}$ și, cum $\omega_{\text{OPT}} \geq \max_{1 \leq k \leq r} \{t_k\}$, rezultă că $d > \max_{1 \leq k \leq r} \{t_k\}$. Cu aceasta demonstrarea aserțiunii 1 este încheiată.

Deoarece cele mai mari m elemente sunt plasate în m rânduri distincte, rezultă că trebuie să existe exact k dintre aceste elemente în rândurile i_1, i_2, \dots, i_k . Unul dintre aceste elemente, t_i^* , trebuie să fie plasat într-un rând ce conține măcar un alt element pozitiv în coloana 3 a aranjamentului optimal, deoarece în coloana 3 există numai $k - 1$ locuri neocupate. Prin urmare $t_i^* + t_r \leq \omega_{\text{OPT}}$. Fie t_j^* elementul plasat de algoritmul *RLPT* în același rând cu t_i^* . Din $d > \max_{1 \leq k \leq r} \{t_k\}$ rezultă că d , definit ca fiind suma minimală pentru rândurile $\{i_1, i_2, \dots, i_k\}$, trebuie să cuprindă măcar un element din coloanele 1 și 2.

Aserțiunea 2. $2t_j^* \leq \omega_{\text{OPT}}$.

Demonstrație. Deoarece t_i^* este plasat înaintea lui t_j^* și cele mai mari m elemente sunt plasate în m rânduri distincte, rezultă că $t_j^* \leq t_m$ și $j^* > m$, unde j^* reprezintă indicele lui t_j^* . Prin urmare, $2t_j^* \leq \omega_{\text{OPT}}$.

În concluzie:

$$\omega_{\text{RLPT}} \leq t_i^* + t_j^* + t_r \leq (t_i^* + t_r) + t_j^* \leq \omega_{\text{OPT}} + 1/2 \omega_{\text{OPT}} = 3/2 \omega_{\text{OPT}},$$

în contradicție cu ipoteza că $\{t_1, t_2, \dots, t_r\}$ este un contraexemplu. ■

Exemplul 2.11. Un exemplu ilustrativ, parametrizat prin ε , pentru cazul în care marginea superioară de mai sus este atinsă asimptotic este:

$$A_{\text{OPT}} = \begin{bmatrix} 0 & 1+\varepsilon & 1-\varepsilon \\ 1 & 1-2\varepsilon & 0 \end{bmatrix}, \quad A_{\text{RLPT}} = \begin{bmatrix} 0 & 1+\varepsilon & 0 \\ 1 & 1-2\varepsilon & 1-\varepsilon \end{bmatrix}.$$

Raportul $\omega_{\text{RLPT}} / \omega_{\text{OPT}}$ este egal cu $(3 - 3\varepsilon) / 2$ și tinde către $3/2$ dacă ε tinde la zero. ■

3 PROBLEME ÎN TEORIA GRAFURILOR

3.1. O euristică pentru problema arborelui lui Steiner

Punerea problemei. Fie $G = (N, E)$ un graf conex, neorientat, cu muchii ponderate pozitiv, adică:

$$w(e) > 0, \text{ pentru orice } e \in E.$$

Fiind dată $S \subseteq N$, se cere să se identifice un subgraf $G_1 = (Y, F)$ al lui G astfel încât G_1 să fie conex, $S \subseteq Y$ și suma $\sum_{e \in F} w(e)$ este minimă. ■

Aplicații posibile: turism, transporturi, energetică, telefonie, canalizare.

Această problemă este cunoscută ca *arborele lui Steiner* și este NP-completă.

În cele ce urmează se descrie o euristică simplă care rezolvă problema cu performanța:

$$\varphi_H / \varphi_{opt} \leq r = 2(k-1) / k,$$

unde $k = |S|$, φ_H este soluția furnizată de euristica propusă și φ_{opt} este soluția optimală.

Lema 3.1. Fie $T = (N, E)$ un arbore ponderat și $S \subseteq N$ o mulțime de noduri ce satisface condiția că toate nodurile terminale ale lui T aparțin lui S . Atunci:

1. Pentru orice indexare a nodurilor lui $S = [S_1, S_2, \dots, S_k]$ are loc inegalitatea:

$$\varphi_T = \sum_{e \in E} w(e) \leq 1/2 \left[\sum_{i=1}^{k-1} w_T(S_i S_{i+1}) + w_T(S_k S_1) \right];$$

2. Există un mod de indexare $S = [S_1, S_2, \dots, S_k]$ astfel încât:

$$\varphi_T = \sum_{e \in E} w(e) = 1/2 \left[\sum_{i=1}^{k-1} w_T(S_i S_{i+1}) + w_T(S_k S_1) \right],$$

unde $w_T(S_i S_{i+1})$ este valoarea lanțului elementar ce conectează nodurile S_i cu S_{i+1} în arborele T .

Demonstrație. 1. În evaluarea $\sum_{i=1}^{k-1} w_T(S_i S_{i+1}) + w_T(S_k S_1)$, valoarea $w(e)$ a fiecărei muchii e figurează cel puțin de două ori. Într-adevăr, fie o muchie $e = xy$ ce

conectează doi subarbori T_1 și T_2 ai lui T ce rezultă în urma eliminării muchiei e (vezi figura 3.1.).




Fig. 3.1.

Pot avea loc două cazuri:

- S_1 și S_k aparțin lui T_1 . T_2 conține atunci un S_i cu $1 < i < k$, $S_{i-1} \in T_1$ și $S_{i+1} \in T_1$ și ponderea muchiei e apare atât în $w_T(S_{i-1}, S_i)$ cât și în $w_T(S_i, S_{i+1})$;
- $S_1 \in T_1$ și $S_2 \in T_2$. Există atunci un i cu $1 \leq i \leq k$, cu $S_i \in T_1$ și $S_{i+1} \in T_2$ și ponderea muchiei e apare o dată în $w_T(S_i, S_{i+1})$ și încă o dată în $w_T(S_k, S_1)$.

2. Fie o indexare a nodurilor lui S care verifică următoarea proprietate: pentru orice muchie e toate nodurile lui S ce aparțin lui $T_1 \cap S$ sunt indexate cu $[S_i, S_{i+1}, \dots, S_p]$ și cele aparținând lui $T_2 \cap S$ sunt indexate cu $[S_1, \dots, S_{i-1}, S_{p+1}, \dots, S_k]$. Atunci:

$$\varphi_T = \sum_{e \in T} w(e) = 1/2 \left[\sum_{i=1}^{k-1} w_T(S_i, S_{i+1}) + w_T(S_1, S_k) \right].$$

Pentru o asemenea metodă de indexare, fiecare muchie este numărată exact de două ori și anume o dată în $w_T(S_{i-1}, S_i)$ și o dată în $w_T(S_p, S_{p+1})$. Această indexare corespunde parcurgerii unui ciclu eulerian ce înconjoară arborele T , fără a intersecta vreo muchie (vezi figura 3.2.). ■




Fig. 3.2.

Pentru rezolvarea problemei studiate se poate utiliza următoarea euristică:

Euristica H.

- Se construiește graful complet $G(S) = (S, E_S)$ cu muchii ponderate cu $w_G(S_i, S_j) =$ = valoarea celui mai scurt lanț ce leagă S_i cu S_j în graful inițial ponderat cu w .

2. Se construiește un arbore T_S maximal de pondere minimală a grafului $G(S)$.
3. Fie $R = \emptyset$. Pentru fiecare muchie $e_S = S_i S_j \in T_S$ se face $R = R \cup \{\text{nodul aparținând celui mai scurt lanț ce leagă pe } S_i \text{ cu } S_j \text{ în graful } G\}$.
4. Se construiește un arbore maximal de pondere minimală a grafului $Y = S \cup R$.
5. Se elimină nodurile terminale ce nu aparțin lui S . ■

Euristica propusă necesită un timp de $O(n^3)$ pentru calculul matricei simetrice a distanțelor și două căutări de $O(m \log \log n)$ a arborilor maximali de pondere minimală, unde n este numărul de noduri și m este numărul de muchii.

Teorema 3.1. $\varphi_{II} / \varphi_{opt} \leq 2(k - 1) / k$.

Demonstrație. Fie T_o o soluție optimală, toate nodurile terminale ale lui T_o aparținând lui S . Conform lemei 3.1., există un mod de indexare a nodurilor lui S astfel încât:

$$\varphi_{opt} = \varphi_{T_o} = 1/2 \left[\sum_{i=1}^{k-1} w_{T_o}(S_i S_{i+1}) + w_{T_o}(S_k S_1) \right].$$

Deoarece $w_G(S_i S_{i+1}) \leq w_{T_o}(S_i S_{i+1})$ rezultă că:

$$\varphi_{opt} \geq 1/2 \left[\sum_{i=1}^{k-1} w_G(S_i S_{i+1}) + w_G(S_k S_1) \right].$$

Fie ciclul $C = S_1, S_2, \dots, S_k, S_1$ în graful $G(S)$; pentru acest ciclu:

$$\varphi_C = \sum_{i=1}^{k-1} w(S_i S_{i+1}) + w(S_k S_1) \text{ și } \varphi_{opt} \geq 1/2 \varphi_C.$$

Ciclul C conține un arbore maximal T_S al grafului $G(S)$. Acest arbore se obține prin eliminarea din C a unei muchii de pondere maximală. Notând ponderea acestei muchii cu w_{max} rezultă că $\varphi_{T_S} = \varphi_C - w_{max}$, deci:

$$\varphi_{T_S} / (k - 1) - \varphi_C / k = (\varphi_C - w_{max}) / (k - 1) - \varphi_C / k = (\varphi_C / k - w_{max}) / (k - 1) \leq 0,$$

deoarece $\varphi_C / k - w_{max} \leq 0$. În consecință:

$$\varphi_{T_S} \leq \varphi_C (k - 1) / k.$$

În virtutea euristicii, $\varphi_{II} \leq \varphi_{T_S}$, deci:

$$\varphi_{II} \leq \varphi_{T_S} \leq \varphi_C (k - 1) / k,$$

de unde rezultă, ținând seama de relația dintre φ_{opt} și φ_C :

$$\varphi_{II} / \varphi_{opt} \leq 2(k - 1) / k. \blacksquare$$

Exemplul 3.1. Pentru lanțurile $[S_1, x_2, S_2]$, $[S_2, x_3, S_3]$, respectiv $[S_1, x_1, S_2]$, $[S_2, x_1, S_3]$, ale grafului G din figura 3.3. se obțin soluțiile date în figura 3.4., a doua fiind optimală.

Prima soluție este extremă, în sensul că se realizează egalitatea:

$$\varphi_{II} / \varphi_{opt} = 2(k - 1) / k.$$

Într-adevăr:

$$\varphi_{II} / \varphi_{opt} = 20 / 15 = 4 / 3. \blacksquare$$




Fig 3.3.




Fig. 3.4.

Exemplul 3.2. În figura 3.5. se dau pentru graful G soluția euristică și soluția optimală. Are loc relația: $\varphi_{II} / \varphi_{opt} = 32 / 28 = 8 / 7 < 2(4 - 1) / 4 = 3 / 2$. ■




Fig. 3.5.

Exemplul 3.2. demonstrează faptul că euristica propusă nu furnizează întotdeauna o soluție optimală.

3.2. Algoritm euristic pentru arbori Steiner rectiliniari

Punerea problemei. Se studiază elaborarea de arbori Steiner, reprezentând conexiunile de pe plăcile circuitelor electronice, care asigură conectarea între ele a n puncte coplanare. Din motive tehnologice și inginerești, segmentele unei astfel de conectări sunt orizontale și verticale. Distanța dintre două puncte u și v este:

$$w(u, v) = |x_u - x_v| + |y_u - y_v|. \blacksquare$$

Aplicații posibile: electronică, energetică, telefonie.

Prima abordare a problemei se datorește lui Hanan [HAN66], care a stabilit următorul rezultat. Fie S o mulțime de n terminale ale unor piese electronice situate într-un plan. Cu ajutorul lor se construiește o rețea externă, în modul ilustrat în figura 3.6., în care terminalele sunt reprezentate prin cercuri.




Fig. 3.6.

Fie graful $G_S(V, E)$, în care V este mulțimea punctelor de intersecție ale liniilor orizontale și verticale din figura 3.6. și E este mulțimea segmentelor ce conectează direct două puncte situate pe aceeași linie orizontală sau verticală. În lucrarea [HAN66] se demonstrează că un arbore Steiner definit de terminalele date este conținut în G_S . *Problema Steiner pentru grafuri (PSG)* constă în identificarea unui subgraf de pondere minimală ce traversează mulțimea S . În virtutea teoremei lui Hanan [HAN66], rezultă că orice algoritm pentru *PSG* poate fi utilizat pentru identificarea unui *arbore Steiner rectiliniar (ASR)*.

Algoritmul Hanan începe cu sortarea celor n puncte (terminale) în ordinea definită de coordonatele y . Dacă au fost găsite două puncte cu aceeași coordonată y , ele sunt sortate în ordinea definită de coordonata x . Primul subarbore identificat conține un singur punct, având cea mai mică valoare a coordonatei y . Pe măsură ce un nou punct este identificat, el este conectat la subarborile curent printr-o conexiune de lungime minimală. Pentru eliminarea preferinței alegerii unor puncte datorită direcției de parcurgere de jos în sus, distribuția punctelor este rotită cu 90° de trei ori, de fiecare dată fiind construit un nou *ASR* minimal. Urmează alegerea unui cel mai bun dintre cei patru arbori.

Observația cheie în implementarea algoritmului constă în aceea că partea de jos a arborelui devine efectiv ascunsă și poate fi uitată. Un punct a acoperă un punct b dacă b se află în interiorul conului de 90° cu vârful în a . Formal, a acoperă pe b dacă $y_b < y_a$, $x_a + y_a \geq x_b + y_b$ și $x_a - y_a \leq x_b - y_b$.

Lema 3.2. Fie a și b două puncte oarecare ale arborelui curent atunci când este procesat punctul c . Dacă a acoperă pe b , atunci:

$$w(c, a) \leq w(c, b).$$

Demonstrație. O demonstrație simplă poate fi construită pe baza analizei cazurilor. De exemplu, dacă $x_c \leq x_b \leq x_a$, atunci $w(c, a) = x_a - x_c + y_c - y_a$ și $w(c, b) = x_b - x_c + y_c - y_b$, deci relația din enunțul lemei este satisfăcută. O demonstrație geometrică a rezultatului poate fi obținută plecând de la observația că un cerc de rază $w(c, a)$ în jurul lui c , desenat ca un pătrat în plan, nu conține nici un punct din conul de sub a . Într-adevăr, un cerc de rază $w(c, a)$ este un pătrat cu centrul în c , cu laturi înclinate la 45° față de un reper cu axa cx orizontală și cy verticală și având o latură ce trece prin a (vezi figura 3.7.). Coordonatele punctelor de pe latura ce trece prin a verifică relația $x + y = x_a + y_a = w(c, a)$. Pentru orice punct b , din interiorul conului definit de a , există un punct b' pe latura pătratului ce trece prin a pentru care $x_a < x_{b'}$, deci $w(c, a) = w(c, b') < w(c, b)$. ■




Fig 3.7.

Lema 3.3. Fie a, b și c ca în lema 3.2. astfel încât b nu acoperă pe a . Dacă $x_c \geq x_a \geq x_b$ sau $x_b \geq x_a \geq x_c$, atunci $w(c, a) \leq w(c, b)$.

Demonstrație. Inegalitatea din enunț rezultă prin calcul elementar aplicând definițiile de mai sus. ■




Fig. 3.8.

Lemele 3.2. și 3.3. sunt ilustrate pe figurile 3.8.a), respectiv 3.8.b). O consecință a lemei 3.2. constă în faptul că orice segment orizontal și extremitatea fiecărui segment vertical neacoperit generează un con și porțiunea relevantă a

arborelui este mulțimea punctelor neacoperite de alte puncte. Această consecință este ilustrată pe figura 3.9.




Fig. 3.9.

Dacă porțiunea acoperită a arborelui este eliminată, ceea ce rămâne este o mulțime de segmente orizontale și puncte singulare. Aceste puncte singulare vor fi interpretate în continuare drept segmente orizontale degenerate. Figura 3.10. ilustrează, cu ajutorul unor linii verticale trasate prin unele puncte terminale, modul în care mulțimea punctelor terminale stângi partiționează mulțimea coordonatelor x .




Fig. 3.10.

Algoritmul 3.1. tratează una dintre cele patru parcurgeri. Structura esențială de date, *SEGMENTS*, este prelucrată de rutinele **pred-succ** și **addsegment**. Această structură păstrează, pentru arborele curent, mulțimea segmentelor orizontale ce nu sunt acoperite și segmentele sunt ordonate de către punctele lor terminale stângi. Atunci când un nou punct p este procesat, **pred-succ**(p) returnează cele două segmente, a și b , adiacente în ordine, astfel încât p este situat în dreapta punctului drept sau deasupra lui a și p este situat la stânga punctului terminal stâng al lui b . Din lema 3.3. rezultă că singurele puncte ce sunt candidați pentru a fi cel mai apropiat punct de p sunt punctele lui a sau punctul terminal stâng al lui b .

Algoritmul 3.1. (Hanan)

1. [Inițializare] Se consideră un arbore vid.
2. [Terminare] Dacă toate punctele au fost incluse în arbore, atunci STOP.
3. [Alegere] Se alege cel mai apropiat punct p dintre neprelucrate.
4. [Vecine] Se determină pentru p segmentele vecine $(a, b) = \text{pred-succ}(p)$.
5. [Test apropiere] Dacă p este mai apropiat de b , atunci se merge la pasul 8.

6. [Poziționare cu a] Dacă p este în dreapta lui a , atunci se extinde p către extremitatea dreaptă a lui a (vezi figura 3.11.) și se conectează cu extremitatea dreaptă a lui a ; altfel se conectează p vertical în jos la a .
7. [Continuare] Se merge la pasul 9.
8. [Poziționare cu b] Se extinde p către extremitatea stângă a lui b și se conectează p cu extremitatea stângă a lui b .
9. [Adăugare] Se adaugă segmentul rezultat pentru p la arbore cu addsegment.
10. [Ciclare] Se merge la pasul 2. ■

Operațiile descrise în ciclul algoritmului sunt ilustrate, parțial, pe figura 3.11.




Fig. 3.11.

În funcție de modul de implementare a algoritmului propus, complexitatea algoritmului este cuprinsă între $O(n^2)$ și $O(n^{3/2})$.

În lema 3.3. se presupune implicit că punctul b poate fi acoperit de a , ceea ce în cazul figurii 3.11. revine la a accepta că pot exista mai multe puncte de pe segmentul a ce satisfac condițiile lemei 3.3.

3.3. Algoritm euristic pentru identificarea drumurilor minime

Punerea problemei. Fiind dat un graf orientat și un nod sursă al său, se cere identificarea celor mai scurte drumuri de la nodul sursă la toate celelalte noduri. ■

Aplicații posibile: transporturi, energetică, telefonie.

Algoritmul Bellman-Ford [FOR62] este un algoritm clasic de complexitate temporală $O(nm)$, unde n și m reprezintă numărul de noduri, respectiv arce, ale grafului. Există de asemenea diferite euristici mai performante decât algoritmul Bellman-Ford în multe probleme particulare. O asemenea euristică este prezentată în continuare.

Problema celor mai scurte drumuri este notată (G, s, l) , unde $G = (V, E)$ este un graf orientat, $l: E \rightarrow \mathbb{R}$ este funcția lungime și $s \in V$ este nodul sursă. Soluția constă în identificarea drumurilor minime de la s la toate celelalte noduri sau în găsirea unui ciclu al lui G de lungime negativă. Dacă G are un asemenea ciclu se consideră că problema este nerealizabilă. Se presupune că G nu are arce multiple și $|V|$ și $|E|$ se notează cu n , respectiv m .

O funcție potențial este o funcție reală definită pe noduri. Fiind dată o funcție potențial d , se definește funcția de cost redus $l_d: E \rightarrow \mathbb{R}$ prin:

$$l_d(v, w) = l(v, w) + d(v) - d(w),$$

unde (v, w) este arcul de la v la w . Fiind dată o funcție potențial d , se zice că arcul a este admisibil dacă $l_d(a) \leq 0$ și mulțimea arcelor admisibile este notată cu E_d . Graful $G_d = (V, E_d)$ se numește admisibil.

Arborele drumurilor minimale ale lui G este un arbore minimal având rădăcina s astfel încât, pentru fiecare $v \in V$, drumul de la v la s în arbore este drumul minimal de la s la v .

3.3.1. Metoda corectării etichetelor

În cadrul acestei metode, fiecărui nod v i se asociază potențialul său $d(v)$, tatăl $\pi(v)$ și statutul $S(v) \in \{\text{neparcurs}, \text{etichetat}, \text{examinat}\}$. Inițial, pentru fiecare nod v , $d(v) = \infty$, $\pi(v) = \text{nimic}$ și $S(v) = \text{neparcurs}$. Metoda începe cu $d(s) = 0$ și $S(s) = \text{etichetat}$ și aplică procedura SCAN tuturor nodurilor etichetate, până când nu mai există nici unul, caz în care aplicarea metodei se încheie.

Procedura SCAN are următoarea formă:

Algoritmul 3.2. (SCAN(v))

1. [Ciclare] Pentru orice w astfel încât $(v, w) \in E$ se execută pasul 2.
2. [Prelucrare w] Dacă $d(v) + l(v, w) < d(w)$, atunci se face $d(w) = d(v) + l(v, w)$, $S(w) = \text{etichetat}$ și $\pi(w) = v$.
3. [Terminare] Se face $S(v) = \text{examinat}$ și STOP. ■

Dacă v este etichetat, atunci $d(v) < \infty$ și $d(v) + l(v, w)$ este finită.

Metoda se încheie dacă și numai dacă G nu are cicluri de lungime negativă.

În momentul încheierii, etichetele nodurilor *tată* definesc un arbore corect al drumurilor minimale și, pentru fiecare $v \in V$ $d(v)$, dă cel mai scurt drum de la s la v .

3.3.2. Algoritmul examinării topologice

Fie v și w etichetate și $l(v, w) < 0$. Atunci este mai convenabil să se examineze v înaintea lui w deoarece, atunci când v este examinat, $d(w)$ crește și w devine etichetat. Algoritmul examinării topologice folosește o generalizare a acestei idei.

Pentru simplificarea descrierii, se presupune că G nu are cicluri de lungime mai mică sau egală cu 0 și, prin urmare, pentru orice d , G_d este aciclic. Mai departe, se va arăta cum se poate renunța la această presupunere.

Algoritmul menține mulțimea nodurilor etichetate în două mulțimi, A și B . Orice nod etichetat aparține numai uneia din aceste mulțimi. Inițial $A = \emptyset$ și $B = \{s\}$.

La începutul fiecărei parcurgeri, algoritmul folosește mulțimea B pentru a determina mulțimea A a nodurilor ce urmează să fie examinate dealungul parcurgerii după care mulțimea B devine vidă. A este o mulțime liniar ordonată. În timpul parcurgerii, elementele sunt extrase conform ordinei din A și examinate. Noile noduri create se introduc în B . Parcurgerea se încheie când A devine vidă. Algoritmul se încheie când B devine vidă la sfârșitul parcurgerii.

Algoritmul calculează pe A din B după cum urmează.

Algoritmul 3.3. (Ordonare Topologică)

1. [Eliminare] Pentru fiecare $v \in B$ din care nu diverge un arc cu cost negativ redus, se elimină v din B și se marchează ca fiind examinat.
2. [Etichetare] Fie A mulțimea tuturor nodurilor din G_d accesibile din B . Se marchează toate nodurile din A ca fiind etichetate.
3. [Ordonare] Se aplică sortarea topologică pentru a ordona pe A astfel încât pentru fiecare pereche de noduri din A cu $(v, w) \in G_d$, v precede pe w și prin urmare v va fi examinat înaintea lui w . ■

În cazul, menționat mai înainte, în care G are cicluri de lungime mai mică sau egală cu 0, este necesar ca graful G_d să nu fie aciclic. Dacă totuși, G_d are un ciclu de lungime negativă, calculul se poate încheia deoarece se pot obține drumuri de lungimi oricât de mici. Dacă G_d are cicluri de lungime nulă, aceste cicluri se elimină, prin contractare, și calculul continuă.

Exemplul 3.3. Pentru graful din figura 3.12., cele mai scurte drumuri de la nodul 1 la nodurile 2, 3, 4 pot fi ușor identificate și sunt: 1 - 2, 1 - 2 - 3, 1 - 2 - 4 și 1 - 2 - 3 - 4, având respectiv lungimile 1, 2, 3 și 3. După cum se vede, pentru nodul 4 există două drumuri minimale, ambele de lungime 3. Modul în care aceste soluții se obțin cu ajutorul metodelor descrise este prezentat în continuare.




Fig. 3.12.

În cazul aplicării metodei corectării etichetelor, soluția se obține succesiv după cum urmează.

Inițializare: $d(1)=d(2)=d(3)=d(4)=\infty$, $\pi(1)=\pi(2)=\pi(3)=\pi(4)=\text{nimic}$, $S(1)=S(2)=S(3)=S(4)=\text{neparcurs}$. Metoda începe cu atribuirile $d(1)=0$, $S(1)=\text{etichetat}$, urmată de parcurgerea procedurii SCAN.

Arcul (1, 2): $d(1) + 1 < \infty$, $d(2) = d(1) + 1 = 1$, $S(2) = \text{etichetat}$, $\pi(2) = 1$.

Arcul (1, 3): $d(1) + 3 < \infty$, $d(3) = d(1) + 3 = 3$, $S(3) = \text{etichetat}$, $\pi(3) = 1$.

$S(1) = \text{examinat}$.

Noile noduri etichetate sunt 2 și 3. Continuând cu nodul 2, se obține:

Arcul (2, 3): $d(2) + 1 = 1 + 1 < 3$, $d(3) = d(2) + 1 = 2$, $S(3) = \text{etichetat}$, $\pi(3) = 2$.

Arcul (2, 4): $d(2) + 2 < \infty$, $d(4) = d(2) + 2 = 3$, $S(4) = \text{etichetat}$, $\pi(4) = 2$.

$S(2) = \text{examinat}$.

Trecând la nodul 3 se obține:

Arcul (3, 4): $d(3) + 1 = 2 + 1 = 3$, deci procedura SCAN nu se mai aplică.

Urmărind calculele precedente, rezultă că:

$$\pi(2) = 1, \pi(3) = 2, \pi(4) = 2, d(2) = 1, d(3) = 2 \text{ și } d(4) = 3.$$

Arborele ce descrie soluția este arătat în figura 3.13.




Fig. 3.13.

În soluția precedentă a fost aplicată, fără a fi menționată, metoda examinării topologice. Într-adevăr, nodul 2 precede pe 3 și a fost examinat înaintea lui 3. Dacă se parcurge mai întâi nodul 3, atunci se obține:

Arcul (3,4): $d(3) + 1 = 3 + 1 = 4 < \infty$, $d(4) = d(3) + 1 = 3$, $S(4) = \text{etichetat}$, $\pi(4) = 3$.

$S(3) = \text{examinat}$.

Trecând la nodul 2, rezultă:

Arcul (2, 3): $d(2) + 1 = 1 + 1 < 3$, $d(3) = d(2) + 1 = 2$, $S(3) = \text{etichetat}$, $\pi(3) = 2$.

Arcul (2, 4): $d(2) + 2 = 3 < 4$, $d(4) = d(2) + 2 = 3$, $S(4) = \text{etichetat}$, $\pi(4) = 2$.

$S(2) = \text{examinat}$.




Fig. 3.14.

Urmărind calculele precedente, rezultă că:

$$\pi(2) = 1, \pi(3) = 2, \pi(4) = 2, d(2) = 1, d(3) = 2 \text{ și } d(4) = 3,$$

adică aceeași soluție cu cea precedentă, dar obținută parcurgând și arcul (3, 4).

Se mai poate observa că, în ambele cazuri, nu s-a obținut și soluția din figura 3.14. care se poate obține dacă, după parcurgerea arcului (2, 3), se parcurge arcul (3, 4), dar această parcurgere nu este conformă algoritmului. ■

Se poate demonstra că algoritmul parcurgerii topologice este corect, are o complexitate temporală $O(nm)$ și că, în multe cazuri, acest algoritm este mai eficient decât algoritmul Bellman-Ford.

3.4. Metodă euristică pentru identificarea clicilor de cardinalitate dată și de cost minimal

Punerea problemei. Fie dat un graf direcționat ponderat complet cu mulțimea de noduri $V = \{1, 2, \dots, m\}$ și ponderile arcelor $t_{ij} \geq 0$, $i, j = 1, 2, \dots, m$, $i \neq j$, ale arcelor. Se cere ca pentru un n dat, $1 < n < m$, să se identifice o mulțime $C \subset V$ cu $|C| = n$ astfel încât expresia:

$$D(C) = \sum_{i \in C} \sum_{j \in C} t_{ij}$$

să fie de valoare minimă. ■

Aplicații posibile: stabilirea unor arondări.

Este ușor de văzut că este suficient să se considere grafuri neorientate având o matrice simetrică a ponderilor:

$$s_{ij} = t_{ij} + t_{ji}, \text{ pentru } i, j = 1, \dots, m, i \neq j$$

și

$$D(C) = \sum_{i \in C} \sum_{j \notin C} s_{ij}. \quad (3.1)$$

Există un număr de $\binom{m}{n}$ grafuri C care, pentru valori mari ale lui m , sunt greu de enumerat. Pentru $n = 2$ și $n = m - 1$ soluțiile pot fi găsite ușor. Astfel, pentru $n = 2$:

$$D(C) = s_{pq}, p, q \in C, |C| = 2,$$

astfel încât $C = \{p, q\}$ poate fi identificat căutând un element minimal s_{ij} . Pentru $n = m - 1$ și $\{k\} = M \setminus C$ rezultă:

$$D(C) = 1/2 \sum_{i \in C} \sum_{j \in C} s_{ij} = 1/2 \sum_{i=1}^m \sum_{j=1}^m s_{ij} - 1/2 \sum_{j=1}^m s_{kj} - 1/2 \sum_{i=1}^m s_{ik},$$

astfel încât C poate fi identificat alegând un k pentru care:

$$\min_C D(C) = \max_{k \in V} \sum_{i=1}^m s_{ik}.$$

Cei doi algoritmi prezentați în continuare constau în îmbunătățirea succesivă a unei soluții inițiale C , aleasă la întâmplare, pe calea schimbării succesive între ele a două noduri $p \in C$ și $q \notin C$. Pentru (3.1) o asemenea schimbare este:

$$D(C \setminus \{p\} \cup \{q\}) = D(C) - \sum_{\substack{j \in C \\ j \neq p}} s_{pj} + \sum_{\substack{j \in C \\ j \neq q}} s_{qj}.$$

Algoritmul 3.4 (G1)

1. [Inițializări] Se consideră un $C^{(0)}$ inițial cu n noduri oarecare și $t = 0$.
2. [Căutare] Se consideră toate cele $n(m - n)$ interschimbări posibile (p, q) între noduri din $C^{(t)}$ și noduri din afara lui $C^{(t)}$.
3. [Terminare] Dacă nu se determină nici o reducere a lui D , atunci STOP.
4. [Modificare] Fie o pereche (p', q') , cu $p' \in C^{(t)}$ și $q' \notin C^{(t)}$, care asigură o reducere maximală. Se efectuează schimbarea $C^{(t+1)} = C^{(t)} \setminus \{p'\} \cup \{q'\}$, $t = t + 1$.
5. [Ciclare] Se merge la pasul 2. ■

Algoritmul 3.5. (G2)

1. [Inițializări] Se consideră un $C^{(0)}$ inițial cu n noduri oarecare și $t = 0$.
2. [Ordonare] Se ordonează lexicografic toate perechile posibile de interschimbări (p, q) între noduri din $C^{(t)}$ și noduri din afara lui $C^{(t)}$.
3. [Modificare] Se parcurge lista ordonată la pasul 2 și, pentru fiecare pereche (p, q) care asigură o reducere, se efectuează schimbarea $C^{(t)} = C^{(t)} \setminus \{p\} \cup \{q\}$ și se elimină din listă perechile care au p pe primul loc.
4. [Terminare] Dacă nu se determină nici o reducere a lui D , atunci STOP.
5. [Ciclare] Se face $C^{(t+1)} = C^{(t)}$, $t = t + 1$ și se trece la pasul 2. ■

Ambii algoritmi se încheie după un număr finit de pași dar nu garantează obținerea unei soluții optimele. Testările experimentale arată că algoritmul $G1$ se execută într-un timp mai mare decât algoritmul $G2$.




Fig. 3.15.

Exemplul 3.4. Pentru graful din figura 3.15., în care numerele de pe arce reprezintă $t_{ij} + t_{ji}$, numărul de clici cu câte trei noduri este egal cu $\binom{5}{3} = 10$. Aceste clici și costurile lor sunt date în tabelul 3.1.

Clica	{1,2,3}	{1,2,4}	{1,2,5}	{1,3,4}	{1,3,5}	{1,4,5}	{2,3,4}	{2,3,5}	{2,4,5}	{3,4,5}
Costul	11	18	12	21	22	19	12	17	17	16

Tabelul 3.1.

Fie $C^{(0)} = \{3, 4, 5\}$ cu $D(C^{(0)}) = 16$. Deoarece $m = 5$ și $n = 3$, numărul de interschimbări ce urmează a fi efectuate este egal cu $3(5 - 3) = 6$. Aceste schimbări și costurile respective sunt:

$$C^{(1)} = \{1, 4, 5\}, C^{(2)} = \{2, 4, 5\}, C^{(3)} = \{3, 1, 5\}, C^{(4)} = \{3, 2, 5\}, C^{(5)} = \{3, 4, 1\}, C^{(6)} = \{3, 4, 2\};$$

$$D(C^{(1)}) = 19, D(C^{(2)}) = 17, D(C^{(3)}) = 22, D(C^{(4)}) = 17, D(C^{(5)}) = 21, D(C^{(6)}) = 12.$$

Deoarece $D(C^{(6)}) = 12 < 16 = D(C^{(0)})$, reluând aplicarea căutării cu $C^{(0)} = \{3, 4, 2\}$, $D(C^{(0)}) = 12$ rezultă:

$$C^{(1)} = \{1, 4, 2\}, C^{(2)} = \{5, 4, 2\}, C^{(3)} = \{3, 1, 2\}, C^{(4)} = \{3, 5, 2\}, C^{(5)} = \{3, 4, 1\}, C^{(6)} = \{3, 4, 5\};$$

$$D(C^{(1)}) = 18, D(C^{(2)}) = 17, D(C^{(3)}) = 11, D(C^{(4)}) = 17, D(C^{(5)}) = 21, D(C^{(6)}) = 16.$$

Se observă că unele dintre clicile noi identificate se întâlnesc și în aplicarea anterioară. Deoarece $D(C^{(3)}) = 11 < 12 = D(C^{(0)})$, se reia căutarea cu $C^{(0)} = \{3, 1, 2\}$, $D(C^{(0)}) = 11$.

$$C^{(1)} = \{4, 1, 2\}, C^{(2)} = \{5, 1, 2\}, C^{(3)} = \{3, 4, 2\}, C^{(4)} = \{3, 5, 2\}, C^{(5)} = \{3, 1, 4\}, C^{(6)} = \{3, 1, 5\};$$

$$D(C^{(1)}) = 18, D(C^{(2)}) = 12, D(C^{(3)}) = 12, D(C^{(4)}) = 17, D(C^{(5)}) = 21, D(C^{(6)}) = 22.$$

Deoarece nu are loc o descreștere a valorii 11 obținută anterior, rezultă că soluția obținută este $\{3, 1, 2\}$ cu costul 11.

Pentru a aplica algoritmul $G2$ se ordonează lexicografic perechile de numere de noduri ale grafului dat:

$$(1, 2), (1, 3), (1, 4), (1, 5), (2, 3), (2, 4), (2, 5), (3, 4), (3, 5), (4, 5).$$

Plecând de la $C^{(0)} = \{3, 4, 5\}$, $D(C^{(0)}) = 16$, rezultă că prima schimbare ce poate fi efectuată este definită de perechea (1,3) și se obține $C^{(1)} = \{1, 4, 5\}$, cu $D(C^{(1)}) = 19 > 16$. Următoarea pereche de noduri ce poate fi utilizată este (1,4) drept rezultat obținându-se $C^{(1)} = \{3, 1, 5\}$, cu $D(C^{(1)}) = 22 > 16$. Continuând cu perechea (1,5) se obține $C^{(1)} = \{3, 4, 1\}$, cu $D(C^{(1)}) = 21 > 16$. Urmează perechea (2,3) pentru care se obține $C^{(1)} = \{2, 4, 5\}$, cu $D(C^{(1)}) = 17 > 16$. Urmează perechea (2,4) pentru care $C^{(1)} = \{3, 2, 5\}$, cu $D(C^{(1)}) = 17 > 16$. Apoi pentru perechea (2,5) se obține $C^{(1)} = \{3, 4, 2\}$, cu $D(C^{(1)}) = 12 < 16$. În continuare algoritmul se reia cu $C^{(0)} = \{3, 4, 2\}$, cu $D(C^{(0)}) = 12$, continuând cu perechea (3,5). Rezultă $C^{(1)} = \{3, 5, 2\}$ cu $D(C^{(1)}) = 17 > 12$ și se constată că perechea (4,5) nu este utilizabilă. Deoarece a existat o reducere, se reia parcurgerea perechilor cu $C^{(1)} = \{3, 4, 2\}$, cu $D(C^{(1)}) = 12$. Rezultă succesiv:

$$\text{perechea } (1, 2), C^{(2)} = \{3, 4, 1\}, \text{ cu } D(C^{(2)}) = 21 > 12,$$

$$\text{perechea } (1, 3), C^{(2)} = \{1, 4, 2\}, \text{ cu } D(C^{(2)}) = 18 > 12,$$

$$\text{perechea } (1, 4), C^{(2)} = \{3, 1, 2\}, \text{ cu } D(C^{(2)}) = 11 < 12,$$

$$\text{se face } C^{(1)} = \{3, 1, 2\} \text{ și } D(C^{(1)}) = 11,$$

perechea (2, 5), $C^{(2)} = \{3, 4, 5\}$, cu $D(C^{(2)}) = 16 > 11$,

perechea (3, 5), $C^{(2)} = \{3, 5, 2\}$, cu $D(C^{(2)}) = 17 > 11$,

perechea (4, 5), $C^{(2)} = \{3, 5, 2\}$, cu $D(C^{(2)}) = 17 > 11$.

Urmează parcurgerea algoritmului pentru $C^{(2)} = \{3, 1, 2\}$, cu $D(C^{(2)}) = 11$.

În continuare se obține succesiv:

perechea (1, 4), $C^{(3)} = \{3, 4, 2\}$, cu $D(C^{(3)}) = 12 > 11$,

perechea (2, 5), $C^{(3)} = \{3, 4, 5\}$, cu $D(C^{(3)}) = 16 > 11$,

perechea (3, 4), $C^{(3)} = \{4, 1, 2\}$, cu $D(C^{(3)}) = 18 > 11$,

perechea (3, 5), $C^{(3)} = \{5, 1, 2\}$, cu $D(C^{(3)}) = 12 > 11$.

Deci, soluția obținută, minimală, este $C^{(2)} = \{3, 1, 2\}$, cu $D(C^{(2)}) = 11$. ■

După cum se vede, ambii algoritmi necesită, în exemplul considerat, un număr de pași mai mare decât cel necesar calculului direct al celor 10 clici și identificarea clicii minimale. Există exemple pentru care algoritmi propuși sunt mai eficienți. Se poate limita numărul de pași făcuți, obținându-se o aproximare a soluției finale. În exemplul considerat, dacă numărul de pași este limitat la 6, atunci ambii algoritmi identifică soluția $C = \{3, 4, 2\}$, cu $D(C) = 12$.

3.5. Localizarea mai multor centre într-un graf

Punerea problemei. 1. Fiind date mai multe puncte de cerere a unor servicii, situate în nodurile unui graf, și p centre de executare a acestor servicii, se cere așezarea acestor centre în nodurile sau pe arcele grafului, astfel încât durata de așteptare sau distanța parcursă necesară sosirii la cel mai îndepărtat punct solicitant să fie minimală. Această problemă se numește *problema p -centrului absolut al unui graf*.

2. O altă problemă, care se poate rezolva în mod asemănător, prin aceeași metodă, constă în identificarea celui mai mic număr de centre de deservire și localizarea lor, pentru o valoare *critică* dată a duratei de așteptare, respectiv a distanței parcurse. Aceasta se numește *problema p -centrului*. ■

Aplicații posibile: servicii, energetică, telefonică.

Notățiile utilizate în continuare sunt:

G - reprezentarea unui graf,

x - nodurile lui G ,

y - puncte oarecare, pe arcele sau nodurile unui graf,

X_p - o mulțime de p noduri ale lui G ,

Y_p - o mulțime de orice p puncte ale lui G ,

v_j - ponderea nodului x_j ,

$G(X_n, U)$ - graf în care X_n este mulțimea celor n noduri și U mulțimea celor m arce.

În continuare se presupune că graful G este conex și nedirecționat. *Matricea distanțelor*, notată cu $D = [d(x_i, x_j)]$, este matricea celor mai scurte distanțe dintre perechile de noduri ale grafului G . Mai precis, cu $d(y_i, y_j)$ se notează distanța minimă dintre orice pereche de puncte y_i, y_j de pe G .

Fiind dat un nod x_i , operația de parcurgere a tuturor drumurilor divergente din x_i până la o distanță de x_i egală cu $\delta_i = \lambda / v_i$, unde λ este o constantă dată, se numește *penetrare*. Fie $Q_\lambda(x_i)$ mulțimea tuturor punctelor y ale lui G față de care distanța unui nod x_i al lui G este mai mică sau egală cu δ_i , pentru un λ dat, adică:

$$Q_\lambda(x_i) = \{y \mid d(y, x_i) \leq \delta_i\}$$

Mulțimea $Q_\lambda(x_i)$, numită *accesibilă din x_i* , poate fi calculată foarte ușor folosind algoritmul lui Dijkstra pentru identificarea drumurilor minimale. O regiune R_λ se definește ca fiind mulțimea punctelor pentru care distanța la aceeași mulțime de noduri ale lui G este mai mică sau egală cu δ_i , pentru un λ dat. O regiune poate fi un segment al unui arc, un punct al lui G sau o reuniune de segmente de arce având noduri comune.




Fig. 3.16.

Exemplul 3.5. Drept exemplificare, fie graful din figura 3.16., în care toate nodurile au ponderea 1 și lungimile arcelor sunt $c_{1,2}=4$, $c_{2,3}=8$ și $c_{3,1}=6$ unități. Pentru $\lambda=3$ unități, rezultă $\delta_i=3$ pentru toți i și șase regiuni menționate mai jos. Mulțimile $Q_\lambda(x_i)$ sunt reprezentate grafic în modul indicat în dreapta grafului G . Cele șase regiuni sunt:

Regiunea 1: Punctul a care este punctul unic aflat la distanța 3 de nodurile x_1 și x_3 .

Regiunea 2: Secțiunea dintre b și c a arcului (x_1, x_2) . Orice punct din această regiune este situat la o distanță mai mică sau egală cu 3 față de x_1 și x_2 .

Regiunea 3: Reuniunea secțiunilor (a, x_1) și (x_1, b) . Orice punct din această regiune are acces la nodul x_1 pe o distanță mai mică sau egală cu 3.

Regiunea 4: Reuniunea secțiunilor (a, x_3) și (x_3, e) . Din această regiune se poate ajunge la nodul x_3 parcurgând o distanță mai mică sau egală cu 3.

Regiunea 5: Reuniunea secțiunilor (c, x_2) și (x_2, d) . Din această regiune se poate ajunge la nodul x_2 parcurgând o distanță mai mică sau egală cu 3.

Regiunea 6: Secțiunea (e, d) a arcului (x_2, x_3) . Orice punct din această regiune este situat la o distanță mai mică sau egală cu 3 de oricare dintre nodurile x_1, x_2 și x_3 . ■

În general, o regiune R_λ poate fi calculată cu ajutorul mulțimilor accesibile $Q_\lambda(x_i)$ după cum urmează. Regiunile ce nu au acces la nici un nod sunt definite de:

$$R_\lambda(0) = \{y \mid y \text{ este situat pe } G\} - \bigcup_i Q_\lambda(x_i). \quad (3.2)$$

Regiunile ce au acces la t noduri dintre $x_{i_1}, x_{i_2}, \dots, x_{i_t}$, pentru orice $t=1, \dots, n$, sunt date de:

$$R_\lambda(x_{i_1}, x_{i_2}, \dots, x_{i_t}) = \bigcap_{q=1}^t Q_\lambda(x_{i_q}) - \left[\bigcap_{q=1}^t Q_\lambda(x_{i_q}) \right] \cap \left[\bigcup_{q=t+1}^n Q_\lambda(x_{i_q}) \right]. \quad (3.3)$$

Algoritmul pentru determinarea p -centrului absolut pentru un p dat este:

Algoritmul 3.6. (Centru absolut)

1. [Inițializare] Se face $\lambda = 0$.
2. [Creștere] Se face $\lambda = \lambda + \Delta\lambda$, cu un $\Delta\lambda$ mic.
3. [Partiționare] Se determină mulțimile $Q_\lambda(x_i)$, pentru toți $x_i \in X_n$, și se calculează regiunile R_λ .
4. [Graf asociat] Se construiește graful $G' = (X', X_n, U')$, unde X' este mulțimea nodurilor reprezentând regiuni și U' este mulțimea arcelor ce unesc un nod x_i cu un nod regiune dacă și numai dacă x_i este accesibil din această regiune.
5. [Acoperire] Se identifică acoperirea minimală a grafului G' .
6. [Ciclare] Dacă numărul de regiuni din X' este mai mare decât p , atunci se trece la pasul 2; altfel STOP. În acest din urmă caz, regiunile din X' definesc p -centrul absolut al grafului G . ■

În cazul când se cere determinarea celei mai mici valori p astfel încât fiecare nod să fie accesibil dintr-un anumit centru parcurgând o distanță critică dată (problema 2. menționată la început), pașii 3 până la 6 ai algoritmului descris trebuie parcurși o singură dată pentru o valoare critică dată a lui λ . Numărul corespunzător al regiunilor din acoperirea minimală a lui G' (pasul 5) reprezintă valoarea cerută a p -centrului.

Aspecte computaționale. Pentru un λ dat, fie $\delta_i = \lambda / v_i$ distanțele asociate fiecărui nod i al grafului G . Un arc oarecare poate fi accesibil din nodul i în întregime, parțial, sau deloc. Dacă numai o parte a arcului este accesibilă, atunci punctului ei limită i se asociază un *marcaj*. Mulțimea acestor marcaje conține informația necesară pentru determinarea mulțimilor $Q_\lambda(x_i)$ și anume $Q_\lambda(x_i)$ cuprinde toate arcele sau părțile lor de pe drumurile minimale dintre orice marcaj și nodul x_i . După ce toate marcajele au fost plasate, fiecare arc rezultă divizat în mai multe secțiuni, fiecare secțiune fiind definită de nodurile la care punctele ei au acces. Rezultă că, o secțiune oarecare poate fi descrisă cu ajutorul unui vector cu valori binare $\{j_1, j_2, \dots, j_n\}$, în care $j_k = 1$ dacă secțiunea considerată are acces la nodul k și $j_k = 0$ în caz contrar.

Totalitatea secțiunilor cărora le este asociat același vector definesc o aceeași regiune R_λ ce poate fi identificată cu ajutorul ecuațiilor (3.2) și (3.3). În continuare, vectorii ce definesc o regiune vor fi notați cu SI .

Dacă mulțimea de valori 1 a unei secțiuni (SI)₁ este inclusă în mulțimea de valori 1 a unei secțiuni (SI)₂, atunci punctele ei au acces la toate nodurile din (SI)₂ și se zice că (SI)₁ domină pe (SI)₂. Mai precis, (SI)₁ domină pe (SI)₂ dacă $(SI)_1 \otimes (SI)_2 = (SI)_1$, unde \otimes este produsul boolean al vectorilor (SI)₁ și (SI)₂.

Teorema 3.2. Pentru un λ dat, acoperirea minimală G' poate fi identificată prin excluderea din mulțimea X' a nodurilor ce corespund la SI -uri dominate de altele.

Demonstrația este imediată și rezultă din definiția relației de dominare. ■




Fig. 3.17.

Exemplul 3.6. Fie graful din figura 3.17. în care ponderile nodurilor sunt egale cu 1 și numerele de lângă arce reprezintă lungimile lor. Se cere identificarea unui p -centru absolut pentru cazul când $\lambda = 3.5$.




Fig. 3.18.

Marcajele asociate extremităților mulțimilor $Q_\lambda(i)$ pot fi identificate urmărind figura 3.17. și sunt încercuite pe figura 3.18., în care mulțimile $Q_\lambda(i)$ corespund la subgrafuri conexe, unele dintre arcele lor fiind suprapuse. Punctele în dreptul cărora sunt încercuite două cifre corespund la segmente punctuale, situate la distanța λ de fiecare dintre vîrfurile încercuite. Pe figura 3.18. sunt, de asemenea, indicați, pentru exemplificare, și câțiva vectori SI . Perechea (000100), (000110) din stînga nodului 4 ilustrează relația de dominare și anume faptul că segmentul definit de (000110) este

inclus în segmentul (000100). Numărul total de secțiuni, inclusiv cele punctuale, este egal cu 33. Unele dintre aceste secțiuni, de exemplu cele două din jurul nodurilor 1 și 2, sunt identice și pot fi unificate în vederea obținerii unei singure regiuni. Efectuând toate unificările rezultă următoarele 18 regiuni:

- | | | | | | |
|-----|--------|------|--------|------|---------|
| (1) | 000000 | (7) | 000011 | (13) | 000101 |
| (2) | 010000 | (8) | 110000 | (14) | 001001 |
| (3) | 001000 | (9) | 001100 | (15) | 111000 |
| (4) | 000100 | (10) | 100010 | (16) | 011100 |
| (5) | 000010 | (11) | 011000 | (17) | 110010 |
| (6) | 000001 | (12) | 010001 | (18) | 100011. |

Utilizând relația de dominare, mai rămân 7 regiuni și anume cele numerotate mai sus de la 12 la 18. Se recunoaște ușor că mulțimea minimală de regiuni ce asigură accesul la toate nodurile grafului G este formată din regiunile:

$$A = (011100) \text{ și } B = (100011),$$

unde A este o regiune punctuală.

Identificarea regiunilor A și B poate fi efectuată și formal în modul următor. Notând cele 7 regiuni cu literele a, b, c, d, e, f, g se construiește forma conjunctivă:

$$(d + f + g)(a + d + e + f)(c + d + e)(b + e)(f + g)(a + b + c + g),$$

unde fiecare paranteză conține regiunile ce au acces la același nod al grafului G și parantezele succesive corespund nodurilor 1, ..., 6 ale lui G . O literă oarecare, de exemplu a , este interpretată ca reprezentând o regiune ce are acces la nodul asociat perechii de paranteze în care figurează. Un produs de forma fa , obținut prin desfacerea parantezelor, este interpretat ca reprezentând afirmația: nodurile lui G ce corespund regiunilor f și a sunt accesibile din puncte aparținând reuniunii regiunilor f și a . Desfăcând parantezele și ținând seama de regulile:

$$x.x = x \text{ și } x.y + x = x,$$

ce au o semnificație evidentă, se identifică cel mai scurt produs de litere reprezentând regiuni asociate nodurilor lui G . Pentru exemplul studiat se obțin succesiv:

$$\begin{aligned} &(d + f + g a + g e)(e + c b + d b)(g + f a + f b + f c) = \\ &= (d e + d c b + d b + f e + f c b + f d b + g a e + g a c b + \\ &\quad + g a d b + g e + g e c b + g e d b)(g + f a + f b + f c) = \\ &= (d e + d b + f e + f c b + g a c b + g e)(g + f a + f b + f c) = \\ &= g e + \text{termeni ce conțin mai mult de două litere.} \end{aligned}$$

Deci regiunile notate cu e și g , adică A și B de mai înainte constituie soluția problemei.

Graful G' corespunzător exemplului studiat este arătat pe figura 3.19. Regiunile din acoperirea minimală sunt reprezentate de nodurile 16 și 18. ■




Fig. 3.19.

Rezultatele experimentale confirmă eficiența algoritmului prezentat. Se pot menționa cel puțin două avantaje ale metodei propuse și anume:

1. Algoritmul se poate încheia atunci când o anumită aproximare a poziției centrelor este acceptabilă și
2. Metoda poate fi ușor modificată în vederea generării de soluții suboptimale.

3.6. Descompunerea unui graf

Punerea problemei. Fiind dat un graf de complexitate mare, se caută reducerea lui la un graf redus ale cărui noduri reprezintă componente suficient de conexe ale grafului dat, după care problema inițială se reformulează pentru graful redus. ■

Aplicații posibile: rețele de telecomunicații, calcul distribuit și calcul paralel.

3.6.1. Identificarea clicilor (θ, α) maximale

Definiția 3.1. Fie un graf nedirecționat $G = (X, E)$, unde X este mulțimea nodurilor și E este mulțimea muchiilor. Fie apoi $\alpha \in [0, 1]$ un număr real. O parte $A \subset X$ se numește α -clică dacă și numai dacă:

$$t(A) = 2\lambda / (n(n-1)) = \alpha,$$

unde λ este numărul de muchii din A și n este cardinalul lui A . ■

Ținând seama că un graf cu n noduri are cel mult $n(n-1)/2$ muchii, rezultă că $\alpha \leq 1$, egalitatea având loc dacă și numai dacă A este clică.




Fig. 3.20.

Exemplul 3.7. Pentru graful din figura 3.20 și $A = X$, $\alpha = 2 \cdot 5 / (4 \cdot 3) = 0.833$, deci $A = \{a, b, c, d\}$ este o 0,833-clică. ■

Funcția $t(A)$ va fi numită în continuare *grad de prezență a arcelor*.

Fie un subgraf A , x un nod ce nu aparține lui A și $m(x, A)$ numărul de muchii din G de la x la noduri din A . Dacă n este numărul de noduri din A și numărul de arce din subgraful corespunzător este λ , atunci:

$$t(A \cup \{x\}) = 2(\lambda + m(x, A)) / (n(n + 1)).$$

Dacă se cere ca $t(A \cup \{x\}) \geq \beta$, atunci trebuie ca:

$$2\lambda + 2m(x, A) \geq \beta n^2 + \beta n. \tag{3.4}$$

Presupunând că $t(A) \geq \beta$, rezultă:

$$2\lambda \geq \beta n^2 - \beta n. \tag{3.5}$$

Din (3.4) și (3.5) se obține condiția suficientă:

$$m(x, A) \geq \beta n,$$

care permite identificarea recursivă de mulțimi A care sunt β -clici maximale.

Dacă se cere un subgraf cu cel mult θ noduri, atunci se consideră un test suplimentar pentru numărul de noduri.

În continuare se prezintă o generalizare a definițiilor precedente, deoarece în cadrul reducerilor succesive se efectuează suprapuneri de noduri, eliminarea unor muchii și suprapunerea unora dintre ele. Din acest motiv, nodurile și muchiile grafului dat și ale celui redus sunt ponderate pentru a conserva, în graful redus, un maximum de informație privind graful dat. Fie:

$$G(X, E, f, g), f: X \rightarrow N, g: E \rightarrow N$$

graful dat, unde f și g sunt funcțiile pondere ale nodurilor și muchiilor. Funcția $t(A)$ are definiția:

$$t(A) = 2 \sum_{\substack{\{x,y\} \in E \\ x,y \in A}} g(\{x,y\}) / \left(\left(\sum_{x \in A} f(x) \right) \left(\sum_{x \in A} f(x) - 1 \right) \right).$$

Pentru simplificarea scrierii se folosește notația:

$$\sum_{x \in A} f(x) = p(A) \text{ (ponderea submulțimii } A).$$

De asemenea, se introduce un criteriu numit *legătură* definit prin:

$$l(A) = \sum_{\substack{\{x,y\} \in E \\ x \in A, y \in X-A}} g(\{x,y\})$$

și care permite identificarea dintre părțile unui graf ce au același grad de prezență a aceleia care este cel mai puțin legată de restul grafului dat.

În continuare se prezintă procedura de identificare a submulțimilor grafului dat G , numite (α, θ) -clici maximale cu legături minimale. Această procedură se notează $ALPHA(G, f, g, \theta, \alpha, E)$ sau mai simplu $ALPHA(\alpha, E)$.

(G, f, g) este graful ponderat.

Valoarea $\alpha \in [0, 1]$ este aleasă a priori.

A este cea mai bună (α, θ -clică maximală cu criteriul l astfel încât $p(A) \neq 0$).

Pentru mulțimile A ce nu sunt muchii $p(A) > 2$. Într-adevăr, dacă $A = \{a, b\}$, $[a, b] \in E$ și $f(a) = f(b) = 1$, $g([a, b]) = 1$, atunci:

$$t(A) = 2 \cdot 1 / (2 \cdot (2 - 1)) = 1.$$

Rezultă că, în acest caz, A este o 1-clică. Aceste mulțimi nefiind semnificative, se vor elimina în pasul 5 al algoritmului.

Algoritmul 3.7. (ALPHA)

1. [Inițializări] Se face $A_0 = \emptyset$, $l_0 = +\infty$ și toate muchiile din E sunt inițial nemarcate.
2. [Terminare] Dacă nu există $[a, b] \in E$ nemarcată, atunci STOP.
3. [Marcare] Se alege o muchie $[a, b] \in E$ nemarcată, se face $A = \{a, b\}$ și se marchează $[a, b]$.
4. [Test clică] Dacă $t(A) < \alpha$ sau $p(A) > 0$, se trece la pasul 2.
5. [Test continuare] Dacă nu există x cu $p(A \cup x) \leq \theta$ și $t(A \cup x) \geq \alpha$, se trece la pasul 8.
6. [Alegere] Se alege x_0 astfel încât: $p(A \cup x_0) \leq \theta$ și pentru orice x pentru care $p(A \cup x) \leq \theta$ să fie adevărată inegalitatea $t(A \cup x) \leq t(A \cup x_0)$.
7. [Adăugare nod la clică] Se face $A = A \cup x_0$ și se trece la pasul 5.
8. [Redefinire] Dacă $p(A) \leq 2$ și $l(A) < l_0$, se face $l_0 = l(A)$ și $A_0 = A$.
9. [Ciclare] Se trece la pasul 2. ■

3.6.2. Procedura contractării grafului

În contractarea unui graf se aplică următoarele trei principii:

1. Graful G cu n noduri și m muchii se transformă într-un graf G' având n' noduri și m' muchii astfel încât: $n > n'$ și $m > m'$.
2. Se păstrează invariantă structura (α, θ -clicilor între G și G' , mai precis, dacă ϕ este aplicația $P(X) \rightarrow P(X')$ indusă de aplicația $\pi: X \rightarrow X'$ de contracție, definită mai departe, atunci se cere ca:

$$t'[\phi(A)] = t(A) \text{ și } p'[\phi(A)] = p(A).$$

3. Fiind date două părți disjuncte A și B ale grafului G , ordinea în care ele sunt folosite pentru a contracta grafurile G este arbitrară. Aplicațiile p și t ale lui $P(X)$ în R^+ sunt construite plecând de la aplicațiile f și g ale lui X , respectiv E , în N . Pentru construirea grafului este necesară conservarea informației conținute în f și g .

În continuare se folosesc notațiile: $G=(X,E,f,g)$, A este o parte conexă a lui X , $G'=(X',E',f',g')=G/A$ este contractia grafului G după A , $X'=(X-A) \cup \{a\}$, cu $a \notin X$, $E'=\{E \cap P_2(X-A)\} \cup E''$, cu $P_2(V)=\{W \subseteq V \mid 1 \leq |W| \leq 2\}$, cu $E''=\{[x,a] \mid x \in X; \exists u \in A; [x,u] \in E\}$.

Funcțiile f și g au definițiile:

$$f(x) = \begin{cases} f(x), & x \in X - A \\ p(A), & x = a \end{cases}$$

$$g([x, y]) = \begin{cases} g([x, y]), & (x, y) \in (X - A) \times (X - A) \\ \sum_{u \in A} g([x, u]), & \text{dacă } y = a \text{ și } x \neq a \\ \sum_{u \in A, v \in A} g([u, v]), & \text{dacă } x = y = a. \end{cases}$$

Figura 3.21. ilustrează modul de efectuare al contractării unui graf.




Fig. 3.21.

Algoritmul 3.8. (Alfa-clică)

1. [Inițializare] Se face $\alpha = 1$.
2. [Construire clică] Se aplică algoritmul 3.7. $ALPHA(\alpha; E)$.
3. [Test] Dacă nu există o A (α, θ)-clică nevidă, se trece la pasul 7.
4. [Contractare] Se contractează graful G în G / A .
5. [Ciclare] Dacă problema rezultată nu are un grad de simplitate suficient, se trece la pasul 2.
6. [Terminare] Se identifică o soluție a problemei reduse și STOP.
7. [Schimbare α] Se face $\alpha = \alpha - \Delta\alpha$.
8. [Ciclare] Dacă $\alpha > \alpha_{\min}$, se trece la pasul 2.
9. [Diagnostic negativ] Se trece la pasul 6. ■

Observații. 1. Datele la intrare sunt α_{\min} și $\Delta\alpha$ (decrementul lui α).

2. Drept grad de simplitate se poate alege, de exemplu, numărul de muchii.

3. În cazul unui diagnostic negativ (pasul 9) se trece totuși la căutarea unei soluții, deoarece această soluție s-ar putea dovedi acceptabilă.

Exemplul 3.8. Un exemplu ilustrativ al procedurii de contractare este arătat în figura 3.22. Nodurile și muchiile grafului G au ponderea 1 și $\alpha_{\min} = 0.5$.

Nodurile grafului G' se obțin prin contopirea nodurilor încadrate în contururi punctate, notate cu A, B, \dots, J și au ponderile notate lângă aceste contururi. Muchiile grafului G' au ponderi egale cu 1, în afară de muchia ce conectează nodurile corespunzătoare conturilor A și B , care au ponderea 2. ■




Fig. 3.22.

Graful G' obținut în modul descris în cele două euristici poate fi utilizat pentru rezolvarea unei probleme de optimizare ce furnizează o soluție aproximativă pentru o problemă inițială, reprezentată prin graful G .

3.7. Așezarea facilităților într-o rețea planară

Punerea problemei. Se cere plasarea unor facilități în plan în vederea elaborării unor sisteme cât mai eficiente. În termeni de teoria grafurilor, problema se poate formula astfel: Fiind dat un graf nedirecționat și ponderat, $G = (V, E)$, să se identifice un subgraf planar al lui, $G_1 = (V, E_1)$, unde $E_1 \subseteq E$, având o pondere totală maximă a muchiilor. ■

Aplicații posibile: servicii, telefonie.

3.7.1. Euristică triunghiului

În cadrul euristicii triunghiului se încearcă identificarea unor subgrafuri planare convenabile pe calea construirii succesive a unei triangulații. Algoritmul începe cu identificarea primelor patru noduri aplicând procedura *SELECT* sau *AVARICE*.

Algoritmul 3.9. (*SELECT*)

- [Ponderi] Se calculează pentru fiecare nod i suma: $M(i) = \sum_{j \in V} w_{ij}$, unde w_{ij} este ponderea muchiei ce unește nodurile v_i și v_j .
- [Ordonare] Se ordonează nodurile în ordinea nedescrescătoare a valorilor $M(i)$.
- [Selectare] Se selectează primele patru noduri. ■

Algoritmul 3.10. (AVARICE)

1. [Muchie inițială] Se identifică o muchie ab de pondere maximă.
2. [Triunghi inițial] Se caută un nod c astfel încât triunghiul $\{a, b, c\}$ să fie de pondere maximă.
3. [Tetraedru inițial] Se caută un nod d astfel încât graful complet $\{a, b, c, d\}$ să fie de pondere maximă. Fie K_4 graful complet definit de aceste noduri (*tetraedru*). Graful are muchiile ab, ac, ad, bc, bd și cd și triunghiurile abc, abd, acd și bcd .
4. [Adăugare noduri] Se adaugă nodurile rămase, succesiv câte unul în ordinea definită de algoritmul 3.9., identificând de fiecare dată triunghiul în care se inserează nodul. Fie de inserat nodul u . Drept triunghi de inserare se alege triunghiul abc pentru care suma $w_{au} + w_{bu} + w_{cu}$ are valoarea maximă. Procesul de adăugare (vezi figura 3.23.) poate fi formalizat în felul următor:

$$V = V \cup \{u\}, E = E \cup \{au, bu, cu\} \text{ și } T = T \cup \{abu, acu, bcu\} \setminus \{abc\}. \blacksquare$$




Fig. 3.23.

Procedeeul de inserare generează succesiv grafuri planare așa încât nu este necesară testarea planarității la aplicarea algoritmului 3.10.

3.7.2. Euristică expandării roților

Această euristică începe, ca și în cazul precedent, de la un tetraedru furnizat de *SELECT* sau *AVARICE*, aplicând succesiv operația de *desbinare* a nodurilor, care constă în înlocuirea unui nod v de grad cel puțin patru cu două noduri v' și v'' , graful obținut fiind o triangulație.

O roată cu n noduri este un graf ce conține un ciclu de $n - 1$ noduri (*obadă*), fiecare nod al lui fiind adiacent cu un același nod (*butuc*). Desbinarea nodului *butuc*, ilustrată pe figura 3.24, crează, intuitiv, două roți suprapuse.

Procedura expandării începe cu generarea unui tetraedru inițial H , utilizând *SELECT* sau *AVARICE*. La fiecare pas următor se adaugă la H un nod în modul următor. Se identifică un nod x în H și un nod y în $G \setminus H$. Se caută două noduri k și l pe obada roții w_x , având ca butuc pe x . Se expandează w_x în vederea formării roții w'_x și a unei noi roți w_y , astfel încât k și l să fie situate pe obada ambelor roți. Procedura este ilustrată pe figura 3.25.




Fig. 3.24.

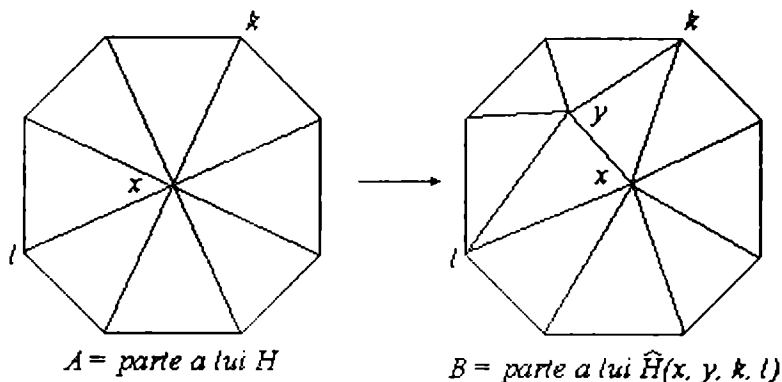


Fig. 3.25.

Graful $\hat{H}(x, y, k, l)$ obținut din H , depinde de alegerea nodurilor x, y, k, l . Pentru obținerea lui A se poate utiliza o strategie *Greedy* care constă în alegerea nodurilor x, y, k și l astfel încât $\hat{H}(x, y, k, l)$ să fie cât mai greu.

3.7.3. Euristică Greedy

În cadrul acestei euristici, se pleacă de la un graf cu n noduri, fără muchii. În continuare se ordonează muchiile necrescător în raport cu ponderile, apoi se identifică succesiv muchiile ce păstrează planaritatea grafului. Procedura se încheie după ce au fost selectate $3n - 6$ arce. Testul de planaritate reprezintă efortul computațional major, chiar dacă testul lui Hopcroft și Tarjan [HOP74] are complexitate liniară în timp.

3.7.4. Îmbunătățirea soluțiilor finale

Fiind obținută o soluție cu una dintre euristicile propuse, ea poate fi îmbunătățită în următoarele două moduri.

1. **Înlocuirea muchiilor.** Eliminarea unei muchii ab dintr-o triangulație crează un patrulater, de exemplu $acbd$. Dacă a doua diagonală cd a patrulaterului nu aparține soluției, ab se poate înlocui cu cd , soluția fiind mai bună dacă $w_{ab} < w_{cd}$.
2. **Relocarea nodurilor.** Un nod a de gradul 3 și arcele incidente cu el ae , af și ag poate fi relocat într-un nou triunghi al triangulației, bcd , introducând arcele ab , ac și bd , în modul descris în figura 3.26.




Fig. 3.26.

Noua triangulație este mai bună dacă:

$$w_{ae} + w_{af} + w_{ag} < w_{ab} + w_{ac} + w_{ad}.$$

3.7.5. Complexitatea euristiciilor propuse

În continuare, cele trei euristici sunt notate cu *DELTA*, *W-E* și *GREEDY*.

Pentru euristica *DELTA* se observă că, la fiecare etapă i a inserării unui nod, există $O(i)$ triunghiuri candidate de luat în considerație. Rezultă că, notând cu C complexitatea în timp:

$$C(\text{DELTA}) = \sum_{i=1}^{n-4} O(i) = O(n^2).$$

Pentru euristica *W-E*, în [EAD82] se demonstrează că $C(\text{W-E}) = O(n^4)$ în cazul cel mai defavorabil. Pentru grafuri generate aleator și având un grad al nodurilor limitat, complexitatea este $O(n^3)$.

În cazul euristicii *GREEDY*, în cel mai rău caz, sunt parcurse $O(n^2)$ muchii, testul Hopcroft și Tarjan fiind apelat ca subrutină. Rezultă o complexitate $O(n^3)$.

3.8. Drum hamiltonian într-un graf planar maximal

Un *drum hamiltonian* într-un graf este un drum minimal ce trece prin fiecare nod măcar o dată. Lungimea drumului hamiltonian este dată de numărul total de muchii parcurse de drum. Fiind dat un graf $G = (V, E)$, numărul nodurilor este notat cu $p = |V|$. Un *drum de lungime k* al lui G este o secvență $v_0 e_1 v_1 e_2 \dots e_k v_k$, astfel încât

nodurile muchiei e_i sunt v_{i-1} și v_i , pentru fiecare $1 \leq i \leq k$. Lungimea unui drum W este notată $l(W)$. Un drum W este *drum închis maximal* (engl. *closed spanning walk*) al lui G dacă $v_0 = v_k$ și fiecare nod din G apare măcar o dată. Un *drum hamiltonian* în G este un drum închis maximal de lungime minimală. Fie $h(G)$ lungimea unui drum hamiltonian în G . Este evident că $p \leq h(G) \leq 2(p - 1)$. Un *ciclu* este un drum închis ale cărui noduri sunt distincte. Un *ciclu hamiltonian* în G este un drum închis maximal de lungime p , adică un ciclu ce trece prin fiecare nod al lui G exact o dată. Un graf este *hamiltonian* dacă conține un ciclu hamiltonian. Un *graf planar maximal* este un graf planar dacă prin adăugarea oricărei alte muchii se obține un graf neplanar. Orice față a unui graf planar maximal este un triunghi. Un triunghi al unui graf planar maximal este numit *triunghi non-față* (engl. *nonface triangle*) dacă nu este frontiera unei fețe.

Pentru un triunghi non-față a unui graf planar maximal G , se notează cu $G_{TI}=(V_{TI},E_{TI})$ subgraful lui G din interiorul lui T și cu $G_{TO}=(V_{TO},E_{TO})$ sugraful lui G din exteriorul lui T . Mai precis, dacă $T = x y z$ ($x, y, z \in V$), $U(T)$ este mulțimea nodurilor din interiorul lui T și $U'(T)$ este mulțimea nodurilor din exteriorul lui T , atunci G_{TI} este subgraful lui G definit de mulțimea de noduri $\{x,y,z\} \cup U(T)$, adică $G_{TI}=G-U'(T)$ și G_{TO} este subgraful lui G definit de nodurile $\{x,y,z\} \cup U'(T)$, adică $G_{TO}=G-U(T)$. Cu p_{TI} și p_{TO} se notează respectiv $|V_{TI}|$ și $|V_{TO}|$.

În algoritmul propus se folosesc două strategii și anume: *divide et impera* în Algoritmul 3.11., numit *HWALK*, și *augmentarea*, descrisă mai jos, în Algoritmul 3.12., numit *LCYCLE*. Fiind dat un triunghi T ce satisface anumite condiții exprimate cu ajutorul valorilor p_{TI} și p_{TO} , se procedează astfel:

Algoritmul 3.11. (HWALK)

1. [Divizare] Se împarte graful G în două grafuri maximale planare G_{TI} și G_{TO} .
2. [Prelucrare] Se apelează algoritmul pentru drumuri maximale în G_{TI} și G_{TO} .
3. [Combinare] Se combină drumurile maximale din G_{TI} și G_{TO} într-un drum maximal al grafului G . ■




Fig. 3.27.

Algoritmul 3.12. (LCYCLE)

Ori de câte ori un graf conține un nod x al unui ciclu C curent obținut și satisfăcând anumite condiții, unele muchii ale lui C sunt înlocuite cu alte muchii, astfel încât x să devină un nod al unui nou ciclu, având o lungime cu unu mai mare. Fie configurațiile din figura 3.27, unde C este reprezentat sub forma $C = v_0 v_1 v_2 \dots v_0$. În figură un ciclu vechi este desenat cu linii subțiri și unul nou cu linii pline.

1. Figura 3.27.a) reprezintă o configurație în care G are un nod x al lui C adiacent cu nodurile v_1 și v_2 ale muchiei $[v_1, v_2]$ din C . De notat că, probabil, $v_j = v_3$, unde v_j este un al treilea nod la care este adiacent x . (Se știe că orice nod din C are gradul 3). Evident că ciclul $C' = v_0 v_1 x v_2 v_3 \dots v_0$ din G este mai lung decât C .
2. Figurile 3.27.b) și 3.27.c) reprezintă configurații, în care pentru un anumit $k \geq 1$ sunt satisfăcute condițiile:
 - i) $(v_{i-1}, v_{i+1}) \in E$ pentru fiecare $i, 1 \leq i \leq k$, și
 - ii) un nod x al lui C este adiacent cu v_1 și v_{k+2} .

Pentru simplificare, nodurile v_i sunt notate în figurile 3.27.b) și 3.27.c) cu i . Dacă k este impar, atunci ciclul:

$$C' = v_0 v_2 v_4 \dots v_{k-1} v_{k+1} v_k v_{k-2} \dots v_3 v_1 x v_{k+2} \dots v_0$$

al lui G este mai lung decât C (vezi figura 3.27.b). Dacă k este par, atunci ciclul:

$$C' = v_0 v_2 v_4 \dots v_k v_{k+1} v_{k-1} \dots v_3 v_1 x v_{k+2} \dots v_0$$

din G este mai lung decât C (vezi figura 3.27.c). De notat că o configurație de tipul 1. poate fi interpretată ca un caz special al tipului 2. cu $k = 0$. ■




Fig. 3.28.

Exemplul 3.9. În figura 3.28. este dat un graf planar maximal $G = (V, E)$, cu $V = \{0, 1, 2, \dots, 16\}$. Ciclul $C = 0 1 2 \dots 14 0$ este reprezentat prin arce pe cerc.

Nodurile 15 și 16 ale ciclului C au gradul 3. Graful G conține o configurație de tipul 1. relativ la nodul 16: $[16, 0], [16, 1] \in E$ și o configurație de tip 2. relativ la nodul 15: $[6, 8], [7, 9], [8, 10], [15, 7], [15, 11] \in E$ ($k=3$). Noul ciclu:

$$C' = 0\ 16\ 1\ 2\ 3\ 5\ 4\ 5\ 6\ 8\ 10\ 9\ 7\ 15\ 11\ 12\ 13\ 14\ 0,$$

mai lung decât C , este desenat cu linii pline. ■

Algoritmul *HWALK* identifică într-un timp $O(p^2)$ un drum maximal închis a cărui lungime este cel mult egală cu $3/2(p-3)$ dacă graful are $p \geq 11$ noduri.

3.9. Algoritm euristic pentru generarea de separatori mici în grafuri arbitrare

Punerea problemei. În multe aplicații este util să se poată efectua descompunerea unui graf G în două părți G_1 și G_2 conectate printr-un număr mic de arce. Un exemplu ilustrativ îl constituie proiectarea circuitelor electronice dreptunghiulare, astfel încât cele două părți ale unui astfel de circuit să fie interconectate printr-un număr mic de conexiuni. ■

Aplicații posibile: circuite electronice și electrice, proiectarea unor sisteme și baze de date distribuite.

O secțiune într-un graf $G=(V,E)$ cu n noduri este o partiție (W, \bar{W}) a mulțimii V . Un separator S într-un graf $G = (V, E)$ cu n noduri este o partiție $C = (W, \bar{W})$ a mulțimii V astfel încât $|W| \geq n/3$ și $|\bar{W}| \geq n/3$, unde cu $|A|$ este notat numărul de elemente al mulțimii A . Un asemenea separator se numește *mic* dacă numărul de arce (v, w) cu v în W și w în \bar{W} este mic.

Algoritmul 3.13. (A)

Ideile de bază ale euristicii propuse, numită *algoritmul A*, sunt următoarele. Fiind dat un graf conex G , se consideră problema p a fluxului, în care o jumătate din nodurile lui G sunt alese drept surse și cealaltă jumătate drept destinații (engl: *sink*). Fie V_A mulțimea surselor și V_Z mulțimea destinațiilor. Fie de asemenea un nou nod sursă A conectat prin arce cu toate sursele și un nou nod destinație Z conectat prin arce cu toate destinațiile. Capacitățile (de transport) ale tuturor arcelor incidente cu A și Z sunt egale cu unu și capacitățile arcelor lui G au valoarea x (în ambele sensuri). Mărimea x constituie *parametrul problemei transporturilor*. Inițial valoarea x se alege suficient de mare astfel încât nici unul dintre arcele lui G nu este saturat de fluxul generat de capacitățile arcelor incidente cu A . Pentru aceasta, este suficientă o valoare x egală cu $n/2$. Arcele din A în V_A și, respectiv, cele din V_Z în Z sunt saturate

(deoarece capacitățile lor au valoarea 1). În continuare, valoarea x este redusă succesiv, folosind de exemplu căutarea binară, până când se identifică o valoare x' astfel încât problema fluxului $p(x' + \varepsilon)$ definește un flux maximal în care nici unul dintre arcele lui G nu este saturat, dar problema $p(x')$ definește un flux maximal care saturează unele dintre arcele lui G . De asemenea, problema fluxului $p(x' - \varepsilon)$ are un flux maximal care nu saturează un arc oarecare (A, y) sau un arc oarecare (w, Z) . De exemplu, dacă G are un singur arc între a și b , a fiind sursă și b destinație, atunci dacă $x > 1$, arcele (A, a) și (b, Z) vor fi saturate în cazul unui flux maximal. Dacă $x = 1$, arcul de la a la b va fi de asemenea saturat în cazul unui flux maximal. Rezultă că problema $p(1 + \varepsilon)$ are un flux maximal pentru care nici unul dintre arcele lui G nu este saturat, dar $p(1)$ are un flux maximal care saturează un arc oarecare din G . De asemenea, $p(1 - \varepsilon)$ are un flux maximal care nu saturează arcele (A, a) și (b, Z) . Dacă valoarea inițială a lui x este n , atunci $\log(n)$ iterații reduc incertitudinea la 1 și fiecare iterație următoare adaugă un supliment semnificativ de informație. Rezultă că $O(\log(n))$ iterații sunt suficiente pentru a obține o valoare semnificativă a fluxului.

Fie A' mulțimea nodurilor y din G astfel încât arcul (A, y) este nesaturat într-un flux maximal pentru problema $p(x' - \varepsilon)$. Fie Z' mulțimea nodurilor din G astfel încât arcul (y, Z') nu este saturat în acest flux. Se poate arăta că arcele saturate ale lui G separă pe A' de Z' și că A' și Z' sunt nevide. Rezultă că arcele saturate ale lui G separă pe G și cu ajutorul lor se poate obține o secțiune C care separă pe A' de Z' astfel încât toate fluxurile prin această secțiune au același sens. Această secțiune se poate obține ușor folosind algoritmul de flux maximal. ■

Eficacitatea algoritmului este dată de următoarea teoremă.

Teorema 3.3. Algoritmul A identifică întotdeauna o secțiune având o capacitate a arcelor aproape maximală. ■

Pentru deducerea unei margini privind performanța algoritmului A se introduce următoarea definiție.

Definiția 3.2. Calitatea $g(C)$ a unei secțiuni $C = (W, \bar{W})$ este definită de raportul $\min(|W|, |\bar{W}|) / |C|$. ■

Teorema 3.4. Fie $C = (W, \bar{W})$ o secțiune a grafului G . Atunci, pentru n , $|W|$ și $|\bar{W}|$ tinzând către infinit, probabilitatea ca algoritmul A să identifice o secțiune având o calitate diferită de $g(C)$ cu mai puțin de $g(C) / \sqrt{n}$ se apropie de o constantă mai mare ca 0.3. Această probabilitate crește dacă raportul $\min(|W|, |\bar{W}|) / n$ scade. ■

Se poate întâmpla ca secțiunea C să nu fie un separator, dacă ea partiționează mulțimea nodurilor în două submulțimi de mărimi foarte diferite. În acest caz, este

posibilă aplicarea algoritmului A pe mulțimea mai mare și repeta acest proces de mai multe ori. Combinând împreună aceste secțiuni într-un mod convenabil se poate obține un separator acceptabil.




Fig. 3.29.

Observații. 1. Se presupune că numărul de noduri din G este par.

2. Un exemplu de graf pentru care valoarea $n / 2$ este atinsă este de forma celui din figura 3.29. (pentru cazul $n = 8$).

Arcele punctate conectează pe A cu mulțimea V_A a nodurilor sursă și pe Z cu mulțimea V_Z a nodurilor destinație. În acest caz o capacitate de transport pe arcului (a, b) egală cu patru nu este suficientă pentru a asigura nesaturarea acestui arc.

4 PROBLEMA COMISVOIAJORULUI

Problema comisvoiajorului este definită în paragraful 1.1.2.2.1., unde este prezentat și un prim algoritm euristic de soluționare (*NN*). Un alt algoritm euristic, bazat pe arborele parțial al unui graf, se află în paragraful 1.1.2.4.2. În continuare vom da alte câteva metode euristice de soluționare a problemei comisvoiajorului, unele restricții și generalizări ale acestei probleme și, în final, sunt prezentate aplicații în care intervin astfel de algoritmi.

4.1. Metode euristice pentru problema comisvoiajorului

Metodele aproximative propuse sunt de tip secvențial și anume la fiecare pas are loc conectarea unor perechi de orașe. Procesul conectării orașelor trebuie să evite generarea de cicluri. Fiecare oraș este conectat cu cel mult altele două și orașele situate la extremitățile unui drum nu pot fi conectate decât în cazul în care toate orașele au fost parcurse și aparțin toate unui singur drum.

4.1.1. Metoda extinderii bilaterale

În prima metodă propusă aici, numită *metoda extinderii bilaterale*, se pleacă de la un drum ce conține o muchie de cea mai mică lungime și sunt adăugate pe rând la acest drum celelalte orașe. La fiecare nouă conectare se alege unul dintre orașele ce nu se află în drum și care se află cel mai aproape de una din extremitățile drumului deja construit. În final se unesc cele două capete ale drumului obținându-se un tur. Aceasta constituie ideea de bază folosită în construirea algoritmului 4.1. În acest algoritm se consideră drept intrare un graf nedirecționat complet cu n orașe ce determină distanțele dintre perechile de orașe considerate. Acest algoritm este asemănător cu metoda *NN*. Deosebirea dintre ele este aceea că în metoda *NN* extinderea se face prin adăugarea unui nou oraș la un singur capăt al drumului,

celălalt capăt rămânând fix (orașul de plecare), pe când în acest algoritmul drumul curent se poate extinde în ambele direcții (adăugarea se poate face la oricare dintre cele două capete).

Algoritmul 4.1. (Extindere bilaterală)

1. [Inițializare] Se determină drumul $P_2 = [a, b]$, unde $[a, b]$ este una din cele mai scurte muchii și se face $i = 2$.
2. [Terminare] Dacă $i = n$, se unesc capetele drumului și STOP.
3. [Alegere] Se alege din mulțimea $\{[x,a]|x \notin P_i\} \cup \{[x,b]|x \notin P_i\}$, a și b fiind cele două capete ale drumului P_i , cea mai scurtă muchie $[x,y]$ astfel încât $x \notin P_i$ și $y \in \{a,b\}$.
4. [Adăugare] Se face $i = i + 1$; dacă $y = a$, atunci se face $P_i = [x, a, \dots, b]$ și $a = x$, altfel se face $P_i = [a, \dots, b, x]$ și $b = x$.
5. [Ciclare] Se merge la pasul 2. ■




Fig. 4.1.

Exemplul 4.1. Pentru graful din figura 4.1., aplicând algoritmul 4.1. se obțin drumurile: $P_2 = [2,3]$, $P_3 = [1,2,3]$, $P_4 = [1,2,3,4]$ și în final se obține ciclul $[1,2,3,4,1]$ de lungime 19. Un tur optimal este $[1,2,4,3,1]$ de lungime 18. ■

4.1.2. Metoda reducerii

Această metodă poate fi privită ca o generalizare a metodei precedente. Se construiesc trei mulțimi de noduri: *IZOLAT*, ce conține orașele care nu au fost unite cu alte orașe, *CAPĂT*, ce conține orașele care au fost unite cu un singur alt oraș și *PROCESAT*, ce conține orașele care au fost unite cu alte două orașe și o mulțime de muchii *TUR*, ce conține muchiiile selectate pentru turul selectat. Algoritmul este:

Algoritmul 4.2. (Reducere)

1. [Inițializare] Se face $IZOLAT = \{1, 2, \dots, n\}$, $CAPĂT = \emptyset$, $PROCESAT = \emptyset$, $TUR = \emptyset$ și se ordonează muchiiile grafului în ordinea nedescrescătoare a lungimii lor.

2. [Terminare] Dacă $IZOLAT = \emptyset$ și $CAPĂT$ conține două orașe, se adaugă la mulțimea TUR muchia ce unește orașele aflate în $CAPĂT$ și STOP.
3. [Muchie nouă] Se elimină prima muchie $[x, y]$ din mulțimea ordonată de muchii.
4. [Muchie nefolositoare] Dacă $x \in PROCESAT$ sau $y \in PROCESAT$ sau x și y sunt legate prin muchiile deja considerate în TUR , atunci se merge la pasul 3.
5. [Adăugare] Se adaugă muchia $[x, y]$ la mulțimea TUR .
6. [Situare x] Dacă $x \in IZOLAT$, se scoate x din $IZOLAT$ și se trece în $CAPĂT$, altfel se scoate x din $CAPĂT$ și se trece în $PROCESAT$.
7. [Situare y] Dacă $y \in IZOLAT$, se scoate y din $IZOLAT$ și se trece în $CAPĂT$, altfel se scoate y din $CAPĂT$ și se trece în $PROCESAT$.
8. [Ciclare] Se merge la pasul 2. ■




Fig. 4.2.

Exemplul 4.2. Pentru graful din figura 4.2., aplicând algoritmul 4.2. se obține mai întâi $IZOLAT = \{1,2,3,4\}$, $CAPĂT = \emptyset$, $PROCESAT = \emptyset$, $TUR = \emptyset$ și mulțimea muchiilor ordonate $\{[1,2], [3,4], [2,3], [1,3], [2,4], [1,4]\}$. Considerarea muchiei $[1,2]$ produce următoarele modificări: $IZOLAT = \{3,4\}$, $CAPĂT = \{1,2\}$, $PROCESAT = \emptyset$, $TUR = \{[1,2]\}$ și mulțimea muchiilor ordonate $\{[3,4], [2,3], [1,3], [2,4], [1,4]\}$. Considerarea muchiei $[3,4]$ produce următoarele modificări: $IZOLAT = \emptyset$, $CAPĂT = \{1,2,3,4\}$, $PROCESAT = \emptyset$, $TUR = \{[1,2], [3,4]\}$ și mulțimea muchiilor ordonate $\{[2,3], [1,3], [2,4], [1,4]\}$. Considerarea muchiei $[2,3]$ produce următoarele modificări: $IZOLAT = \emptyset$, $CAPĂT = \{1,4\}$, $PROCESAT = \{2,3\}$, $TUR = \{[1,2], [3,4], [2,3]\}$ și mulțimea muchiilor ordonate $\{[1,3], [2,4], [1,4]\}$. Acum sunt îndeplinite condițiile din pasul 2 rezultând $TUR = \{[1,2], [3,4], [2,3], [1,4]\}$, din care rezultă ciclul $[1,2,3,4,1]$ de lungime 17. Un tur optimal este $[1,2,4,3,1]$ de lungime 16. ■

4.1.3. Metoda proximității

Deoarece fiecare oraș este conectat cu altele două, rezultă că lungimea minimală a turneului, respectiv marginea inferioară, este cel puțin egală cu jumătatea sumei distanțelor dintre fiecare oraș și două dintre orașele cele mai apropiate lui. În practică această limită este atinsă destul de rar.

În metoda următoare, numită *metoda proximității* (engl. *proximity method*), orașele sunt conectate în ordinea crescătoare a distanțelor de conectare. Pentru orașele izolate se consideră cele mai apropiate două orașe care au cel mult o legătură, dar nelegate între ele și pentru orașele cu o legătură se consideră acea legătură și cel mai apropiat oraș cu cel mult o legătură și diferit de celălalt capăt al drumului la care aparține orașul respectiv. Algoritmul este următorul:

Algoritmul 4.3. (*Proximitate*)

- [Inițializare] Se face $IZOLAT = \{1, 2, \dots, n\}$, $CAPĂT = \emptyset$, $PROCESAT = \emptyset$, $TUR = \emptyset$ și $CAP(i) = 0$, pentru $i = 1, 2, \dots, n$.
- [Terminare] Dacă $IZOLAT = \emptyset$ și $CAPĂT$ conține două orașe, se adaugă la mulțimea TUR muchia ce unește orașele aflate în $CAPĂT$ și STOP; altfel, dacă $IZOLAT = \{i\}$ și $CAPĂT = \{j, k\}$, se adaugă la mulțimea TUR muchiile $[i, j]$ și $[i, k]$ apoi STOP.
- [Orașe izolate] Pentru fiecare $i \in IZOLAT$ se determină două orașe j și k din $IZOLAT \cup CAPĂT$, $k \neq CAP(j)$ care minimizează expresia $d_i = w(i, j) + w(i, k)$.
- [Orașe capete] Pentru fiecare $i \in CAPĂT$ se determină orașul $j \neq CAP(i)$ din $IZOLAT \cup CAPĂT$ care minimizează $d_i = w(i, j) + w(i, k)$, unde $[i, k] \in TUR$.
- [Alegere] Se alege $i \in IZOLAT \cup CAPĂT$ pentru care valoarea d_i este minimă.
- [i izolat] Dacă $i \in IZOLAT$, se adaugă la TUR muchiile $[i, j]$ și $[i, k]$, unde j și k sunt determinate la pasul 3, se mută j și k din $IZOLAT$ în $CAPĂT$ sau din $CAPĂT$ în $PROCESAT$ și se schimbă corespunzător valorile din CAP pentru j și k și alte capete legate de ele.
- [i capăt] Dacă $i \in CAPĂT$, se adaugă la TUR muchia $[i, j]$, unde j este determinat la pasul 4, se mută j din $IZOLAT$ în $CAPĂT$ sau din $CAPĂT$ în $PROCESAT$ și se schimbă valorile din CAP pentru j și eventual celălalt capăt legat de el.
- [Marcare] Se trece i în $PROCESAT$ și se face $CAP(i) = 0$.
- [Ciclare] Se merge la pasul 2. ■

Exemplul 4.3. Pentru rețeaua din figura 4.3.a), marginea inferioară a lungimii turneului este egală cu:

$$\frac{1}{2} [(1 + 3) + (1 + 2) + (2 + 3) + (3 + 4) + (2 + 3)] = \frac{1}{2} (4 + 3 + 5 + 7 + 5) = 12,$$




Fig. 4.3.

unde perechile de numere din parantezele interioare se referă la nodurile 1, 2, ..., 5 ale rețelei date obținând valorile $d_1 = 4$, $d_2 = 3$, $d_3 = 5$, $d_4 = 7$ și $d_5 = 5$. Se vede că orașul 2 urmează a fi ales, deoarece suma distanțelor lui la orașele 1 și 3 este cea mai mică dintre sumele minimale ale distanțelor celorlalte orașe la câte alte două orașe. Configurația obținută este arătată pe figura 4.3.b). Noile valori calculate sunt $d_1 = 5$, $d_3 = 5$, $d_4 = 7$ și $d_5 = 7$. Următoarea conectare ce evită generarea unui ciclu și asigură o creștere minimală este, de exemplu, cea dintre orașele 3 și 5 (ar mai putea fi și cea dintre 1 și 4), configurația generată fiind arătată pe figura 4.3.c). Acum sunt îndeplinite condițiile din pasul 2 (partea a doua) și se unește orașul 4 cu capetele 1 și 5 ale drumului deja generat cum se arată în figura 4.3.d). Turneul generat are lungimea 14, care depășește cu 2 marginea inferioară. ■

4.1.4. Metode bazate pe pierderi

Pentru formalizarea altor euristici, se introduce noțiunea de *pierdere* (engl. *loss*) a orașului i , notată $pierd(i)$ și definită după cum urmează. Fie $l(1, i)$, $l(2, i)$, și $l(3, i)$ cele mai apropiate trei orașe de i , excluzându-le pe cele conectate de două ori și, dacă i este deja conectat, excluzând orașul situat la cealaltă extremitate lanțului. și $d(1, i)$, $d(2, i)$, și $d(3, i)$ distanțele corespunzătoare dintre i și cele trei orașe menționate. Pierderea unui oraș i , notată $pierd(i)$, măsoară diferența dintre realizarea celei mai favorabile configurații pentru nodul respectiv și cea mai defavorabilă configurație ce s-ar putea obține în urma unei conexiuni provocată de un alt oraș ce se poate uni cu unul dintre candidații orașului i la un moment anterior, anulând astfel unele dintre posibilitățile de cuplare.

Algoritmuluristic care ține seama de pierderi are următoarea structură:

Algoritmul 4.4. (*Pierderi*)

1. [Inițializare] Se face $IZOLAT = \{1, 2, \dots, n\}$, $CAPĂT = \emptyset$, $PROCESAT = \emptyset$, $TUR = \emptyset$ și $CAP(i) = 0$, pentru $i = 1, 2, \dots, n$.

2. [Terminare] Dacă $IZOLAT = \emptyset$ și $CAPĂT$ conține două orașe, se adaugă la mulțimea TUR muchia ce unește orașele aflate în $CAPĂT$ și $STOP$; altfel, dacă $IZOLAT = \{i\}$ și $CAPĂT = \{j, k\}$, se adaugă la mulțimea TUR muchiile $[i, j]$ și $[i, k]$ apoi $STOP$.
3. [Pierderi] Se calculează $pierd(i)$ pentru fiecare oraș $i \in IZOLAT \cup CAPĂT$.
4. [Alegere] Se alege din mulțimea $IZOLAT \cup CAPĂT$ orașul i pentru care $pierd(i)$ este cea mai mare.
5. [Modificări] Se face pentru i conexiunea cea mai favorabilă și se efectuează modificările corespunzătoare ei.
6. [Ciclare] Se merge la pasul 2. ■

În continuare vom da câteva metode posibile de calcul pentru pierderile asociate unui oraș. Aceste funcții sunt comparabile ca eficiență, putându-se da contraexemple prin care se demonstrează că nu există o relație de dominare între ele.

4.1.4.1. Pierdere simplă

Dacă i nu este conectat cu un alt oraș, adică este izolat, atunci sunt necesare două conexiuni, în situația cea mai favorabilă fiind orașele $l(1, i)$ și $l(2, i)$ și cea defavorabilă fiind orașele $l(2, i)$ și $l(3, i)$, deci:

$$pierd(i) = d(3, i) - d(1, i)$$

și, dacă i este deja conectat, atunci este necesară o conexiune, în situația cea mai favorabilă fiind orașul $l(1, i)$ și cea defavorabilă fiind orașul $l(2, i)$, deci:

$$pierd(i) = d(2, i) - d(1, i),$$

În ambele cazuri, dacă $pierd(i)$ este pierderea maximală dintre toate pierderile nodurilor care nu au două conexiuni, i este conectat la cel mai apropiat vecin, indicat de $l(1, i)$. Această funcție are avantajul simplității.

4.1.4.2. Pierdere compusă

Să considerăm trei exemple pentru care pierderea simplă este logic inconsistentă. Primul dintre ele este al unui oraș i neconectat, cele două mai apropiate orașe de el fiind conectate între ele. În acest caz, orașul i nu poate fi conectat la cele mai apropiate două orașe, deoarece în felul acesta ar rezulta un ciclu. Legăturile alese vor fi atunci către primul cel mai apropiat oraș și cel de al treilea. Dacă legătura preferată la cel mai apropiat oraș nu este obținută, pierderea minimală sau costul minimal se realizează prin conectarea la al doilea cel mai apropiat oraș și, dacă legătura la al treilea cel mai apropiat oraș nu este obținută, atunci pierderea minimală sau costul minimal se realizează pe calca conectării la al patrulea cel mai apropiat oraș. Deci, dacă $l(1, i)$ este conectat cu $l(2, i)$ și i este neconectat, atunci:

$$pierd(i) = \max \{d(2, i) - d(1, i), d(4, i) - d(3, i)\},$$

după care se preferă conectarea lui i la $l(1, i)$, respectiv $l(3, i)$, după cum $pierd(i)$ este egală cu $d(2, i) - d(1, i)$, respectiv $d(4, i) - d(3, i)$.

Al doilea exemplu este cel în care cele două capete ale unui drum au ambele drept candidat de legătură un același oraș. Al treilea exemplu este cel în care capetele unui drum au printre candidate orașe ce sunt capetele altui drum, fiecare în parte un alt capăt. Se mai pot obține multe alte combinații care pot duce la cicluri.

Ținând seama de toate aceste situații se poate construi o funcție $pierd(i)$ mai complicat de explicat prin multitudinea situațiilor analizate. Pentru cei interesați prezentăm o variantă a acestei funcții în limbaj C. Menționăm că în limbajul C cea mai mică valoare a unui index este 0, nu 1 ca în alte limbaje, și, de aceea, valorile corespunzătoare indicilor orașelor sunt diminuate cu o unitate. Numărul maxim de orașe este dat de NMO fiind în cazul nostru 1000. Parametrii de intrare sunt numărul n de orașe, matricea l care dă pe fiecare coloană i indicii celor mai apropiate patru orașe cu cel mult o legătură de orașul i , matricea d care dă distanțele corespunzătoare orașelor indicate în matricea l și vectorul cap în care se pune indicele celui mai apropiat capăt al unui drum dacă orașul curent este un capăt de drum sau se pune valoarea -2 dacă orașul curent are deja două legături sau se pune valoarea -1 dacă orașul curent nu are nici o legătură, adică este nod izolat. Parametrii de ieșire sunt vectorii $pref$ în care se păstrează preferința fiecărui oraș pentru o legătură care ar produce o pierdere mai mare prin nerealizare și $pierd$ care dă pierderea maximă prin nerealizarea uneia dintre legăturile optime. Fiecare rând al funcției este comentat pentru a se înțelege diferitele cazuri considerate.

```
#define NMO 1000
void pierdere(int n, int l[4][NMO], float d[4][NMO], int cap[NMO], int pref[NMO],
             float pierd[NMO])
{ int i, j, k, a, b, c;
  for(i = 0; i < n; i++) // parcurgere orașe pentru calculul pierderilor;
  { pierd[i] = 0; pref[i] = -1; // inițializare pierdere și preferință pentru orașul i;
    if(cap[i] == -2) continue; // pentru oraș i cu două legături nu se fac investigații;
    a = l[0][i]; b = l[1][i]; // fixare legături posibile cele mai apropiate de i;
    pref[i] = a; // fixare cel mai apropiat oraș ca preferatul principal al lui i;
    if(cap[i] == -1) // cazul unui oraș izolat (fără legături deja considerate);
    { pierd[i] = d[2][i] - d[0][i]; // se leagă i cu orașul l(3, i) în loc de l(1, i);
      if(cap[a] == l[1][i]) // orașele l(1, i) și l(2, i) legate între ele;
```

```

{pierd[i] = d[1][i] - d[0][i]; // pierdere oraș l(2, i) în loc de l(1, i);
if(pierd[i] < d[3][i] - d[2][i]) // pierdere mai mare cu l(4, i) în loc de l(3, i);
{pierd[i] = d[3][i] - d[2][i]; pref[i] = l[2][i];} // schimbare în i;
} // terminare calcule orașele l(1, i) și l(2, i) legate;
else // orașele l(1, i) și l(2, i) nu sunt legate;
if(cap[a] == l[2][i]) // orașele l(1, i) și l(3, i) legate între ele;
{if(pierd[i] < d[3][i] - d[1][i]) // pierdere mai mare cu l(4, i) în loc de l(2, i);
{pierd[i] = d[3][i] - d[1][i]; pref[i] = l[1][i];} // schimbare în i;
} // terminare calcule orașele l(1, i) și l(3, i) legate;
else // orașele l(1, i) și l(3, i) nu sunt legate;
{if(cap[b] == l[2][i]) // orașele l(2, i) și l(3, i) legate între ele;
pierd[i] = d[3][i] - d[0][i]; // pierdere oraș l(4, i) în loc de l(1, i);
} // terminare calcule orașele l(1, i), l(2, i) și l(3, i) nelegate;
} // terminare calcule pentru oraș i izolat;
else // cazul unui oraș cu o legătură deja stabilită;
{pierd[i] = d[1][i] - d[0][i]; // pierdere oraș l(2, i) în loc de l(1, i);
j = cap[i]; // j este celălalt capăt legat de i;
if(j < i) // capătul corespunzător lui i a fost procesat;
// coordonează alegerile între cele două capete;
{k = l[1][j]; // k este noua preferință posibilă pentru j;
if(l[0][i] == l[0][j]) // l(1, i) același cu l(1, j);
if(l[1][i] == l[1][j]) // l(2, i) același cu l(2, j);
if(l[1][i] == cap[a]) // orașele l(1, i) și l(2, i) legate;
if(d[2][i] - d[0][i] < d[2][j] - d[0][j]) // alegere între i și j;
{pierd[i] = d[3][i] - d[2][i]; pref[i] = l[2][i];} // schimbare i;
else // se modifică alegerea din j;
{pierd[j] = d[3][j] - d[2][j]; pref[j] = l[2][j];} // schimbare j;
else // orașele l(1, i) și l(2, i) nelegate;
if(pierd[j] > pierd[i]) // se face schimbare pentru preferința lui i;
{pierd[i] = d[2][i] - d[1][i]; // pierdere oraș l(3, i) în loc de l(2, i);
pref[i] = l[1][i]; // se preferă orașul l(2, i) în i;
if(l[2][i] == cap[a]) // sunt legate orașele l(1, i) cu l(3, i),
pierd[i] = d[3][i] - d[1][i]; // pierdere oraș l(4, i) în loc de l(2, i);
if(l[2][j] == cap[k]) // sunt legate orașele l(2, j) și l(3, j);
pierd[j] = d[3][j] - d[0][j]; // pierdere oraș l(4, j) în loc de l(1, j);
else // nu sunt legate orașele l(2, j) și l(3, j);

```



```

    pierd[j] = d[2][j] - d[0][j];
}
else
{pierd[i] = d[2][i] - d[0][i];
if(l[2][i] == cap[b])
    pierd[i] = d[3][i] - d[0][i];
if(l[2][j] == cap[a])
    pierd[j] = d[3][j] - d[1][j];
else
    pierd[j] = d[2][j] - d[1][j];
pref[j] = l[1][j];
}
else
if(l[1][i] == cap[a])
if(pierd[j] < d[2][i] - d[0][i])
{if(l[2][j] == cap[a])
    pierd[j] = d[3][j] - d[1][j];
else
    pierd[j] = d[2][j] - d[1][j];
pref[j] = l[1][j];
} // terminare calcule j cu pierdere mai mică decât i;
else // i cu pierdere mai mică decât j;
{pierd[i] = d[3][i] - d[2][i]; pref[i] = l[2][i];} // schimbare în i;
else // orașele l(1, i) și l(2, i) nu sunt legate;
if(l[1][j] == cap[a]) // sunt legate orașele l(1, i) și l(2, j);
if(pierd[i] < d[2][j] - d[0][j]) // pierdere în i mai mică decât în j;
{if(l[2][i] == cap[a]) // orașele l(1, i) și l(3, i) legate;
    pierd[i] = d[3][i] - d[1][i]; // pierdere oraș l(4, i) în loc de l(2, i);
else // orașele l(1, i) și l(3, i) nu sunt legate;
    pierd[i] = d[2][i] - d[1][i]; // pierdere oraș l(3, i) în loc de l(2, i);
pref[i] = l[1][i]; // schimbare preferință i pentru l(2, i);
} // terminare calcule pierdere în i mai mică decât în j;
else // pierdere în j mai mică decât în i;
{pierd[j] = d[3][j] - d[2][j]; pref[j] = l[2][j];} // schimbare j;
else // orașele l(1, i) și l(2, j) nu sunt legate;
if(pierd[j] > pierd[i]) // se face schimbare pentru preferința lui i;

```

```

{if(l[2][i] == cap[a]) // orașele l(1, i) și l(3, i) legate;
  pierd[i] = d[3][i] - d[1][i]; // pierdere oraș l(4, i) în loc de l(2, i);
else // orașele l(1, i) și l(3, i) nu sunt legate;
  pierd[i] = d[2][i] - d[1][i]; // pierdere oraș l(3, i) în loc de l(2, i);
  pref[i] = l[1][i]; // schimbare preferință i pentru l(2, i);
} // terminare calcule pierdere în i mai mică decât în j;
else // se face schimbare pentru preferința lui j;
{if(l[2][j] == cap[a]) // sunt legate orașele l(1, i) și l(3, j);
  pierd[j] = d[3][j] - d[1][j]; // pierdere oraș l(4, j) în loc de l(2, j);
else // nu sunt legate orașele l(1, i) și l(3, j);
  pierd[j] = d[2][j] - d[1][j]; // pierdere oraș l(3, j) în loc de l(2, j);
  pref[j] = l[1][j]; // preferatul lui j este orașul l(2, j);
} // terminare calcule l(1, i) același cu l(1, j);
else // orașele l(1, i) și l(1, j) diferite;
if(l[1][i] == l[0][j]) // orașul l(2, i) același cu orașul l(1, j);
if(l[0][i] == l[1][j]) // orașul l(1, i) același cu orașul l(2, j);
if(l[1][i] == cap[a]) // orașele l(1, i) și l(2, i) sunt legate;
if(d[2][i] - d[0][i] < d[2][j] - d[0][j]) // pierderea din i mai mică;
  {pierd[i] = d[3][i] - d[2][i]; pref[i] = l[2][i];} // schimbare în i;
else // pierderea din j mai mică;
  {pierd[j] = d[3][j] - d[2][j]; pref[j] = l[2][j];} // schimbare în j;
else // orașele l(1, i) și l(2, i) nu sunt legate;
{pierd[i] = d[2][i] - d[0][i]; // pierdere oraș l(3, i) în loc de l(1, i);
if(l[2][i] == cap[b]) // orașele l(2, i) și l(3, i) sunt legate;
  pierd[i] = d[3][i] - d[0][i]; // pierdere oraș l(4, i) în loc de l(1, i);
if(l[2][j] == cap[k]) // orașele l(2, j) și l(3, j) sunt legate;
  pierd[j] = d[3][j] - d[0][j]; // pierdere oraș l(4, j) în loc de l(1, j);
else // orașele l(2, j) și l(3, j) nu sunt legate;
  pierd[j] = d[2][j] - d[0][j]; // pierdere oraș l(3, j) în loc de l(1, j);
} // terminare calcule pentru orașele l(1, i) și l(2, i) nelegate
else // orașul l(1, i) diferit de orașul l(2, j);
if(l[1][i] == cap[a]) // orașele l(1, i) și l(2, i) sunt legate;
  if(d[2][i] - d[0][i] < pierd[j]) // pierderea din i mai mică;
    {pierd[i] = d[3][i] - d[2][i]; pref[i] = l[2][i];} // schimbare în i;
  else // pierderea din j mai mică;
    {pierd[j] = d[2][j] - d[1][j]; pref[j] = l[1][j];} // schimbare în j;

```

```

else // orașele l(1, i) și l(2, i) nu sunt legate;
  if(l[2][i] == cap[b]) // orașele l(2, i) și l(3, i) sunt legate;
    pierd[i] = d[3][i] - d[0][i]; // pierdere oraș l(4, i) în loc de l(1, i);
  else // orașele l(2, i) și l(3, i) nu sunt legate;
    pierd[i] = d[2][i] - d[0][i]; // pierdere oraș l(3, i) în loc de l(1, i);
else // orașul l(2, i) diferit de orașul l(1, j);
  if(l[0][i] == l[1][j]) // orașul l(1, i) același cu orașul l(2, j);
    if(l[0][j] == cap[k]) // orașele l(1, j) și l(2, j) sunt legate;
      if(d[2][j] - d[0][j] > pierd[i]) // pierderea din i mai mică;
        {pierd[i] = d[2][j] - d[0][j]; pref[i] = l[1][i];} // schimbare în i;
      else // pierderea din j mai mică;
        {pierd[j] = d[3][j] - d[2][j]; pref[j] = l[2][j];} // schimbare în j;
    else // orașele l(1, j) și l(2, j) nu sunt legate;
      if(l[2][j] == cap[k]) // orașele l(2, j) și l(3, j) sunt legate;
        pierd[j] = d[3][j] - d[0][j]; // pierdere oraș l(4, j) în loc de l(1, j);
      else // orașele l(2, j) și l(3, j) nu sunt legate;
        pierd[j] = d[2][j] - d[0][j]; // pierdere oraș l(3, j) în loc de l(1, j);
else // orașul l(1, i) diferit de orașul l(2, j);
  if(l[1][i] == l[1][j]) // orașul l(2, i) același cu orașul l(2, j);
    if(l[1][i] == cap[a]) // orașele l(1, i) și l(2, i) sunt legate,
      if(l[0][i] == l[2][j]) // orașul l(1, i) același cu orașul l(3, j);
        pierd[j] = d[3][j] - d[0][j]; // pierdere oraș l(4, j) în loc de l(1, j);
      else // orașele l(1, i) și l(3, j) sunt diferite;
        pierd[j] = d[2][j] - d[0][j]; // pierdere oraș l(3, j) în loc de l(1, j);
    else // orașele l(1, i) și l(2, i) nu sunt legate;
      if(l[0][j] == cap[k]) // orașele l(1, j) și l(1, j) sunt legate;
        if(l[2][i] == l[0][j]) // orașele l(3, i) și l(1, j) coincid;
          pierd[i] = d[3][i] - d[0][i]; // pierdere oraș l(4, i) în loc de l(1, i);
        else // orașele l(3, i) și l(1, j) diferite;
          pierd[i] = d[2][i] - d[0][i]; // pierdere oraș l(3, i) în loc de l(1, i);
  } // terminare tratare coordonare cele două capete i și j;
} // terminare calcule pentru oraș i cu o legătură deja stabilită;
} // terminare ciclul pentru parcurgere orașe;
} // terminare funcție de calcul pierderi și preferințe de legare.

```

4.1.4.3. Folosirea distanțelor ajustate

La stabilirea pierderilor, în loc să se țină seama de situația unui singur oraș, se pot avea în vedere perechile de orașe. Aceasta deoarece, dacă orașul j este cel mai apropiat de orașul i , s-ar putea ca orașul i să nu fie cel mai apropiat de orașul j , existând un alt oraș k mai aproape de j . Aceasta implică, în cazul legării lui i cu j , să fie favorabil pentru i dar nu pentru j .

Pentru stăpânirea fenomenului menționat, se poate utiliza noțiunea de *distanță ajustată* dintre două orașe care este dată de expresia:

$$da(i, j) = 2 d(i, j) - d1(i) - d1(j),$$

unde $d1(i)$, respectiv $d1(j)$, reprezintă distanțele orașului i , respectiv j , la cel mai apropiat oraș de i , respectiv de j și $d(i, j)$ este distanța dintre i și j . Utilizând distanța ajustată în locul distanței obișnuite în calculul pierderilor simple sau compuse, se pot construi alte euristici numite *cu pierderi simple ajustate*, respectiv *cu pierderi compuse ajustate*, în a doua dintre ele fiind considerate construcțiile ce evită inconsistența logică. De multe ori, euristicele ce folosesc distanța ajustată dau rezultate mai bune decât euristicele cu distanțe obișnuite.

4.1.4.4. Euristici mai rapide

Euristicele bazate pe pierderi pot fi ușor modificate pentru a reduce timpul necesar pentru calculul pierderilor în modul următor. În loc să se recalculeze pierderile la fiecare realizare a unei legături, se pot folosi aceleași pierderi până la apariția realizării unei legături pentru care pierderea este influențată de legăturile realizate între timp, caz în care este necesară recalcularea pierderilor. Mai precis, este necesară recalcularea în momentul când se face tentativa de a lega orașul i cu j dacă:

1. Modificările efectuate afectează cel puțin una din valorile $pierd(i)$ sau $pierd(j)$ produse eventual de celelalte capete cu care ele sunt legate.
2. Cel puțin unul din cele două orașe este candidat la o legătură realizată sau nu.
3. Cel puțin unul din cele două orașe a avut legătură cu un nod capăt care a participat la o legătură de la ultima recalculare a pierderilor.

Eficiența euristicilor obținute este comparabilă cu cea a celor din care provin din punct de vedere al lungimii turului determinat. Avantajul este că numărul de calcule scade simțitor, mai ales în cazul unui număr mare de orașe, de foarte multe ori fiind necesară numai recalcularea a 2-4 pierderi la majoritatea legăturilor. În schimb apare un efort ceva mai mare la programare.

4.1.5. Metoda ciclurilor crescătoare

Algoritmul următor se bazează pe ideea construirii unor cicluri cu un număr din ce în ce mai mare de orașe până când sunt cuprinse toate cele n orașe.

Algoritmul 4.5. (Cicluri crescătoare)

1. [Inițializare] Se alege o pereche oarecare de orașe și se listează arbitrar în vederea generării permutării aciclice (i_1, i_2) de lungime doi; se face $k = 2$.
2. [Terminare] Dacă $k = n$, atunci STOP.
3. [Alegere] Se alege un oraș h dintre cele nealese încă și, pentru $j = 1, 2, \dots, k$, se calculează $d_j = a_{i_j, h} + a_{h, i_{j+1}} - a_{i_j, i_{j+1}}$, unde prin definiție $i_{k+1} = i_1$ dacă $j = k$.
4. [Localizare] Fie j^* o valoare a lui j pentru care d_{j^*} este minimul costurilor calculate la pasul 3.
5. [Inserare] Se reetichetează i_j cu i_{j+1} pentru $j = j^*, \dots, k$ și se etichetează h cu i_{j^*} .
6. [Ciclare] Se face $k = k + 1$ și se trece la pasul 2. ■

Prin $a_{i,j}$ am notat distanța de la orașul i la orașul j . Ordinea de alegere a orașelor din pasul 3 poate să influențeze calitatea soluției finale.




Fig. 4.4.

Exemplul 4.4. Se consideră graful din figura 4.4, în care turul optimal 1 2 3 4 5 este desenat cu linii pline. Acest tur are lungimea 148. Un alt tur identificat de algoritmul 4.5. este 1 2 4 5 3 de lungime 152. ■

4.1.6. Rectificarea turului

Fie S mulțimea tuturor muchiilor (legăturilor), în număr de $n(n - 1) / 2$, dintre cele n localități, T o submulțime de n muchii ce formează un tur de lungime $f(T)$ și T' un tur de lungime $f(T') < f(T)$. Să presupunem că T și T' diferă, ca mulțimi de n muchii, prin k muchii. În cadrul algoritmului de bază, se încearcă transformarea lui T în T' pe calea identificării succesive, secvențiale, a k perechi de muchii ce urmează a fi schimbate între T și $S - T$. Prin urmare, se încearcă identificarea a două mulțimi de muchii $x = \{x_1, \dots, x_k\}$ și $y = \{y_1, \dots, y_k\}$ astfel încât, dacă muchiile din x sunt eliminate și înlocuite cu muchiile din y , se obține un tur de cost mai mic.




Fig. 4.5.

Un exemplu ilustrativ este arătat pe figura 4.5. pentru $k = 3$. Numerotările muchiilor satisfac condiția că o pereche de muchii x_i și y_i și y_i și x_{i+1} au un nod comun, cu $x_{k+1} = x_1$. În mod frecvent, numerotarea precedentă poate fi efectuată și drept rezultat trecerea de la T la T' se realizează în mod secvențial. Un exemplu în care numerotarea precedentă nu poate fi efectuată este arătat în figura 4.6.




Fig. 4.6.

Presupunând că enumerarea muchiilor, în modul descris mai înainte, poate fi efectuată, succesiunea schimbărilor căutate este $x_1, y_1; x_2, y_2; \dots$ etc. Problema constă în identificarea unei secvențe care reduce pe T la T' cu condiția $f(T') < f(T)$, unde f reprezintă costul turului, urmată de iterarea procesului pentru T' până când nu se mai poate realiza o reducere.

Fie $|x_i|$ și $|y_i|$ lungimile muchiilor x_i și y_i și $g_i = |x_i| - |y_i|$, câștigul obținut prin schimbarea lui x_i cu y_i . Chiar dacă unele valori g_i sunt negative, dacă $f(T') < f(T)$, $\sum_1^k g_i = f(T) - f(T') > 0$. O parte din procedura propusă se bazează pe următoarea proprietate:

Lema 4.1. Dacă o secvență de numere au o sumă pozitivă, atunci există o permutare a acestor numere astfel încât *fiecare sumă parțială* este pozitivă.

Demonstrație: Fie k cel mai mare indice pentru care $g_1 + g_2 + \dots + g_{k-1}$ este minimă. Dacă $k \leq j \leq n$, atunci:

$$g_k + \dots + g_j = (g_1 + \dots + g_j) - (g_1 + \dots + g_{k-1}) > 0.$$

Dacă $1 \leq j < k$, atunci:

$$g_k + \dots + g_n + g_1 + \dots + g_j \geq g_k + \dots + g_n + g_1 + \dots + g_{k-1} > 0. \blacksquare$$

În concluzie, deoarece se caută secvențe de valori g_i ce au o sumă pozitivă, *este suficient să se considere numai secvențe de câștiguri a căror sumă parțială este totdeauna pozitivă*. Acest criteriu de câștig permite reducerea esențială a numărului de secvențe ce urmează a fi examinate.

Algoritmul euristic următor folosește notațiile din figura 4.7.




Fig. 4.7.

Algoritmul 4.6. (Rectificare)

1. [Inițializare] Se generează aleator un tur inițial T .
2. [Start rectificare] Fie $G^* = 0$ (G^* reprezintă cea mai bună ameliorare obținută anterior). Se alege un nod t_1 și o muchie x_1 din T adiacentă lui t_1 . Se face $i = 1$.

3. [Identificare pereche] Plecând de la cealaltă extremitate t_2 a lui x_1 , se identifică o muchie y_1 conectată la t_3 cu $g_1 > 0$. Dacă nu există un asemenea y_1 , se trece la pasul 6a. (Aceasta este prima aplicație a criteriului de câștig.)
4. [Extindere] Se face $i = i + 1$. Se caută un x_i care unește nodul t_{2i-1} cu nodul t_{2i} și un y_i care unește nodul t_{2i} cu nodul t_{2i+1} după cum urmează:
 - a. Se identifică x_i astfel încât, dacă t_{2i} este conectat la t_1 , configurația obținută este un tur. În acest fel, pentru un y_{i-1} dat, x_i este determinat în mod unic.
 - b. Fie y_i o legătură accesibilă la nodul final t_{2i} al muchiei x_i și satisfăcând condițiile c., d. și e.. Dacă nu există un asemenea y_i , se trece la pasul 5.
 - c. Pentru a garanta că mulțimile x și y sunt disjuncte, x_i nu poate fi o legătură anterior realizată (adică $y_j, j < i$) și, în mod similar, y_i nu poate fi o legătură anterior eliminată.
 - d. Se calculează $G_i = \sum_1^i g_j > 0$ (Criteriul câștigului).
 - e. În vederea asigurării criteriului realizabilității din a. pentru $i + 1$, muchia y_i aleasă trebuie să asigure eliminarea unei muchii x_{i+1} .
 - f. Înainte ca y_i să fie construit, se testează dacă încheierea căutării prin conectarea lui t_{2i} la t_1 dă un câștig mai bun decât cel mai bun observat anterior (criteriul realizabilității a fost satisfăcut pentru $i \geq 2$, deci conexiunea lui t_{2i} la t_1 furnizează un tur). Fie y_i^* legătura între t_{2i} și t_1 și $g_i^* = |y_i^*| - |x_i|$. Dacă $G_{i-1} + g_i^* > G^*$, atunci se face $G^* = G_{i-1} + g_i^*$ și $k = i$.
5. [Reluare extindere] Se încheie construirea lui x_i și y_i din pașii 2 - 4 dacă nici o muchie nu mai satisface condițiile 4.c.-4.e. sau dacă $G_i \leq G^*$. Dacă $G^* > 0$, atunci se consideră turul T cu $f(T) = f(T) - G^*$ și se repetă întregul proces începând cu pasul 2, folosind pe T drept tur inițial.
6. [Întoarcere] Dacă $G^* = 0$, atunci se utilizează un backtracking limitat după cum urmează:
 - a. Se repetă pașii 4 și 5 și se identifică muchii y_2 în ordinea crescătoare a lungimii cât timp este satisfăcut criteriul câștigului $g_1 + g_2 > 0$. Dacă apare o îmbunătățire, atunci se trece la pasul 2.
 - b. Dacă toate căutările lui y_2 în pasul 4.b. nu furnizează un profit, atunci se reia de la pasul 4.a. și se încearcă altă alegere pentru x_2 .
 - c. Dacă nu s-a obținut o ameliorare, atunci se reia pasul 3 examinând muchiile y_1 în ordinea crescătoare a lungimilor (vezi figura 4.7.d).
 - d. Dacă și muchiile y_1 au fost parcurse fără un profit, atunci se reia pasul 2 pentru alte muchii x_1 .

e. Dacă nu s-a identificat o nouă muchie x_1 , atunci se selectează un nou t_1 și se reia de la pasul 2.

7. Procedura se încheie după ce toate cele n valori ale lui t_1 au fost prelucrate fără a furniza un profit. În continuare se pot considera alte tururi aleatoare în pasul 1. ■




Fig. 4.8.

Dăm în continuare câteva informații suplimentare privind acest algoritm. În pasul 4.a. este aplicabil criteriul realizabilității care garantează că întotdeauna este posibilă obținerea unui tur conectând pe t_2 cu t_1 , pentru orice $i \geq 2$. Alegerea lui y_{i-1} în conformitate cu pasul 4.e. asigură existența întotdeauna a unui unic astfel de x_{i-1} . Un exemplu ilustrativ este arătat în figura 4.7.a). Evident că pentru asigurarea unei reduceri mari a costului, $|y_i|$ din pasul 4.b. trebuie să fie mic, așa încât, în general, se preferă cel mai apropiat vecin. Figura 4.7.b) ilustrează cazul $i = 4$, cu observația că t_8 este unic. Un caz ilustrativ privind pasul 4.c. pentru $i = 5$ este arătat în figura 4.7.c), cu mențiunea că ambele muchii originale conectate la t_5 au fost eliminate. În pasul 4.f. G^* este întotdeauna cea mai bună ameliorare a lui T construit anterior și constituie un standard de comparație. El are proprietățile: $G^* \geq 0$ și este monoton descrescător. Valoarea lui k definește mulțimile ce urmează a fi schimbate pentru a obține G^* .

De notat că backtracking-ul indicat în pasul 6 se efectuează *numai* dacă nu s-a obținut un câștig și *numai* de la nivelele 1 și 2 ($i = 1$ și $i = 2$).

Exemplul 4.3. Fie turul T din figura 4.8.a), două noduri adiacente t_1 și t_2 și x_1 muchia ce le unește. Fie t_3 cel mai apropiat nod de t_2 ; y_1 este muchia (t_2, t_3). Deoarece mulțimile x și y trebuie să fie disjuncte, y_1 nu poate fi o muchie conectată la t_2 . Se calculează $g = |x_1| - |y_1|$; dacă g nu este pozitiv, se efectuează o reluare (pasul 4.d.) și fie t_2 un alt nod vecin al lui t_1 . Acum $i = 2$ și fie t_4 vecinul lui t_3 în modul ilustrat pe figura 4.8.b) și x_2 muchia (t_3, t_4). Dacă y_2 este ales pentru a conecta pe t_4 cu t_1 , atunci se obține un tur și dacă $g_1 + g_2 > 0$, atunci turul T poate fi îmbunătățit schimbând pe x_1 și x_2 respectiv cu y_1 și y_2 . Se memorează în G^* , îmbunătățirea potențială obținută. Apoi $k = 2$ în pasul 4.f.. Se caută cel mai apropiat vecin t_5 al lui t_4 și fie y_2 muchia (t_4, t_5). Din nou, t_5 nu poate fi unul dintre nodurile conectate anterior la t_4 .

După cum se vede în figura 4.8.c), nu este posibilă decât o singură alegere pentru t_6 și t_3 pentru obținerea unui tur. Dacă x_3 este cealaltă muchie conectată la t_5 , atunci se obțin două tururi distincte, arătate în figura 4.8.d).

Procesul de identificare a unui tur mai bun continuă până este satisfăcut criteriul de încheiere din pasul 5. ■

4.2. Problema restrictivă a comisvoiajorului

Punerea problemei. Fie un graf direcționat complet $G = (V, A)$ cu mulțimea $V = \{v_1, v_2, \dots, v_n\}$ de n noduri și mulțimea A a arcelor (v_i, v_j) , fiecare având costul $c_{i,j}$. Problema restrictivă a comisvoiajorului (PRC) constă în identificarea unui ciclu hamiltonian, definit ca mulțime ordonată de noduri

$$H = (v_{h_1}, v_{h_2}, \dots, v_{h_n}, v_{h_{n+1}} \equiv v_{h_1}), \quad (4.1)$$

astfel încât:

$$z = \max \{c_{h_i, h_{i+1}} \mid 1 \leq i \leq n\} \quad (4.2)$$

să fie minim.

Fără a micșora generalitatea, se presupune că $n > 2$, $c_{i,j}$ sunt întregi pozitivi, pentru toate arcele $(v_i, v_j) \in A$, și $c_{i,i} = +\infty$, pentru toate nodurile $v_i \in V$. ■

Problema PRC este NP-completă. Pentru obținerea soluției se poate elabora relativ ușor un algoritm *branch and bound* cu căutare în lățime.

Vom indica în continuare mai multe margini inferioare pentru PRC.

Problema asignării restrictive. Problema asignării restrictive (PAR) constă în identificarea unei permutări (a_i) a întregilor $1, 2, \dots, n$ care minimizează pe $z^u = \max \{c_{i,a_i} \mid 1 \leq i \leq n\}$. Dacă (a_i) este un ciclu hamiltonian, atunci $z = z^u$. Dacă (a_i)

definește m subtururi ($m > 1$) pe G , atunci z^d este o margine inferioară pentru z . Soluția *PAR* necesită $O(n^3)$ operații [LAW76].

Drumuri restrictive. Fiind dat $G = (V, A)$, un drum restrictiv (*DR*) de la nodul v_i la nodul distinct v_j este un drum $P_{i,j} = (v_i \equiv v_{p_1}, v_{p_2}, \dots, v_{p_k} \equiv v_j)$ astfel încât este minimizată expresia $z_{i,j}^P = \max\{c_{p_k, p_{k+1}} \mid 1 \leq k \leq t - 1\}$. Fie toate *DR* dintre toate perechile ordonate ale nodurilor din V . Atunci:

$$z^P = \max_{\substack{i=1, \dots, n \\ j=1, \dots, n, j \neq i}} \{z_{i,j}^P\} \tag{4.3}$$

este margine inferioară pentru z . Într-adevăr, din (4.1) și (4.2) rezultă că ciclul hamiltonian care rezolvă *PRC* conține un drum de la orice nod v_i la un alt nod v_j astfel încât costul maxim al arcelor sale nu depășește pe z . Rezultă că $z_{i,j}^P \leq z$, pentru toți i, j . Un mod eficient pentru calculul lui z^P este dat de următoarea teoremă.

Teorema 4.1. Pentru orice nod $v_r \in V$, valoarea lui:

$$\bar{z} = \max_{j=1, \dots, n, j \neq r} \{z_{r,j}^P, z_{j,r}^P\} \tag{4.4}$$

coincide cu valoarea lui z^P .

Demonstrație. Din (4.3) și (4.4) rezultă că $z^P \geq \bar{z}$. Urmează să se arate că $z^P \leq \bar{z}$. Pentru fiecare pereche de noduri distincte $v_s, v_t \in V$,

- a) dacă $s = r$ sau $t = r$, atunci din (4.4) rezultă că $z_{s,t} \leq \bar{z}$;
- b) dacă $s \neq r$ și $t \neq r$, atunci un drum de la v_s la v_t poate fi obținut unind un *DR* de la v_s la v_r cu un *DR* de la v_r la v_t . Din (4.4) rezultă că $z_{s,t}^P \leq \max\{z_{s,r}^P, z_{r,t}^P\} \leq \bar{z}$. ■

Dacă pentru fiecare nod $v_i \in V$ se definesc

$$\hat{z}_i^P = \max\{z_{i,j}^P \mid 1 \leq j \leq n, j \neq i\},$$

$$\hat{z}_i^P = \max\{z_{j,i}^P \mid 1 \leq j \leq n, j \neq i\},$$

atunci, din teorema 4.1., rezultă că z^P poate fi obținută dacă pentru orice nod $v_r \in V$ se calculează $z^P = \max\{z_r^P, \hat{z}_r^P\}$.

Se poate arată că z^P poate fi calculat astfel în $O(n^2)$ operații.

Înlănțuirea nodurilor. Fie nodul oarecare v_i și valorile $c_{i,j} = \min\{c_{i,j} \mid 1 \leq j \leq n\}$, $c_{u,i} = \min\{c_{j,i} \mid 1 \leq j \leq n\}$. Deoarece în orice circuit hamiltonian un arc trebuie să iasă din v_i și un altul trebuie să intre în v_i , rezultă că $b_i = \max\{c_{i,i}, c_{u,i}\}$ este evident o margine inferioară pentru z . Mai mult, dacă $v_i \equiv v_u$, caz fals în circuit hamiltonian, se poate îmbunătăți marginea inferioară calculând pe $c_{i,i'} = \min\{c_{i,j} \mid 1 \leq j \leq n \text{ și } j \neq i\}$ și pe $c_{u',i} = \min\{c_{j,i} \mid 1 \leq j \leq n \text{ și } j \neq u\}$. O margine mai bună este dată de:

$$b'_i = \begin{cases} b_i & \text{dacă } v_i \neq v_u, \\ \max\{b_i, \min\{c_{i,i'}, c_{u',i}\}\} & \text{dacă } v_i = v_u. \end{cases}$$

Deoarece acest rezultat are loc pentru orice $v_i \in V$, rezultă că $z^i = \max_{v_i \in V} \{b_i^i\}$ este o margine inferioară pentru z . Calculul lui b_i^i necesită evident $O(n)$ operații, așa încât z^i poate fi calculat în $O(n^2)$ operații.

Înlănțuirea subtururilor. Dacă problema *PAR* a fost rezolvată, atunci o margine inferioară poate fi calculată într-un mod analog cu cel descris anterior. Fie $S = \{S_1, S_2, \dots, S_m\}$ partiția mulțimii V definită de m subtururi obținute drept rezultat al rezolvării *PAR*, cu $m > 1$, și fie subturul ce corespunde lui S_k . Deoarece în orice circuit hamiltonian măcar un arc trebuie să iasă din S_k și măcar unul trebuie să intre în S_k , o margine inferioară pentru z este $d_k = \max\{c_{s,t}, c_{u,q}\}$, unde $c_{s,t} = \min\{c_{i,j} \mid v_i \in S_k, v_j \in V - S_k\}$ și $c_{u,q} = \min\{c_{j,i} \mid v_i \in S_k, v_j \in V - S_k\}$. În acest caz se impune de asemenea ca $v_s \neq v_q$ și $v_t \neq v_u$, adică se caută o pereche de arce, unul care intră și altul care iese, fără o extremitate comună. O margine mai bună este dată de:

$$d'_k = \min\left\{\max\{c_{s,t}, c_{u,q}\} \mid v_q, v_s \in S_k, v_q \neq v_s; v_t, v_u \in V - S_k, v_t \neq v_u\right\}.$$

Valoarea lui d'_k se poate calcula pentru toate subtururile din S , așa că marginea inferioară pentru z este dată de:

$$z^S(S) = \max\{d'_k \mid 1 \leq k \leq m\}.$$

Se poate construi o procedură care calculează pe $z^S(S)$ în $O(n^2 \log n)$ operații.




Fig. 4.9.




Fig. 4.10.

O margine mai bună poate fi obținută dacă numărul de subtururi furnizat de *PAR* este redus în mod euristic pe calea conectării perechilor de subtururi prin arce a căror cost nu-i mai mare decât orice margine inferioară. În cazul grafului din figura 4.9., în care liniile punctate notează soluția *PAR*, marginile inferioare sunt $z''=2$, $z^i=3$, $z^j=4$. Pentru cele patru subtururi furnizate de *PAR*, procedura descrisă furnizează marginea $z^S=3$. Dacă însă S este modificată pe calea conectării celor două subtururi din stânga și din dreapta, pe calea înlocuirii arcelor de cost 1 cu arce de cost 3, rezultă $z^S=5$.

Trebuie menționat că nici una dintre marginile prezentate nu le domină pe celelalte. În graful din figura 4.9., $z'' < z^i < z^j < z^S(S)$ în timp ce în graful din figura 4.10., $z'' = 6 > z^i = 5 > z^j = 4 > z^S(S) = 3$.

Algoritmul propus pentru *PRC* folosește o schemă de ramificare prezentată în [CAR80]. La fiecare nod al arborelui de decizie, algoritmul parcurge procedura de mărginire prezentată mai jos. Această procedură se bazează pe marginile anterioare și căutarea euristică a unui circuit hamiltonian.

Fiind date graful $G = (V, A)$ și o valoare \bar{z} a marginii inferioare, se definește submulțimea $A: A(\bar{z}) = \left\{ (v_i, v_j) \mid (v_i, v_j) \in A \text{ și } c_{i,j} \leq \bar{z} \right\}$. În continuare, se aplică o procedură euristică pentru identificarea unui circuit hamiltonian în graful parțial $\bar{G} = (V, A(\bar{z}))$. În particular, se poate folosi algoritmul enumerativ din [MAR83] care, fiind parcurs pe calea limitării numărului de iterații, are trei ieșiri posibile:

- 1) a fost găsit un circuit hamiltonian,
- 2) nu există nici un circuit hamiltonian și
- 3) nu a fost găsit un circuit hamiltonian.

Procedura de mărginire. Fie z^* valoarea curentă a unei soluții optimale.

Faza 1. Fie $\bar{z} = \max\{z', z'', z'''\}$ și se memorează în S soluția corespunzătoare lui z'' . Dacă $\bar{z} \geq z^*$ sau S este un circuit hamiltonian, atunci STOP.

Faza 2. Se execută procedura euristică pentru găsirea unui circuit hamiltonian în $\bar{G} = (V, A(\bar{z}))$. Dacă a fost găsit un asemenea circuit, atunci STOP. Dacă nu există un circuit hamiltonian, atunci se pune $\bar{z} = \min\{c_{i,j} \mid (v_i, v_j) \in A - A(\bar{z})\}$ și dacă $\bar{z} \geq z^*$, atunci STOP. Se modifică S în vederea reducerii numărului de subtururi. Dacă S este un circuit hamiltonian, atunci STOP. Se pune $\bar{z} = \max\{\bar{z}, z^S(S)\}$. Dacă $\bar{z} \geq z^*$, atunci STOP. Dacă execuția fazei 2 a îmbunătățit marginea inferioară \bar{z} , atunci se iterează faza 2, altfel STOP.

Dacă $\bar{z} \geq z^*$ la încheierea procedurii de mărginire, atunci algoritmul trece în backtracking. Altfel, dacă S este un circuit hamiltonian, atunci soluția optimală este reactualizată și se trece în backtracking. Dacă S nu este un circuit hamiltonian, atunci se trece la subtururile lui S . ■

4.3. Problema comisvoiajorului cu k persoane

Fie un graf complet $G = (V, E)$ conținând n noduri v_1, v_2, \dots, v_n . Pentru un k întreg pozitiv, un k -tur H reprezintă o mulțime de k subtururi notate H_1, \dots, H_k , unde:

1. H_i este un ciclu simplu conținând cel puțin 3 arce, pentru $i = 1, 2, \dots, k$.
2. H_i conține nodul 1, pentru $i = 1, 2, \dots, k$.
3. Pentru fiecare $v \in V \setminus \{v_1\}$ există un singur subtur H_i ce trece prin v .

Se presupune că cei k comisvoiajori pleacă fiecare din nodul 1 și vizitează mulțimea de noduri, care cuprinde toate nodurile din $V \setminus \{v_1\}$. Funcția distanță $d: E \rightarrow \mathbb{R}$ satisface condiția:

$$d(u, v) + d(v, w) \geq d(u, w), \text{ pentru toți } u, v, w \in V.$$

Un k -tur H are lungimea $d(H) = \sum_{i=1}^k d(H_i)$, unde pentru orice $S \subseteq E$, $d(S) = \sum_{e \in S} d(e)$.

Problema de rezolvat constă în identificarea unui k -tur de lungime minimă.

Euristica propusă reprezintă o generalizare naturală a euristicii Christofides și are aproape aceeași performanță.

Algoritmul 4.7. (k -tururi)

1. [Arbore parțial] Se identifică un arbore maximal T_0 al lui G de lungime minimă printre arborii ce au $2k$ arce incidente cu nodul v_1 . (În lucrarea [GLO7...] se arată că această problemă poate fi rezolvată într-un timp $O(|V|^2)$).
2. [Împerechere] Se determină mulțimea de noduri $X_0 \subseteq T$ de grad impar. Se realizează o împerechere M_0 perfectă de lungime minimă în subgraful G indus de X_0 ($|X|$ este mereu par și problema împerecherii este rezolvată în timp de $O(|X|^3)$ [LAW76]).
3. [Ciclu eulerian] Graful $G_0 = (V, T_0 \cup M_0)$ este conex și fiecare nod al său are grad par. Se construiește un ciclu eulerian EC_0 al lui G_0 , adică un ciclu ce conține o singură dată fiecare arc al lui G_0 . (EC_0 poate fi construit în timp liniar).
4. [Reducere] Ciclul EC_0 este în continuare redus la un k -tur H_0 . Fie U mulțimea nodurilor adiacente la v_1 în T_0 . Presupunem că EC_0 cuprinde secvența de noduri $v_1 = w_1, w_2, \dots, w_m = v_1$. Parcurgând această secvență, un nod w_i se elimină dacă:
 - a. $w_i \neq v_1$ și w_i a mai apărut anterior,
 - b. $w_i \in U$ și $v_1 \notin \{w_{i-1}, w_{i+1}\}$. ■

La încheierea pasului 4, secvența de noduri obținută definește un k -tur H_0 . Eliminările din a. asigură vizitarea o singură dată a unui nod $v \neq v_1$ și eliminările din b. asigură prezența în orice subtur a măcar două noduri diferite de v_1 .

Exemplul 4.5. În figura 4.11.a) este reprezentat subgraful unui graf complet G , arcele subgrafului având lungimea 1 și arcele nefigurate (v, w) o lungime $d(v, w)$ egală cu cea mai scurtă distanță de la v la w în subgraf. Astfel, distanța între nodurile x și y este egală cu 7. Arborele T_0 al grafului G este arătat cu linii pline în figura 4.11.b). Completând arborele T_0 cu cele două arce punctate, se obține soluția generată de euristica descrisă, pentru cazul $k = 2$. Ținând seama că lungimile celor două arce punctate sunt egale cu 10, rezultă că suma lungimilor celor două subtururi este egală cu $2 \cdot (10 + 2 \cdot 9) = 56$. Soluția optimală H^* este arătată pe figura 4.11.c), suma lungimilor celor două subtururi fiind în acest caz egală cu $2 \cdot (2 \cdot 9 + 4) = 44$, unde 4 reprezintă lungimile arcelor (1, 2) respectiv (3, 4). ■




Fig. 4.11.

Se poate demonstra că:

$$d(H_0) \leq 3/2 d(H^*),$$

considerând o generalizare a exemplului descris mai înainte. În exemplul 4.4., $d(H_0) = 56 < 3/2 \cdot 44 = 66 = 3/2 d(H^*)$.

4.4. Localizarea stației de deservire în problema comisvoiajorului

Punerea problemei. Se consideră o rețea $G(N, L)$ unde N este o mulțime de n noduri și L mulțimea legăturilor (drumurilor). O singură unitate de deservire este localizată într-un centru X al rețelei. În fiecare zi se înregistrează până la un termen t_0 mulțimea cererilor ce urmează să fie satisfăcute. Se presupune că din fiecare nod i poate apare zilnic cel mult o cerere, cu probabilitatea h_i . Se notează cu k numărul de cereri înregistrate până la momentul t_0 . Prin listă se înțelege numărul de noduri înregistrate, într-un catalog, în cazul $k > 0$. Numărul total de liste posibile dintr-o anumită zi este $2^n - 1$. Se notează cu E mulțimea listelor posibile și cu R o listă dată din E .

Fie $T(R \cup X)$ turul optimal, adică turul cel mai scurt în problema comisvoiajorului, ce începe din centrul de deservire și trece prin fiecare nod din R măcar o dată și se încheie în centrul de deservire.

$$T(R \cup X) = X \rightarrow \pi(1) \rightarrow \pi(2) \rightarrow \dots \rightarrow \pi(j) \rightarrow \dots \rightarrow \pi(k) \rightarrow X,$$

unde $\pi(j)$ este al j -lea nod din $T(R \cup X)$. Fie apoi $L(R \cup X)$ lungimea turului $T(R \cup X)$:

$$L(R \cup X) = d(X, \pi(1)) + \sum_{j=1}^{k-1} d(\pi(j), \pi(j+1)) + d(\pi(k), X),$$

unde $d(z, y)$ este cea mai mică distanță (cel mai scurt drum) între nodurile $z, y \in G$. ■

Fie P_R probabilitatea ca unitatea de deservire să recepționeze lista R pentru un $k > 0$ dat și

$$P_w = 1 - \prod_{i \in N} (1 - h_i)$$

probabilitatea ca lista să nu fie vidă. Rezultă că:

$$P_R = (1 / P_w) \left[\prod_{j \in R} h_j \right] \left[\prod_{j \notin R} (1 - h_j) \right] = K \prod_{j \in R} h_j / (1 - h_j),$$

unde:

$$K = (1 / P_w) \prod_{j \in N} (1 - h_j).$$

Problema de rezolvat constă în identificarea unei locații X^* din $G(N, L)$ care să minimizeze lungimea $g(X)$ a turului de deservire:

$$X^* = \arg \min_X g(X) \equiv \arg \min_X \sum_{R \in E} P_R L(R \cup X),$$

unde cu $\arg \min_X$ s-a notat *argumentul* X ce minimizează și:

$$g(X) = \sum_{R \in E} P_R L(R \cup X),$$

$L(R \cup X)$ fiind lungimea turului optimal.

Aproximarea lungimii turului optimal. Deoarece timpul necesar calculului turului optimal are $O(2^{|R|})$ este de dorit folosirea unei aproximări a acestui tur. Pentru aceasta se propune următoarea euristică:

1. Se identifică un tur optimal pentru submulțimea K de noduri de unde au fost efectuate cereri.
2. Se calculează $\min_{j \in R} d(X, j) \equiv d(X, F_R(X))$ care este cea mai mică distanță dintre X și cel mai apropiat nod de X din R , notat cu $F_R(X)$. Se conectează turul obținut la pasul 1 cu nodul X prin intermediul a două arce de lungime $d(X, F_R(X))$. Lungimea turului aproximativ este:

$$A(R \cup X) = L(R) + 2 d(X, F_R(X)). \quad (4.5)$$

Idea principală a euristicii constă în identificarea în locul lui X^* a unui vîrf \tilde{X} care satisface condiția:

$$\tilde{X} = \arg \min_{X \in N} f(X) \equiv \arg \min_{X \in N} \sum_{R \in E} P_R A(R \cup X),$$

unde $f(X) = \sum_{R \in E} P_R A(R \cup X)$.

Utilizând (4.5), $f(X)$ se poate scrie sub forma:

$$f(X) = \sum_{R \in E} P_R A(R \cup X) = 2 \sum_{R \in E} P_R d(X, F_R(X)) + \sum_{R \in E} P_R L(R). \quad (4.6)$$

Deoarece ultimul termen din (4.6) este o constantă independentă de X , rezultă că:

$$\tilde{X} = \arg \min_{X \in N} \sum_{R \in E} P_R d(X, F_R(X)).$$

În continuare se arată că pentru un X dat, $\sum_{R \in E} P_R d(X, F_R(X))$ se poate calcula într-un mod eficient. Pentru fiecare $X \in N$ nodurile j_1, j_2, \dots, j_n din N se renumerotează

astfel încât $d(X, j_k) \leq d(X, j_l)$, pentru $l \geq k$ (unde nodul $X \equiv j_1$). Se definește E_{X, j_k} , $k \neq 1$, prin expresia:

$$E_{X, j_k} = \{R \in E; j_1, j_2, \dots, j_{k-1} \notin R, j_k \in R\}.$$

Din definițiile lui $d(X, F_R(X))$ și E_{X, j_k} rezultă că:

$$d(X, F_R(X)) = d(X, j_k) \text{ dacă și numai dacă } R \in E_{X, j_k}.$$

Deoarece atunci când $X = F_R(X)$, $P_R d(X, F_R(X)) = 0$, rezultă:

$$\sum_{R \in E} P_R d(X, F_R(X)) = \sum_{k=2}^n d(X, j_k) \sum_{R \in E_{X, j_k}} P_R.$$

În lema ce urmează este indicat modul în care se poate calcula $\sum_{R \in E_{X, j_k}} P_R$.

Lema 4.2. $\sum_{R \in E_{X, j_k}} P_R = h_{j_k} / P_W \prod_{m=1}^{k-1} (1 - h_{j_m})$, pentru $k \geq 2$.

Demonstrație. Fie \tilde{R} o listă aleasă la întâmplare; atunci:

$$\begin{aligned} \sum_{R \in E_{X, j_k}} P_R &= \text{Prob}\{\tilde{R} \in E_{X, j_k} \mid k > 0\} = \text{Prob}\{j_1, j_2, \dots, j_{k-1} \in \tilde{R}, j_k \notin \tilde{R} \mid k > 0\} = \\ &= 1 / P_W (1 - h_{j_1}) (1 - h_{j_2}) \dots (1 - h_{j_{k-1}}) h_{j_k}. \blacksquare \end{aligned}$$

Rezultă că:

$$\sum_{R \in E} P_R d(X, F_R(X)) = 1 / P_W \sum_{k=2}^n d(X, j_k) h_{j_k} \prod_{m=1}^{k-1} (1 - h_{j_m}). \quad (4.7)$$

Analiza celui mai defavorabil caz. În euristica ce urmează se calculează \tilde{X} în loc de X astfel: pentru fiecare nod $X \in N$ se evaluează expresia (4.7) și se selectează \tilde{X} ca fiind nodul pentru care se realizează cea mai mică valoare.

Algoritmul 4.8. (Aproximare lungime tur)

1. [Drumuri minime] Se calculează matricea D a celor mai scurte distanțe.
2. [Inițializare] Se face $m = \infty$.
3. [Ciclare noduri] Pentru orice nod $X \in N$ se execută pașii 4 - 7, apoi STOP.
4. [Renumerotare] Se renumerează nodurile din N , j_1, j_2, \dots, j_n astfel încât $d(X, j_k) \leq d(X, j_l)$, pentru toți $l \geq k$ (nodul $X \equiv j_1$).
5. [Calcul ponderi] Pentru $k = 2, 3, \dots, n$ se calculează $U_k = \prod_{m=1}^{k-1} (1 - h_{j_m})$.
6. [Ponderea totală] Se calculează $V = \sum_{k=2}^n d(X, j_k) U_k h_{j_k}$.
7. [Rectificare] Dacă $V < m$, atunci se face $m = V$ și $\tilde{X} = X$. \blacksquare

Pasul 1 are complexitatea $O(n^3)$ ([F...O62]). Pași 4, 5, 6 și 7 sunt parcurși de n ori; fiecare execuție a pasului 4 are complexitatea $O(n \log_2 n)$ și pașii 5 și 6 au complexitatea $O(n)$. Complexitatea totală este de $O(n^3)$. Dacă matricea D este dată, atunci complexitatea este $O(n^2 \log_2 n)$.

Se poate demonstra proprietatea următoare:

Lema 4.3. $A(R \cup X) \leq 3/2 L(R \cup X)$, pentru orice R . ■

Se poate vedea că marginea din lema poate fi atinsă ca în exemplul următor.

Exemplul 4.6. Se consideră exemplul unei rețele cu nodurile $\{1, 2, 3\}$ și arcele $(1,2)$, $(2,3)$ și $(3,1)$ de lungimi 1, 2, respectiv 1 (vezi figura 4.12.). Fie $R = \{2,3\}$ și $X=1$. Într-adevăr, $L(R \cup X) = 1 + 2 + 1 = 4$ și $A(R \cup X) = 1 + 2 + 2 + 1 = 6$. ■



Fig. 4.12.

Lema 4.4. $(g(\tilde{X}) - g(X^*)) / g(X^*) \leq 0.5$.

Demonstrație. Din definițiile lui $f(X)$ și $g(X)$ rezultă că $g(\tilde{X}) \leq f(\tilde{X})$. Din definiția lui \tilde{X} rezultă $f(\tilde{X}) \leq f(X^*)$. În virtutea lemei 4.3, $f(\tilde{X}) \leq 3/2 g(X^*)$. Din inegalitățile precedente se deduce:

$$g(\tilde{X}) \leq f(\tilde{X}) \leq f(X^*) \leq 3/2 g(X^*),$$

de unde:

$$(g(\tilde{X}) - g(X^*)) / g(X^*) \leq (3/2 g(X^*) - g(X^*)) / g(X^*) = 0.5. \blacksquare$$




Fig. 4.13.




Fig. 4.14.

Exemplul 4.7. Fie graful din figura 4.13. în care $h_1 = h_2 = h_3 = h_4 = 0.5$ și h_5 variază între 0 și 1. S-au făcut experimentări pentru determinarea erorii relative maxime prin aplicarea euristicii. Eroarea relativă maximă determinată a fost egală cu aproximativ 11.6% și a fost obținută în urma testării euristicii pentru o valoare a lui h_5 egală aproximativ cu 0.34. Pentru valori mai mici ale lui h_5 eroarea crește liniar. Pentru valori mai mari ale lui h_5 eroarea relativă este nulă (vezi figura 4.14). ■

4.5. Margini pentru problema transportului cu vehicule de capacitate limitată

Punerea problemei. Fie $X = \{x_1, x_2, \dots, x_n\}$ mulțimea clienților, puncte în plan euclidian, unde clientul x_i este la distanța r_i de originea O , depozitul. Distanța maximă $\max_i \{r_i\}$ este notată r_{\max} , distanța totală $\sum_{i=1}^n r_i$ cu $\sum r_i$ și distanța medie $\left(\frac{\sum_{i=1}^n r_i}{n}\right)$ cu \bar{r} . Fiecare client urmează să fie vizitat de un vehicul. Al j -lea vehicul pleacă de la depozit și se întoarce după ce a vizitat submulțimea $X_j \subseteq X$; mulțimea de puncte vizitate de acest vehicul este notată cu $X_j^0 = X_j \cup \{O\}$. Capacitatea fiecărui vehicul este q și nici un vehicul nu vizitează mai mult decât q clienți ($|X_j| \leq q$).

Problema constă în identificarea unei mulțimi de drumuri astfel încât lungimea lor totală să fie cât mai mică; această soluție optimală se notează cu $R^*(X)$. Un rol esențial în cele ce urmează îl are cel mai scurt drum al comisvoiajorului ce vizitează fiecare consumator o singură dată și a cărei lungime este notată cu $T^*(X)$. ■

4.5.1. Margini inferioare și superioare

Teorema 4.2. $\max\left\{2\frac{n}{q}\bar{r}, T^*(X)\right\} \leq R^*(X) \leq 2\left\lceil\frac{n}{q}\right\rceil\bar{r} + \left(1 - \frac{1}{q}\right) T^*(X)$.

Demonstrația rezultă din următoarele două leme. ■

Lema 4.5. $R^*(X) \geq \max\left\{2(n/q)\bar{r}, T^*(X)\right\}$.

Demonstrație. Fie X_j mulțimea clienților vizitați de vehiculul j în soluția optimală. Evident că:

$$T^*(X_j^0) \geq 2 \max_{x_i \in X_j} \{r_i\} \geq 2 \frac{\sum_{x_i \in X_j} r_i}{|X_j|} \geq \frac{2}{q} \sum_{x_i \in X_j} r_i,$$

de unde:

$$R^*(X) = \sum_j T^*(X_j^0) \geq \frac{2}{q} \sum r_i = 2\frac{n}{q}\bar{r}.$$

Inegalitatea $R^*(X) \geq T^*(X)$ este o consecință imediată a inegalității triunghiului. ■

Lema 4.6. $R^*(X) \leq 2\lceil n/q \rceil\bar{r} + (1 - \lceil n/q \rceil/n) T^*(X)$.

Demonstrație. Demonstrația este constructivă, în sensul că se folosește o euristică pentru construirea unei soluții a problemei transportului a cărei valoare este cel mult egală cu marginea superioară.

Fiind dat un cel mai scurt tur al comisvoiajorului, acest tur se împarte în $l = \lceil n/q \rceil$ segmente disjuncte astfel încât fiecare segment nu conține mai mult decât q

clienți după care capetele segmentelor se conectează la depozit. În cadrul acestei construcții sunt eliminate l arce din turul comisvoiajorului. Această euristică este notată *PTO* (*partiționarea turului optimal*). Soluția obținută poate fi îmbunătățită pe calea alegerii unei orientări arbitrare a turului comisvoiajorului, urmată de repetarea construcției de mai sus prin deplasarea capetelor celor l drumuri 1, 2, ... cu până la $n - 1$ poziții în direcția orientării turului. Urmează alegerea celei mai bune dintre soluțiile obținute.

Pentru analiza acestei euristici, notată *IPTO* (*iterarea partiționării turului optimal*), se observă că lungimea totală a n soluții este egală cu:

$$2l \sum r_i + (n-l) T^*(X). \quad (4.8)$$

Primul termen reflectă faptul că fiecare client este vizitat pentru prima dată și ultima dată de fiecare din cele l vehicule. Al doilea termen reflectă faptul că fiecare arc al turului este exclus de l ori și prin urmare este prezent de $n - l$ ori.

Evident că valoarea $R^{IPTO}(X)$ a soluției optimale este mai mică decât media expresiei (4.8), deci:

$$R^*(X) \leq R^{IPTO}(X) \leq 2l\bar{r} + (n-l) T^*(X) = 2 \lfloor n/q \rfloor \bar{r} + (1 - \lfloor n/q \rfloor / n) T^*(X). \blacksquare$$

4.5.2. Margini superioare pentru problema comisvoiajorului

Prima margine pentru $T^*(X)$ este exprimată în termeni de aria A și perimetrul p al regiunii ce conține pe X .

Teorema 4.3. Dacă X este conținută într-o regiune plană conexă de arie A și perimetru (finit) p , atunci:

$$T^*(X) \leq \sqrt{2nA} + 3/2p. \blacksquare$$

Înainte de a demonstra teorema 4.3., se deduce un rezultat mai simplu pentru cazul când regiunea ce conține pe X este dreptunghiulară.

Lema 4.7. Dacă X este conținută într-un dreptunghi cu laturile a și b , atunci:

$$T^*(X) \leq \sqrt{2(n-1)ab} + 2(a+b).$$

Demonstrație. Dreptunghiul se împarte în h benzi paralele cu latura a , presupusă orizontală (vezi figura 4.15.). Folosind marginile orizontale ale benzilor și laturile verticale ale dreptunghiului, se construiesc două drumuri alternative prin dreptunghi. Fiecare dintre aceste drumuri este extins la un drum hamiltonian prin X , adăugând o legătură verticală dublă între fiecare punct x_i și punctul de pe cel mai apropiat drum hamiltonian. Suma lungimilor acestor două drumuri hamiltoniene este:

$$(h+1)a + \left(2b - 2\frac{b}{h}\right) + 2n\frac{b}{h}.$$




Fig. 4.15.

Pentru a extinde fiecare dintre cele două drumuri hamiltoniene, în vederea obținerii a două tururi ale comisvoiajorului, trebuie adăugată o lungime de cel mult $2b - 2b / h$ în direcție verticală și una de cel mult $2a$ în direcție orizontală. Rezultă că suma lungimilor celor două tururi este egală cu cel mult:

$$3a + 4b + ah + (2n - 4) b / h$$

și, prin urmare:

$$T^*(X) \leq 3 / 2a + 2b + 1 / 2ah + (n - 2) b / h. \tag{4.9}$$

Partea din dreapta a condiției (4.9) este minimă pentru $h = \sqrt{2(n - 2) b / a}$. ■

Demonstrarea teoremei 4.3. Primul pas constă în interconectarea regiunii cu un sistem de linii orizontale paralele la distanța h între ele. Lungimea totală a acestei corzi nu depășește valoarea A / h . Pentru a demonstra această afirmație, fie o translatăre a sistemului inițial cu o lungime uniform distribuită între 0 și h . Lungimea totală medie a corzilor astfel generate este A / h și, prin urmare, această valoare trebuie să fie realizată pentru o anumită poziție a sistemului.




Fig. 4.16.

Presupunând liniile orientate ascendent, mulțimea lor se partiționează în linii numerotate impar și par. Adăugând frontierele regiunii la cele două mulțimi, rezultă două grafuri conexe (vezi figura 4.16.). Se poate arăta că ambele grafuri pot fi făcute euleriene, adăugând arce de lungime totală egală cu cel mult $p / 2$. Pentru aceasta se observă că, în fiecare graf, frontiera regiunii este constituită dintr-un număr finit de cicluri. Ignorând tangența, rezultă că o linie intersectează un ciclu de un număr par de

ori astfel încât fiecare ciclu conține un număr par de puncte terminale ale corzilor și, prin urmare, un număr par de arce. Graful este transformat într-unul eulerian pe calea duplicării oricărui alt arc al ciclului. Pentru fiecare ciclu se poate alege una din cele două mulțimi de arce ce urmează a fi duplicate. Alegând mulțimea cea mai favorabilă, lungimea totală adăugată nu depășește $p/2$.

În pasul următor, fiecare punct din X este conectat la ambele grafuri prin câte două arce, lungimea totală a celor patru arce fiind egală cu $2h$. Ambele grafuri rămân euleriene, lungimea arcelor lor nedepășind valoarea:

$$A/h + 3p + 2nh.$$

Rezultă că există un drum eulerian și, prin urmare, un tur de lungime ce nu depășește $A/2h + 3p/2 + nh$. Pentru $h = \sqrt{A/2n}$ se obține marginea menționată în enunț. ■




Fig. 4.17.

Teorema 4.4. $T^*(X) \leq 2\sqrt{\pi n r_{\max}} \bar{r} + (2 + \pi)r_{\max}$, unde r_{\max} reprezintă raza unui cerc în care este conținut X .

Demonstrație. Primul pas constă în împărțirea cercului de rază r_{\max} în $4h$ sectoare egale. Ca și în cazul lemei 4.7. și a teoremei 4.3., frontierele sectoarelor și circumferința ciclului se folosesc două drumuri închise de forma unor flori, ce traversează cercul (vezi figura 4.17., în care $h = 4$). Fiecare drum este transformat într-un tur al comisvoiajorului printr-o conexiune dublă de lungime minimă la fiecare punct x_i ; suma lungimilor acestor conexiuni duble este mai mică decât $2(2\pi/4h)r_i = \pi r_i/h$. Rezultă că suma tururilor este mai mică decât:

$$\pi n \bar{r} \frac{1}{h} + 4h r_{\max} + 2\pi r_{\max}$$

și în concluzie:

$$T^*(X) \leq \pi n \bar{r} \frac{1}{2h} + 2hr_{\max} + \pi r_{\max}. \tag{4.10}$$

Alegând pentru h valoarea pentru care este minimizată expresia din dreapta în (4.10) și rotunjind-o superior, adică luând $h = \lceil \sqrt{\pi n \bar{r} / 4r_{\max}} \rceil$ se obține rezultatul din enunțul teoremei. ■

Exemplul 4.8. Un exemplu ilustrativ pentru euristica IPTO, în care $n = 5$, $l = 2$ și $q = 3$ este prezentat în figurile 4.18.a) - e). Se vede ușor că fiecare arc este prezent de $n - l = 5 - 2 = 3$ ori și fiecare arc r_i este prezent de câte $2l = 4$ ori. ■




Fig. 4.18.

Observație. Expresia rotunjită a lui h are valoarea $\sqrt{\pi n \bar{r} / 4r_{\max}} + \varepsilon$, unde $0 < \varepsilon < 1$. Introducând această expresie în partea din dreapta din (4.10) rezultă expresia:

$$\frac{\pi n \bar{r}}{\sqrt{\pi n \bar{r} / 4r_{\max}} + \varepsilon} + 2r_{\max}(\sqrt{\pi n \bar{r} / 4r_{\max}} + \varepsilon) + \pi r_{\max},$$

care are o valoare mai mică decât:

$$\frac{\pi n \bar{r}}{\sqrt{\pi n \bar{r} / 4r_{\max}} + \varepsilon} + 2r_{\max}(\sqrt{\pi n \bar{r} / 4r_{\max}} + \varepsilon) + \pi r_{\max} = 2\sqrt{\pi n \bar{r} r_{\max}} + (2 + \pi)r_{\max}.$$

4.6. Problema orientării

Punerea problemei. Fiind date n puncte într-un spațiu euclidian pl., fiecare având scorul $s(i) \geq 0$, cu observația că $s(1) = s(n) = 0$, se cere identificarea unui drum de scor maxim ce începe în punctul 1 și se încheie în punctul n , durata parcurgerii drumului fiind cel mult $TMAX$. Problema enunțată este considerată ca reprezentând o generalizare a problemei comisvoiajorului și este rezolvată în contextul concursurilor de orientare turistică. ■

Euristica propusă. Ideea de bază a euristicii propuse constă în deplasarea succesivă dintr-un centru de greutate într-un alt centru de greutate. Fiecare centru de greutate are o mulțime de noduri (puncte) asociate și un drum corespunzător. Progresarea continuă până când este satisfăcută o regulă de încheiere. Euristica este constituită din următorii trei pași: 1. Construire drum, 2. Îmbunătățire drum, 3. Calcul centru de greutate.

Pasul 1. Obiectivul acestui pas constă în generarea unui drum inițial ce începe în nodul 1 și se încheie în nodul n și are un scor relativ mare, durata parcurgerii nedepășind $TMAX$. Procedura utilizată se bazează pe un criteriu de gradare ponderată (*weighted ranking*). Mai precis, inserțiile se efectuează pe o combinație liniară de trei gradări. Aceste trei gradări sunt: scorul $SR(I)$, distanța la centrul de greutate $CR(I)$ și suma distanțelor la două focare ale unei elipse $ER(I)$. Pentru un nod nesituat pe drumul ce trebuie generat, gradul ponderat este definit de:

$$WR(I) = \alpha SR(I) + \beta CR(I) + \gamma ER(I),$$

unde $\alpha + \beta + \gamma = 1$. Nodului cu cel mai mare scor i se atribuie rangul 1 și ranguri crescătoare pentru cazul când scorurile descresc. În cazul a două scoruri egale se atribuie ranguri egale. În cazul rangului $ER(I)$, drept focare ale elipsei se consideră nodul inițial și cel final. Nodului cu sumă minimală a distanțelor la cele două focare i se asignează rangul 1. Nodurilor cu valori crescătoare ale sumei distanțelor la cele două focare li se atribuie ranguri mai mari. Inițial, $CR(I)$ se calculează pentru mulțimea tuturor nodurilor din rețea. Nodului cel mai apropiat de $CR(I)$ i se atribuie rangul 1 și ranguri crescătoare pe măsură ce distanțele cresc. După fiecare inserție a unui nod, centrul de greutate se recalculază pentru nodurile curente de pe drumul generat. La fiecare pas se identifică nodul cu $WR(I)$ minim, drept nod ce urmează a fi inserat în drum. În continuare se aplică succesiv procedura de inserție de cost minimal, cât timp nu e depășit $TMAX$.

Pasul 2. Drumul precedent este modificat pe calea schimbării între ele a câte două noduri (algoritmul *2-OPT*), în vederea obținerii unui drum mai scurt pe mulțime de noduri respectivă. Urmează inserarea unui număr cât mai mare de noduri astfel încât $TMAX$ să nu fie depășit. Fie L drumul obținut.

Pasul 3. Se calculează centrul de greutate al drumului L , $g = (\bar{x}, \bar{y})$, unde:

$$\bar{x} = \frac{\sum_{i \in L} s(i)x(i)}{\sum_{i \in L} s(i)}, \quad \bar{y} = \frac{\sum_{i \in L} s(i)y(i)}{\sum_{i \in L} s(i)}.$$

Fie $a(i) = t(i, g)$ pentru $i = 1, \dots, n$, unde $t(i, g)$ este timpul necesar pentru a parcurge drumul de la i la g . În continuare se identifică drumul de la 1 la n , după cum urmează:

- Se calculează raportul $s(i) / a(i)$ pentru toți i .
- Se adaugă noduri în ordinea descrescătoare a $s(i) / a(i)$, folosind inserții de cost minimal, până când nu mai poate fi adăugat nici un nod fără a depăși $TMAX$.
- Se folosește pasul 2. pentru a ajusta drumul obținut. ■

Fie L_1 drumul rezultat. Pasul 3. se reia succesiv până când în șirul L_1, L_2, \dots al drumurilor obținute apare un ciclu, adică drumurile L_p și L_q sunt identice pentru $q > p$. În încheiere, se alege drumul de scor maxim din mulțimea $\{L, L_1, \dots, L_q\}$. Reluarea

pasului 3. este limitată de condiția $q \leq 10$. În experimentările efectuate, valoarea lui q nu a depășit 5.

Observații. 1. În lucrarea [WRE72] se utilizează euristica împărțirii regiunii geografice în sectoare definite de cercuri concentrice.

2. În lucrarea [TSI84] se utilizează o euristică bazată pe tehnica Monte Carlo.

4.7. O aplicație a problemei comisvoiajorului

Punerea problemei. Fiind date paletele unei turbine de forma unei coroane circulare, se cere identificarea succesiunii plasării lor astfel încât ariile dintre două palete succesive să fie distribuite cât mai uniform. Dacă se notează cu c_{ij} aria dintre paletele i și j , atunci aria totală T are expresia:

$$T = \sum_i \sum_j c_{ij} x_{ij}, \tag{4.11}$$

unde:

$$x_{ij} = \begin{cases} 1 & \text{dacă paleta } j \text{ este plasată în sens orar față de paleta } i \\ 0 & \text{altfel. } \blacksquare \end{cases}$$




Fig. 4.19.

Problema este dificilă datorită faptului că nu există o metodă eficientă pentru identificarea tuturor valorilor c_{ij} . O metodă care necesită numai n măsurători constă în identificarea pentru fiecare paletă a două valori A_i și B_i , astfel încât:

$$c_{ij} = A_i + B_j, \text{ pentru toți } i \text{ și } j.$$

O proprietate importantă, care facilitează formularea și rezolvarea problemei studiate, constă în faptul că aria totală T , definită prin (4.11), nu depinde de ordinea plasării paletelor și are valoarea:

$$T = \sum_{i=1}^n (A_i + B_i).$$

Folosind valoarea medie:

$$\bar{d} = 1/n \sum_i (A_i + B_i),$$

rezultă că o distribuire uniformă are loc dacă:

$$c_{ij} - \bar{d} = 0, \text{ pentru toți } i \text{ și } j \text{ cu } x_{ij} = 1.$$

Deoarece realizarea condiției precedente este foarte dificilă din puncte de vedere tehnologic, o soluție aproximativă acceptabilă constă în plasarea paletelor astfel încât să se minimizeze suma pătratelor abaterilor valorilor c_{ij} de \bar{d} . În felul acesta problema așezării optime a paletelor se poate enunța sub forma următoarei probleme a comisvoiajorului:

Problema P1. Să se minimizeze valoarea expresiei:

$$U(X) = \sum_i \sum_j \left(\bar{d} - (A_i + B_j) \right)^2 x_{ij}, \text{ unde } X = \{x_{ij}\}, \quad (4.12)$$

astfel încât să fie satisfăcute condițiile:

$$\sum_i x_{ij} = 1, \text{ pentru toți } i, \quad (4.13)$$

$$\sum_j x_{ij} = 1, \text{ pentru toți } j, \quad (4.14)$$

$$x_{ij} \in \{0, 1\}, \text{ pentru toți } i \text{ și } j, \quad (4.15)$$

$$\text{permutarea indicilor } i \text{ să nu conțină nici-un subciclu. } \blacksquare \quad (4.16)$$

O formulare cu o structură de cost mai ușor tratabilă se poate obține în virtutea următoarei proprietăți:

Teorema 4.5. Pentru orice $X = \{x_{ij}\}$ ce satisface condițiile (4.13), (4.14) și (4.15) are loc relația:

$$U(X) = -n \bar{d}^2 + \sum_i (A_i^2 + B_i^2) + 2 \sum_i \sum_j (A_i B_j) x_{ij}. \quad (4.17)$$

Demonstrație. Fiecare termen din (4.12) se poate retranscrie astfel:

$$(\bar{d} - (A_i + B_j))^2 x_{ij} = (\bar{d}^2 - 2(A_i + B_j) \bar{d} + A_i^2 + B_j^2) x_{ij} + 2(A_i B_j) x_{ij}.$$

Deoarece pentru fiecare i , $x_{ij} = 1$ pentru o singură valoare j și pentru fiecare j , $x_{ij} = 1$ pentru o singură valoare i , rezultă:

$$\sum_i \sum_j (\bar{d}^2 - 2(A_i + B_j) \bar{d} + A_i^2 + B_j^2) x_{ij} = \sum_i (\bar{d}^2 - 2(A_i + B_i) \bar{d} + A_i^2 + B_i^2)$$

și, ținând seama de definiția lui \bar{d} , rezultă (4.17). \blacksquare

În virtutea teoremei 4.5., problema P1 poate fi reformulată astfel:

Problema P2. Să se minimizeze:

$$h(X) = \sum_i \sum_j (A_i B_j) x_i x_j, \quad (4.18)$$

astfel încât să fie satisfăcute condițiile (4.13), (4.14), (4.15) și (4.16). \blacksquare

În continuare problema este studiată ținând seama de faptul că $c_{ij} = A_i B_j$ pot fi interpretate ca elementele unei matrice produs.

Se presupune că paletelile sunt ordonate descrescător după valorile A_i , adică au loc inegalitățile $A_1 \geq A_2 \geq \dots \geq A_n$. Primul pas al algoritmului propus constă în identificarea unei soluții optimale ce satisface (4.18), (4.13), (4.14) și (4.15). Se poate demonstra că o soluție optimală a problemei P2, fără condiția (4.16), se poate obține considerând $x_{ij} = 1$ atunci când B_j este a i -a cea mai mică valoare B , în cazul a două valori egale alegerea este arbitrară. Astfel soluția optimală menționată se poate obține ordonând valorile B nedescrescător și atribuind variabilelor x_{ij} valoarea 1.

Pentru descrierea în continuare a euristicii se folosește noțiunea de permutare. Orice vector $X = (x_{ij})$ ce satisface (4.13), (4.14) și (4.15) poate fi interpretat ca fiind o permutare a întregilor $1, 2, \dots, n$. Fiind dată o permutare $\Phi = (\Phi(1), \Phi(2), \dots, \Phi(n))$, se efectuează atribuirea $\Phi(i) = j$ dacă $x_{ij} = 1$. Deoarece pentru fiecare i , $x_{ij} = 1$ pentru un singur j rezultă că funcția $\Phi(i) = j$ este bine definită. Fiind dat un X ce satisface (4.13), (4.14) și (4.15) și Φ reprezentarea ca permutare a lui X , rezultă că:

$$\sum_i \sum_j (A_i B_j) x_{ij} = \sum_i A_i B_{\Phi(i)}$$

Această valoare este notată în continuare cu $c(\Phi)$ și este interpretată drept cost al permutării Φ .

Fie Φ^{-1} o permutare ce satisface condițiile (4.13), (4.14), (4.15) și (4.18), obținută în modul descris mai înainte. După cum s-a menționat, Φ^{-1} este un vector al indicilor paletelor, obținut pe calea asocierii lor cu valorile lui B parcurse în ordine nedescrescătoare.

Exemplul 4.9. Fie $n=6$ și $\{(A_i, B_i) : i=1,2,\dots,6\} = \{(0.9,0.4), (0.8,0.1), (0.6,0.3), (0.5,0.9), (0.3,0.6), (0.1,0.8)\}$. În acest caz, $\Phi^{-1} = (2,3,1,5,6,4)$ deoarece $B_2 \leq B_3 \leq B_1 \leq B_5 \leq B_6 \leq B_4$. Urmează identificarea faptului dacă Φ^{-1} reprezintă un singur ciclu. Pentru aceasta se reprezintă sub formă de tabel (vezi tabelul 4.1.) corespondența $\Phi^{-1}(i)=j$:

$i:$	1	2	3	4	5	6
$\Phi^{-1}(i):$	2	3	1	5	6	4

Tabelul 4.1.

Din examinarea tabelului 4.1. rezultă că Φ^{-1} conține două subcicluri și anume $1 \rightarrow 2 \rightarrow 3 \rightarrow 1$ și $4 \rightarrow 5 \rightarrow 6 \rightarrow 4$. În cazul când Φ^{-1} conține mai multe cicluri, urmează conectarea lor pe calea schimbării atribuirilor la doi indici ce figurează în cicluri distincte. Astfel, dacă indicii j și k figurează în cicluri distincte, aceste două cicluri pot fi conectate prin j și k schimbând asignarea Φ^{-1} în Φ^2 , unde $\Phi^{-1}(i) = \Phi^2(i)$, pentru toți $i \neq j$ și $i \neq k$, $\Phi^2(j) = \Phi^{-1}(k)$ și $\Phi^2(k) = \Phi^{-1}(j)$. În exemplul considerat, dacă

se consideră $j = 3$ și $k = 4$, atunci $\Phi^2 = (2, 3, 5, 1, 6, 4)$ și reprezintă ciclul $1 \rightarrow 2 \rightarrow 3 \rightarrow 5 \rightarrow 6 \rightarrow 4 \rightarrow 1$ definit de corespondența din tabelul 4.2. ■

$i:$	1	2	3	4	5	6
$\Phi^2(i):$	2	3	5	1	6	4

Tabelul 4.2.

În cazuri mai complexe cu $k \geq 3$ subcicluri, după prima operație de conectare, Φ^2 conține $k - 1$ cicluri. În continuare se identifică succesiv Φ^3, \dots, Φ^k , unde Φ^k conține un singur ciclu.

Creșterea costului c datorită conectării a două cicluri prin j și k se calculează ținând seama că la trecerea de la Φ^l la Φ^{l+1} au loc relațiile $\Phi^{l+1}(i) = \Phi^l(i)$ pentru $i \neq j$ și $i \neq k$, $\Phi^{l+1}(j) = \Phi^l(k)$ și $\Phi^{l+1}(k) = \Phi^l(j)$. Rezultă că:

$$c(\Phi^{l+1}) - c(\Phi^l) = \sum_i A_i B_{\Phi^{l+1}(i)} - \sum_i A_i B_{\Phi^l(i)} = \quad (4.19)$$

$$= A_j B_{\Phi^l(k)} + A_k B_{\Phi^l(j)} - A_j B_{\Phi^l(j)} - A_k B_{\Phi^l(k)} = (A_j - A_k) (B_{\Phi^l(k)} - B_{\Phi^l(j)}).$$

Creșterea costului definită de (4.19) se notează cu $\delta_{\Phi^l, j, k}$.

Trebuie menționat faptul că fiind date două subcicluri conținând p , respectiv, q indici, numărul total de perechi de indici ce urmează a fi testate în vederea conectării este egal cu $p \cdot q$. În cadrul euristicii propuse se consideră numai perechile j, k , unde $k = j + 1$. Astfel, în exemplul de mai sus, se efectuează numai conectarea definită de $j = 3$ și $k = 4$. O asemenea conectare se numește *adiacentă*. Deoarece în cadrul euristicii se consideră numai conectările menționate, notația $\delta_{\Phi^l, j, j+1}$ se poate renota sub forma mai simplă $\delta_{\Phi^l, j}$. La etapa l a algoritmului, dacă Φ^l conține două sau mai multe subcicluri, indicii i și $i+1$ se identifică astfel încât:

$$\delta_{\Phi^l, i} = \min\{\delta_{\Phi^l, j} : j \text{ și } j+1 \text{ se află în submulțimi distincte}\}. \quad (4.20)$$

Valoarea minimă definită de (4.20) se notează cu δ^l .

Algoritmul 4.7. (UNIFLOW)

- [Inițializare] Se obține o asignare optimală Φ^1 și se identifică cele k subcicluri definite de Φ^1 . Se face $l = 1$.
- [Terminare] Dacă $l = k$, atunci STOP.
- [Reducere] Se calculează δ^l și se identifică un i care satisface condiția $\delta_{\Phi^l, i} = \delta^l$. Se modifică Φ^l în Φ^{l+1} punând $\Phi^{l+1}(i) = \Phi^l(i+1)$, $\Phi^{l+1}(i+1) = \Phi^l(i)$ și $\Phi^{l+1}(j) = \Phi^l(j)$, pentru toți $j \neq i$, și $j \neq i+1$. Se crește l cu 1 și se trece la pasul 2. ■

Algoritmul UNIFLOW se încheie după pasul 1 dacă Φ^1 definește un singur subciclu, adică un ciclu al întregilor de la 1 la n . Dacă Φ^1 definește k subcicluri, se identifică $k - 1$ conectări și $k - 1$ valori ($\delta^1, \delta^2, \dots, \delta^{k-1}$).

5 PLANIFICAREA ACTIVITĂȚILOR

În acest capitol abordăm o problemă cu foarte multe aplicații, cunoscută în literatura de specialitate sub mai multe denumiri, unele cu anumite particularități, dintre care menționăm pe cele de *planificarea activităților*, *metode de ordonanțare*, *metoda drumului critic*, *programare dinamică* și altele. Complexitatea și varietatea acestor probleme permite folosirea unor metode exacte de rezolvare numai în cazuri cu totul particulare. Cele mai multe soluții sunt metode euristice. Unele din probleme au fost abordate în paragrafele 1.1.2.3.1. și 1.1.2.4.1.

5.1. Modelarea problemelor de planificarea activităților

Punerea problemei. Programarea activităților este planificarea la execuție a unei mulțimi de activități prin atribuirea de resurse materiale și temporale diferitelor activități și fixarea momentelor la care sunt procesate toate aceste activități cu o eficiență cât mai bună posibil. ■

Aplicații posibile: toate domeniile din economie, turism, transporturi, educație, cultură, servicii, justiție, statistică și multe altele.

Datele luate în considerație în problemele de programarea activităților privesc *activitățile*, *constrângerile potențiale*, *resursele* și *funcția obiectiv*. Constrângerile potențiale cuprind atât *constrângeri de succesiune* cât și *constrângeri de localizare temporală*. Resursele pot să genereze *constrângeri disjunctive*, cum ar fi faptul că două activități care folosesc același procesor nu se pot executa simultan, sau *constrângeri cumulative*, de exemplu, în cazul în care trei procesoare ar trebui să execute patru activități, ele nu pot să execute trei dintre cele patru activități în același timp fără să fi decis anterior care este activitatea care va fi întârziată.

Programarea activităților se face în așa fel încât să fie optimizat un anumit obiectiv care va fi, după caz, minimizarea duratei totale, respectarea termenelor din

comenzi, omogenizarea numărului ce măsoară mâna de lucru necesară sau eventual minimizarea unui cost. Principalele obiective sunt: utilizarea eficace a resurselor, o întârziere a execuției activităților cât mai mică posibil și respectarea termenelor prescrise pentru terminarea fiecărei activități în parte.

Spunem că o problemă de programarea activităților este o problemă *statică* sau *determinată* dacă mulțimea activităților de executat este dată de la început. În caz contrar spunem că această problemă este o problemă *dinamică* sau *nedeterminată* sau *stochastică*. În acest caz, activitățile evoluează în timp de o manieră nedeterminată.

5.1.1. Notății utilizate

Vom nota cu A mulțimea activităților și cu n numărul activităților de executat; durata activității i este t_i ; execuția nu poate să înceapă înainte de r_i , care este momentul de disponibilitate sau de începere cel mai devreme și trebuie să se termine înainte de d_i , care este momentul cel mai târziu sau termenul de abandon (*deadline*).

Vom nota cu s_i momentul de începere a execuției activității i și cu c_i momentul terminării execuției. Dacă activitatea i nu este interruptibilă, are loc relația:

$$c_i = s_i + t_i.$$

O condiție necesară pentru a se putea realiza o planificare a unor activități este:

$$r_i \leq s_i < c_i \leq d_i, \text{ pentru orice } i = 1, 2, \dots, n.$$

În unele cazuri, se pot considera ponderi w_i pentru activități, acestea putând fi de exemplu penalități de întârziere dacă $c_i > d_i$. Mai general, se poate asocia activității i o funcție $g_i(u)$ care este în cele mai multe dintre cazuri crescătoare și reprezintă costul asociat terminării execuției activității i la momentul u .

Două activități din A care nu sunt legate între ele prin relații de precedență se numesc *activități independente*. Constrângerile de precedență cele mai generale între două activități i și j , numite *constrângeri potențiale*, se pot scrie sub forma $s_j - s_i \geq a_{ij}$. În particular, dacă $a_{ij} = t_i$, spunem că i precede pe j . Mulțimea constrângerilor potențiale se poate reprezenta printr-un graf direcționat ponderat $G = (A, R)$, unde A este mulțimea activităților și R este mulțimea constrângerilor potențiale din care s-au eliminat toate arcele tranzitive ce reprezintă constrângeri redundante. Acest graf este cunoscut sub numele de *diagramă Hasse*.

5.1.2. Modul de execuție

Vom spune că o activitate este *fractionabilă* sau că este *interruptibilă* sau că este *preemptivă* dacă activitatea se poate executa pe bucăți, la momente diferite și eventual pe procesoare diferite. Activitatea i poate fi *întreruptă* de o activitate j la momentul t

dacă i este în execuție înainte de t și folosește o resursă alocată lui j la momentul t , aceasta producând întreruperea execuției activității i .

Pentru o *problemă repetitivă* se pleacă de la o mulțime de activități A de bază pentru care se definesc o mulțime de constrângeri ce privesc resursele și o mulțime de constrângeri interne de succesiune. Fiecare activitate de bază i dă naștere la o infinitate de activități derivate $(i, 1), (i, 2), \dots, (i, h), \dots$ care sunt executate cu respectarea *constrângerile interne*, de tipul activitatea (i, h) precede activitatea (j, h) , și, de asemenea, o mulțime de *constrângeri externe* definite prin triplete de forma (i, j, k) , $i \in A, j \in A$ și $k \in \mathbb{N}^*$ care arată că, pentru orice h , activitatea derivată $(j, h+k)$ se execută după executarea activității derivate (i, h) . Acest tip de probleme se întâlnesc în producțiile de serie din industrie.

Pentru o *problemă de atelier* activitățile, considerate ca operații elementare, sunt grupate în entități numite *lucrări* (engl. *job*). Un atelier conține m mașini distincte și fiecare lucrare este o mulțime de m operații elementare, fiecare dintre ele executându-se pe câte o mașină diferită de mașinile ce execută celelalte operații ale aceleiași lucrări. Dacă operațiile elementare sunt independente și unele dintre lucrări nu conțin toate cele m tipuri de activități, atunci se spune că este vorba de o *problemă open-shop*. Dacă cele m operații elementare ale unei lucrări sunt ordonate total, nu neapărat aceeași ordonare pentru toate lucrările, atunci se spune că este vorba de o *problemă job-shop*. Dacă operațiile elementare ale lucrărilor sunt ordonate total fiind utilizate procesoarele în aceeași ordine pentru toate lucrările, atunci spunem că este vorba de o *problemă flow-shop* sau *prelucrare în flux*.

5.1.3. Resurse

Se spune despre o resursă că este *refolosibilă* dacă, după ce a fost alocată la o activitate, ea redevine disponibilă la terminarea acestei activități pentru alte activități. De exemplu, mașinile, procesoarele, fișierele, personalul sunt resurse refolosibile. O resursă este *consumabilă* dacă, după ce a fost alocată la o activitate, nu mai este disponibilă pentru activitățile care mai sunt de executat. Așa pot fi considerate drept resurse consumabile banii, materiile prime, hârtia de scris etc. O anumită resursă poate să fie disponibilă numai la un anumit moment.

Mașinile pot să fie *identice*, activitățile respective putându-se efectua practic pe oricare dintre ele fără deosebire, sau *diferite*. În cazul mașinilor diferite se notează cu t_{ij} timpul de execuție al activității i pe mașina j . Deosebirea între mașini se face fie prin viteza de lucru, mașinile executând același fel de operații, fie prin tipurile de operații ce se pot executa, fie prin ambele criterii de deosebire.

5.1.4. Funcții obiectiv

Variabilele care intervin cel mai frecvent în exprimarea funcțiilor ce definesc eficacitatea unei programări sunt: momentul c_i al terminării execuției activității i , întârzierea activității i dată de $T_i = \max \{0, c_i - d_i\}$ și indicatorul de întârziere notat U_i și definit prin $U_i = 0$ dacă $c_i \leq d_i$ și $U_i = 1$ altfel.

Criteriile sau funcțiile obiectiv cele mai utilizate sunt următoarele:

1. *Durata totală*, notată C_{\max} , care este egală cu momentul de terminare al celei mai întârziată activități; expresia corespunzătoare este: $C_{\max} = \max_{i \in A} \{c_i\}$. În continuare, dacă nu se specifică altfel, acesta este criteriul principal pentru problemele de programarea activităților pe care le prezentăm.
2. *Respectarea termenelor*. Se poate urmări minimizarea celei mai mari întârzieri dată de expresia $T_{\max} = \max_{i \in A} \{T_i\}$ sau suma întârzierilor dată de expresia $\sum_{i \in A} T_i$ sau suma ponderată a întârzierilor dată de expresia $\sum_{i \in A} w_i T_i$ sau numărul de activități întârziate dat de expresia $\sum_{i \in A} U_i$ sau, în sfârșit, numărul ponderat al activităților întârziate dat de expresia $\sum_{i \in A} w_i U_i$.
3. *Minimizarea costului*. De exemplu, criteriul $\sum_{i \in A} w_i c_i$ permite evaluarea stocurilor utilizate.
4. *Numărul întreruperilor*. Dacă activitatea i este întreruptă de n_i ori, atunci numărul total de întreruperi dat de expresia $\sum_{i \in A} n_i$ poate să fie considerat drept un criteriu secundar esențial.
5. *Criterii pentru probleme repetitive*. În acest caz se poate urmări maximizarea frecvenței de execuție a unei activități particulare sau minimizarea unei durate generalizate definite, pentru o soluție dată, prin expresia $\limsup_{n \rightarrow \infty} (D_n / n)$, unde D_n este momentul terminării celei de-a n -a subprobleme, adică $D_n = \max_{i \in A} \{c^{(n)}\}$.

Se spune că un criteriu de minimizare $f(c_1, c_2, \dots, c_n)$ este regulat dacă:

$$(c_1 \leq d_1, c_2 \leq d_2, \dots, c_n \leq d_n) \Rightarrow f(c_1, c_2, \dots, c_n) \leq f(d_1, d_2, \dots, d_n).$$

Un criteriu regulat permite de foarte multe ori punerea în evidență a unor submulțimi de programări care conțin soluția optimală, numite *submulțimi dominante*.

De exemplu, un caz particular în care este asigurată existența unei mulțimi dominante este specificat în teorema următoare:

Teorema 5.1. Pentru orice criteriu regulat corespunzător unei probleme cu un procesor, în cazul în care toate activitățile sunt disponibile la momentul 0, mulțimea

programărilor pentru care mașina nu este liberă atâta timp cât nu au fost executate toate lucrările formează o mulțime dominantă. ■

Spunem că două criterii sunt *echivalente* dacă orice soluție optimală în raport cu primul criteriu este soluție optimală în raport cu al doilea criteriu și reciproc.

Exemplul 5.1. Criteriul bazat pe media momentelor de terminare, notată cu \bar{c} , este echivalent cu cel bazat pe media întârzierilor algebrice, notată \bar{L} , dar criteriul bazat pe întârzierea absolută, notată T_{\max} , nu este echivalent cu criteriul bazat pe întârzierea algebrică absolută, notată L_{\max} . Se poate demonstra că o soluție optimală pentru L_{\max} este soluție optimală și pentru T_{\max} dar nu și reciproc, după cum se poate vedea pe exemple simple. ■

5.1.5. Reprezentarea soluțiilor

O metodă de reprezentare a unei soluții a planificării activităților este prin intermediul *diagramelor Gantt*. Figurile 5.1. și 5.4. sunt exemple de diagrame Gantt. În aceste diagrame este inclusă o axă a timpului în raport cu care sunt indicate asignările diferitelor activități pentru fiecare dintre procesoare. În diagrame se pot efectua reprezentări în raport cu timpul și modul de alocare a celorlalte resurse implicate în executarea activităților.




Fig.5.1.

Exemplul 5.2. În figura 5.1. se găsește diagrama Gantt pentru programarea a cinci activități $A = \{1, 2, 3, 4, 5\}$, având respectiv duratele $t_1 = 6, t_2 = 3, t_3 = 4, t_4 = 5, t_5 = 5$, utilizând din resursa R1 câte 4, 1, 3, 2, 3 unități, din resursa R2 câte 8, 7, 10, 10, 4 unități și începând execuția la momentele 0, 3, 6, 8, 10. Se pot utiliza două procesoare P1 și P2. Graficul pentru R2 este deasupra celui pentru R1. ■

5.1.6. Modelarea problemei principale de programare

Pentru o mulțime $A = \{1, 2, \dots, n\}$ de activități care respectă constrângeri temporale de tip inegalități potențiale $s_j - s_i \geq a_{ij}$, unde s_i , respectiv s_j , este momentul de începere a activității i , respectiv j , și a_{ij} este un număr real dat, trebuie determinată o mulțime $S = \{s_i \mid i \in A\}$ de momente pozitive care face minimă durata totală a programării $\max_{i \in A} (s_i + t_i)$ și satisface inegalitățile potențiale.

Acestei probleme i se asociază un graf direcționat ponderat $G = (X, U)$, numit *graf de precedență*, unde $X = A \cup \{0, n + 1\}$, cu 0 o activitate fictivă de *start* și $n + 1$ o activitate fictivă *finală*, ambele de timp nul și U conține arcele $(0, i)$, $i \in A$, de valoare 0, arcele (i, j) asociate constrângerilor potențiale, de valoare a_{ij} , și arcele $(i, n + 1)$, $i \in A$, de valoare t_i . Dacă există trei arce astfel încât $a_{ik} \leq a_{ij} + a_{jk}$, atunci arcul (i, k) poate fi eliminat fiind redondant.

Exemplul 5.3. Fie $A = \{1, 2, 3, 4, 5\}$, $t_1 = t_3 = t_5 = 1$, $t_2 = 3$, $t_4 = 2$ care sunt supuse la următoarele constrângeri temporale:

1. Activitatea 2 începe la momentul 3.
2. Activitățile 3 și 4 să se suprapună pe cel puțin o unitate de timp.
3. Activitatea 4 nu poate să înceapă decât după terminarea activităților 1 și 3.
4. Activitatea 5 nu poate să înceapă înainte de a începe activitatea 3.




Fig. 5.2.

Prima constrângere se traduce prin $s_2 - s_0 \geq 3$ și $s_0 - s_2 \geq -3$. Pentru a doua constrângere trebuie descris faptul că activitățile 3 și 4 încep înainte de terminarea celeilalte cu cel puțin o unitate de timp, adică $s_3 \leq s_4 + t_4 - 1$ și $s_4 \leq s_3 + t_3 - 1$. A treia constrângere se traduce prin $s_4 - s_2 \geq t_2$ și $s_4 - s_1 \geq t_1$. Ultima constrângere duce la $s_5 \geq s_3$. Se obține astfel graful de precedență din figura 5.2, și, după eliminarea arcelor inutile, se obține graful echivalent simplificat din figura 5.3. O soluție a problemei este $\{s_1=0, s_2=3, s_3=6, s_4=6, s_5=5\}$ și diagrama Gantt corespunzătoare ei este dată în figura 5.4. Această soluție este optimă deoarece existența drumului $(0,2,4,6)$ în graf implică $s_6 \geq 8$, valoarea găsită fiind chiar 8. ■




Fig. 5.3.




Fig. 5.4.

5.1.7. Modelarea cu rețele Petri

Rețelele Petri sunt utilizate pentru a modela comportamentul dinamic al sistemelor discrete. Ele permit reprezentarea pe un singur graf a evenimentelor generatoare de schimbare a stărilor, condițiile necesare pentru a face aceste schimbări de stare și regulile de calcul a unei noi stări dacă se produce evenimentul corespunzător.

Rețelele Petri sunt alcătuite din două tipuri de obiecte: *locuri* și *tranziii*. Locurile sunt asociate cu variabilele de stare ale sistemelor și tranzițiile reprezintă evenimente susceptibile de a modifica starea sistemului. Dacă o rețea Petri modelează o problemă de programarea activităților, locurile vor fi asociate de cele mai multe ori cu diferitele tipuri de resurse utilizate de activități și constrângerilor de succesiune între activități. Tranzitiile sunt asociate cu activitățile. Evenimentele, realizarea tranzițiilor, corespund executării activităților. Execuția unor activități nu este posibilă decât dacă ele dispun de resursele necesare și dacă activitățile care le preced au fost terminate. Aceste *precondiții* pentru executarea unei activități se traduc prin existența unor arce ponderate cu valori întregi care leagă unele locuri cu tranzițiile considerate. La terminarea execuției unei activități, pot să fie restituite sau pot să fie consumate sau pot să fie generate unele resurse. Aceste *postcondiții* de terminare a activităților se traduc prin arce ponderate ce leagă tranziția considerată cu o submulțime de locuri.

Exemplul 5.4. Să considerăm mulțimea activităților $A=\{1,2,3,4\}$, cu timpii de execuție $t_1=6, t_2=7, t_3=4, t_4=5$, care sunt supuse la următoarele constrângeri temporale:

1. Activitatea 1 precede activitățile 2 și 3.
2. Activitatea 4 poate să înceapă de îndată ce s-a executat jumătate din activitatea 3.

În figura 5.5. este dată rețeaua Petri temporizată asociată acestei probleme. Pe această figură, cercurile sunt stări și dreptunghiurile sunt tranziții. A fost introdusă tranziția $T_{3,1}$ pentru a marca jumătate din execuția activității 3, T_0 este tranziția inițială și T_5 este tranziția finală a rețelei Petri. ■




Fig. 5.5.

Exemplul 5.5. Să considerăm mulțimea activităților independente $A=\{1,2,3,4,5,6\}$, cu timpii de execuție $t_1=2, t_2=7, t_3=3, t_4=5, t_5=8, t_6=4$, care sunt executate pe trei procesoare identice. Figura 5.6. reprezintă rețeaua Petri pentru modelarea acestei probleme, pe arce fiind marcate resursele utilizate și respectiv produse de fiecare tranziție. Figura 5.7. prezintă diagrama Gantt pentru o soluție a problemei. Această soluție are timpul total 11 unități, pe când soluția optimă are timpul total de 10 unități fiind obținută, de exemplu, prin executarea activităților 1 și 5 pe primul procesor, a activităților 2 și 3 pe al doilea procesor și a activităților 4 și 6 pe al treilea procesor. ■




Fig. 5.6.




Fig. 5.7.

Exemplul 5.6. Să considerăm mulțimea activităților independente $A=\{1,2,3,4\}$, cu timpii de execuție $t_1=2, t_2=6, t_3=9, t_4=3$, care sunt executate pe două procesoare identice. Activitățile 1 și 4 sunt interruptibile și celelalte nu sunt interruptibile. Figura 5.8. reprezintă rețeaua Petri pentru modelarea acestei probleme și figura 5.9. prezintă diagrama Gantt pentru o soluție a problemei. Această soluție este chiar soluția optimă în raport cu minimizarea timpului total de lucru. ■




Fig. 5.8.




Fig. 5.9.

5.2. Metode polinomiale de rezolvare a problemei planificării activităților

În acest paragraf vom prezenta mai multe metode polinomiale de soluționare a problemei planificării activităților. Vom prezenta metode bazate pe drumul critic, metode bazate pe circuite critice și metode clasice de soluționare. Dintre metodele polinomiale fac parte și metodele ce folosesc programarea liniară. Aceste metode sunt prezentate în capitolul 6.

5.2.1. Algoritmi bazați pe metoda drumului critic

5.2.1.1. Mulțimi de potențiale pe un graf conjunctiv

Se numește *graf conjunctiv* un graf direcționat, ponderat $G = (A, U)$ care are un nod 0, numit *rădăcină*, și un nod $n + 1$, numit *antirădăcină*, astfel încât există un drum de valoare pozitivă de la rădăcină la orice alt nod și un drum de valoare pozitivă de la orice nod diferit de antirădăcină la aceasta.

Se numește *mulțime de potențiale* pe un graf conjunctiv $G = (A, U)$ orice aplicație s definită pe mulțimea A cu valori reale astfel încât $s_0 = 0$ și pentru orice arc conjunctiv (i, j) de valoare v_{ij} are loc relația $s_j - s_i \geq v_{ij}$. Mulțimea potențialelor se notează τ , deci $\tau = \{s, | i \in A\}$.

Teorema 5.2. (de existență) O condiție necesară și suficientă pentru a exista o mulțime de potențiale pe un graf conjunctiv $G = (A, U)$ este aceea de a nu exista nici un circuit de valoare strict pozitivă. ■

Corolarii: 1. Dacă un graf conjunctiv este fără circuite, atunci există pentru el cel puțin o mulțime de potențiale.

2. Dacă ponderile arcelor unui graf conjunctiv nu sunt negative, atunci există o mulțime de potențiale dacă și numai dacă toate circuitele sunt de valoare nulă.

Pentru un graf conjunctiv fără circuite de valori strict pozitive, vom nota cu $l(i,j)$ valoarea maximă a unui drum de la i la j ; prin definiție $l(i,i)=0$ pentru orice $i \in A$ și $l(i,j) = -\infty$ dacă nu există drum de la i la j .

Lema 5.1. Dacă $\tau = \{s_i \mid i \in A\}$ este o mulțime de potențiale și l este definit ca mai sus, atunci $s_j - s_i \geq l(i,j)$, pentru orice $(i,j) \in U$. ■

Demonstrația lemei rezultă ușor din definiții. Cu ajutorul lemei 5.1. se poate demonstra următoarea proprietate:

Teorema 5.3. Pentru orice mulțime de potențiale $\tau = \{s_i \mid i \in A\}$ are loc relația $r_i \leq s_i$, unde $r_i = l(0, i)$. ■

Teorema 5.3. arată că, pentru mulțimea de potențiale $R = \{r_i \mid i \in A\}$, activitățile se execută cel mai devreme posibil. Se spune că R este *calată la stânga*.

În metoda potențialelor, se caută o programare a activităților de durată totală minimă. O astfel de programare corespunde la o mulțime de potențiale cu s_{n+1} minimală care este valoarea maximă a unui drum de la 0 la $n+1$. Un astfel de drum se numește *drum critic* și valoarea optimală a lui se notează cu s^* .

Teorema 5.4. Fie $F = \{f_i = \min[l(0, n+1) - l(i, n+1)] \mid i \in A\}$ o mulțime de potențiale optimală. Dacă $\tau = \{s_i \mid i \in A\}$ este o altă mulțime de potențiale optimală, atunci $s_i \leq f_i$, pentru orice $i \in A$. ■

Teorema 5.4. arată că F este o mulțime de potențiale optimală în care orice activitate se execută cel mai târziu posibil. Se spune că F este *calată la dreapta*.

Teorema 5.5. Mulțimea $F(\delta) = \{f_i(\delta) = \min\{-l(i, 0), f_i + \delta\} \mid i \in A\}$ este o mulțime de potențiale de durată $\min\{s^* + \delta, -(n+1, 0), f_i + \delta\}$. Ea este *calată la dreapta* dintre programările de aceeași durată. ■

5.2.1.2. Metoda potențiale-activități

Pentru definirea metodei potențiale-activități dăm următorul exemplu.

Exemplul 5.7. Fie mulțimea activităților $A = \{1,2,3,4,5,6,7\}$, cu duratele $t_1=3, t_2=7, t_3=4, t_4=6, t_5=5, t_6=3, t_7=2$, cu constrângerile: 1 precede pe 3, 1 și 2 preced pe 4, 3 precede pe 5, 3 și 4 preced pe 6 și 6 precede pe 7. Se caută un mod de execuție a celor 7 activități într-un timp cât mai scurt. În figura 5.10. este reprezentat graful de precedență asociat acestei probleme. Au fost adăugate, pe lângă arcele care decurg din relațiile de precedență impuse, arce de la rădăcină la nodurile care nu au predecesori și arce de la nodurile care nu au succesori la antirădăcină. ■




Fig. 5.10.

Pentru orice programare optimală $\tau = \{s_i \mid i \in A\}$ au loc relațiile $r_i \leq s_i \leq f_i$. Pentru un graf fără circuite se pot calcula programările cel mai devreme R și cel mai târziu F aplicând algoritmi următorii cunoscuți sub numele de *algoritmi lui Bellman*.

Algoritmul 5.1. (Bellman)

1. [Inițializare] Se face $r_0 = 0$ și se marchează nodul 0.
2. [Terminare] Dacă toate nodurile au fost marcate, atunci STOP.
3. [Testare circuite] Dacă nu există noduri nemarcate pentru care toți predecesorii sunt marcați, atunci STOP. (Graful are cel puțin un circuit).
4. [Alegere] Se alege un nod j nemarcat, care are toți predecesorii marcați.
5. [Marcare] Se face $r_j = \max_{(i,j) \in U} (r_i + v_{ij})$ și se marchează nodul j .
6. [Ciclare] Se merge la pasul 2. ■

Algoritmul 5.2. (Bellman)

1. [Algoritm 5.1.] Se aplică algoritmul 5.1. pentru determinarea valorilor r_0, \dots, r_{n+1} .
2. [Testare circuite] Dacă a fost detectat un circuit, adică algoritmul 5.1. s-a terminat în pasul 3., atunci STOP.
3. [Inițializare] Se face $f_{n+1} = r_{n+1}$ și se marchează nodul $n + 1$.
4. [Terminare] Dacă toate nodurile au fost marcate, atunci STOP.
5. [Alegere] Se alege un nod i nemarcat, pentru care toți succesorii au fost marcați.
6. [Marcare] Se face $f_i = \min_{(i,j) \in U} (f_j - v_{ij})$ și se marchează nodul i .
7. [Ciclare] Se merge la pasul 4. ■

Exemplul 5.8. Aplicând algoritmi 5.1. și 5.2. pentru datele din exemplul 5.7. se obțin succesiv valorile: $r_0=0, r_1=0, r_2=0, r_3=3, r_4=7, r_5=8, r_6=13, r_7=16, r_8=18$, apoi $f_8=18, f_7=16, f_6=13, f_5=13, f_4=7, f_3=8, f_2=0, f_1=4, f_0=0$. ■

În raport cu valorile calculate aplicând algoritmi lui Bellman se pot defini diferite cantități care dau gradul de libertate al activităților. Astfel numim *marje totală* M_i a unei activități i timpul maxim de variație a începutului execuției acestei activități care nu influențează momentul de terminare a tuturor activităților. Aceasta este dată de formula $M_i = f_i - r_i$.

Prin *marje liberă* m_i a unei activități i se înțelege timpul maxim de variație a începutului execuției acestei activități care nu influențează pentru succesorii ei începerea execuției cel mai devreme posibil. Aceasta este dată de formula $m_i = \min_{j \in U^+(i)} (r_j - r_i - v_{ij})$. Prin *marje sigură* μ_i a unei activități i se înțelege timpul maxim de variație, dacă există, de care se dispune pentru execuția activității i când predecesorii ei încep execuția cel mai târziu posibil și succesorii ei încep execuția cel mai devreme posibil. Aceasta este dată de formula:

$$\mu_i = \max \{0, \min_{j \in U^+(i)} (r_j - v_{ij}) - \max_{j \in U^-(i)} (f_j + v_{ji})\}.$$

În formulele anterioare, $U^+(i)$ reprezintă mulțimea succesorilor direcți ai lui i și $U^-(i)$ reprezintă mulțimea predecesorilor direcți ai lui i .

Drumurile de valoare maximală de la 0 la $n + 1$ au un rol central în problemele de programarea activităților și se numesc *drumuri critice*. Activitățile cuprinse în aceste drumuri au marja totală zero. Se spune despre aceste activități că sunt *activități critice*. Întârzierea unei activități critice cu o valoare δ produce întârzierea întregii programări cu aceeași valoare. La supravegherea realizării unei planificări, atenția principală trebuie acordată activităților critice.

i	0	1	2	3	4	5	6	7	8
M_i	0	4	0	5	0	5	0	0	0
m_i	0	0	0	0	0	5	0	0	-
μ_i	-	0	0	0	0	0	0	0	-

Tabelul 5.1.

Exemplul 5.9. Pentru datele din exemplul 5.7. se obțin valori pentru marja totală, marja liberă și marja sigură date în tabelul 5.1. Există un singur drum critic și anume (0, 2, 4, 6, 7, 8) de lungime 18. ■

5.2.1.3. Metode seriale de planificare folosind drumuri critice

În metodele seriale, euristicele permit clasificarea activităților în raport cu diferite relații de ordine de prioritate. Astfel activitățile pot să fie programate plecând de la un moment inițial 0 și crescând timpul în funcție de activitățile deja programate. La momentul t se alege o sarcină de cea mai mare prioritate dintre sarcinile disponibile, adică acelea pentru care toți predecesorii au fost terminați și pentru care cererile de resurse sunt cel mult egale cu cantitățile disponibile la momentul t . Stabilirea ordinelor de prioritate se poate face static sau dinamic. În metodele statice, prioritățile nu se modifică în timpul planificărilor, fiind stabilite o singură dată la începutul planificării, pe când în cazul dinamic ordinea de prioritate se pot modifica

în timp în funcție de situație. Algoritmii de acest fel fac parte din clasa algoritmilor de planificare pe bază de liste și au structura următoare.

Algoritmul 5.3. (pe bază de liste)

1. [Inițializare] Se face $B = \emptyset$ și $t = 0$.
2. [Terminare] Dacă B conține toate activitățile, atunci STOP.
3. [Disponibilitate] Se determină momentul t mai mare sau egal cu valoarea curentă la care devine disponibilă prima activitate dintre cele care nu aparțin lui B .
4. [Alegere] Se alege dintre activitățile disponibile la momentul t o activitate i de cea mai mare prioritate și se face $s_i = t$ și $B = B \cup \{i\}$.
5. [Ciclare] Se merge la pasul 2. ■

Dintre euristicile cele mai utilizate pentru a stabili reguli de prioritate amintim:

- ordonarea activităților crescător în raport cu începerea cel mai târziu dată de f_i ;
- ordonarea activităților crescător în raport cu terminarea cel mai târziu dată de $f_i + t_i$, unde t_i este timpul de execuție a activității i .




Fig. 5.11.

i	1	2	3	4	5	6	7	8	9	10
t_i	10	4	2	8	6	5	9	2	7	4
$R1$	3	3	1	1	1	2	3	2	1	2
$R2$	0	0	0	1	1	1	0	1	0	0
r_i	0	2	0	10	6	2	18	12	27	10
f_i	0	6	18	10	12	20	18	25	27	30

Tabelul 5.2.

Exemplul 5.10. În figura 5.11. sunt reprezentate constrângerile unei probleme de programare cu 10 activități (0 este rădăcina și 11 este antirădăcina). Activitățile necesită la începutul execuției două tipuri de resurse, $R1$ cu cel mult 5 unități și $R2$ cu cel mult o unitate. Timpii de execuție, cererile de resurse $R1$ și $R2$ și momentele de începere a execuției cel mai devreme posibil, respectiv cel mai târziu posibil sunt date în tabelul 5.2. În figura 5.12. este dată diagrama Gantt corespunzătoare soluției obținută prin aplicarea algoritmului 5.3. cu priorități pentru activități cu cele mai mici termene, pentru începerea cel mai târziu posibil. Sunt indicate, de asemenea, consumul din fiecare resursă pe fiecare perioadă de timp. Această soluție nu este optimală având valoarea 44. În figura 5.13 este dată o soluție optimală a problemei de valoare 40. ■




Fig. 5.12.




Fig. 5.13.

Pentru metodele seriale se pot da exemple în care nu se poate determina cât de departe este soluția găsită față de soluția optimală. De asemenea în aplicarea acestei metode pot să apară diferite anomalii. De exemplu, prin creșterea disponibilității resurselor se așteaptă obținerea unor soluții mai bune dar rezultatul poate fi contrar așteptărilor. Exemple de astfel de anomalii sunt prezentate în paragraful 5.2 2.6.

5.2.1.4. Euristică Schrage pentru un singur procesor

Punerea problemei. Fiind date n activități accesibile la timpii r_i , necesitând duratele de procesare t_i și termenele d_i , $i = 1, 2, \dots, n$ se cere planificarea ordinei de execuție a activităților pe un procesor astfel încât timpul de lucru să fie minimizat. ■

Algoritmul 5.4. (Schrage)

1. [Inițializare] Se face $i = 0$.
2. [Terminare] Dacă toate activitățile au fost planificate, atunci STOP.
3. [Disponibilitate] Se determină momentul U_i la care devine liber procesorul și V_i cel mai mic moment de acces al unei activități neprocesate încă.
4. [Alegere] Se alege activitatea k din mulțimea $\{j \mid j \text{ este o activitate neprocesată și } r_j \leq \max\{U_i, V_i\}\}$ cu termenul cât mai mare posibil. Dacă mai multe activități satisfac această condiție, se alege activitatea cu cel mai mare timp de execuție.
5. [Planificare] Se face $s_k = U_i$ și se consideră k planificată.
6. [Ciclare] Se face $i = i + 1$ și se merge la pasul 2. ■

Această euristică necesită $O(n \log n)$ pași.

Fie $\sigma = (\sigma(1), \sigma(2), \dots, \sigma(n))$ secvența generată în modul descris de algoritmul Schrage și T_σ timpul total. Atunci, după cum este ilustrat în figura 5.14. în care segmentele punctate corespund unor intervale de execuție sau de așteptare a eliberării procesorului, are loc relația:

$$T_S = r_{\sigma(i)} + \sum_{h=i}^j t_{\sigma(h)} + d_{\sigma(j)}, \quad (5.1)$$

unde $1 \leq i \leq j \leq n$. Dacă există mai multe moduri de calcul pentru T_S , atunci se presupune că i și j au valorile cele mai mici posibile. Deoarece i este cât mai mic posibil, rezultă fie că activitatea $\sigma(i)$ este prima în σ , fie că procesorul este neocupat imediat înaintea executării activității $\sigma(i)$. În ambele cazuri, din modul de construire a lui σ rezultă că:

$$r_{\sigma(i)} \leq r_{\sigma(h)}, \text{ pentru } h = i, i + 1, \dots, j. \quad (5.2)$$




Fig. 5.14.

Dacă $d_{\sigma(j)} \leq d_{\sigma(h)}$, pentru $h = i, i + 1, \dots, j$, atunci din (5.1) și (5.2) rezultă că σ este o secvență optimală. Altfel, se poate defini o activitate $\sigma(k)$ astfel încât $i \leq k < j$ și $d_{\sigma(j)} > d_{\sigma(k)}$ dar $d_{\sigma(h)} \geq d_{\sigma(j)}$, pentru $h = k + 1, k + 2, \dots, j$. Activitatea $\sigma(k)$ se numește în continuare *activitate de interferență* pentru secvența σ , deoarece ea poate întârzia momentele la care sunt furnizate activitățile $\sigma(k + 1), \sigma(k + 2), \dots, \sigma(j)$, ocupând procesorul atunci când măcar una din activitățile $\sigma(k + 1), \sigma(k + 2), \dots, \sigma(j)$ este furnizată spre procesare. Această activitate se numește *activitate critică*.

În continuare prezentăm o euristică modificată. Ideea de bază a euristicii modificate constă în aplicarea succesivă a algoritmului Schrage, cu restricția ca activitatea de interferență să fie executată după activitatea critică în cadrul unei noi secvențe. Până la urmă, oricare dintre activitățile cu timp mare de executare va înceta să fie activitate de interferență. Descrierea formală a euristicii este dată în continuare.

Algoritmul 5.5. (*Schrage modificat*)

- [Inițializare] Se face $t = 0$.
- [Algoritm Schrage] Se aplică algoritmul Schrage obținând timpul total $T_S^{(t)}$ și secvența de planificare la execuție $\sigma^{(t)}$.
- [Terminare] Dacă $t = n - 1$ sau nu mai apare nici o interferență în programare, atunci se face $T_S = \min \{ T_S^{(0)}, \dots, T_S^{(t)} \}$ și STOP.
- [Restricție suplimentară] Dacă $\sigma^{(t)}(k^{(t)})$ și $\sigma^{(t)}(j^{(t)})$ sunt respectiv activitățile de interferență și cea critică, se adaugă restricția ca activitatea $\sigma^{(t)}(j^{(t)})$ să precedă activitatea $\sigma^{(t)}(k^{(t)})$. (Dacă $j = \sigma^{(t)}(j^{(t)})$ și $k = \sigma^{(t)}(k^{(t)})$, această restricție este ușor de implementat făcând $r^k = r^j$).
- [Ciclare] Se face $t = t + 1$ și se merge la pasul 2. ■

Algoritmul modificat necesită $O(n^2 \log n)$ pași.

Se poate demonstra că $T_S/T^* < 3/2$, unde T^* este soluția optimală. Se poate construi un exemplu care arată că marginea anterioară este cea mai bună pentru euristica propusă.

Exemplul 5.11. Fie un sistem de 3 activități cu $r_1=0$, $r_2=1$, $r_3=(p+1)/2$, $t_1=(p-1)/2$, $t_2=(p-1)/2$, $t_3=1$, $d_1=0$, $d_2=(p-3)/2$, $d_3=(p-1)/2$, unde p este un întreg și $p \geq 3$. Algoritmul Schrage furnizează soluția $\sigma^{(0)}=(1,2,3)$ cu $T_S^{(0)}=(3p-1)/2$. Activitatea 2 este activitatea de interferență și activitatea 3 este critică. Restricția ca activitatea 3 să precedă activitatea 2 în $\sigma^{(1)}$ se obține luând $r_2=r_3=(p+1)/2$. Reluarea algoritmului Schrage furnizează secvența $\sigma^{(1)}=(1,3,2)$, cu $T_S^{(1)}=(3p-1)/2$. La această etapă nu există nici o activitate de interferență astfel încât algoritmul se încheie cu $\sigma^{(1)}=(1,3,2)$. Secvența optimală este $(2,3,1)$ cu timpul de operare $T^*=p+1$. Rezultă că raportul $T_S/T^*=3/2-2/(p+1)$ poate fi făcut oricât de aproape de $3/2$, pentru valori suficient de mari ale lui p . ■

5.2.1.5. Probleme cu resurse consumabile

Punerea problemei: Fie o mulțime cu n activități $A = \{1, 2, \dots, n\}$ legate prin constrângeri potențiale reprezentate printr-un graf conjunctiv $G = (X, U)$ care nu conține arce de forma $(i, 0)$, care ar duce la imposibilitatea unei programări. Activitatea i necesită la începutul execuției ei la momentul s_i o cantitate a_i dintr-o resursă consumabilă. Disponibilitatea acestei resurse este dată de un grafic care conține momentele u_1, u_2, \dots, u_q în care sosesc respectiv cantitățile b_1, b_2, \dots, b_q din această resursă. Obiectivul este de a determina o programare a activităților de durată minimă în care să se țină seama de disponibilitatea resursei. ■

Aplicații posibile: realizarea unei finanțări, cheltuielile unei familii, gestionarea memoriei centrale a unui calculator, rentabilizarea unor împrumuturi.

Programarea activităților este în acest caz o mulțime de potențiale care satisfac condiția de admisibilitate următoare:

$$D(t) = \sum_{i \in J(t)} a_i \leq \sum_{k \in K(t)} b_k, \text{ pentru orice } t,$$

unde $J(t)$ este mulțimea activităților care au început înainte de momentul t și $K(t)$ este mulțimea momentelor de sosire a resurselor precedente momentului t .

Pentru rezolvarea acestei probleme se poate aplica algoritmul următor, numit *algoritm de decalare*, în care se determină o mulțime de potențiale calate la dreapta F , apoi se caută cea mai mică valoare $\hat{\delta}$ a lui δ astfel încât $F(\hat{\delta})$ să fie o programare.

Algoritmul 5.6. (algoritm de decalare)

1. [Admisibilitate] Dacă $\sum_{i \in A} a_i > \sum_{k=1}^q b_k$, atunci STOP. (Nu există programare.)
2. [Calcul F] Se determină $F = \{f_i = l(0, n+1) - l(i, n+1) \mid i \in X\}$.
3. [Renumerotare] Se renumerează activitățile în ordinea nedescrescătoare a valorilor f_i .
4. [Inițializări] Se face $\hat{\delta}=0, k=1, D=0, S(u_1)=b_1$ și $S(u_i)=S(u_{i-1})+b_i$, pentru $i=2,3,\dots,q$.
5. [Ciclare] Pentru $i = 1, 2, \dots, n$ se aplică pașii 6 - 8, apoi STOP.
6. [Consum curent] Se face $D = D + a_i$.
7. [Moment disponibil] Atâta timp cât $S(u_k) < D$, se face $k = k + 1$.
8. [Ajustare] Dacă $u_k - f_i > \hat{\delta}$, atunci se face $\hat{\delta} = u_k - f_i, \hat{i} = i, \hat{k} = k$. ■

Algoritmul de decalare determină o programare de durată minimală în $O(|U|+n \log n+q)$ operații dacă $G=(X,U)$ este fără circuite și în $O(n|U|+n \log n+q)$ altfel.

Exemplul 5.12. Fie mulțimea activităților $A=\{1,2,3,4\}$ cu duratele de execuție $t_1=7, t_2=8, t_3=9$ și $t_4=6$. Activitatea 1 trebuie să preceadă activitatea 4 și activitatea 2 trebuie să preceadă activitățile 3 și 4. Toate activitățile necesită la începutul executării lor câte o cantitate $a_i=7$ de resurse. Cantitățile de resurse $b_1=b_2=b_3=10$ sunt disponibile la momentele $u_1=0, u_2=5, u_3=10$. Aplicând algoritmul de decalare, se calculează mulțimea de potențiale calate la dreapta $F: f_0=0, f_1=4, f_2=0, f_3=8, f_4=11, f_5=17$. Apoi, pentru orice activitate i , se determină cea mai mică valoare u_k astfel încât $S(u_k) \geq D(f_i)$. Se determină $\hat{\delta}$, cea mai mică valoare astfel încât $S(f_i + \hat{\delta}) \geq D(f_i)$, pentru orice i ; aici $\hat{\delta}=2$. O programare de durată minimală este: $s_0=0, s_1=6, s_2=2, s_3=10, s_4=13, s_5=19$. ■

Teorema 5.6. (de existență) O condiție necesară și suficientă pentru a exista o programare este aceea ca graful $G = (X, U)$ să fie fără circuite de valori strict pozitive

și ca $\sum_{i \in A} a_i \leq \sum_{k=1}^q b_k$. ■

Fie f^* durată optimală a unei programări; u_k este un *moment critic* dacă pentru orice programare optimală τ există o sarcină i astfel încât: $s_i = u_k; s_i + l(i, n+1) = f^*$; $S(u_k) \geq \sum_{j \in J} a_j > S(u_{k-1})$, unde $J = \{j \in A \mid l(j, n+1) \geq l(i, n+1)\}$. Activitatea i se numește în acest caz *activitate pivot*. Dacă $f^* = l(0, n+1)$, atunci orice activitate pivot este și activitate critică.

Teorema 5.7. (de criticitate) Dacă durată optimală f^* a unei programări nu este egală cu valoarea $l(0, n+1)$ a drumului critic, există un moment critic u_k și o activitate pivot i . Într-o programare optimală, cel puțin una din activitățile pivot asociate momentului critic va începe la momentul u_k . În plus, dacă toate valorile $l(i, n+1)$ sunt distincte, activitatea pivot i este definită unic și se execută la momentul critic u_k . ■

Exemplul 5.13. Pentru datele din exemplul 5.12. rezultă că $\hat{i} = 3$ este activitatea pivot și $\hat{k} = 3$ este momentul critic. ■

5.2.1.6. Probleme cu termene de predare

Punerea problemei: Fie o mulțime cu n activități $A = \{1, 2, \dots, n\}$ legate prin constrângeri potențiale reprezentate printr-un graf conjunctiv $G = (X, U)$ care nu conține arce de forma $(i, 0)$, care ar duce la imposibilitatea unei programări. Activitatea i necesită un timp de execuție t_i , costul c_i , termenul de predare d_i și la începutul execuției ei la momentul s_i o cantitate a_i dintr-o resursă consumabilă. Disponibilitatea acestei resurse este dată de un grafic ce conține momentele u_1, u_2, \dots, u_q în care sosesc respectiv cantitățile b_1, b_2, \dots, b_q din această resursă. Obiectivul este de a determina o programare a activităților, dacă există, de durată minimă în care să se țină seama de disponibilitatea resursei. ■

Aplicații posibile: realizarea unei finanțări, cheltuielile unei familii, gestionarea memoriei centrale a unui calculator, rentabilizarea unor împrumuturi.

Se numește *graf complet* graful \bar{G} obținut din G prin introducerea arcelor $(i, 0)$ ponderate cu $t_i - d_i$.

Înainte de a determina soluția problemei sunt ajustate valorile d_i în așa fel încât să fie îndeplinită condiția $d_i \leq \min_{k \in U^+(i)} (d_k - v_{ik} - t_k) + t_i$. Aceasta se poate face printr-un

algoritm de determinare a drumurilor din graful G . Complexitatea acestui algoritm este $O(|U|)$, pentru un graf fără circuite, și $O(n^3)$, pentru un graf cu circuite.

În acest caz, mulțimea potențialelor calate la dreapta $F(\delta)$ este dată de:

$$F(\delta) = \{f_i(\delta) = \min(f_i + \delta, d_i - t_i) \mid i \in X\},$$

unde $f_i = l(0, n+1) - l(i, n+1)$. Pentru un δ suficient de mare, $F(\delta) = \{d_i - t_i \mid i \in X\}$. Prin abuz de notație, vom nota această mulțime de potențiale cu $F(\infty)$.

Teorema 5.8. (de existență) O condiție necesară și suficientă pentru a exista o programare este ca graful complet $\bar{G} = (X, \bar{U})$ să fie fără circuite absorbante și ca mulțimea potențialelor $F(\infty) = \{d_i - t_i \mid i \in X\}$ să fie o planificare. ■

Se numește *latitudinea* unei activități i cantitatea $\delta_i = d_i - f_i - t_i$. Valoarea δ_i reprezintă cantitatea maximală cu care poate să întârzie activitatea fără să depășească termenul său de predare. În algoritmul următor, numit *algoritmul dicotomic*, se numerotează activitățile în ordinea nedescrescătoare în raport cu δ_i și se face o căutare dicotomică pentru a determina în ce interval $[\delta_i, \delta_{i+1})$ se găsește δ astfel încât $F(\delta)$ să fie optimal.

Algoritmul 5.7. (dicotomic)

1. [Calcul F] Se determină $F = \{f_i = l(0, n+1) - l(i, n+1) \mid i \in X\}$ și $F(\infty) = \{d_i - t_i \mid i \in X\}$.
2. [Realizabil] Dacă $F(\infty)$ nu este admisibil, atunci STOP. (Nu există programare).
3. [Renumeroțare] Se renumeroțază activitățile în ordinea nedescrescătoare a valorilor δ_i , unde $\delta_i = d_i - f_i - t_i$.
4. [Inițializări] Se face $j = 0$, $k = n$, $i = [(k + j) / 2]$ și $b = 0$.
5. [Algoritm decalare] Se aplică algoritmul de decalare pentru $F(0)$.
6. [Testare soluție] Dacă $\hat{\delta} \leq \delta_i$, atunci se face $\hat{\delta} = \delta_i$ și $b = 0$.
7. [Terminare] Dacă $b = 1$, atunci STOP.
8. [Algoritm decalare] Se aplică algoritmul de decalare pentru $F(\delta_i)$.
9. [Mutare în jos] Dacă $\hat{\delta} = 0$, atunci se face $k = i$ și $i = [(k + j) / 2]$.
10. [Mutare în sus] Dacă $\hat{\delta} + \delta_i > \delta_{i+1}$, atunci se face $j = i$ și $i = [(k + j) / 2]$.
11. [Determinare interval] Dacă $\hat{\delta} > 0$ și $\hat{\delta} + \delta_i \leq \delta_{i+1}$, atunci se face $b = 1$ și $\delta = \hat{\delta} + \delta_i$.
12. [Ciclare] Se merge la pasul 7. ■

Se poate demonstra că algoritmul dicotomic determină o programare ori de câte ori există o programare pentru o problemă dată. Complexitatea lui este $O(|U| + n \log n + q \log n)$, dacă graful G este fără circuite și $O(|U| + q \log n)$, altfel.

5.2.1.7. Metoda PERT

În metoda *PERT* (*Program Evaluation and Research Technique*) se poate folosi pentru determinarea drumurilor de valoare maximală un graf de precedență în care nodurile sunt asociate cu evenimente de tipul *terminarea activității i , începutul sarcinilor j și k* și arcele sunt asociate activităților. Activitățile pot să fie reale sau fictive. Activitățile fictive sunt utilizate pentru a reprezenta anumite constrângeri potențiale și au, în general, durata 0.

Un inconvenient al acestei metode în raport cu metoda potențialelor este numărul dublu de noduri din graf. Aceasta deoarece fiecărei activități i îi corespunde un nod I_i pentru începutul execuției și un nod F_i pentru terminarea ei. Un avantaj al acestei metode este o mai ușoară urmărire de către practicieni, fiecare activitate putând să fie reprezentată printr-un singur segment ce poate avea o lungime proporțională cu timpul de execuție. Schemele ce se obțin pentru graful asociat pot să arate sub forma unor diagrame Gantt.

Pentru reflectarea modului în care sunt reflectate pe graful G constrângerile potențiale vom da în continuare câteva exemple. Menționăm că rădăcina este notată I și antirădăcina F .

- Activitatea i precede activitatea j se traduce prin adăugarea arcului (F_i, I_j) de valoare 0.
- Activitatea i începe după r_i unități se traduce prin adăugarea arcului (I, I_i) de valoare r_i .
- Activitatea j poate să înceapă numai după ce s-a consumat $2/3$ din timpul de execuție al activității i se traduce prin înlocuirea lui i prin două activități i' ce reprezintă prima parte din i de timp $2/3$ din timpul lui i și i'' ce reprezintă ultima parte din i de timp $1/3$ din timpul lui i . Apoi se înlocuiesc arcele de forma (\bullet, I_i) cu arce $(\bullet, I_{i'})$ și arcele (F_i, \bullet) cu $(F_{i'}, \bullet)$, de aceleași valori, și se adaugă arcele $(F_{i'}, I_{i''})$ de valoare 0 și $(F_{i'}, I_j)$ de valoare 0.
- Activitatea j începe la un interval t' după terminarea activității i se traduce prin includerea unui arc (F_i, I_j) de valoare t' .
- Activitatea i nu se poate termina după termenul d_i se traduce prin includerea unui arc (F_i, I) de valoare $-d_i$.
- Activitatea i să înceapă înainte de momentul t' se traduce prin includerea unui arc (I, I) de valoare $-t'$.

Graful obținut în urma transformărilor de tipul celor indicate mai sus se poate simplifica prin eliminarea arcelor redundante.

5.2.2. Metoda circuitelor critice

Punerea problemei: Se cere determinarea unei programări a mulțimii de activități $A = \{1, 2, \dots, n\}$, fiecare activitate putându-se executa repetitiv, supuse la constrângeri interne date prin relații de precedență între activități și la constrângeri externe prin care se stabilesc relații între copiile activităților. ■

Aplicații posibile: fabricarea unor elemente de serie, executarea programelor.

Execuția repetitivă a activităților poate fi asimilată cu calculul de mână. Multe ori a unei funcții $F = (A, <)$ care stabilește ordinea de executare a câte unei copii a fiecărei activități. Vom nota cu $<$ mulțimea constrângerilor interne și cu $<'$ mulțimea finită de constrângeri externe. O constrângere externă este de forma (i, j, k) , unde i și j sunt activități părinți și k este un număr întreg strict pozitiv, și exprimă faptul că, pentru orice n număr natural, execuția activității j pentru al $(n + k)$ -lea calcul al funcției nu poate să înceapă înainte de terminarea execuției lui i pentru al n -lea calcul al funcției. Pentru a evita reentranta se face presupunerea că $(i, i, 1) \in <'$, pentru orice $i \in A$. Aceasta este cunoscută sub numele de *ipoteza de nereentranta*.

Dacă se notează cu t_i^n momentul de începere a celei de-a n -a execuții a activității i , atunci a n -a execuție a lui F are loc între momentul α_n dat de expresia $\alpha_n = \min\{t_i^n | i \in A\}$ și momentul β_n dat de expresia $\beta_n = \max\{t_i^n | i \in A\}$. De cele mai multe ori se presupune că orice execuție a lui F se efectuează într-un timp finit. Aceasta se poate exprima prin existența unei constante K astfel încât $\beta_n - \alpha_n < K$. Se poate vedea ușor că, pentru fiecare $i \in A$, are loc inegalitatea $t_i^n \leq t_i^{n+1}$ pentru orice n număr natural. La fel, șirurile $(\alpha_n)_n$ și $(\beta_n)_n$ sunt crescătoare. Ele sunt strict crescătoare dacă $t_i > 0$.

În continuare vom numi *activitate derivată* de ordinul n a activității părinte i perechea (i, n) , pentru un n număr natural nenul.

Dacă F se calculează de un număr dat N de ori, problema se poate rezolva prin metodele prezentate anterior, considerând N copii identice ale grafului asociat și stabilind arce între activități din copii diferite în funcție de constrângerile externe.

5.2.2.1. Modelarea problemei centrale repetitive

Vom utiliza noțiunea de *graf de evenimente* definit prin $R = (G, p, E^0)$, unde $G = (T, P)$ este un graf direcționat conex în care T este mulțimea tranzițiilor și P este mulțimea locurilor; $p: T \rightarrow N$ asociază durate tranzițiilor și $E^0 = (M^0 = P \rightarrow N, R^0 = T \rightarrow N)$ este starea inițială. Vom presupune că $t_i > 0$ și că duratele reziduale sunt 0 la momentul 0. De aici rezultă că postmarcajul inițial este egal cu marcajul inițial.

Fie funcția $F = (A, <)$ cu constrângerile externe $<$. Vom asocia problemei centrale repetitive graful de evenimente temporizat următor: fiecărei activități i de durată t_i îi corespunde tranziția T_i de aceeași durată și de durată reziduală inițială nulă; fiecărei precedente $i < j$ îi corespunde locul P_{ij} de marcă inițială nulă, cu unica intrare T_i și unica ieșire T_j ; fiecărei constrângeri externe $(i, j, k) \in <$ îi corespunde un loc P_{ij} de marcă inițială k , având o intrare T_i și o ieșire T_j . Execuțiile controlate în evenimente ale grafului de evenimente $R = (G, p, E^0)$ sunt soluții pentru problema centrală repetitivă.

Exemplul 5.14. Pentru realizarea unei piese se efectuează activitățile $\{1, 2, \dots, 12\}$ repartizate în trei ateliere A_1, A_2 și A_3 . Limitările interne sunt date în figura 5.15. Constrângerile externe sunt implicate de restricția că fiecare atelier A_i poate lucra la cel mult K_i piese la un moment dat, unde $K_1=3, K_2=2, K_3=1$ și de ipoteza de nereentrănță. Aceste constrângeri externe se traduc în satisfacerea următoarelor inegalități: $t_1^{n+3} - t_6^n \geq t_6$ (primul atelier poate lucra la cel mult 3 piese la un moment dat), $t_7^{n+2} - t_{10}^n \geq t_{10}$ (al doilea atelier poate lucra la cel mult 2 piese la un moment dat), $t_{11}^{n+1} - t_{12}^n \geq t_{12}$ (al treilea atelier poate lucra la cel mult o piesă la un moment dat),

$t_i^{n+1} - t_i^n \geq t_i$, pentru orice $n > 0$ și orice activitate i (piesele se pot lucra numai în ordinea numerelor asociate lor). Graful de evenimente corespunzător procedurii expus anterior este reprezentat în figura 5.16. ■




Fig. 5.15.




Fig. 5.16

Din graful de evenimente $R=(G,p.E^i)$ se poate construi un graf infinit, numit *graful dezvoltat*, $g(R)=(\tau,S,\nu)$, unde $\tau = T_0^0 \cup \{T_i^n \mid T_i \in T, n \geq 1\}$, T_0^0 fiind nodul asociat activității fictive de început (rădăcina) și T_i^n fiind nodul asociat activității derivate (i,n) , $S=S_1 \cup S_2$, cu $S_1 = \{(T_0^0, T_j^{M_{ij}^0}) \mid (T_i, T_j) \in P \text{ și } M_{ij}^0 > 0\}$, $S_2 = \{(T_i^n, T_j^{n+M_{ij}^0}) \mid (T_i, T_j) \in P \text{ și } n \geq 1\}$, M_{ij}^0 fiind marcajul inițial al lui P_{ij} ; $\nu(T_0^0, T_j^{M_{ij}^0}) = 0$, pentru orice arc din S_1 și $\nu(T_i^n, T_j^{n+M_{ij}^0}) = t_i$, pentru fiecare arc din S_2 . Traversarea de indice $n + M_{ij}^0$ a lui T_j poate să înceapă după a n -a traversare a lui T_i .

• Fie un element ω pe care îl adăugăm la mulțimea numerelor naturale obținând mulțimea $\bar{N} = N \cup \{\omega\}$. Presupunem că ω are următoarele proprietăți: $\omega > n$, pentru orice număr natural n , $\omega + n = \omega - n = \omega$, pentru orice număr natural n , $\omega + \omega = \omega - \omega = \omega$.

O mulțime de potențiale pe $g(R)$, graful extins al grafului de evenimente temporizate R , este o aplicație s a mulțimii τ a vârfurilor lui $g(R)$ cu valori reale cu următoarele proprietăți: $s_0^0 = 0$; $s_i^n \in \bar{\mathbb{N}}$, pentru orice $n \geq 1$ și orice $T_i \in T$: $s_j^q - s_i^p \geq v(T_i^p, T_j^q)$, pentru orice $(T_i^p, T_j^q) \in S$. Există o bijecție între execuțiile controlate ale lui R și mulțimile de potențiale pe $g(R)$. Un graf de evenimente temporizate are o execuție controlată infinită dacă și numai dacă pentru orice circuit suma marcajelor inițiale este strict pozitivă.

Soluția optimă a problemei de programare repetitivă este execuția controlată cea mai devreme. Relația de ordine între execuții ordonate se definește în felul următor: dacă X și Y sunt execuții controlate având respectiv asociate mulțimile de potențiale x și y , atunci $X \leq Y$ dacă și numai dacă $x_i^n \leq y_i^n$, pentru orice $T_i \in T$ și orice $n \geq 1$.

Data cea mai devreme a celei de-a n -a execuții a activității părinte i a unei probleme de programare repetitivă este valoarea maximală a unui drum de la T_0^0 la T_i^n în graful extins.

Notând cu γ_i^n momentul cel mai devreme a celei de-a n -a traversare a tranziției T_i , se obține $\gamma_i^n = \omega$ dacă există în $g(R)$ un drum de valoare ∞ de la T_0^0 la T_i^n și $\gamma_i^n =$ valoarea maximă a unui drum de la T_0^0 la T_i^n .

Fie C mulțimea tranzițiilor ce aparțin circuitelor cu toate arcele marcate inițial cu zero. Fie A^n mulțimea nodurilor lui $g_p(R)$ care rezultă din C , dată de expresia $A^n = \{T_i^p \mid T_i \in C\}$. Dacă \mathcal{C} este mulțimea nodurilor lui $g_p(R)$, atunci graful $g'_p(R)$ cu nodurile $\mathcal{C} - A^n$ și arcele corespunzătoare lor din $g_p(R)$ este fără circuite. Deci acest graf admite o numerotare a nodurilor astfel încât pentru orice arc (T_i^p, T_j^p) din $g'_p(R)$ are loc $i < j$. Această numerotare permite o ordonare a tuturor nodurilor din copii ce nu aparțin la circuite și determinarea potențialelor până la o limită M de copii date aplicând algoritmul următor:

Algoritmul 5.8. (*potmin*)

1. [Inițializare] Se face $\gamma_0^0 = 0$ și $\gamma_i^1 = \omega$, pentru orice $T_i^1 \in C^1$.
2. [Ciclare copii] Pentru $p = 1, 2, \dots, M$ se aplică pasul 3, apoi STOP.
3. [Ciclare noduri] Pentru $i = 1, 2, \dots, n$ se aplică pasul 4.
4. [Calcul potențial] Dacă $T_i^p \in C^p$, atunci $\gamma_i^p = \omega$, altfel:

$$\gamma_i^p = \max_{(T_j^q, T_i^p) \text{ arc în } g(R)} \left\{ \gamma_j^q + v(T_j^q, T_i^p) \right\}. \blacksquare$$

Complexitatea acestui algoritm este $O(n^2 M)$.

5.2.3. Metode clasice

În acest paragraf vom prezenta metodele devenite clasice pentru programarea activităților. Am clasificat aceste metode în două categorii: metode de schimb și metode pe bază de liste.

5.2.3.1. Metode de schimb

5.2.3.1.1. Programarea pe un procesor

Punerea problemei. Fiind date n activități disponibile la momentul 0, cu timpii de execuție t_1, t_2, \dots, t_n , cu ponderile w_1, w_2, \dots, w_n se cere programarea lor pe un procesor prin care să se minimizeze valoarea $\sum_{i=1}^n w_i c_i$, unde c_i este momentul terminării activității i . ■

Dacă activitățile sunt independente, programarea activităților în ordinea necrescătoare a valorilor $\rho_i = w_i / t_i$ conduce la o soluție optimă.

5.2.3.1.1.1. Proprietăți ale soluțiilor optime pentru activități dependente

Pentru o submulțime x de activități vom folosi următoarele notații: $t(x) = \sum_{i \in x} t_i$, $w(x) = \sum_{i \in x} w_i$, $\rho(x) = w(x) / t(x)$, $G(x)$ subgraful generat de x și $\bar{x} = A - x$.

Se vede imediat că dacă s este o programare pentru A , atunci $s(x)$ este o programare pentru x .

Vom spune că o submulțime de activități x este *inițială* dacă pentru orice $i \in x$ predecesorii lui i sunt elemente ale lui x .

Oricare ar fi soluția problemei de programare $s = (i_1, i_2, \dots, i_n)$, mulțimile $\{i_1, i_2, \dots, i_k\}$ sunt inițiale pentru orice $k = 1, 2, \dots, n$.

Vom spune că o submulțime de activități y este ρ -*maximală* dacă este nevidă, $\rho(y) \geq \rho(x)$, pentru orice submulțime x inițială, și este minimală în raport cu incluziunea cu aceste proprietăți.

Teorema 5.9. Dacă $s^* = (s^*(x), s^*(\bar{x}))$ este o programare optimală, atunci $s^*(x)$ este soluție optimală pentru $G(x)$ și $s^*(\bar{x})$ este soluție optimală pentru $G(\bar{x})$.

Teorema 5.10. Dacă y este inițială ρ -maximală, atunci există o programare optimală s^* astfel încât $s^* = (s^*(y), s^*(\bar{y}))$. În plus, y apare ca un șir neîntrerupt în orice soluție optimală. ■

Lema 5.2. Dacă (x_1, x_2) este o partiție a lui x , atunci:

$$\rho(x) = (t(x_1) / t(x)) \rho(x_1) + (t(x_2) / t(x)) \rho(x_2). \blacksquare$$

Lema 5.3. Dacă $s=(s(x),s(x_1),s(x_2),s(y))$ și $s'=(s(x),s(x_2),s(x_1),s(y))$ sunt programări de valori $\varphi(s)$, respectiv $\varphi(s')$, atunci $\varphi(s) \leq \varphi(s')$ dacă și numai dacă $\rho(x_1) \geq \rho(x_2)$. ■

Lema 5.4. Dacă (x_1, x_2, \dots, x_r) este o partiție a lui x , atunci $\max\{\rho(x_1), \rho(x_2), \dots, \rho(x_r)\} \geq \rho(x)$. Egalitatea are loc dacă și numai dacă $\rho(x_1) = \rho(x_2) = \dots = \rho(x_r)$. ■

Teorema 5.11. Dacă s^* este o programare optimală, atunci există o mulțime inițială ρ -maximală de activități y astfel încât $s^* = (s^*(y), s^*(\bar{y}))$. ■

Din proprietățile precedente rezultă următorul procedeu de determinare a unei soluții optimale: se determină mulțimile inițiale ρ -maximale de activități y și se alege soluția $(s(y), s(\bar{y}))$ care are cea mai mică valoare.

5.2.3.1.1.2. Dependente de tip antiarborescență

Reamintim că un *antiarbore* este un graf conex cu un nod numit *antirădăcină* care nu are nici un succesor, toate celelalte noduri având câte un succesor imediat. G este o familie de antiarbori dacă orice componentă conexă a lui G este un antiarbore. Vom nota cu $A(i)$ antiarborii generat de i .

Teorema 5.12. Mulțimile de activități inițiale ρ -maximale ale unei familii de antiarbori sunt $A(i), i = 1, 2, \dots, n$. ■




Fig. 5.17.

i	1	2	3	4	5	6	7
$A(i)$	{1, 2, 3, 4}	{2, 3, 4}	{3}	{4}	{5, 6, 7}	{6, 7}	{7}
$w(A(i))$	15	9	2	3	13	7	3
$t(A(i))$	7	6	1	3	5	4	2
$\rho(A(i))$	$2 + 1/7$	$1 + 1/2$	2	1	$2 + 3/5$	$1 + 3/4$	$1 + 1/2$

Tabelul 5.3.

Exemplul 5.15. Fie mulțimea de activități $A = \{1, 2, 3, 4, 5, 6, 7\}$ cu timpii de execuție $(1, 2, 1, 3, 1, 2, 2)$, cu ponderile $(6, 4, 2, 3, 6, 4, 3)$ și cu graful de precedență din figura 5.17. În tabelul 5.3. sunt sintetizate informațiile privind mulțimile de activități inițiale corespunzătoare. Rezultă că mulțimea $A(5)$ este ρ -maximală. Deci $s^* = (s^*(A(5)), s^*(\overline{A(5)}))$. Apoi se determină componentele acestei soluții după modelul $s^*(A(5)) = (s^*(A(5) - \{5\}), 5)$. ■

Algoritmul de determinare a soluției optimale este în acest caz:

Algoritmul 5.9. $OPT(A)$

1. [Terminare] Dacă $A = \emptyset$, atunci STOP.
2. [Prefix soluție] Se planifică activitățile date de soluția $OPT(A(1) - \{1\})$.
3. [Planificare centrală] Se planifică prima activitate din A .
4. [Sufix soluție] Se planifică activitățile date de soluția $OPT(\overline{A(1)})$. ■

Complexitatea acestui algoritm este $O(n^2)$.

Exemplul 5.16. Cu datele din exemplul 5.15., deoarece pentru $A(5)$ există o singură planificare, $s^*(A(5)) = (7, 6, 5)$. Cum $\overline{A(5)} = A(1)$, soluția optimală este $(7, 6, 5, s^*(A(2)), 1)$. $A(3)$ este ρ -maximală pentru $A(2)$ și, cum $\overline{A(3)} = \{4, 2\}$, rezultă soluția optimală a problemei inițiale $(7, 6, 5, 3, 4, 2, 1)$. ■

5.2.3.1.1.3. Euristică Greedy pentru activități cu termene de predare

Punerea problemei. Presupunem executarea pe un procesor a n activități, activitatea i având timpul de execuție t_i , ponderea w_i și termenul de predare d_i , pentru $i = 1, 2, \dots, n$. ■

În euristica propusă, se programează pe ultimul loc activitatea cu valoare maximă a raportului t_i / w_i și care nu depășește termenul limită de încheiere d_i . Procedura se reia până când s-a efectuat programarea tuturor activităților. Descrierea formală este dată în continuare.

Algoritmul 5.10. (*Greedy*)

1. [Inițializări] Se face $k = n$ și $T_n = \sum_{i=1}^n t_i$, $V_n = \{1, 2, \dots, n\}$.
2. [Terminare] Se determină $E_k = \{j \in V_k \mid d_j \geq T_k\}$. Dacă $E_k = \emptyset$, atunci nu există o soluție realizabilă și STOP.
3. [Alegere] Se alege $r_k \in \{i \mid t_i / w_i = \max_{j \in E_k} \{t_j / w_j\}\}$ cu d_k cât mai mare. În cazul unor valori maxime egale ale rapoartelor și ale limitelor de încheiere corespunzătoare lor d_k , se alege aleator una dintre valorile r_k .
4. [Modificări] Dacă $k = 1$, atunci STOP; altfel se face $T_{k-1} = T_k - t_{r_k}$, $V_{k-1} = V_k - \{r_k\}$, $k = k - 1$ și se trece la pasul 2. ■

Această procedură are complexitatea temporală $O(n \log n)$ și identifică o soluție realizabilă, dacă aceasta există.

În vederea investigării eficienței euristicii propuse, fie o clasă de probleme pentru care euristica furnizează o soluție optimală. Se presupune că activitățile sunt

indexate astfel încât $t_1 / w_1 \leq t_2 / w_2 \leq \dots \leq t_n / w_n$. Pentru o programare dată σ se afirmă că activitățile $\sigma(i)$, $\sigma(j)$ și $\sigma(k)$ sunt într-o configurație interzisă dacă $i < j < k$ și $\sigma(j) > \sigma(i) > \sigma(k)$. Dacă σ are trei activități, nu neapărat adiacente, într-o configurație interzisă, atunci activitatea situată în poziția mijlocie, activitatea $\sigma(j)$ din poziția j , are valoarea maximă a raportului t_r / w_r , activitatea din prima poziție, activitatea $\sigma(i)$, are valoarea imediat mai mică a raportului t_r / w_r , și activitatea din ultima poziție, activitatea $\sigma(k)$, are cea mai mică valoare a raportului t_r / w_r .

Teorema 5.13. Fie σ^* o soluție optimală a problemei studiate. Dacă în σ^* nu există o configurație interzisă a trei activități din σ^* , atunci soluția σ^0 , adică cea furnizată de euristică, este și ea optimală.

Demonstrație. Să presupunem că $\sigma^0 \neq \sigma^*$. Fie $s = \max\{k \mid \sigma^0(k) \neq \sigma^*(k)\}$. În virtutea pasului 3 al euristicii, $\sigma^*(s) < \sigma^0(s)$. Fie $i \in \{1, 2, \dots, s-1\}$ astfel încât $\sigma^*(i) = \sigma^0(i)$. În virtutea ipotezei $\sigma^*(j) < \sigma^*(i)$, pentru toți $j \in \{i+1, i+2, \dots, s-1\}$. O succesiune de interschimbări de perechi de intervale are drept rezultat o soluție cel puțin la fel de bună cu activitatea $\sigma^*(i)$ inserată în poziția s . Procedeu descris poate fi repetat până când $\sigma^0 = \sigma^*$. Deci σ^0 este optimală. ■

5.2.3.1.2. Probleme de atelier cu două procesoare

În problemele de programare cu m procesoare numite *flowshop* se presupun un număr de n lucrări, fiecare lucrare i constă din m activități $(i, 1)$, $(i, 2)$, ..., (i, m) , activitatea (i, j) se execută timp de t_{ij} pe procesorul j și (i, j) precede $(i, j+1)$, pentru $j = 1, 2, \dots, m-1$ și $i = 1, 2, \dots, n$.

Pentru $m = 2$, vom nota $a_i = t_{i1}$ și $b_i = t_{i2}$, pentru $i = 1, 2, \dots, n$. Fie relația ρ pe mulțimea lucrărilor definită prin $i \rho j$ dacă și numai dacă $\min(a_i, b_i) < \min(a_j, b_j)$.

Teorema 5.14. Relația ρ este o relație de ordine parțială strictă.

Pentru demonstrație a se vedea [BÂS89]. ■

Teorema 5.15. Orice ordine totală compatibilă cu ρ este o planificare optimală a lucrărilor executate pe două procesoare diferite.

Pentru demonstrație a se vedea [BÂS89]. ■

Proprietățile enunțate anterior permit obținerea unei planificări optime aplicând următorul algoritm cunoscut sub numele de *algoritmul lui Johnson*.

Algoritm 5.11. (Johnson)

- [Inițializări] Se face $R = \{1, 2, \dots, n\}$, $s = 1$ și $l = n$.
- [Terminare] Dacă $R = \emptyset$, atunci STOP.

3. [Alegere] Se alege o pereche (i, j) care corespunde celei mai mici valori t_{ij} , pentru $i \in R$ și $j = 1, 2$. Dacă sunt mai multe, se alege oricare dintre ele.
4. [Programare] Dacă $j = 1$, atunci se planifică i pe poziția s și se face $s = s + 1$, altfel se planifică i pe poziția d și se face $d = d - 1$.
5. [Ciclare] Se face $R = R - \{i\}$ și se merge la pasul 2. ■

Complexitatea algoritmului este $O(n^2)$.

Exemplul 5.17. Pentru $n=5$, $a_1=3$, $b_1=6$, $a_2=5$, $b_2=2$, $a_3=1$, $b_3=2$, $a_4=6$, $b_4=6$, $a_5=7$ și $b_5=5$, prin aplicarea algoritmului precedent, mai întâi se face $R=\{1,2,3,4,5\}$, $s=1$ și $d=5$. Cum $a_3=1$ este cea mai mică valoare a unui timp, se plasează lucrarea 3 pe locul 1, se face $s=2$ și $R=\{1,2,4,5\}$. Pentru activitățile rămase $b_2=2$ este cea mai mică valoare a unui timp, deci se plasează lucrarea 2 pe locul 5, se face $d=4$ și $R=\{1,4,5\}$. Pentru activitățile rămase $a_1=3$ este cea mai mică valoare a unui timp, deci se plasează lucrarea 1 pe locul 2, se face $s=3$ și $R=\{4,5\}$. Pentru activitățile rămase $b_5=5$ este cel mai mic timp, deci se plasează lucrarea 5 pe locul 4, se face $d=3$ și $R=\{4\}$. În final se plasează lucrarea 4 pe locul 3 și se obține planificarea optimă $(3,1,4,5,2)$. ■

5.2.3.1.3. Euristici de planificare pe două mașini cu timpi de accesibilitate

Fie n activități cu timp de accesibilitate r_i , $i = 1, 2, \dots, n$ și durate de procesare a_i și b_i pe mașinile A și respectiv B . Obiectivul constă în planificarea (ordonarea) activităților astfel încât timpul maxim de încheiere C_{\max} să fie minimizat. Pentru rezolvarea problemei, se propun patru euristici pe care le prezentăm în continuare.

Prima euristică, numită *ARB*, constă în ordonarea arbitrară a activităților, după care C_{\max}^{ARB} este evaluat în $O(n)$ pași. În a doua euristică, numită *R*, activitățile sunt ordonate în ordinea nedescrescătoare a timpilor de accesibilitate și în a treia euristică, numită *J*, ordonarea are loc în conformitate cu *regula Johnson*, ignorând timpii de accesibilitate, și anume: activitățile cu $a_i \leq b_i$ sunt ordonate primele în ordinea nedescrescătoare a duratelor a_i după care activitățile rămase (cu $a_i > b_i$) sunt ordonate în ordinea necrescătoare a duratelor b_i . În ambele cazuri, procesarea se efectuează în $O(n \log n)$ pași. Dacă e adoptată euristica *R*, atunci nu există timp neocupat în mod necesar pe mașina A . A patra euristică, numită *RJ*, este o variantă a euristicii *R* în care se ține seama de avantajul euristicii *J* de a elimina timpii neocupați în mod necesar: ori de câte ori trebuie aleasă o activitate dintr-o secvență care evită timpii neocupați în mod necesar, se alege acea activitate care urmează să fie procesată prima în conformitate cu regula lui Johnson. Această euristică are complexitatea $O(n \log n)$ și este prezentată în continuare.

Algoritmul 5.12. (Euristică RJ)

- [Inițializări] Se face $k = 0$ și $T = \min_{i \in S} \{r_i\}$, unde S este mulțimea activităților.
- [Alegeri] Se determină mulțimea $S' = \{i \mid i \in S, r_i \leq T, a_i \leq b_i\}$ și mulțimea $S'' = \{i \mid i \in S, r_i \leq T, a_i > b_i\}$. Dacă $S' \neq \emptyset$, se alege o activitate i din S' cu a_i cât mai mic; altfel se alege o activitate i din S'' cu b_i cât mai mare.
- [Plasare] Se face $k = k + 1$, se plasează activitatea i în poziția k , se face $T = T + a_i$ și $S = S - \{i\}$.
- [Terminare sau ciclare] Dacă $S = \emptyset$, atunci STOP (s-a obținut o programare); altfel se face $T = \max\{T, \min_{i \in S} \{r_i\}\}$ și se trece la pasul 2. ■

Dacă o euristică H generează o secvență $(\sigma(1), \dots, \sigma(n))$, atunci timpul de execuție maxim al euristicii H este:

$$C_{\max}^H = r_{\sigma(u)} + \sum_{i=u}^v a_{\sigma(i)} + \sum_{i=v}^n b_{\sigma(i)}, \quad (5.3)$$

pentru anumiți $u, v \in \{1, 2, \dots, n\}$, unde $u \leq v$, și u este ales cât mai mic posibil.

În continuare se prezintă performanțele celor patru euristici în cel mai rău caz. Fie C_{\max}^* valoarea minimă a timpului maxim de încheiere a unei procesări.

Teorema 5.16. $C_{\max}^{ARB}/C_{\max}^* < 3$, $C_{\max}^R/C_{\max}^* < 2$, $C_{\max}^J/C_{\max}^* < 2$ și $C_{\max}^{RJ}/C_{\max}^* < 2$; aceste margini sunt cele mai bune posibil.

Demonstrație. De fiecare dată, se presupune că secvența generată este $(\sigma(1), \sigma(2), \dots, \sigma(n))$ și timpul maxim de execuție este dat de (5.3). Evident că C_{\max}^* este mai mare decât orice timp de accesibilitate, adică:

$$C_{\max}^* > r_{\sigma(u)}. \quad (5.4)$$

Timpul necesar pentru procesarea activităților $\{\sigma(u), \sigma(u+1), \dots, \sigma(v)\}$ pe mașina A satisface inegalitatea:

$$C_{\max}^* > \sum_{i=u}^v a_{\sigma(i)}. \quad (5.5)$$

În mod analog, timpul necesar pentru procesarea activităților $\{\sigma(u), \sigma(u+1), \dots, \sigma(v)\}$ pe mașina B satisface inegalitatea:

$$C_{\max}^* > \sum_{i=u}^v b_{\sigma(i)}. \quad (5.6)$$

Pentru euristică ARB , însumând (5.4), (5.5) și (5.6) și ținând seama de (5.3) rezultă $3C_{\max}^* > C_{\max}^{ARB}$. Pentru euristici R și RJ , valoarea minimă a timpului de accesibilitate a activităților $\{\sigma(u), \sigma(u+1), \dots, \sigma(v)\}$ este $r_{\sigma(u)}$. Rezultă că:

$$C_{\max}^* > r_{\sigma(u)} + \sum_{i=u}^v a_{\sigma(i)}. \quad (5.7)$$

Adunând (5.6) cu (5.7) și ținând seama de (5.3), rezultă $2C_{\max}^* > C_{\max}^R$ și $2C_{\max}^* > C_{\max}^{RJ}$.

În euristica J , activitățile din $\{\alpha(u), \alpha(u+1), \dots, \alpha(v)\}$ sunt ordonate în conformitate cu regula lui Johnson. Timpul maxim de execuție, ignorând timpii de accesibilitate, satisface inegalitatea:

$$C_{\max}^* > \sum_{i=u}^v a_{\alpha(i)} + \sum_{i=u}^v b_{\alpha(i)}. \quad (5.8)$$

Adunând (5.4) și (5.8) și ținând seama de (5.3), rezultă $2C_{\max}^* > C_{\max}^J$. Faptul că limitele date sunt cele mai mici posibile rezultă din următorul exemplu. ■

Exemplul 5.18. Fie problema cu trei lucrări specificată cu datele din tabelul 5.4., unde $0 < 8k < K$.

i	1	2	3
r_i	k	0	$K-3k$
a_i	$2k$	$K-6k$	k
b_i	$K-6k$	k	$2k$

Tabelul 5.4.

Pentru secvența (1,2,3) rezultă timpul de execuție $K=C_{\max}^*$. Într-adevăr, lucrarea 3 are timpul de accesibilitate $K-3k$ și timpul de execuție este $a_3+b_3=3k$, deci încheierea procesării lucrărilor nu poate fi mai mică decât $K-3k+3k=K$. Dacă lucrările sunt ordonate arbitrar în ordinea (3,2,1) se obține $C_{\max}^{ARB}=3K-12k$, deci $C_{\max}^{ARB}/C_{\max}^*=3-12k/K$ și are o valoare oricât de apropiată de 3. Pentru euristicile R și RJ se obține secvența (2,1,3) pentru care $C_{\max}^R=C_{\max}^{RJ}=2K-8k$, deci $C_{\max}^R/C_{\max}^*=C_{\max}^{RJ}/C_{\max}^*=2-8k/K$ și are o valoare oricât de apropiată de 2. Euristica J generează secvența (3,1,2) cu $C_{\max}^J=2K-5k$, deci $C_{\max}^J/C_{\max}^*=2-5k/K$ și are o valoare oricât de apropiată de 2. ■

Pentru euristica RJ există două cazuri pentru care abaterea maximă de la valoarea optimală este mai mică decât 0.5.

Lema 5.5. Dacă $a_{\alpha(i)} \leq b_{\alpha(i)}$, pentru $i = u, u + 1, \dots, v$ sau dacă $a_{\alpha(i)} \geq b_{\alpha(i)}$, pentru $i = v, v + 1, \dots, u$, atunci $C_{\max}^{RJ} / C_{\max}^* < 3/2$.

Demonstrație. Pentru secvența $\{\alpha(u), \alpha(u+1), \dots, \alpha(v)\}$ timpii de procesare ai lucrărilor pe mașinile A și B satisfac respectiv condițiile:

$$C_{\max}^* > r_{\alpha(u)} + \sum_{i=u}^v a_{\alpha(i)} \text{ și} \quad (5.9)$$

$$C_{\max}^* > r_{\alpha(v)} + \sum_{i=v}^u b_{\alpha(i)}. \quad (5.10)$$

Scăzând (5.10) din (5.3), rezultă că:

$$C_{\max}^{RJ} - C_{\max}^* < \sum_{i=u}^v a_{\alpha(i)} - \sum_{i=u}^{v-1} b_{\alpha(i)}. \quad (5.11)$$

Dacă $a_{\alpha(i)} \leq b_{\alpha(i)}$, pentru $i = u, u + 1, \dots, v$, atunci din (5.11) rezultă că:

$$C_{\max}^{RJ} - C_{\max}^* < a_{\sigma(v)} \leq 1/2 (a_{\sigma(v)} + b_{\sigma(v)}) \leq 1/2 C_{\max}^*,$$

deci $C_{\max}^{RJ} / C_{\max}^* < 3/2$. Scăzând (5.9) din (5.3) rezultă că:

$$C_{\max}^{RJ} - C_{\max}^* < \sum_{i=v}^u b_{\sigma(i)} - \sum_{i=v+1}^u a_{\sigma(i)}.$$

Dacă $a_{\sigma(i)} \geq b_{\sigma(i)}$, pentru $i = v, v + 1, \dots, u$, atunci din (5.11) rezultă că:

$$C_{\max}^{RJ} - C_{\max}^* < b_{\sigma(v)} \leq 1/2 (a_{\sigma(v)} + b_{\sigma(v)}) \leq 1/2 C_{\max}^*,$$

deci $C_{\max}^{RJ} / C_{\max}^* < 3/2$. ■

Există o euristică îmbunătățită pentru care $C_{\max}^{RJ} / C_{\max}^* < 5/3$.

Exemplul 5.19. Cu datele din exemplul 5.18., pentru succesiunea (2, 1, 3), calculele se efectuează după cum urmează:

$$u = 1, v = 1: C_{\max}^H = 0 + \sum_{i=1}^1 a_{\sigma(i)} + \sum_{i=1}^3 b_{\sigma(i)} = 0 + K - 6k + K - 6k + 2k + k = 2K - 9k,$$

$$u = 1, v = 2: C_{\max}^H = 0 + \sum_{i=1}^2 a_{\sigma(i)} + \sum_{i=2}^3 b_{\sigma(i)} = 0 + K - 6k + 2k + K - 6k + 2k = 2K - 8k,$$

$$u = 1, v = 3: C_{\max}^H = 0 + \sum_{i=1}^3 a_{\sigma(i)} + \sum_{i=3}^3 b_{\sigma(i)} = 0 + K - 6k + 2k + k + 2k = K - k,$$

maximul având loc pentru $u = 1, v = 2$. Programarea este arătată în figura 5. ■




Figura 5.18.

5.2.3.1.4. Algoritm euristic pentru procesare pe mai multe procesoare

Punerea problemei. Fiind date n lucrări ce urmează a fi executate pe m procesoare, ocupate în aceeași ordine, timpul de execuție a lucrării i pe procesorul j fiind t_{ij} , $i = 1, 2, \dots, n; j = 1, 2, \dots, m$, se cere determinarea ordinii în care cele n lucrări trebuie executate pe cele m mașini astfel încât timpul total de lucru să fie minim.

Fie σ o secvență parțială conținând $k < n$ lucrări, o lucrare a și σa :zultatul concatenării lui a cu σ . Atunci, folosind ipotezele menționate în [BAK69], relația recursivă pentru timpul de execuție a secvenței parțiale σa de lungime $k + 1$ pe mașina j , notat $T(\sigma a, j)$, este:

$$T(\sigma a, j) = \max [T(\sigma, j); T(\sigma a, j - 1)] + t_{aj}, \tag{5.12}$$

unde:

$$T(\emptyset, j) = T(\sigma, 0) = 0, \text{ pentru toți } \sigma \text{ și } j.$$

Problema planificării constă în minimizarea lui $T(\sigma(a, j))$, unde a parcurge toate lucrările și σ parcurge toate secvențele posibile de $n-1$ lucrări diferite de lucrarea a . ■

Problema planificării lucrărilor este interpretată drept un caz complex de sortare a n obiecte astfel încât să se asigure minimizarea funcției $f(t_{11}, t_{12}, \dots, t_{nm})$ a timpului de lucru. Dificultatea problemei echivalente de sortare constă în faptul că o asemenea funcție nu poate fi definită fără cunoașterea secvențelor anterioare și posterioare ale fiecărei lucrări. După cum se arată în lucrările [DUD64] și [PAG61], pentru cazul a două procesoare, funcția $f(i)$ asociată lucrării i are forma:

$$f(i) = A / \min(t_{i1}, t_{i2}), \text{ unde } A = 1 \text{ dacă } t_{i2} \leq t_{i1} \text{ și } A = -1 \text{ altfel.}$$

Pentru cazul a trei procesoare, studiat de Johnson [JOH54], atunci când:

$$t_{a2} \leq \min_{1 \leq b \leq n} (t_{b1}, t_{b3}),$$

funcția $f(i)$ are forma:

$$f(i) = A / \min_{1 \leq j \leq 2} (t_{ij} + t_{ij+1}), \text{ unde } A = 1 \text{ dacă } t_{i3} \leq t_{i1} \text{ și } A = -1 \text{ altfel.}$$

Problema planificării, în cazul a două sau trei procesoare, este echivalentă cu problema sortării a n numere astfel încât $f(a_1) \leq f(a_2) \leq \dots \leq f(a_n)$, unde a_i reprezintă lucrarea de pe locul i . Pentru cazul a mai mult de trei procesoare se propune o generalizare a funcției $f(i)$ definită astfel:

$$f(i) = A / \min_{1 \leq j \leq m-1} (t_{ij} + t_{ij+1}), \text{ unde } A = 1 \text{ dacă } t_{im} \leq t_{i1} \text{ și } A = -1 \text{ altfel.} \quad (5.13)$$

Algoritmuluristic propus este:

Algoritmul 5.13. (Johnson generalizat)

1. [Calcul funcție] Pentru fiecare lucrare i se calculează $f(i)$ definit prin (5.13).
2. [Ordonare] Se ordonează lucrările în ordinea crescătoare a valorilor $f(i)$, în cazul egalității $f(i) = f(i+1)$, acordând prioritate lucrării pentru care suma timpilor de lucru pe toate procesoarele este mai mică.
3. [Calcul timp] Se calculează timpul necesar efectuării lucrărilor utilizând (5.12). ■

Exemplul 5.20. Pentru ilustrarea euristicii propuse, se consideră următorul exemplu cu patru lucrări și cinci procesoare timpii de lucru fiind dați în tabelul 5.5.

$i \backslash j$	1	2	3	4	5
1	4	3	7	2	8
2	3	7	2	8	5
3	1	2	4	3	7
4	3	4	3	7	2

Tabelul 5.5.

Pentru acest exemplu, valorile $f(i)$ sunt: $f(1) = -1/7, f(2) = -1/9, f(3) = -1/3, f(4) = 1/7$. Rezultă secvența 3124 a lucrărilor. Utilizând relația (5.12) rezultă că timpul de lucru este egal cu 34 de unități. Soluția optimală este definită de secvența 3412 și necesită un timp de lucru egal cu 33 de unități. ■

Pe baza testărilor efectuate pe mai multe exemple, rezultă că euristica propusă furnizează soluții aproape optimale sau optimale în majoritatea cazurilor.

Se poate demonstra că euristica propusă de Palmer [PAL65] se bazează pe analogia, menționată de Page [PAG61], dintre problemele de sortare și planificare. Dacă t_{ij} este timpul necesar lucrării i pe procesorul $j, i = 1, 2, \dots, n, j = 1, 2, \dots, m$, Palmer a propus ordonarea lucrărilor în ordinea descrescătoare a $s(i)$, unde:

$$s(i) = 1/2 (-(m-1) t_{i1} - (m-3) t_{i2} + \dots + (m-3) t_{i,m-1} + (m-1) t_{im}) = 1/2 \sum_{j=1}^m (2j-m-1) t_{ij}.$$

Pentru a considera problema planificării drept o problemă de sortare, Page a propus o funcție $f(i)$ astfel încât lucrările să fie parcurse în ordinea crescătoare a valorilor acestei funcții. Funcția propusă este:

$$f(i) = -2 s(i) = \sum_{j=1}^m (m-2j+1) t_{ij}.$$

Exemplul 5.21. Figura 5.19. ilustrează soluția furnizată de euristică pentru datele din exemplul 5.20.




Fig. 5.19.

Segmentele ce corespund valorilor t_{ij} pentru $i = 1$ și $i = 3$ sunt desenate cu linii pline și celelalte, pentru $i = 2$ și $i = 4$, sunt desenate cu linii punctate. ■

5.2.3.1.5. Euristici bazate pe indicele de înclinare

Punerea problemei. Fiind date n lucrări și m procesoare, se cere identificarea ordinei în care urmează să fie parcurse cele n lucrări în vederea minimizării timpului de execuție. Timpul de ocupare a procesorului j de lucrarea i se notează cu t_{ij} . ■

Dacă ordonarea lucrărilor pe fiecare procesor este aceeași, soluția optimă se obține pentru una din cele $n!$ ordonări inițiale, a căror enumerare necesită un timp exponențial, fapt ce justifică utilizarea metodelor euristice de rezolvare a problemei.

Două margini inferioare, obținute pe calea inspecției diferitelor situații, sunt date în continuare, dar este puțin probabilă atingerea lor pentru valori mari ale lui n și m .

- a. Timpul total nu este mai mic decât: (timpul total pe procesorul j) + (timpul pe procesoarele 1 până la $j - 1$ a lucrării i_1) + (timpul pe procesoarele $j + 1$ până la n a lucrării i_2), pentru toți j și în ipoteza că i_1 și i_2 reprezintă prima și ultima lucrare, fiind diferite între ele și fiind alese în așa fel încât să minimizeze suma ultimilor doi termeni. Se presupune, de asemenea, că nu există intervale de timp neocupate în etapele lui i_1 ce preced începutul lucrului pe procesorul j , în timpul lucrului procesorului j și în etapele lui i_2 ce succed încheierii lucrului pe procesorul j .
- b. Timpul total nu este mai mic decât: (timpul total pentru lucrarea i) + (suma timpilor minimali pe procesorul 1 și procesorul m consumați pentru celelalte lucrări), pentru toate valorile lui i . Această margine presupune că nu există întreruperi în procesarea lucrării i ; lucrările cu timp de lucru mai mic pe procesorul 1 decât pe procesorul m sunt considerate înaintea lucrării i și celelalte după i , astfel încât timpul consumat înaintea și după procesarea lucrării i este redus la minimum.

Dacă unele dintre t_{ij} sunt nule, atunci lucrările cu $t_{i,j}$ și $t_{i,j}$ nule trebuie excluse în cazul marginii a.. Trebuie de asemenea avută în vedere posibilitatea schimbării ordinii lucrărilor ce afectează marginea b..

Definițiile celor două margini inferioare sunt ilustrate pe figurile 5.20.a) și b).




Fig. 5.20.

Euristica propusă utilizează noțiunea de *indice de înclinare (slope index)* în care principiul de bază este: "Se acordă prioritate activităților ce au cea mai mare tendință de trecere de la timpii de lucru mici la timpii de lucru mari în ordinea încărcării pe procesoare". Pentru fiecare activitate i se poate utiliza un *indice de înclinare* definit prin:

$$S_i = - (m - 1) t_{i1} - (m - 3) t_{i2} - \dots + (m - 3) t_{i,m-1} + (m - 1) t_{im}.$$

În această formulă ponderile asociate timpilor de lucru pe procesoare sunt determinate prin metoda celor mai mici pătrate plecând de la o aproximare liniară a timpilor în raport cu indicele procesorului. Activitățile sunt procesate în ordinea descrescătoare a indicelui S_i .

Această aproximare favorizează evident apropierea de marginile a. și b. de mai sus. O argumentare neriguroasă este ilustrată pe figura 5.21. Blocurile 1,2,3 reprezintă, respectiv, lucrări cu timp de procesare crescător, uniform și descrescător. Ele pot fi cuplate mai economic, din punct de vedere al timpului de lucru total, în ordinea 1,2,3.

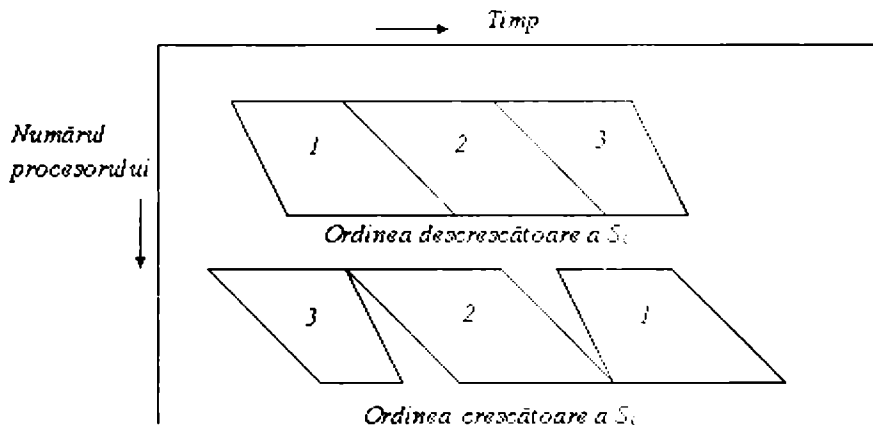


Fig. 5.21.

Rezultatele obținute în urma comparării soluțiilor obținute cu ajutorul euristicii propuse și cele optimale arată că diferența timpilor de lucru este cel mult de 10% din timpul optimal.

Rezultate mai bune se pot obține considerând indicii de înclinare ce utilizează ponderi asociate timpilor de lucru pe procesoare care sunt determinate prin metoda celor mai mici pătrate plecând de la o aproximare parabolică a timpilor în raport cu indicii procesorului. Se obține astfel pentru S_i expresia următoare:

$$S_i = \sum_{j=1}^m (6j^2 - 6j(m+1) + m+2)t_{ij}$$

Avantajul împachetării parabolice în ordinea descrescătoare a valorilor S_i este evident.

5.2.3.1.6. Planificarea pe procesoare cu viteze diferite

Punerea problemei. Se studiază problema procesării a n activități independente pe m procesoare de viteze diferite. Procesoarele sunt nepreferențiale, în sensul că nu există noțiunea de procesor rapid sau lent. ■

Un sistem de n activități și m procesoare este o matrice $n \times m$, notată μ , cu elemente din mulțimea $\mathbb{R}^+ \cup \{\infty\}$, pentru $n, m \geq 1$, astfel încât pentru fiecare i există un j astfel încât $\mu(i, j) \neq \infty$, $i=1, 2, \dots, n$. Valoarea $\mu(i, j)$ este timpul consumat de activitatea i pe procesorul j , pentru $i=1, 2, \dots, n, j=1, 2, \dots, m$. O funcție de asignare $A: \{1, 2, \dots, n\} \rightarrow \{1, 2, \dots, m\}$ satisface condițiile $\mu(i, A(i)) \neq \infty$, pentru $i=1, 2, \dots, n$. Funcția $s: \{1, 2, \dots, n\} \rightarrow \mathbb{R}$, numită funcție de start, satisface condițiile:

- Pentru orice $j = 1, 2, \dots, m$ cel mult o activitate este executată la un moment oarecare pe procesorul j .
- Pentru orice $j = 1, 2, \dots, m$, dacă $0 \leq x < \sum_{i: A(i)=j} \mu(i, j)$ măcar o activitate a fost executată la momentul x pe procesorul j .

Intuitiv, prima condiție exprimă faptul că toate activitățile asignate unui procesor sunt executate secvențial și a doua condiție previne perioadele neocupate pe procesori.

O activitate i este executată pe procesorul j la momentul x dacă $x = A(i)$ și $s(i) \leq x < s(i) + \mu(i, j)$. Timpul de încheiere al activității i este definit prin:

$$f(i) = s(i) + \mu(i, A(i)).$$

Matricea μ asociază m durate posibile pentru fiecare activitate. Cea mai bună durată pentru activitatea i , notată $b(i)$ este $b(i) = \min_j \{\mu(i, j)\}$. Eficiența procesorului j pentru activitatea i este definită astfel: $ef(i, j) = b(i) / \mu(i, j)$. Timpul de încheiere a unei asignări A , notat $f(A)$ este definit de:

$$f(A) = \max_{1 \leq j \leq m} \sum_{i: A(i)=j} \mu(i, j).$$

Algoritmul descris în continuare generează o asignare A și o funcție de start s pentru un sistem μ de sarcini. În cadrul algoritmului se construiește câte o listă separată a sarcinilor pentru fiecare procesor, în vederea reflectării eficienței lui pentru diferite activități. Dacă un procesor nu este destul de eficient pentru următoarea activitate din listă, atunci el este desactivat.

Algoritmul 5.14. (Asignare)

- [Calcul b] Pentru $i = 1, 2, \dots, n$, se calculează $b(i) = \min_{j=1, \dots, m} \mu(i, j)$.
- [Calcul ef] Pentru $i = 1, 2, \dots, n, j = 1, 2, \dots, m$, se calculează $ef(i, j) = b(i) / \mu(i, j)$.
- [Inițializări] Pentru $j=1, 2, \dots, m$ se construiește o listă de sarcini $i=1, 2, \dots, n$ sortate în ordine nedescrescătoare a valorilor $ef(i, j)$. Se face $sum_j = 0$, pentru $j=1, 2, \dots, m$ (sum_j este timpul de încheiere pe procesorul j a activităților atribuite până la un anumit moment). Se declară toate procesoarele ca fiind "active" și toate activitățile ca "neasignate".
- [Terminare] Dacă toate activitățile sunt asignate, atunci STOP.
- [Alegere procesor] Se alege un procesor j astfel încât sum_j este minimă pentru procesoarele active.

6. [Alegere activitate] Se alege următoarea activitate neasignată din lista j a activităților. Dacă nu mai există o astfel de activitate sau dacă $ef(i, j) < 1 / \sqrt{m}$, atunci se marchează j ca inactiv, altfel se definește $A(i) = j$, se notează i ca fiind asignată, se definește $s(i) = sum_j$ și se face $sum_j = sum_j + \mu(i, j)$.

7. [Ciclare] Se trece la pasul 4. ■

Se poate demonstra că eficiența algoritmului 5.14. este dată de relația:

$$f(A) / f(B) \leq 2.5 \sqrt{m} + 1 + 1 / (2\sqrt{m}),$$

unde $f(B)$ este timpul de încheiere a unui algoritm optimal.

În continuare vom prezenta alte variante îmbunătățite ale algoritmului 5.14.

Algoritmul 5.15. (Asignare îmbunătățită)

În pasul 3 al Algoritmului 5.14 se face precizarea că, dacă $ef(i, j) = ef(k, j)$, atunci i este procesată înainte de k dacă $\mu(i, j) \geq \mu(k, j)$; restul rămâne neschimbat. ■

Se poate demonstra că eficiența algoritmului 5.15. este dată de relația:

$$f(A) / f(B) \leq (1 + \sqrt{2})\sqrt{m} + 2 + 1 / (\sqrt{8}\sqrt{m}).$$

Algoritmul 5.16. (Asignare performantă)

- [Soluție inițială] Se determină o asignare A_1 și funcția de start s utilizând Algoritmul 5.14.
- [Reformulare] Fie u activitatea cu ultim timp de start în s și $U = \{i: f(i) > s(u)\}$.
- [Optimizare] Se determină o asignare optimală pentru mulțimea U , considerată ca sistem de activități, încercând toate asignările posibile. Se asignează fiecare activitate din U procesorului ce îi este atribuit în această asignare optimală, activitățile din U fiind asignate a fi procesate după activitățile ce nu aparțin lui U care au fost deja asignate. ■

Se poate demonstra că eficiența algoritmului 5.15. este dată de relația:

$$f(A) / f(B) \leq 1.5 \sqrt{m} + 2 + 1 / (2\sqrt{m}).$$

Algoritmul 5.17. (Asignare cu subintervale)

Fie parametrul $\delta = 1/m^r$ pentru un r dat. În pasul 3 din Algoritmul 5.14. se înlocuiește sortarea activităților după eficiență cu următorii pași: Se împarte intervalul $[0,1]$ în k subintervale $[0, 1/\sqrt{m})$, $[1/\sqrt{m}, (1+\delta)/\sqrt{m})$, $[(1+\delta)/\sqrt{m}, (1+2\delta)/\sqrt{m})$, ..., $[(1+k\delta)/\sqrt{m}, 1)$, unde $k \approx (\sqrt{m} / \delta) = m^{r+1/2}$. Se consideră fiecare dintre eficiențe $ef(i, j)$ drept un element al unui subinterval. Pentru fiecare procesor j se sortează activitățile în ordinea necrescătoare a subintervalului la care aparțin. ■

Se poate demonstra că eficiența algoritmului 5.17. este dată de relația:

$$f(A) / f(B) \leq \left(\frac{5-4\delta}{2(1-\delta)} \right) \sqrt{m} + \frac{1}{1-\delta} + \frac{1}{2\sqrt{m}(1-\delta)}.$$

O altăuristică este dată de algoritmul următor:

Algoritmul 5.18. (*Asignare eficientă*)

1. [Inițializare] Se face $sum_j = 0$, pentru $j = 1, 2, \dots, m$ și $S = \{1, 2, \dots, n\}$.
2. [Terminare] Dacă $S = \emptyset$, atunci STOP.
3. [Prelucrare] Se determină un indice $i \in S$ astfel încât $\min_j \{sum_j + \mu(i, j)\} \leq \min_j \{sum_j + \mu(i', j)\}$, pentru toți $i' \in S$. Fie j astfel încât $sum_j + \mu(i, j)$ este minimă. Se definește $A(i) = j$. Se face $sum_j = sum_j + \mu(i, j)$ și $S = S - \{i\}$.
4. [Ciclare] Se trece la pasul 2. ■

Ideea de bază a algoritmului 5.18. este următoarea. După ce k activități au fost procesate, se încearcă procesarea încă a unei activități și minimizarea timpului de încheiere, pe calea alegerii activității și a procesorului căruia îi este asignată. Algoritmul se încheie după reluarea de n ori a pasului 3.

Problema eficienței algoritmului 5.18. este o problemă deschisă.

Menționăm un algoritm foarte simplu care, de fapt, generalizează algoritmi precedenți la situația în care există o relație de precedență. În acest caz un procesor poate fi neocupat cât timp condiția de precedență nu este satisfăcută. Timpul de încheiere al unei procesări depinde în mare măsură de ordinea procesării activităților.

Acest algoritm naiv constă în asignarea fiecărei activități unui procesor ce are eficiența 1 pentru activitatea considerată. Deoarece în acest caz general există o relație de precedență, unele procesoare pot fi temporar neocupate, dar nu există momente la care toate procesoarele să fie neocupate.

Se poate demonstra că eficiența algoritmului precedent este dată de relația:

$$f(B) / f(A) \leq m.$$

5.2.3.2. Metode de planificare pe bază de listă

Deoarece există situații în care timpii de execuție ai activităților nu sunt cunoscuți dinainte, este motivată considerarea unui mod de planificare care folosește lista activităților și constrângerile la care sunt supuse acestea. O planificare pe bază de liste, notată prescurtat *PL*, se poate descrie în felul următor: De fiecare dată când un procesor devine liber, se planifică la execuție pe acest procesor prima activitate din listă care nu a fost planificată și pentru care toți predecesorii au fost executați, dacă există o astfel de activitate. Lista de activități se alcătuiește, de cele mai multe ori, în ordinea dată de o lege de prioritate impusă de problema dată.

Exemplul 5.22. Să considerăm 9 activități cu timpii de execuție $t_1=3, t_2=t_3=t_4=2, t_5=t_6=t_7=t_8=4, t_9=9$, activitatea 1 precede pe 9 și activitatea 4 precede pe 5,6,7 și 8. Considerând lista $L=(1,2,3,4,5,6,7,8,9)$ se obține, pentru un sistem cu 3 procesoare, planificarea din figura 5.22. de durată totală 12. ■




Fig. 5.22

Planificarea *LPT* (vezi paragraful 1.1.2.3.1) este un caz particular de programare pe bază de listă, în care lista de priorități este dată de ordinea necrescătoare a timpilor de execuție.

Euristicile bazate pe programarea cu liste pot să producă unele anomalii pe care le vom exemplifica în continuare. Durata totală a unei planificări depinde în cea mai mare parte de numărul de procesori disponibili, de timpul de execuție al fiecărei activități, de constrângerile de precedență și de prioritățile atribuite activităților.

Dacă numărul procesoarelor crește, este de așteptat obținerea unei soluții mai bune. Exemplul următor arată că această regulă nu se poate aplica în toate cazurile.

Exemplul 5.23. Să considerăm datele din exemplul 5.22. cu singura deosebire că în loc de 3 procesori se pot folosi 4 procesori. Aplicarea euristicii pe bază de listă produce, în acest caz, planificarea din figura 5.23. de durată totală 15, deci mai mare decât cea din figura 5.22. pentru numai 3 procesoare. ■




Fig. 5.23.

Dacă timpii de execuție se micșorează, se așteaptă obținerea unei soluții mai bune. Exemplul următor arată că această regulă nu se poate aplica în toate cazurile.

Exemplul 5.24. Să considerăm datele din exemplul 5.22. cu singura deosebire că fiecare din timpii de execuție se micșorează cu o unitate. Aplicarea euristicii pe bază de listă produce, în acest caz, planificarea din figura 5.24. de durată totală 13, deci mai mare decât cea din figura 5.22. cu timpi mai mari de execuție. ■




Fig. 5.24

Dacă sunt eliminate unele dintre constrângerile de precedență, este de așteptat obținerea unei soluții mai bune, mulțimea soluțiilor posibile fiind mai numeroasă. Exemplul următor arată că această regulă nu se poate aplica în toate cazurile.

Exemplul 5.25. Să considerăm datele din exemplul 5.22. cu singura deosebire că activitatea 4 nu mai trebuie să preceadă activitățile 5 și 6. Aplicarea euristicii pe bază de listă produce, în acest caz, planificarea din figura 5.25. de durată totală 16, deci mai mare decât cea din figura 5.22. cu mai multe constrângeri. ■

P1	1			6								9					
P2	2		4			7											
P3	3			5				8									
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16

Fig. 5.25.

Dacă se fac unele modificări în listă care se par că aduc avantaje planificărilor, este de așteptat obținerea unei soluții mai bune. Exemplul următor arată că această regulă nu se poate aplica în toate cazurile.

Exemplul 5.26. Să considerăm datele din exemplul 5.22. cu singura deosebire că în loc de lista L se folosește lista $L'=(1,2,4,5,6,3,9,7,8)$, făcând ca activitatea 3 care nu mai are succesori să fie de o prioritate mai mică decât activitatea 4 care are succesori și atribuind activității 9 care are o durată mare de execuție o prioritate mai mare, sugerată de *LPT*. Aplicarea euristicii pe bază de listă produce, în acest caz, planificarea din figura 5.26. de durată totală 14, deci mai mare decât cea din figura 5.22. care pare să se facă folosind o listă mai puțin eficientă. ■

P1	1			3								9			
P2	2			5				7							
P3	4			6				8							
	0	1	2	3	4	5	6	7	8	9	10	11	12	13	14

Fig. 5.26.

5.2.3.2.1. Margini pentru anomaliiile din multiprocesare

Fie date m procesoare $P_j, j = 1, \dots, m$, și o mulțime de activități $A = \{1, \dots, n\}$ ce urmează a fi atribuite procesoarelor P_j , timpul de procesare al sarcinii i fiind t_i .

Algoritmul 5.19. (Programare euristică)

- [Problema redusă] Se determină o soluție optimă pentru un număr $k \geq 0$ dintre sarcinile cu cei mai mari timpi de procesare, soluția obținută fiind o listă L .
- [Completare] Se adaugă la lista L , într-o ordine arbitrară, cele $n - k$ sarcini rămase, noua listă obținută fiind notată $L(k)$. ■

Sistemul multiprocesor are următorul mod de operare. Dacă un procesor P_i a terminat de procesat o sarcină, el caută o nouă sarcină în lista L . Dacă o astfel de sarcină nu există, atunci P_i rămâne neocupat până ce un alt procesor P_j devine liber.

Teorema 5.17. Fie $\omega(k)$ timpul de încheiere al procesării listei $L(k)$ dată de algoritmul 5.20. și ω_0 timpul optimal necesar procesării mulțimii A ; atunci are loc următoarea inegalitate:

$$\frac{\omega(k)}{\omega_0} \leq 1 + \frac{1 - 1/m}{1 + [k/m]},$$

unde cu $[\cdot]$ este notată partea întreagă superioară a unui număr real. Această margine este cea mai bună pentru $k \equiv 0 \pmod{n}$.

Demonstrație. Fie ω_k soluția optimală furnizată de primul pas al algoritmului. Dacă $\omega(k) = \omega_k$, atunci $\omega(k) = \omega_0$ și teorema este verificată. Să presupunem că $\omega(k) > \omega_k$ și $r > k$. Fie $t^* = \max_{k+1 \leq i \leq n} \{t_i\}$. În virtutea definiției lui t^* și a modului de operare a sistemului multiprocesor, rezultă că nici un procesor nu poate fi neocupat înaintea timpului $\omega(k) - t^*$. Rezultă că:

$$\sum_{i=1}^n t_i \geq m(\omega(k) - t^*) + t^*$$

și prin urmare:

$$\omega_0 \geq \frac{1}{m} \sum_{i=1}^n t_i \geq \omega(k) - \left(\frac{m-1}{m}\right) t^*. \quad (5.14)$$

Există cel puțin $k+1$ sarcini A_i ce au o durată de cel puțin t^* . Prin urmare, un anumit procesor execută măcar $1 + [k/m]$ dintre aceste sarcini lungi. Rezultă că:

$$\omega_0 \geq \left(1 + \left[\frac{k}{m}\right]\right) t^*. \quad (5.15)$$

Din (5.14) și (5.15) se obține:

$$\omega(k) \leq \omega_0 + \left(\frac{m-1}{m}\right) t^* \leq \omega_0 \left(1 + \frac{m-1}{m} \cdot \frac{1}{1 + [k/m]}\right),$$

adică marginea enunțată în teoremă.

Pentru a demonstra că această margine este cea mai bună posibilă, pentru $k \equiv 0 \pmod{n}$, fie următorul exemplu. Se definește t_i , pentru $1 \leq i \leq k+1+m(m-1)$, în felul următor:

$$t_i = \begin{cases} m, & \text{pentru } 1 \leq i \leq k+1, \\ 1, & \text{pentru } k+2 \leq i \leq k+1+m(m-1). \end{cases}$$

Pentru aceste sarcini și lista $L(k) = (A_1, \dots, A_k, A_{k+2}, \dots, A_{k+1+m(m-1)}, A_{k+1})$, se obține $\omega(k) = k + 2m - 1$. Deoarece $\omega_0 = k + m$, se obține:

$$\frac{\omega(k)}{\omega_0} = \frac{k + 2m - 1}{k + m} = 1 + \frac{m-1}{k+m} = 1 + \frac{1-1/m}{1+k/m} = 1 + \frac{1-1/m}{1+[k/m]}.$$

Cu aceasta demonstrația teoremei este încheiată. ■

Cazuri particulare. Pentru $k = 0$:

$$\frac{\omega(0)}{\omega_0} \leq 2 - \frac{1}{m}.$$

Pentru $k = 2m$:

$$\frac{\omega(2m)}{\omega_0} \leq 1 + \frac{1-1/m}{1+[2m/m]} = \frac{4}{3} - \frac{1}{3m}.$$

Un alt caz particular este acela în care cele mai lungi $k = m$ sarcini sunt alocate câte una fiecăruia procesor, ceea ce furnizează o soluție optimală pentru ω_k . Dacă cele $n - m$ sarcini rămase sunt alese arbitrar, rezultă că:

$$\frac{\omega(m)}{\omega_0} \leq \frac{3}{2} - \frac{1}{2m}.$$

Exemplul 5.27. Pentru $n = 13$, $k = 6$, $m = 3$ și timpii de procesare:

$$t_i = \begin{cases} 3, & \text{pentru } 1 \leq i \leq 7, \\ 1, & \text{pentru } 8 \leq i \leq 13, \end{cases} \quad \omega(k) / \omega_0 = 1 + \frac{1-1/m}{1+[k/m]} = 1 + \frac{1-1/3}{1+2} = \frac{11}{9}.$$

Soluția furnizată de algoritm și cea optimală sunt date în figura 5.27. ■

P1	1		4	8	11	7						
P2	2		5	9	12							
P3	3		6	10	13							
	0	1	2	3	4	5	6	7	8	9	10	11

P1	1		4			7				
P2	2		5		8	10	12			
P3	3		6		9	11	13			
	0	1	2	3	4	5	6	7	8	9

Fig. 5.27.

O margine a efectelor date de anomaliile euristiciilor bazate pe liste este dată în următoarea teoremă.

Teorema 5.18. Fie un sistem S de n activități care trebuie planificate pe m procesori, cu timpii de execuție t_1, t_2, \dots, t_n , cu lista L și relația de precedență ρ . Fie un alt sistem S' cu n activități care trebuie planificate pe m' procesori, cu timpii de execuție p_1, p_2, \dots, p_n , cu lista L' și relația de precedență ρ' . Să presupunem că $p_i \leq t_i$, pentru $i=1, 2, \dots, n$, $\rho' \subseteq \rho$, timpul de planificare pe bază de listă a lui S este t și cel al lui S' este t' . Atunci are loc relația:

$$\frac{t'}{t} \leq 1 + \frac{m-1}{m'}.$$

O demonstrație a acestei teoreme se poate găsi în [BÂS89]. ■

Faptul că nu se poate determina o margine mai bună se poate vedea din exemplul următor.

Exemplul 5.28. Să considerăm un sistem cu $2m-1$ activități independente având timpii $t_i=1$, pentru $i=1, 2, \dots, m-1$, $t_i=m-1$, pentru $i=m, m+1, \dots, 2m-2$ și $t_{2m-1}=m$ care trebuie planificate pe m procesoare. Aplicând algoritmul de planificare pe bază de listă pentru lista $L=(1, 2, \dots, m-1, 2m-1, m, m+1, \dots, 2m-2)$ se obține planificarea din figura 5.28.a) de durată totală m , fiind planificarea optimală. Dacă se folosește drept listă $L'=(1, m, m+1, \dots, 2m-2, 2, 3, \dots, m-1, 2m-1)$, algoritmul de programare pe bază de listă dă planificarea din figura 5.28.b) de durată $2m-1$. Cum raportul celor două durate este $\frac{2m-1}{m} = 1 + \frac{m-1}{m}$, rezultă că marginea din teorema 5.18. este cea mai bună posibilă. ■




Fig. 5.28.

Se poate vedea că rezultatul din teorema 5.17 este un caz particular al rezultatului din teorema 5.18.

5.2.3.2.2. Activități cu timpi egali și precedente tip antiarborescențe

Fie un sistem A de n activități cu timpi de execuție egali, pentru care relația de precedență corespunde unui graf de tip antiarborescență. Vom considera, fără a micșora din generalitate, că unitatea de timp este timpul de execuție a unei activități

Vom spune că o activitate este *terminală* dacă nu are succesori. Numim *nivelul unui nod* lungimea maximă a unui drum de la nodul respectiv la un nod terminal.

Se poate construi o listă cu nodurile în ordinea necrescătoare a nivelurilor nodurilor aplicând următorul algoritm.

Algoritm 5.20. (Ordonare pe nivele)

1. [Inițializări] Se face $R = \{1, 2, \dots, n\}$ și $k = n + 1$.
2. [Terminare] Dacă R nu conține noduri terminale, atunci STOP. (Dacă $R \neq \emptyset$, graful conține cel puțin un ciclu și deci nu se poate face planificarea).
3. [Alegere] Se alege o activitate terminală i din R .
4. [Adăugare la listă] Se face $k = k - 1$, se pune activitatea i pe locul k în lista L , se elimină i din R și arcele care intră în i .
5. [Ciclare] Se merge la pasul 2. ■

Complexitatea algoritmului este $O(n)$.

Cu lista generată de algoritmul 5.20. se obține o planificare a activităților aplicând algoritmul următor.

Algoritm 5.21. (Planificare antiarborescență)

Când un procesor devine liber, se programează pe el prima activitate din listă care nu a fost programată și pentru care toți predecesorii direcți au fost executați. ■

Demonstrația faptului că algoritmul 5.21. construiește o soluție optimă poate fi găsită în [BĂS89].

5.2.3.2.3. Euristici bazate pe nivelurile nodurilor

Considerăm un sistem cu n activități supuse la o relație de precedență oarecare, activitatea i având timpul de execuție t_i .

Definim *nivelul* unui nod i , notat $niv(i)$, în modul următor: dacă i este nod terminal, adică fără succesori, atunci $niv(i)=t_i$, altfel $niv(i) = t_i + \max_{j \in S(i)} niv(j)$, unde $S(i)$ este mulțimea succesorilor direcți ai lui i .

Algoritmul 5.22. (Programare pe nivele)

Când un procesor devine liber, se programează pe el o activitate de nivel maxim dintre activitățile care nu au fost programate și pentru care toți predecesorii direcți au fost executați. ■

În cazul în care există mai multe activități cu același nivel se pot aplica diferite euristici de alegere cum ar fi:

- Se preferă o activitate de timp de execuție cât mai mare.
- Se preferă o activitate de timp de execuție cât mai mic.
- Se preferă o activitate cu cât mai mulți succesori direcți.
- Se alege la întâmplare oricare dintre ele.

Se pot da exemple prin care se arată că aceste euristici nu sunt comparabile.

Algoritmul 5.22. este de tip programare pe bază de listă dacă lista se alcătuiește în ordinea descrescătoare a nivelului asociat fiecărui nod, eventual ținând seama de euristica menționată în cazul când există noduri cu același nivel.

5.2.3.2.4. Programare optimală pentru doi procesori și timpi egali

Pentru cazul utilizării a doi procesori pentru programarea a n activități cu timpi de execuție egali se poate construi o numerotare a activităților care permite obținerea unei programări optimale. Numerotarea nodurilor se face aplicând algoritmul următor.

Algoritmul 5.23. (numerotare)

1. [Inițializări] Se etichetează toate activitățile terminale cu λ (cuvântul vid) și se face $k = 0$.
2. [Terminare] Dacă nu sunt noduri etichetate și nenumerotate, atunci STOP. (Dacă au rămas noduri nenumerotate, atunci graful asociat conține cel puțin un ciclu).
3. [Alegere] Se determină o activitate i etichetată și nenumerotată care are eticheta cea mai mică în raport cu ordinea lexicografică dintre toate nodurile de acest tip. Dacă sunt mai multe activități cu aceeași etichetă minimă se ia oricare dintre ele.
4. [Numerotare] Se face $k = k + 1$ și se numerotează activitatea i cu valoarea k .

5. [Etichetare] Fiecare dintre predecesorii direcți ai lui i care are toți succesorii numerotați se etichetează cu șirul numerelor asociate succesorilor lui direcți în ordine descrescătoare.
6. [Ciclare] Se merge la pasul 2. ■

Exemplul 5.29. Aplicând algoritmul 5.23. pentru sistemul cu 13 activități având graful de precedență din figura 5.29., mai întâi se etichetează activitățile 1 și 3 cu (). Se numerotează activitatea 1 cu 1 și se etichetează activitățile 2 și 5 cu (1). Se numerotează activitatea 3 cu 2 și se etichetează activitatea 4 cu (2). Se numerotează activitatea 5 cu 3 și nu se fac etichetări. Se numerotează activitatea 2 cu 4 și nu se fac etichetări. Se numerotează activitatea 4 cu 5 și se etichetează activitățile 7 cu (5,4,3) și 6 cu (5,4). Se numerotează activitatea 6 cu 6 și nu se fac etichetări. Se numerotează activitatea 7 cu 7 și se etichetează activitățile 8 cu (7) și 9 cu (7,6). Analog se numerotează și activitățile celelalte după ce au fost etichetate activitățile 10 cu (9,8), 11 cu (10), 12 cu (10) și 13 cu (10,6). Numerotarea obținută este dată în tabelul 5.6. ■




Fig. 5.29.

i	1	2	3	4	5	6	7	8	9	10	11	12	13
număr	1	4	2	5	3	6	7	8	9	10	11	12	13

Tabelul 5.6.

Lista se constituie luând activitățile în ordinea descrescătoare a numerelor asociate. Aplicând algoritmul de programare utilizând această listă se obține soluția optimă. Pentru demonstrarea acestei proprietăți a se vedea [BÂS89].

Exemplul 5.30. Cu datele din exemplul 5.29., aplicând algoritmul de programare prin liste se obține soluția din figura 5.30. de timp total 8. ■

P1	13	11	10	9	7	4	5	1	
P2	12			8	6	2	3		
	0	1	2	3	4	5	6	7	8

Fig. 5.30.

Prin relaxarea unor condiții se obțin din algoritmul precedent diferite euristici. Astfel planificarea pe un număr de $m > 2$ procesoare poate să nu genereze soluția optimală, după cum se vede din exemplul următor.

Exemplul 5.31. Pentru sistemul cu 12 activități cu timpi de execuție egali, cu graful de precedență din figura 5.31.a) (numerele de pe figură corespund celor obținute prin algoritmul de numerotare), planificate pe 3 procesoare, aplicând algoritmul de planificare pe bază de liste se obține planificarea din figura 5.31.b) de timp total 5. O planificare optimală este dată în figura 5.31.c) fiind de timp total 4. ■




Fig. 5.31.

Un alt mod de relaxare prin care se obține o euristică este cazul unor timpi diferiți. Din exemplul următor se vede că nu se determină mereu soluția optimală.




Fig. 5.32.

Exemplul 5.32. Pentru sistemul cu 5 activități cu timpi de execuție $t_1=t_2=t_4=t_5=1$ și $t_3=2$, cu graful de precedență din figura 5.32.a) (numerele de pe figură corespund celor obținute prin algoritmul de numerotare), planificate pe 2 procesoare, aplicând algoritmul de planificare pe bază de liste se obține planificarea din figura 5.32.b) de timp total 4. O planificare optimală este dată în figura 5.32.c) fiind de timp total 3. ■

5.3. Metode nepolinomiale de programarea activităților

În acest paragraf vom trata unele din metodele nepolinomiale de programarea activităților. Am considerat metodele acestea împărțite pe două tipuri: metode bazate pe programarea dinamică și metode arborescente.

5.3.1. Algoritmi bazați pe programarea dinamică

O primă clasă de metode de programare nepolinomială se bazează pe metoda programării dinamice. Această metodă permite determinarea soluției optimale. Vom trata două cazuri și anume tratarea prin programare dinamică a sistemelor cu activități independente și cea a activităților dependente.

5.3.1.1. Programarea activităților independente

Se consideră un sistem A cu n activități independente de durate t_1, t_2, \dots, t_n , disponibile la momentul 0, care trebuie să fie planificate pe un procesor. Se consideră funcțiile $\gamma_i: \mathbb{R}^+ \rightarrow \mathbb{R}^+$, care sunt funcții cost crescătoare, $\gamma_i(t)$ este costul ca activitatea i să se termine la momentul t . Dintre planificările posibile, se caută o planificare care minimizează expresia $\sum_{i \in A} \gamma_i(c_i)$, unde c_i este momentul în care se termină activitatea i în planificarea considerată.

În termeni de programare dinamică, problema precedentă se enunță astfel: starea la momentul k este $x(k) \subset A$, cu $x(0) = \emptyset$ și $x(n) = A$; $\Delta(x, k) = A - x$, $r_k(x, u) = \gamma_u(t_x + t_u)$, unde $u \in \Delta(x, k)$ și $t_x = \sum_{i \in x} t_i$ dacă $x \neq \emptyset$, altfel $t_x = 0$. Drept criteriu se poate lua $J = \sum r_k(x, u)$. Un exemplu de funcții γ_i este: $\gamma_i(t) = w_i$ dacă $t \leq d_i$, altfel $\gamma_i(t) = 0$, unde w_i este profitul obținut dacă activitatea i nu întârzie.

Soluționarea se poate face prin *recurență înapoi* sau prin *recurență înainte*. În recurența înapoi se calculează funcția f^* definită astfel:

$$f^*(A, n) = 0, f^*(x, k) = \max_{u \in A-x} \{ \gamma_u(t_x + t_u) + f^*(x \cup \{u\}, k+1) \}.$$

Analog, în recurența înainte se calculează funcția g^* definită astfel:

$$g^*(\emptyset, 0) = 0, g^*(x, k) = \max_{u \in x} \{ \gamma_u(t_x) + g^*(x - \{u\}, k-1) \}.$$

Complexitatea acestor metode de soluționare este $O(n 2^{n-1})$.

i	1	2	3	4
t_i	6	8	10	7
d_i	9	14	16	16
w_i	5	3	4	2

Tabelul 5.7.

Exemplul 5.33. Să considerăm un sistem cu 4 activități independente cu timpii de execuție t_i , termenele de predare d_i și profiturile w_i date în tabelul 5.7. În tabelul 5.8. sunt sintetizate calculele pentru recurența înapoi. Liniile, în afară de prima, corespund valorilor posibile pentru $x(k)$ menționate în prima coloană și coloanele reprezintă valorile calculate pentru aflarea lui f^* , cu menționarea celor doi termeni din formula dată, la diferitele alegeri pentru u . Se marchează cu X combinațiile care nu sunt valide. Penultima coloană este valoarea calculată pentru f^* și ultima coloană indică valorile lui u pentru care se obține valoarea lui f^* . Soluțiile se obțin astfel: din tabelul 5.8.d) rezultă o singură posibilitate pentru planificare și anume activitatea 1; din tabelul 5.8.c), pentru mulțimea $\{1\}$, se află o singură alegere și anume activitatea 3 este a doua planificată; din tabelul 5.8.b), pentru mulțimea $\{1,3\}$, sunt posibile două

alegeri și anume activitățile 2 și 4 pentru a le planifica pe al treilea loc; dacă se alege 2, din tabelul 5.8.a) urmează 4, obținând soluția (1,3,2,4), și dacă se alege 4, din tabelul 5.8.a) urmează 2, obținând soluția (1,3,4,2), ambele soluții obținute fiind optime, de valoare 9.

În mod analog, se pot face calculele pentru recurența înainte. Aceste calcule sunt sintetizate în tabelul 5.9. Soluțiile se obțin la fel ca mai sus, doar că parcurgerea programărilor se face de la sfârșit către început. ■

$x(3) \setminus u(3)$	1	2	3	4	$f'(x, 3)$	$v(x, 3)$
{1, 2, 3}	X	X	X	0+0	0	4
{1, 2, 4}	X	X	0+0	X	0	3
{1, 3, 4}	X	0+0	X	X	0	2
{2, 3, 4}	0+0	X	X	X	0	1

a) $k = 3$.

$x(2) \setminus u(2)$	1	2	3	4	$f'(x, 2)$	$v(x, 2)$
{1, 2}	X	X	0+0	0+0	0	3, 4
{1, 3}	X	0+0	X	0+0	0	2, 4
{1, 4}	X	0+0	0+0	X	0	2, 3
{2, 3}	0+0	X	X	0+0	0	2, 3
{2, 4}	0+0	X	0+0	X	0	1, 3
{3, 4}	0+0	0+0	X	X	0	1, 2

b) $k = 2$.

$x(1) \setminus u(1)$	1	2	3	4	$f'(x, 1)$	$v(x, 1)$
{1}	X	3+0	4+0	2+0	4	3
{2}	0+0	X	0+0	2+0	2	4
{3}	0+0	0+0	X	0+0	0	1, 2, 4
{4}	0+0	0+0	0+0	X	0	1, 2, 3

c) $k = 1$.

$x(0) \setminus u(0)$	1	2	3	4	$f'(x, 0)$	$v(x, 0)$
∅	5+4	3+2	4+0	2+0	9	1

d) $k = 0$.

Tabelul 5.8.

Se poate obține un algoritm mai eficient bazat pe următoarea proprietate.

Teorema 5.19. Există o planificare optimală astfel încât activitățile terminate la termenele fixate să se execute înainte de cele întârziate și în ordinea termenelor de predare. ■

$x(1) \setminus u(1)$	1	2	3	4	$g^*(x, 1)$	$w(x, 1)$
{1}	5	X	X	X	5	1
{2}	X	3	X	X	3	2
{3}	X	X	4	X	4	3
{4}	X	X	X	2	2	4

a) $k = 1$.

$x(2) \setminus u(2)$	1	2	3	4	$g^*(x, 2)$	$w(x, 2)$
{1, 2}	0 + 3	3 + 5	X	X	8	2
{1, 3}	0 + 4	X	4 + 5	X	9	3
{1, 4}	0 + 2	X	X	2 + 5	7	4
{2, 3}	X	0 + 4	0 + 3	X	4	2
{2, 4}	X	0 + 2	X	2 + 3	5	4
{3, 4}	X	X	0 + 2	0 + 4	4	4

b) $k = 2$.

$x(3) \setminus u(3)$	1	2	3	4	$g^*(x, 3)$	$w(x, 3)$
{1, 2, 3}	0 + 4	0 + 9	0 + 8	X	9	2
{1, 2, 4}	0 + 5	0 + 7	X	0 + 8	8	4
{1, 3, 4}	0 + 4	X	0 + 7	0 + 9	9	4
{2, 3, 4}	X	0 + 4	0 + 5	0 + 4	5	3

c) $k = 3$.

$x(4) \setminus u(4)$	1	2	3	4	$f^*(x, 4)$	$w(x, 4)$
{1, 2, 3, 4}	0 + 5	0 + 9	0 + 8	0 + 9	9	2, 4

d) $k = 4$.

Tabelul 5.9.

O mulțime de activități cu terminare în termenele fixate ale unei soluții optimale se numește *mulțime dominantă*. Pentru o mulțime x vom nota $\bar{i}(x) = \sum_{i \in x} t_i$ și

$\bar{w}(x) = \sum_{i \in x} w_i$. Are loc următoarea proprietate.

Teorema 5.20. Dacă $y_1, y_2 \subset \{1, 2, \dots, i\}$, $\bar{i}(y_1) \geq \bar{i}(y_2)$ și $\bar{w}(y_1) \leq \bar{w}(y_2)$, atunci orice soluție x_1 care restricționată la $\{1, 2, \dots, i\}$ furnizează drept rezultat pe y_1 este dominată de o soluție x_2 pentru care $y_2 \subset x_2$. ■

Algoritmul 5.24. (Programare dinamică)

O stare $x(i)$ corespunde la o submulțime din $\{1, 2, \dots, i\}$ nedominată de o stare a etapei i deja calculată cu algoritmul de activități la termen. Se consideră $x(0) = \emptyset$ și starea finală necunoscută. Mulțimea deciziilor $\Delta(x, i)$ se definește astfel: dacă are loc inegalitatea $\bar{i}(x) + t_{i+1} \leq d_i$, atunci se face $\Delta(x, i) = \{u_0, u_1\}$, altfel se face $\Delta(x, i) = u_1$ și $g(x, u_0, i) = x \cup \{i + 1\}$, $g(x, u_1, i) = x$. Criteriul de evaluare este $\bar{w}(x(n))$. ■

Complexitatea algoritmului este $O(nM)$, unde $M = \min(\bar{l}(A), \bar{w}(A))$.

Exemplul 5.34. Cu datele din exemplul 5.33., se obțin succesiv mulțimile $X_0 = \{\emptyset\}$, $X_1 = \{\emptyset, \{1\}\}$, $X_2 = \{\emptyset, \{1\}, \{1,2\}\}$, $X_3 = \{\emptyset, \{1\}, \{1,2\}, \{1,3\}\}$, $X_4 = \{\emptyset, \{1\}, \{1,2\}, \{1,3\}, \{1,4\}\}$. Dintre variantele găsite, cea de profit maxim este $\{1,3\}$, care conduce la cele două soluții $(1,3,2,4)$ și $(1,3,4,2)$ de profit 9. ■

5.3.1.2. Programarea activităților dependente

Pentru rezolvarea problemei în cazul activităților dependente prin programare dinamică se poate adapta algoritmul recursiv înainte sub forma următoare. În acest algoritm se consideră *mulțime inițială* mulțimea nodurilor fără predecesori și *mulțime terminală*, notată $s(x)$, mulțimea activităților din x fără succesori.

Algoritmul 5.25. (Programare dinamică)

- [Inițializări] Se face $f^*(\emptyset, 0) = 0$ și $k = 0$.
- [Terminare] Dacă toate valorile lui f^* au fost calculate, atunci STOP.
- [Calcul] Pentru un x și un k pentru care se pot defini elementele de calcul se face:

$$f^*(x, k) = \min_{u \in s(x)} \{ \gamma_u(t_x) + f^*(x - \{u\}, k - 1) \}.$$
- [Ciclare] Se merge la pasul 2. ■

5.3.2. Metode arborescente

5.3.2.1. Minimizarea sumei întârzierilor

Punerea problemei. Fiind dată mulțimea $A = \{1, 2, \dots, n\}$ de activități independente cu duratele de execuție t_1, t_2, \dots, t_n și termenele limită de predare d_1, d_2, \dots, d_n , să se determine ordinea de planificare a acestor activități pe un procesor astfel încât să se minimizeze $\sum_{i=1}^n T_i$ cu $T_i = \max\{0, c_i - d_i\}$, unde c_i este momentul terminării activității i în planificarea dată. ■

Folosirea metodei arborescente pentru rezolvarea acestei probleme se bazează pe următoarele proprietăți:

Teorema 5.21. Pentru orice submulțime $B = \{i_1, i_2, \dots, i_r\}$ de activități ale nodului S_σ care sunt programate în ordinea $\sigma = (i_r, i_{r-1}, \dots, i_1)$, aceste activități sunt terminate cel mai târziu la momentele: $c_{i_1} = \sum_{i=1}^n t_i$, $c_{i_2} = c_{i_1} - t_{i_1}$, ..., $c_{i_r} = c_{i_{r-1}} - t_{i_{r-1}}$. ■

Teorema 5.22. În aceleași condiții ca la teorema 5.21. valoarea:

$$F(\sigma) = \sum_{j=1}^r \max(c_{i_j} - d_{i_j}, 0)$$

este o evaluare prin lipsă a sumei întârzierilor. ■

Teorema 5.23. (de dominanță) Fie S_σ un nod al arborescenței și B mulțimea activităților acestui nod. Dacă există $k \notin B$ astfel încât $d_k > \sum_{i \in A-B} t_i$, atunci se poate înlocui S_σ cu $S_{k\sigma}$. ■

Teorema 5.24. (de dominanță) Fie S_{σ_1} cu activitățile B_1 și S_{σ_2} cu activitățile B_2 două noduri ale arborescenței astfel încât $B_1 \subset B_2$ și $F(\sigma_2) \leq F(\sigma_1)$; atunci se poate elimina nodul S_{σ_1} . ■

Algoritmul de determinare a unei soluții optimale este următorul:

Algoritmul 5.26. (Optimal)

- [Inițializări] Se consideră rădăcina arborescenței corespunzătoare succesiunii vide $\sigma = ()$, se face $\hat{f} = +\infty$ și $F(\sigma) = 0$.
- [Terminare] Dacă toate nodurile neeliminate au fost expandate, atunci STOP. Dacă $\hat{f} \neq +\infty$, atunci aceasta este valoarea optimală; altfel problema nu are soluție.
- [Alegere] Se alege un nod S_σ de valoare $F(\sigma)$ cât mai mică dintre nodurile neeliminate și neexpandate; dacă sunt mai multe cu aceeași valoare, se preferă un nod cu cât mai multe activități.
- [Expandare] Se expandează nodul S_σ introducând nodurile $S_{k\sigma}$, pentru orice $k \notin \sigma$.
- [Extindere] Pentru fiecare nod nou introdus S_σ și orice $k \notin \sigma$ astfel încât $d_k > \sum_{i \in A-\sigma} t_i$ se înlocuiește S_σ cu $S_{k\sigma}$.
- [Evaluare] Se evaluează valorile corespunzătoare noilor noduri introduse folosind formulele din teoremele 5.21. și 5.22.
- [Ajustare] Dacă pentru un nod terminal nou, care conține toate activitățile, valoarea calculată $F(\sigma)$ este mai mică decât \hat{f} , atunci se face $\hat{f} = F(\sigma)$.
- [Eliminare] Se elimină nodurile care au valoare mai mare sau egală cu \hat{f} sau cele pentru care există o supramulțime de valoare cel mult valoarea nodului respectiv (conform teoremei 5.24).
- [Ciclare] Se trece la pasul 2. ■

Exemplul 5.35. Fie $A = \{1,2,3,4,5\}$ cu timpii de execuție $t_1=4, t_2=3, t_3=7, t_4=2, t_5=2$ și termenele de predare $d_1=5, d_2=6, d_3=8, d_4=8$ și $d_5=17$. Se pleacă de la rădăcina S_0 de valoare 0 și cu $\hat{f}=+\infty$. Se alege pentru expandare nodul S_0 obținându-se noile noduri S_1, S_2, S_3, S_4 și S_5 . Pasul 5 permite înlocuirea primelor patru noduri respectiv prin S_{31}, S_{52}, S_{53} și S_{54} . Prin evaluare se obțin următoarele: $F(51)=13, F(52)=12, F(53)=10, F(54)=10$ și $F(5)=1$. Nu se poate aplica o ajustare și nici eliminări de noduri. Se alege pentru expandare nodul S_5 și se adaugă noile noduri S_{15}, S_{25}, S_{35} și S_{45} care prin evaluări dau valorile: $F(15)=12, F(25)=11, F(35)=9$ și $F(45)=9$. Aceste valori duc la eliminarea nodurilor S_{51}, S_{52}, S_{53} și S_{54} . În continuare se pot expanda oricare din

nodurile S_{35} și S_{45} . Se alege S_{45} și se introduc noile noduri S_{145}, S_{245} și S_{345} , cu valorile corespunzătoare $F(145)=18$, $F(245)=17$ și $F(345)=15$. Se alege apoi S_{35} pentru expandare și se introduc noile noduri S_{135}, S_{235} și S_{435} , cu valorile corespunzătoare $F(135)=13$, $F(235)=12$ și $F(435)=10$. Se elimină nodul S_{345} . Se alege S_{435} pentru expandare și se introduc noile noduri S_{1435} și S_{2435} și se pot înlocui cu S_{21435} și S_{12435} cu valorile corespunzătoare $F(21435)=12$ și $F(12435)=11$. Se elimină nodurile $S_{145}, S_{245}, S_{135}, S_{235}$ și S_{21435} . Se face $\hat{f}=11$ și algoritmul se termină deoarece nu mai sunt noduri neeliminate care pot să fie expandate. Valoarea optimală este 11 și corespunde programării (12435). Din cele 206 noduri posibil de expandat, au fost expandate numai 5. ■

5.3.2.2. Minimizare durată totală pentru activități cu timp de latență

Punerea problemei. Se consideră mulțimea $A = \{1, 2, \dots, n\}$ de activități independente cu duratele de execuție t_1, t_2, \dots, t_n , cu momentele de disponibilitate r_1, r_2, \dots, r_n și duratele de latență, adică timpul de execuție a diferitelor operații ce se fac după terminarea execuției unei activități pe procesor, q_1, q_2, \dots, q_n . Se cere să se determine o planificare a activităților pe un procesor astfel încât să se minimizeze $\max_{i \in A} (s_i + t_i + q_i)$, unde s_i este momentul de începere a execuției activității i . ■

O evaluare prin lipsă a duratei optimale este dată de expresia:

$$h(B) = \min_{i \in B} r_i + \sum_{i \in B} t_i + \min_{i \in B} q_i,$$

pentru orice $B \subset A$.

În algoritmul următor notăm cu U mulțimea activităților planificate și cu \bar{U} mulțimea activităților neplanificate la un moment dat. Se consideră două activități fictive, 0 activitatea de început, care precede toate activitățile din A și $n+1$ activitatea finală, care succede la toate activitățile din A . La terminarea algoritmului, s_{n+1} reprezintă timpul total de programare.

Algoritmul 5.27. (Jackson)

- [Inițializări] Se face $s_0 = 0$, $t = \min_{i \in A} r_i$, $U = \emptyset$ și $\bar{U} = A$.
- [Terminare] Dacă $\bar{U} = \emptyset$, atunci se face $s_{n+1} = \max_{i \in A} (s_i + t_i + q_i)$ și STOP.
- [Ajustare] Se face $t = \max\{t, \min_{i \in \bar{U}} r_i\}$.
- [Alegere] Se alege din \bar{U} o activitate i disponibilă la momentul t , adică pentru care $r_i \leq t$, și care are pentru q_i o valoare cât mai mare posibil.
- [Modificări] Se face $U = U \cup \{i\}$, $\bar{U} = \bar{U} - \{i\}$, $s_i = t$ și $t = t + t_i$.
- [Ciclare] Se trece la pasul 2. ■

Exemplul 5.36. Fie un sistem cu $n=7$ activități ale căror date sunt menționate în tabelul 5.10. Aplicând algoritmul se obține succesiv $s_0=s_6=0$, $s_1=10$, $s_2=15$, $s_3=21$, $s_4=28$, $s_5=32$, $s_7=35$, $s_8=53$. Un drum critic în graful asociat acestui sistem de activități este $(0,1,2,3,4,8)$ de valoare 53. ■

i	1	2	3	4	5	6	7
r_i	10	13	11	20	30	0	30
t_i	5	6	7	4	3	6	2
q_i	7	26	24	21	8	17	0

Tabelul 5.10.

Fie mulțimea $A = \{1,2,\dots,n\}$, unde activitățile sunt numerotate în ordinea dată de algoritmul precedent. Vom spune că l este *activitate pivot inițială* dacă este de număr maxim dintre activitățile ce aparțin unui drum critic; analog spunem că h este *activitate pivot terminală* dacă este de număr minim dintre activitățile ce aparțin drumului critic $(0,\dots,l,n+1)$. Vom spune că c este *activitate critică* dacă este de număr maxim pe drumul (h,\dots,l) pentru care $q_c < q_l$. Dacă nu există o astfel de activitate, se ia prin definiție $c=h-1$. Se definește *mulțimea critică* mulțimea $J = \{c+1, c+2, \dots, l\}$ de pe drumul critic.

Teorema 5.25. (fundamentală) Diferența între durata optimală și durata obținută prin aplicarea algoritmului lui Jackson este majorată de durata maximă de execuție a unei activități. Mai precis, dacă soluția dată de algoritmul lui Jackson nu este optimală, atunci $h(J) > f^* - t_c$; altfel, $f^* = h(J)$. ■

Se poate obține eventual o soluție mai bună dacă se pleacă de la soluția obținută aplicând algoritmul lui Jackson și se mută c după l . Apoi se alege dintre cele două soluții cea mai bună.

Dacă se consideră o estimare prin adaus \hat{f} a valorii optimale, se pot determina soluții mai bune dacă se aplică următoarele proprietăți, în care am notat cu:

$$K = \{k \in A - J \mid t_k > \hat{f} - t_c\}.$$

Teorema 5.26. Dacă există $k \in K$ astfel încât $r_k + t_k + \sum_{i \in J} t_i + q_l \geq \hat{f}$, atunci, pentru o soluție de durată mai mică decât \hat{f} , activitatea k se va executa după toate activitățile din J și deci se poate pune $r_k = \max(r_k, \min_{i \in J} r_i + \sum_{i \in J} t_i)$. ■

Teorema 5.27. Dacă există $k \in K$ astfel încât $\min_{i \in J} r_i + t_k + \sum_{i \in J} t_i + q_k \geq \hat{f}$, atunci, pentru o soluție de durată mai mică decât \hat{f} , activitatea k se va executa înainte de toate activitățile din J și deci se poate pune $q_k = \max(q_k, \min_{i \in J} q_i + \sum_{i \in J} t_i)$. ■

Pentru aplicarea metodei arborescente la rezolvarea problemei, nodurile sunt descrise prin tripletele (r_i, t_i, q_i) și se determină o evaluare prin lipsă $g(S)$ a problemei de rezolvat care poate fi determinată de exemplu prin rezolvarea problemei preemtive corespunzătoare. Se mai poate utiliza drept evaluare $h(J)$. În algoritm se alege un nod S terminal cu $g(S)$ minim și se aplică pentru el algoritmul Jackson. Se calculează c și J și dacă valoarea programării este $f_0 = \hat{f}$, atunci se elimină nodul S , altfel se construiește soluția cu c după J de valoare f_1 și dacă $f_1 < \hat{f}$, atunci se face $\hat{f} = f_1$. Se face apoi separarea lui S în două probleme: una cu c înainte de J în care se consideră $q_c = \max(q_c, \sum_{i \in J} t_i + q_i)$ și una cu c după J în care $r_c = \max(r_c, \min_{i \in J} q_i + \sum_{i \in J} t_i)$. Algoritmul de tip metodă arborescentă construit conform procedurii descris anterior are următoarea structură.

Algoritmul 5.28. (Metoda arborescentă)

1. [Inițializare] Se face $\hat{f} = +\infty$ și se consideră arborescența cu un nod ce corespunde problemei de rezolvat.
2. [Terminare] Dacă toate nodurile au fost eliminate, atunci STOP.
3. [Alegere] Se determină un nod terminal S de cea mai mică evaluare prin lipsă $g(S)$. Dacă $g(S) \geq \hat{f}$, atunci se elimină toate nodurile arborescenței și STOP.
4. [Algoritm Jackson] Se aplică algoritmul lui Jackson pentru problema asociată lui S și se calculează c , J și valoarea f_0 .
5. [Ajustare] Dacă $f_0 < \hat{f}$, se scrie soluția găsită, se face $\hat{f} = f_0$ și se trece la pasul 2.
6. [Eliminare] Dacă $c = h - 1$, atunci se elimină nodul S și se trece la pasul 2.
7. [Soluție cu c după J] Se construiește soluția cu c după J de durată f_1 . Dacă $f_1 < \hat{f}$, atunci se scrie soluția și se face $\hat{f} = f_1$.
8. [Succesor înainte] Se construiește succesorul S_1 al lui S asociat problemei înainte recopiind datele lui S , apoi se modifică q_c . Se calculează $g(S_1)$ aplicând un algoritm cu preemțiune. Dacă $g(S_1) \geq \hat{f}$, atunci se elimină S_1 .
9. [Succesor după] Se construiește succesorul S_2 al lui S asociat problemei înapoi recopiind datele lui S , apoi se modifică r_c . Se calculează $g(S_2)$ aplicând un algoritm cu preemțiune. Dacă $g(S_2) \geq \hat{f}$, atunci se elimină S_2 .
10. [Ciclare] Se trece la pasul 2. ■

Exemplul 5.37. Cu datele din exemplul 5.36., prin aplicarea algoritmului bazat pe metoda arborescentă se obține mai întâi $h(J)=53$, $c=1$ și $J=\{2,3,4\}$. Deoarece pentru c înainte de J se obține $h(J \cup \{1\})=53$, nu se mai introduce nodul S_1 . Deci c se execută după J , se pune $r_1=28$ și se introduce nodul S_2 . Se aplică apoi algoritmul lui Jackson pentru problema obținută și se găsește valoarea 50. Cu c după J se obține valoarea 51, deci valoarea optimală este 50 și corespunde la succesiunea $(6,3,2,4,1,5,7)$. ■

5.4. Alți algoritmi aproximativi pentru programarea activităților

5.4.1. Planificarea activităților pe procesoare distincte

Punerea problemei. Se studiază problema planificării a n activități pe m procesoare într-o ordine comună. ■

Problema este NP-completă chiar și în cazul unui singur procesor, soluția optimă neputând fi identificată decât pe calea parcurgerii celor $n!$ permutări posibile ale activităților.

Fie t_i^k timpul necesar pentru activitatea $i=1,2,\dots,n$ pe procesorul $k=1,2,\dots,m$ și s_{ij}^k intervalul de timp scurs între terminarea activității i pe procesorul k și începutul activității j pe același procesor. În lucrarea [SZW87] se consideră cazul aditiv în care:

$$s_{ij}^k = x_{ik} + y_{jk}, \quad 1 \leq i \neq j \leq n, \quad 1 \leq k \leq m,$$

unde x_{ik} și y_{jk} sunt mărimi pozitive. În continuare se consideră cazul în care aceste mărimi pot lua și valori negative, fapt ce arată că modelul aditiv este mai general decât se presupune în [SZW87].

Fie o secvență P arbitrară de n activități numerotate $1, 2, \dots, n$. Fie T_i^k timpul de încheiere a activității i pe procesorul k . Momentul încheierii activității i pe procesorul k fiind egal cu $\max(T_i^{k-1}, T_{i-1}^k + s_{i-1,i}^k)$ rezultă că:

$$T_i^k = \max(T_i^{k-1}, T_{i-1}^k + s_{i-1,i}^k) + t_i^k, \quad \text{unde } T_i^0 = T_0^k = 0, \quad (5.16)$$

pentru $i = 1, 2, \dots, n$ și $k = 1, 2, \dots, m$. Pentru a construi modelul aditiv, se caută pentru fiecare k acei x_{ik} și y_{jk} , $1 \leq i \neq j \leq n$, care minimizează valoarea expresiei:

$$z = \sum_i \sum_j (s_{ij}^k - x_{ik} - y_{jk})^2.$$

Anulând gradientul expresiei z și rezolvând sistemul liniar de ecuații în x_{ik} și y_{jk} rezultă soluțiile:

$$x_{ik} = x_{1k} + (n-1)/n u_i^k - v_k, \quad y_{jk} = u_j^k - x_{jk}, \quad (5.17)$$

unde x_{1k} are o valoare arbitrară pozitivă sau negativă și u_i^k și v_k sunt expresiile:

$$u_i^k = 1/(n-2) \left(\sum_{j=1}^n s_{ij}^k + \sum_{j=1}^n s_{ji}^k - 1/(n-1) \sum_i \sum_j s_{ij}^k \right), \quad i \neq j,$$

$$v_k = 1/n \left(u_1^k + \sum_{j=1}^n s_{1j}^k + \sum_{j=1}^n s_{j1}^k - 1/(n-1) \sum_i \sum_j s_{ij}^k \right), \quad i \neq j.$$

În locul problemei inițiale se caută mai întâi o soluție definită de (5.17) și se consideră modelul aditiv ce se obține prin înlocuirea termenilor $s_{i-1,i}^k$ cu $x_{i-1,k} + y_{ik}$ în (5.16). Acest model este definit de:

$$T_i^k = \max(T_i^{k-1}, T_{i-1}^k + x_{i-1,k} + y_{ik}) + t_i^k.$$

Se consideră apoi substituțiile:

$$a_{ik} = -x_{i,k-1} - y_{ik}, a_{i1} = 0 \text{ și } t_{ik} = t_i^k + x_{ik} + y_{ik} \quad (5.18)$$

și

$$A_{iu} = \sum_{k=u}^{m-1} t_{ik} + \sum_{k=u+1}^m a_{ik}, B_{iu} = \sum_{k=u+1}^m t_{ik} + \sum_{k=u+1}^m a_{ik}.$$

În continuare se prezintă un algoritm în care se utilizează algoritmul lui Johnson [JOH54], devenit acum clasic.

Algoritmul 5.29. (tip Johnson)

- [Diferențe] Se calculează diferențele $A_{iu} - B_{iu}$, pentru toți i .
- [Separare] Fie $\alpha = \{i \mid A_{iu} - B_{iu} \leq 0\}$ și $\beta = \{i \mid A_{iu} - B_{iu} > 0\}$. Se așează activitățile din α înaintea celor din β .
- [Ordonare] Se ordonează activitățile din α în ordinea nedescrescătoare a valorilor A_{iu} și activitățile din β în ordinea necrescătoare a valorilor B_{iu} .

Un algoritm echivalent ce utilizează metoda lui Johnson este următorul:

Algoritmul 5.30. (Variantă)

- [Inițializare] Se face $u = 1$.
- [Doi procesori] Se utilizează metoda lui Johnson pentru rezolvarea problemei planificării pe două procesoare cu timpi de lucru A_{iu} și B_{iu} , pe primul, respectiv al doilea procesor. Fie $P = p_1, p_2, \dots, p_n$ secvența rezultată.
- [Timpi] Se calculează timpul consumat pentru P cât și pentru cele $n - 1$ secvențe de forma $p_1, p_2, \dots, p_{i-1}, p_{i+1}, \dots, p_n, p_i, i = 1, 2, \dots, n - 1$, utilizând formula (5.16).
- [Ciclare] Se face $u = u + 1$. Dacă $u < n$, se trece la pasul 2; altfel se identifică cea mai bună secvență dintre cele $n(n - 1)$ secvențe examinate și STOP. ■

Problema alegerii valorilor x_{1k} , $1 \leq k \leq m$ este neesențială, putându-se arăta că soluția nu depinde de aceste valori, ele putând fi deci toate nule.

Exemplul 5.38. Se consideră o problemă de dimensiune 2×6 , intervalele de timp t_i^1 și t_i^2 fiind respectiv 25,88,12,12,48,1 și 24,71,33,8,99,95. Valorile s_{ij}^1 și s_{ij}^2 sunt date în tabelele 5.11 și 5.12.

	-	3	6	11	18	2	40
	18	-	18	9	13	1	59
	10	17	-	1	9	11	48
$(s_{ij}^1) =$	4	7	5	-	2	6	24
	10	6	17	4	-	5	42
	11	3	7	8	19	-	48
	53	36	53	33	61	25	(261)

Tabelul 5.11.

	-	31	42	43	41	45	202
	30	-	47	42	32	30	181
	32	46	-	36	38	45	197
$(s_{ij}^2) =$	30	49	32	-	42	44	197
	42	37	35	44	-	32	190
	48	32	48	42	41	-	211
	182	195	204	207	194	196	(1178)

Tabelul 5.12.

În aceste tebele sunt menționate și sumele valorilor s_{ij}^m pe linii și pe coloane și în paranteze sumele tuturor valorilor s_{ij}^m , $m = 1, 2$. Valorile x_{ik} și y_{ik} , calculate cu (5.17) și rotunjite la valori întregi, sunt date în tabelul 5.13.

	x_{i1}	y_{i1}	x_{i2}	y_{i2}
1	0	10	0	37
2	3	8	-4	39
3	2	10	0	41
4	-4	5	0	42
5	1	12	-2	39
6	1	4	2	41

Tabelul 5.13.

Cum $m = 2$, singura valoare a variabilei u este 1. Utilizând formulele (5.18) se calculează valorile a_{i2} , t_{i1} și t_{i2} , valorile a_{i1} sunt toate nule. Valorile A_{i1} și B_{i2} sunt: -2, 57, -19, -25, 21, -36 și respectiv 24, 64, 31, 12, 96, 96.

Soluția furnizată de pasul 1 al algoritmului pentru exemplul considerat este dată de secvența $P=6,4,3,1,5,2$ și necesită un timp egal cu 515 (unități de timp). După testarea în pasul 2 a încă cinci secvențe pe calea mutării fiecărei activități din P la sfârșit a rezultat permutarea 6,4,3,1,2,5 care necesită un timp egal cu 500 și este acceptată ca soluție aproximativă. Soluția optimală este 6,2,5,3,4,1 și necesită un timp egal cu 496.

Generarea valorii 515 menționată mai sus se determină astfel:

$$\begin{aligned}
 T_6^1 &= \max(T_6^0, --) + t_6^1 = \max(0, --) + 1 = 1; \\
 T_4^1 &= \max(T_4^0, T_6^1 + s_{64}^1) + t_4^1 = \max(0, 1 + 8) + 12 = 21; \\
 T_3^1 &= \max(T_3^0, T_4^1 + s_{43}^1) + t_3^1 = \max(0, 21 + 5) + 12 = 38; \\
 T_1^1 &= \max(T_1^0, T_3^1 + s_{31}^1) + t_1^1 = \max(0, 38 + 10) + 25 = 73; \\
 T_5^1 &= \max(T_5^0, T_1^1 + s_{15}^1) + t_5^1 = \max(0, 73 + 18) + 48 = 139;
 \end{aligned}$$

$$T_2^1 = \max(T_2^0, T_5^1 + s_{52}^1) + t_2^1 = \max(0, 139 + 61) + 88 = 233;$$

$$T_6^2 = \max(T_6^1, --) + t_6^2 = \max(0, --) + 96 = 96;$$

$$T_4^2 = \max(T_4^1, T_6^2 + s_{64}^2) + t_4^2 = \max(21, 96 + 42) + 8 = 146;$$

$$T_3^2 = \max(T_3^1, T_4^2 + s_{43}^2) + t_3^2 = \max(38, 146 + 32) + 33 = 211;$$

$$T_1^2 = \max(T_1^1, T_3^2 + s_{31}^2) + t_1^2 = \max(73, 211 + 32) + 24 = 267;$$

$$T_5^2 = \max(T_5^1, T_1^2 + s_{15}^2) + t_5^2 = \max(139, 267 + 41) + 99 = 397;$$

$$T_2^2 = \max(T_2^1, T_5^2 + s_{52}^2) + t_2^2 = \max(233, 397 + 37) + 71 = 515.$$

La efectuarea calculului s-a ținut seama de faptul că la aplicarea relației (5.16) indicii $i=1,2,3,4,5,6$ din această relație corespund respectiv activităților 6,4,3,1,5,2. ■

5.4.2. Altă euristică pentru planificarea pe procesoare diferite

Punerea problemei. Fiind date n activități ce urmează a fi procesate pe m mașini, timpul de ocupare (procesare) al procesorului k de către activitatea i fiind t_i^k , $i = 1, 2, \dots, n$; $k = 1, 2, \dots, m$, se cere identificarea ordinii în care trebuie parcurse activitățile în vederea minimizării timpului total de ocupare a celor m mașini. ■

Fie o secvență σ după care urmează o activitate a . Atunci (vezi [GUP71]) relația recursivă ce definește timpul de completare al secvenței σa pe mașina j este:

$$T(\sigma a, j) = \max \{T(\sigma, j); T(\sigma a, j - 1)\} + t_a^j, \quad (5.19)$$

unde $T(\emptyset, j) = T(\sigma, 0) = 0$, pentru toți σ și j .

Problema de rezolvat constă în minimizarea lui $T(\sigma a, m)$, unde a aparține mulțimii activităților și σ aparține mulțimii tuturor secvențelor de $(n - 1)$ activități și care nu conțin activitatea a .

Ideea de bază a algoritmului propus constă în construirea, cu ajutorul datelor problemei de rezolvat, a mai multor probleme auxiliare de procesare pe numai două mașini, după care se alege ordinea de parcurgere a activităților ce necesită un timp minimal. Pentru cazul a două mașini, problema studiată este reducibilă (vezi [GUP71]) la cea a sortării, în ordine crescătoare, a n numere asociate fiecărei activități, conform definiției:

$$f(i) = A_i / \min(t_i^1, t_i^2), \quad A_i = \begin{cases} 1, & \text{dacă } t_i^1 \geq t_i^2 \\ -1, & \text{altfel,} \end{cases} \quad (5.20)$$

unde t_i^1 , respectiv t_i^2 , este timpul de ocupare de activitatea i a mașinii 1, respectiv 2.

În cazul a $m > 2$ mașini, se construiesc $p = m - 1$ probleme auxiliare după cum urmează: suma timpilor de procesare pentru primele k , $k = 1, 2, \dots, p$, mașini este interpretată drept timp de procesare pe mașina 1 a problemei auxiliare și suma

timpilor de procesare a ultimilor k mașini este interpretată ca fiind timpul de procesare pe mașina 2 a problemei auxiliare.

Definițiile timpilor de procesare $p_k(i,1)$ și $p_k(i,2)$ ai problemei auxiliare k sunt:

$$\left. \begin{aligned} p_k(i,1) &= \sum_{j=1}^k t_i^j & i &= 1, 2, \dots, n \\ p_k(i,2) &= \sum_{j=m-k+1}^m t_i^j & k &= 1, 2, \dots, m \end{aligned} \right\} \quad (5.21)$$

Funcția corespunzătoare $R(k, i)$, analogă cu $f(i)$ din (5.20), este:

$$R(k, i) = A_{ki} / \min(p_k(i, 1), p_k(i, 2)), \quad A_{ki} = \begin{cases} 1, & \text{dacă } p_k(i, 1) \geq p_k(i, 2) \\ -1, & \text{altfel,} \end{cases} \quad (5.22)$$

Cu aceste notații, algoritmul euristic propus este:

Algoritmul 5.31. (Procesoare diferite)

- [Calculare R] Pentru fiecare k și i , se calculează $R(k, i)$ prin relațiile (5.21) și (5.22).
- [Ordonare] Pentru fiecare k , se ordonează activitățile în ordinea crescătoare a valorilor $R(k, i)$. Dacă $R(k, i) = R(k, i+1)$ se acordă prioritate activității cu valoare mai mică a lui $R(\alpha, i)$, $\alpha = k+1, k+2, \dots, m-1$ sau $\alpha = k-1, k-2, \dots, 1$. Dacă această procedură nu se încheie cu un rezultat, atunci se alege în mod arbitrar una dintre activități, adică i sau $i+1$.
- [Timp] Pentru fiecare dintre cele k ordonări astfel obținute, se calculează timpul total de lucru, utilizând relația (5.19).
- [Alegere] Se alege ordonarea cu timp total de lucru minimal și care reprezintă soluția aproximativă a problemei. ■

Exemplul 5.39. Fie problema cu 4 activități și 5 mașini cu timpii de execuție dați în tabelul 5.14.

$\begin{matrix} j \\ i \end{matrix}$	1	2	3	4	5
1	4	3	7	2	8
2	3	7	2	8	5
3	1	2	4	3	7
4	3	4	3	7	2

Tabelul 5.14.

Pasul 1. Cu relațiile (5.21) și (5.22), se obțin rezultatele din tabelul 5.15.

Pasul 2. Urmărind tabelul 5.15., se constată că, pentru $k=2$, valorile $R(2,1) = R(2,4)$ sunt egale. Deoarece $k=2$, se consideră $\alpha = k+1 = 3$ și se observă că $R(3,4) < R(3,1)$. În consecință, se acordă prioritate activității 4. Procedând în acest mod, se obțin patru programe de procesare.

i	$R(k, i)$			
	$k = 1$	$k = 2$	$k = 3$	$k = 4$
1	-1/4	-1/7	-1/14	-1/16
2	-1/3	-1/10	-1/12	-1/20
3	-1	-1/3	-1/7	-1/10
4	1/2	-1/7	-1/10	1/16

Tabelul 5.15.

Pasul 3. Cu relația (5.19), se obțin timpii de lucru din tabelul 5.16.

Programare	Timp de lucru
3214	36
3412	33
3421	39
3124	34

Tabelul 5.16.

Pasul 4. Programarea 3412 are timpul de lucru minimal și este acceptată drept soluție a problemei. ■

Euristica propusă are la bază ideea de a reduce problema dată la câteva probleme care reflectă, într-o măsură suficient de bună, interconstrucțiile dintre activitățile date.

5.4.3. Minimizarea duratei totale cu timpi de adaptare

Punerea problemei. Se studiază problema minimizării timpului de încheiere a execuției mai multor activități, pe calea ordonării lor convenabile, în cazul unei singure unități productive (procesor). ■

Fie $A = \{a_i\}$, $i=1,2,\dots,n$, o mulțime de n activități ce urmează a fi procesate pe o singură unitate productivă; t_{ij} = timpul necesar pentru a adapta unitatea productivă în vederea procesării activității j după activitatea i . Se presupune că întotdeauna $t_{ij} > 0$ și că, în general, $t_{ij} \neq t_{ji}$. De asemenea, se presupune că activitatea a_1 este procesată inițial. Rezultă că, în acest caz, numărul de secvențe distincte ce încep cu activitatea a_1 este egal cu $(n - 1)!$. Deoarece duratele de execuție a activităților nu depind de ordinea lor, rezultă că problema studiată constă în minimizarea sumei intervalelor de timp necesare pentru trecerea de la o activitate la alta. Fie k permutarea $k_1=1, k_2, \dots, k_n$. Atunci problema constă în minimizarea sumei:

$$T_1 = \sum_{i=1}^{n-1} t_{k_i, k_{i+1}},$$

valoarea ei minimală fiind notată în continuare cu T_{\min} .

Exemplul 5.40. Fie cazul a șase activități pentru care intervalele t_{ij} sunt date în tabelul 5.17. În acest tabel, locurile notate cu X corespund la succesiuni de perechi de activități ce nu se realizează și valorile din tabel reprezintă pe t_{ij} . În acest exemplu, timpul T_{\min} este egal cu 8.6 și corespunde secvenței 1, 4, 3, 6, 2, 5. ■

i	j					
	1	2	3	4	5	6
1	X	3.0	2.8	2.2	2.5	1.7
2	X	X	1.7	2.3	1.8	0.9
3	X	3.4	X	3.5	2.7	1.9
4	X	1.8	1.2	X	1.2	2.2
5	X	2.5	2.4	3.6	X	2.5
6	X	1.5	2.6	3.4	2.4	X

Tabelul 5.17.

Problema studiată este o variantă a problemei comisvoiajorului și, în consecință, identificarea unei soluții optimale este dificilă. Din acest motiv, utilizarea unor metode euristice este de preferat. O primă metodă euristică este *metoda celei mai apropiate activități*. Ideea acestei metode constă în selectarea în calitate de activitate următoare a acelei activități pentru care timpul t_{ij} este minimal.

Exemplul 5.41. În cazul datelor din exemplul 5.40., această metodă furnizează secvența 1, 6, 2, 3, 5, 4, pentru care $T_k = 11.2$. ■

Altă euristică se numește *metoda celei mai apropiate activități cu schimbarea originii*. În acest caz, metoda precedentă este aplicată succesiv, de cel puțin $n - 1$ ori, alegând pe rând altă activitate ce urmează după activitatea 1. Dacă la o etapă oarecare sunt mai multe activități candidat, atunci procesul se reia pentru toate aceste activități.

Exemplul 5.42. Pentru exemplul studiat, aplicând această metodă se obțin soluțiile din tabelul 5.18. ■

Secvența	T_k
1, 2, 6, 5, 3, 4	12.2
1, 3, 6, 2, 5, 4	11.6
1, 4, 3, 6, 2, 5	8.6
1, 4, 5, 3, 6, 2	9.2
1, 5, 3, 6, 2, 4	10.6
1, 6, 2, 3, 5, 4	11.2

Tabelul 5.18.

A treia euristică se numește *metoda celei mai apropiate activități cu micșorarea valorilor pe coloane*. Metoda celei mai apropiate activități se aplică după scăderea din valorile fiecărei coloane a valorii minime din această coloană.

Exemplul 5.43. Pentru exemplul studiat, se obține astfel tabelul 5.19.

i	j					
	1	2	3	4	5	6
1	X	1.5	1.6	0	1.3	0.8
2	X	X	0.5	0.1	0.6	0
3	X	1.9	X	1.3	1.5	1.0
4	X	0.3	0	X	0	1.3
5	X	1.0	1.2	1.4	X	1.6
6	X	0	0.4	1.2	1.2	X

Tabelul 5.19.

Aplicând metoda celei mai apropiate activități se obține secvențele 1,4,3,6,2,5 și 1,4,5,2,6,3 la care corespund valorile T_k : 8.6 și 9.4, prima fiind optimală. ■

Din testările experimentale efectuate rezultă că metoda propusă furnizează valori cu cel mult circa 1.27 ori mai mari decât cele optime.

5.4.4. Planificări cu profit maxim

Punerea problemei. Fiind date n activități independente de durate t_1, t_2, \dots, t_n , cu termene de predare la momentele d_1, d_2, \dots, d_n și cu profiturile w_1, w_2, \dots, w_n dacă activitățile sunt terminate la timp, se cere o programare pe un procesor în așa fel încât profitul total să fie maxim. ■

Să presupunem că activitățile sunt numerotate în așa fel încât $d_1 \leq d_2 \leq \dots \leq d_n$ și că profiturile sunt numere naturale. O euristică polinomială pentru determinarea unui profit cât mai mare este următorul algoritim.

Algoritmul 5.32. (*ProfitMax*)

- [Inițializări] Se face $P_0(0) = 0$ și $P_0(i) = +\infty$, pentru $i = 1, 2, \dots, \sum_{j=1}^n w_j$.
- [Ciclare activități] Pentru $i = 1, 2, \dots, n$ se execută pașii 3 și 4.
- [Valori inițiale] Se face $P_i(k) = P_{i-1}(k)$, pentru $k = 1, 2, \dots, \sum_{j=1}^{i-1} w_j$.
- [Ciclare valoare profit] Pentru $k = w_i, w_i + 1, \dots, \sum_{j=1}^i w_j$ se execută pasul 5.
- [Ajustare] Dacă $P_{i-1}(k-w_i) + t_i < \min(d_i, P_i(k))$, atunci se face $P_i(k) = P_{i-1}(k-w_i) + t_i$.
- [Calcul profit] Se determină $w^* = \max\{w \mid 0 \leq w \leq \sum_{i=1}^n w_i \text{ și } P_n(w) \neq +\infty\}$.

Se calculează mulțimea J^* optimală corespunzătoare, apoi STOP. ■

Complexitatea acestui algoritim este $O(n \sum_{i=1}^n w_i)$.

Se poate folosi algoritmul precedent pentru a obține o soluție ε -aproximativă pentru cazul general, după cum se vede din algoritmul următor.

Algoritmul 5.33. (Caz general)

- [Inițializări] Se face $W = \max_{1 \leq i \leq n} \{w_i\}$ și $K = \varepsilon W / n$.
- [Trunchiere] Se face $w'_i = \lfloor w_i / K \rfloor$, $t'_i = t_i$, $d'_i = d_i$, pentru $i = 1, 2, \dots, n$.
- [Algoritm] Se aplică algoritmul **ProfitMax** pentru datele transformate, rezultatul fiind o aproximație a soluției problemei inițiale, și STOP. ■

Complexitatea acestui algoritm este $O(n^3 / \varepsilon)$.

O metodă mai eficientă se numește metoda de partiție dinamică a intervalelor și este dată în algoritmul următor.

Algoritmul 5.34. (partiție dinamică a intervalelor)

- [Inițializări] Se face $m = \lfloor n / \varepsilon \rfloor$, $T_{ik} = +\infty$ și $W_{ik} = 0$, pentru $i = 0, 1, \dots, n$ și $k = 1, 2, \dots, m$, $T_{01} = 0$, $h_0 = 0$.
- [Ciclu activități] Pentru $i = 1, 2, \dots, n$ se execută pașii 3, 4 și 5, apoi se trece la pasul 6.
- [Calcul h_i] Se face $h_i = h_{i-1}$ și pentru $k = 1, 2, \dots, m$, dacă $T_{i-1,k} + \cdot \leq d_i$ și $W_{i-1,k} + w_i \geq h_i$, atunci se face $h_i = W_{i-1,k} + w_i + 1$.
- [Calcule $T_{i,j}$ și $W_{i,j}$] Pentru $k = 1, 2, \dots, n$ se face $j = \lfloor (m W_{i-1,k} + 1) / h_i \rfloor$ și dacă $T_{i-1,k} < T_{i,j}$, atunci se face $T_{i,j} = T_{i-1,k}$ și $W_{i,j} = W_{i-1,k}$.
- [Calcule $T_{i,l}$ și $W_{i,l}$] Pentru $k = 1, 2, \dots, m$ se face $l = \lfloor (m (W_{i-1,k} + w_i) + 1) / h_i \rfloor$ și dacă $T_{i-1,k} + t_i < \min (T_{i,l}, d_i)$, atunci se face $P_{i,l} = P_{i-1,k} + t_i$ și $W_{i,l} = W_{i-1,k} + w_i$.
- [Soluție aproximativă] Se face $k' = 1$ și $\hat{w} = 0$. Pentru $k = 1, 2, \dots, m$, dacă $T_{n,k} \neq +\infty$ și $W_{n,k} > \hat{w}$, atunci se face $k' = k$ și $\hat{w} = W_{n,k}$. Apoi STOP. ■

Complexitatea acestui algoritm este $O(n^2 / \varepsilon)$.

5.4.5. Minimizarea sumei întârzierilor

Punerea problemei. Inițial sunt accesibile n activități de către un procesor ce poate parcurge o singură activitate la un moment dat. Nu se admit priorități în parcurgerea activităților. Activitatea i , unde $i = 1, \dots, n$, necesită un *timp de procesare* t_i , are o *scadență* d_i și o *pondere* w_i . Problema constă în identificarea unei permutări s_i din mulțimea permutărilor mulțimii $\{1, \dots, n\}$ care minimizează întârzierea totală ponderată:

$$\sum_{i=1}^n w_{s(i)} \max\left(\sum_{j=1}^i t_{s(j)} - d_{s(i)}, 0\right). \blacksquare$$

Problema enunțată este NP-completă. În continuare se prezintă euristici de rezolvare bazate pe înlocuirea generării tuturor permutărilor prin generarea unor submulțimi de permutări, vecine într-un anumit sens, cu permutarea $(1, 2, \dots, n)$.

5.4.5.1. Căutarea locală și vecinătăți

Se consideră patru vecinătăți ale unei permutări s definite după cum urmează:

- $N_A(s)$ = vecinătatea bazată pe interschimbarea adiacentă și definită prin:
 $\{g \mid g \in S, \text{unde } g \text{ se obține din } s \text{ prin permutarea unei perechi de activități adiacente}\}.$
- $N_K(s)$ = vecinătatea bazată pe K interschimbări în s și definită astfel:
 $\{g \mid g \in S, \text{unde } g \text{ se obține din } s \text{ prin interschimbarea oricărei perechi de activități de cel mult } K \text{ ori succesiv, pentru } K = 1, 2, \dots, n-1\}.$
- $N_{BS}(s)$ = vecinătatea bazată pe mutarea înapoi și definită astfel:
 $\{g \mid g \in S, \text{unde } g = (s(1), \dots, s(k-1), s(k+1), \dots, s(l), s(k), s(l+1), \dots, s(n)),$
 pentru $k = 1, 2, \dots, n-1$ și $l = k+1, \dots, n\}.$
- $N_{GS}(s)$ = vecinătatea bazată pe schimbarea generală și definită astfel:
 $N_{BS}(s) \cup \{g \mid g \in S, \text{unde } g = (s(1), \dots, s(l-1), s(k), s(l), \dots, s(k-1), s(k+1), \dots, s(n)),$
 pentru $k = 2, 3, \dots, n$ și $l = 1, 2, \dots, k-1\}.$

Exemplul 5.44. Cele patru vecinătăți definite mai înainte sunt ilustrate în tabelul 5.20., pentru cazul $s = (1, 2, 3, 4)$ și $n = 4$. ■

Permutări	Vecinătate			
	$N_A(s)$	$N_I(s)$	$N_{BS}(s)$	$N_{GS}(s)$
1243	*	*	*	*
1324	*	*	*	*
1342			*	*
1423				*
1432		*		
2134	*	*	*	*
2143				
2314			*	*
2341			*	*
3124				*
3214		*		
4123				*
4231		*		

Tabelul 5.20.

Din definiții rezultă că $N_A(s) \subset N_I(s) \subset \dots \subset N_{n-1}(s)$ și $N_A(s) \subset N_{BS}(s) \subset N_{GS}(s)$.
 Numerele de elemente din mulțimile de vecinătăți sunt respectiv $|N_A(s)| = n - 1$,
 $|N_I(s)| = |N_{BS}(s)| = n(n - 1) / 2$ și $|N_{GS}(s)| = (n - 1)^2$.

Procesul căutării locale constă în identificarea unei permutări g din vecinătatea unei permutări inițiale s care micșorează întârzierea totală. Dacă există un asemenea g , se pune $s = g$ și se repetă procedura precedentă. Altfel, s este un optim local. Atunci când se elaborează o euristică de căutare locală, trebuie determinate următoarele trei elemente: 1) metoda de identificare a permutării sursă (*seed permutation*), 2) vecinătatea și 3) metoda de identificare a următoarei permutări sursă.

Metodele de căutare bazate pe vecinătățile N_A , N_K , N_{BS} și N_{GS} sunt notate respectiv cu ADJ , $K-INT$, BS și GS . Pentru evaluarea performanțelor euristicilor de căutare locală sunt folosite următoarele notații:

t - vector cu $2n$ elemente $(t_1, t_2, \dots, t_n, d_1, d_2, \dots, d_n)$ care specifică problema dată, numită în continuare problema t .

F - mulțimea problemelor t posibile = $\{t \mid t = (t_1, t_2, \dots, t_n, d_1, d_2, \dots, d_n) \text{ și } d_i \geq 0, \text{ pentru } i = 1, 2, \dots, n\}$.

$LS(t; N)$ - mulțimea optimelor locale pentru problema t în vecinătatea lui N , unde N reprezintă una dintre cele patru vecinătăți.

$T(s; t)$ - întârzierea totală a permutării s la problema t .

$L(t; N)$ - valoarea maximă a întârzierii în problema t în cadrul optimelor locale din vecinătatea $N = \max T(s; t)$, cu $s \in LS(t; N)$.

$v(t)$ - întârzierea totală optimă pentru problema t .

$$e(t; N) = \begin{cases} L(t; N) / v(t) & \text{pentru } v(t) > 0 \\ 1 & \text{pentru } v(t) = L(t; N) = 0 \\ M & \text{pentru } v(t) = 0 \text{ și } L(t; N) > 0, \end{cases}$$

unde $M \geq 1$.

Eroarea relativă a unei euristici de căutare locală folosind vecinătatea N este definită astfel:

$$re(N) = \sup_{t \in F} e(t; N).$$

În continuare se consideră numărul de pași per iterație parcurși în cel mai defavorabil caz pentru fiecare euristică. Pentru ADJ , $|N_A(s)| = n-1$. Pentru compararea a două permutări adiacente se parcurge un număr finit de pași. Rezultă că numărul de pași per iterație este $O(n)$. Următorul exemplu arată că BS are o complexitate apropiată de ADJ .

Exemplul 5.45. Fie problema cu patru activități: $s_2 = (2, 1, 3, 4)$, $s_3 = (2, 3, 1, 4)$ și $s_4 = (2, 3, 4, 1)$. Toate aceste permutări fac parte din $N_{BS}(s_1)$, pentru $s_1 = (1, 2, 3, 4)$. Fie Δ_2 , Δ_3 și Δ_4 creșterea întârzierii totale la trecerea din s_1 în s_2 , din s_2 în s_3 și din s_3 în s_4 . Dacă una dintre valorile Δ_2 , $\Delta_2 + \Delta_3$ și $\Delta_2 + \Delta_3 + \Delta_4$ este negativă, căutarea locală se efectuează pentru o altă vecinătate. Dacă euristica BS este realizată astfel încât

creșterile să fie parcurse în ordinea Δ_2 , $\Delta_2+\Delta_3$ și $\Delta_2+\Delta_3+\Delta_4$ atunci numărul de pași necesari pentru calculul fiecărei creșteri este constant. ■

Deoarece $|N_{BS}(s)| = n(n-1)/2$ rezultă că o iterație din *BS* necesită un număr de pași $O(n^2)$. În mod similar, *GS* necesită un număr de $O(n^2)$ pași per iterație. Deoarece aparent nu există relații recursive între valorile obiectiv (*objective values*) între membrii lui N_1 , rezultă că *1-INT* necesită un număr de $O(n^3)$ pași per iterație.

5.4.5.2. Valorile maxime ale erorilor pentru *K-INT* și *ADJ*

Teorema 5.28. Eroarea relativă pentru o interschimbare euristică *n-2-INT* poate fi oricât de mare, pentru $n \geq 4$, adică $re(N_{n-2}) = \infty$, pentru $n \geq 4$.

Demonstrație. Se construiește un exemplu cu $n \geq 4$ care are o eroare relativă arbitrar de mare. Fie ε , $0 < \varepsilon < 1/2$ și următoarea problemă t : $d_1=2n-2$, $d_2=2-\varepsilon$, $d_i=1+(2i-3)(1-\varepsilon)$, pentru $i=3,4,\dots,n-1$, $d_n=1+(2n-4)(1-\varepsilon)$, $t_1=1-\varepsilon$, $t_2=1$, $t_i=2(1-\varepsilon)$, pentru $i=3,4,\dots,n-1$, și $t_n=2-\varepsilon$. Au loc următoarele relații:

$$d_2 < d_3 < \dots < d_{n-1} < d_n < d_1, \quad (5.23)$$

$$\sum_{i=1}^n t_i - d_n = 1, \quad (5.24)$$

$$\sum_{i=2}^n t_i - d_n = \varepsilon, \quad (5.25)$$

$$\sum_{i=2}^n t_i - d_{n-1} = 1, \quad (5.26)$$

$$\sum_{i=2}^k t_i - d_{k-1} = 1 - \varepsilon, \text{ pentru } k = 3, 4, \dots, n-1. \quad (5.27)$$

Din (5.24) și (5.25) rezultă respectiv:

$$T(1, 2, \dots, n) = \sum_{i=1}^n t_i - d_n = 1, \quad T(2, 3, \dots, n, 1) = \sum_{i=2}^n t_i - d_n = \varepsilon.$$

În continuare se arată că $T(a_1, a_2, \dots, a_n) \geq 1$ pentru toate secvențele (a_1, a_2, \dots, a_n) cu excepția secvențelor $(1, 2, \dots, n)$ și $(2, 3, \dots, n, 1)$. Rezultă că $(1, 2, \dots, n)$ este optim local și $(2, 3, \dots, n, 1)$ este optim global. Deoarece $e(t) \geq 1/\varepsilon$, dacă ε tinde către zero, $e(t)$ tinde către infinit.

Pentru a arăta că $T(a_1, a_2, \dots, a_n) \geq 1$, pentru orice (a_1, a_2, \dots, a_n) cu excepția cazurilor $(1, 2, \dots, n)$ și $(2, 3, \dots, n, 1)$, se consideră următoarele trei cazuri:

Cazul 1: $a_n \neq 1$.

$$T(a_1, a_2, \dots, a_n) \geq \max\left(\sum_{i=1}^n t_{a_i} - d_{a_n}, 0\right) \geq \sum_{i=1}^n t_i - d_n \text{ (din (5.23))} = 1 \text{ (din (5.24)).}$$

Cazul 2: $a_n = 1$ și $a_{n-1} \neq n$.

$$T(a_1, a_2, \dots, a_{n-1}, 1) \geq \max\left(\sum_{i=1}^{n-1} t_{a_i} - d_{a_{n-1}}, 0\right) \geq \sum_{i=2}^n t_i - d_{n-1} \text{ (din (5.23))} = 1 \text{ (din (5.26)).}$$

Cazul 3: $a_n = 1, a_{n-1} = n, a_{n-2} = n - 1, \dots, a_k = k + 1, a_{k-1} \neq k$, pentru $k = n - 1, n - 2, \dots, 3$.

$$T(a_1, a_2, \dots, a_{k-1}, k + 1, \dots, n - 1, n, 1) \geq \max\left(\sum_{i=1}^{k-1} t_{a_i} - d_{a_{k-1}}, 0\right) + \max\left(\sum_{i=1}^{n-1} t_{a_i} - d_{a_{n-1}}, 0\right) \geq \sum_{i=2}^k t_i - d_{k-1} + \sum_{i=2}^n t_i - d_{n-1} \text{ (din (5.24))} = 1 - \varepsilon + \varepsilon = 1 \text{ (din (5.27) și (5.25)).} \blacksquare$$

Corolarul 1. Eroarea relativă pentru euristica 1-INT poate fi oricât de mare, pentru $n \geq 4$, adică $re(N_1) = \infty$, pentru $n \geq 4$. ■

Corolarul 2. Eroarea relativă pentru euristica ADJ poate fi oricât de mare, pentru $n \geq 4$, adică $re(N_A) = \infty$, pentru $n \geq 4$. ■

Se pot demonstra proprietăți asemănătoare pentru erorile relative ale euristicilor BS și GS.

Observație: Identificarea vecinătăților din tabelul 5.20. se efectuează astfel. Pentru $N_A(s)$ și $N_1(s)$ modul de identificare este evident. Pentru $N_{BS}(s)$ și $N_{GS}(s)$ se obțin succesiunile de mai jos din care se elimină, parcurgându-le de la dreapta la stânga $s(i)$ -urile ce se repetă.

$$\begin{array}{ll} N_{BS}(s) & k = 1, l = 2 \quad g = (s(1), s(2), s(1), s(3), s(4)) = (2, 1, 3, 4), \\ & k = 1, l = 3 \quad g = (s(1), s(2), s(3), s(1), s(4)) = (2, 3, 1, 4), \\ & k = 1, l = 4 \quad g = (s(1), s(2), s(3), s(4), s(1)) = (2, 3, 4, 1), \\ & k = 2, l = 3 \quad g = (s(1), s(1), s(3), s(2), s(4)) = (1, 3, 2, 4), \\ & k = 2, l = 4 \quad g = (s(1), s(1), s(3), s(4), s(2)) = (1, 3, 4, 2), \\ & k = 3, l = 4 \quad g = (s(1), s(2), s(4), s(3)) = (1, 2, 4, 3). \end{array}$$

$N_{GS}(s) = N_{BS}(s) \cup$ mulțimea ce urmează în care secvențele marcate cu * se elimină, deoarece figurează și în $N_{BS}(s)$.

$$\begin{array}{ll} k = 2, l = 1 & g = (s(1), s(2), s(1), s(3), s(4)) = (2, 1, 3, 4), \quad * \\ k = 3, l = 1 & g = (s(1), s(3), s(1), s(2), s(4)) = (3, 1, 2, 4), \\ k = 3, l = 2 & g = (s(1), s(3), s(2), s(4)) = (2, 3, 4, 1), \quad * \\ k = 4, l = 1 & g = (s(1), s(4), s(1), s(2), s(3)) = (4, 1, 2, 3), \\ k = 4, l = 2 & g = (s(1), s(1), s(4), s(2), s(3)) = (1, 4, 2, 3), \\ k = 4, l = 3 & g = (s(1), s(2), s(4), s(3)) = (1, 2, 4, 3). \quad * \end{array}$$

5.4.6. Planificarea activităților folosind grafuri liniare

Punerea problemei. Fie $G(A, R)$ un graf orientat în care A este mulțimea nodurilor reprezentând operațiile și R mulțimea arcelor reprezentând ordonarea operațiilor pe procesoare, astfel încât operația corespunzătoare nodului k o precede pe cea corespunzătoare nodului l dacă arcul $(k, l) \in R$ și se notează $k \ll l$. Fiecărui arc (k, l) i se asociază o pondere t_k reprezentând timpul necesar efectuării operației ce

corespunde nodului k . Fie n numărul de activități și A_j mulțimea nodurilor asociate operațiilor ce urmează să fie efectuate pe procesorul j , m numărul de procesoare și $B_i \subset A$ mulțimea nodurilor asociate activității i . Momentele de start ale operațiilor corespunzătoare nodului k se notează cu s_k și momentele (timpii) de încheiere ale acestor operații cu c_k , unde $c_k = s_k + t_k$. Se cere să se identifice momentele de start ale operațiilor astfel încât timpul de încheiere a procesării $T(S) = \max_k [c_k]$ să fie minim. ■

Se prezintă un algoritm pentru găsirea unei soluții optimale sau aproape optimale a planificării activităților. În cadrul algoritmului se folosesc grafuri liniare pentru formularea problemei, un criteriu eficient pentru rezolvarea conflictelor și un procedeu quasi-boolean pentru evaluarea secvențelor realizabile.

Exemplul 5.46. Fie cazul a două activități ce urmează să fie efectuate pe trei procesoare, în modul descris în tabelul 5.21. și figura 5.33.

Activitatea i		1			2	
Procesorul j	1	3	2		3	2
Operația i_j	11	13	12		23	22
Nodul k	1	5	3		6	4
Timpul de lucru t_k	2	4	1		3	5

Tabelul 5.21.




Fig. 5.33.

Ordinea de ocupare a celor trei procesoare de către cele două activități este $11 \ll 13 \ll 12$, pentru activitatea 1, și $23 \ll 21 \ll 22$, pentru activitatea 2.

Nodurile grafului de precedență din figura 5.33. sunt numerotate astfel încât $k=j+(i-1)n$, unde $n=2$ este numărul de activități. Rezultă că $B_1=\{1,2\}$, $B_2=\{3,4\}$ și $B_3=\{5,6\}$. Mulțimile A_1 și A_2 sunt respectiv $\{1,5,3\}$ și $\{6,2,4\}$. Arcele pline din figura 5.33. definesc ordinea ocupării procesoarelor de către activitățile 1 și 2, nodurile grafului fiind parcurse în ordinea (1,5,3) pentru activitatea 1 respectiv în ordinea (6,2,4) pentru activitatea 2. Arcele punctate definesc succesiunea posibilă a operațiilor celor două activități pe cele trei procesoare și anume: $1 \ll 2$ sau $2 \ll 1$ pe procesorul 1, $3 \ll 4$ sau $4 \ll 3$ pe procesorul 2 și $5 \ll 6$ sau $6 \ll 5$ pe procesorul 3.

Urmărind graful din figura 5.33. și ținând seama de ordinile $11 \ll 13 \ll 12$, respectiv, $23 \ll 21 \ll 22$, ale operațiilor celor două activități pe cele trei procesoare, rezultă că operațiile 11, 13, respectiv 23, 21, pot fi efectuate în paralel pe procesoarele 1, 3 și 3, 1. Urmează efectuarea operațiilor 12 și 22 pe procesorul 2, fapt ce constituie un conflict, în sensul că aceste operații nu pot fi efectuate simultan. Rezolvarea acestui conflict trebuie să aibe în vedere minimizarea timpului de lucru, dar având în vedere că operațiile menționate sunt ultimele, rezultă că, independent de ordinea în care vor fi efectuate, ele vor necesita împreună $1+5=5+1=6$ unități de timp.

Ținând seamă de ordinea în care au fost parcurse arcele succesive divergente din nodul 6 al grafului din figura 5.33., rezultă că timpul consumat pentru efectuarea activităților este egal cu 13 unități. Acest rezultat este ilustrat pe figura 5.34. în care s-a presupus că momentele de start ale celor două activități sunt $r \in [0, 1]$ (pe desen s-a luat $r = 0$), respectiv 0, și intervalele de timp ocupate de aceste activități sunt desenate cu linii pline, respectiv întrerupte. ■




Fig. 5.34.

Plecând de la un graf de forma celui din figura 5.33., se construiește o matrice inițială de precedență Q^0 în care toate elementele asociate aceluiași procesor sunt grupate într-un același bloc. Astfel această matrice constă din m blocuri, fiecare conținând n elemente, dacă toate activitățile sunt executate pe fiecare procesor. Fiecare element $q_{k,l}^0$ al matricii este egal cu t_k dacă relația $k \ll l$ este precizată (arc plin în graf), xt_k dacă $k \ll l$ este posibilă (arce punctate în graf) și 0 dacă relația menționată este imposibilă. Această matrice este succesiv rescrisă astfel încât la fiecare iterație măcar una dar nu mai multe decât m valori xt_k trec în t_k și celelalte devin nule, ceea ce corespunde la reprezentarea prin linii pline a arcelor din graf G asociate valorilor t_k și eliminarea celor asociate valorilor devenite nule.

În procesul iterativ de atribuire de noi valori elementelor matricii pot apare situații de conflict, de forma celei exemplificate. Pentru rezolvarea acestor situații se pot folosi diferite strategii, cum ar fi: alegerea aleatoare a variantei de continuare sau utilizarea unei margini convenabil alese. Pe baza investigațiilor experimentale se propune o margine care asigură valori foarte apropiate ale timpului consumat față de timpul minimal. Această margine este definită prin atribuirea fiecărui nod k a mulțimii în conflict a valorilor expresiei:

$$L(k) = c_k + \max \left(\sum_{\substack{l \in M_{j,\phi} \\ l \neq k}} t_l, \sum_{\substack{l \in M_{j,\theta} \\ l \neq k}} t_l, \sum_{\substack{l \in J_{m,\phi} \\ l \neq k}} t_l, \min_{l \in J_{m,\phi}} (s_l - t_l) - c_k + \sum_l t_l \right),$$

unde c_k este timpul de terminare în nodul k , θ mulțimea nodurilor în conflict și Φ mulțimea nodurilor neasignate. Prima sumă reprezintă timpul total de procesare al nodurilor neasignate asociate aceleiași activități ca și nodul k . A doua sumă reprezintă timpul total de procesare a nodurilor din mulțimea în conflict asociate altor procesoare decât cele asociate nodului k . A treia sumă reprezintă timpul total de procesare a nodurilor neasignate asociate aceluiași procesor ca și nodul k . În sfârșit, ultimul termen reprezintă timpul minimal pentru procesarea celorlalte noduri neasignate. Din mulțimea nodurilor în conflict se alege acela pentru care $L(k)$ are o valoare minimă. Algoritmul propus este prezentat în continuare.

Algoritmul 5.35. (*Grafuri liniare*)

- [Inițializare] Se construiește vectorul start inițial: $S^0 = [s_k^0]$, $k = 1, 2, \dots, n$, unde $s_k^0 = i$ dacă k nu are predecesor și $s_k^0 = 0$ altfel. Se construiește matricea de precedență cuantificată astfel încât: $Q^0 = [q_{k,l}^0]$, $k, l = 1, 2, \dots, n$, unde $q_{k,l}^0 = t_k$ dacă $k \ll l$ este dată, $q_{k,l}^0 = xt_k$ dacă $k \ll l$ este posibilă și $q_{k,l}^0 = 0$ dacă $k \ll l$ este imposibilă. Se face $i = 0$.
- [Alegere] Se identifică coloana (coloanele) candidat în care elementele nenule figurează într-un rând marcat sau au coeficientul x . Dacă nu există noduri (coloane ale matricii) în conflict în nici un bloc asociat procesoarelor, se marchează fiecare coloană candidat cu "V". Dacă există un conflict într-un bloc de procesare, se calculează marginea $L(k)$ pentru fiecare nod și se alege nodul cu $L(k)$ minim.
- [Asignare] Se asignează nodurile având coloanele marcate. Se schimbă elementele coloanei l din matricea de precedență punând $xt_k = t_k$ dacă rândul k este marcat și $xt_k = 0$ altfel. Se schimbă fiecare rând marcat k din matricea de precedență punând $xt_k = 0$ în toate coloanele. Se marchează modificările pe coloane cu "W" și pe linii cu "V". Se obține astfel matricea Q^{i+1} . Se face $i = i + 1$.
- [Ciclare] Se determină o secvență realizabilă repetând pașii 2 și 3 până când toate nodurile sunt marcate.
- [Evaluare] Se evaluează secvența obținută. Se identifică primul vector S calculând succesiv: $S^k = S^{k-1} * [S^{k-1} \# Q^k]$, $k = 1, 2, \dots$ până când doi vectori succesivi devin identici. Se calculează timpul de lucru: $T(S) = \max_k (s_k + t_k)$ și secvența corespunzătoare. ■

Operatorul $\#$ reprezintă un caz special de înmulțire a două matrice, la înmulțire participând numai liniile și coloanele marcate "V" și elementele de forma x_j nu participă la înmulțire. Operatorul $*$ semnifică concatenarea intervalelor de timp și

alegerea celui mai mare dintre intervale atunci când două sau mai multe rânduri ale lui Q sunt marcate cu "V".

Exemplul 5.47. Pentru datele din exemplul 5.46., calculele evoluează după cum urmează.

Pasul 1. Inițializare graful de precedență. Vectorul inițial S^0 și matricea de precedență Q^0 se deduc din figura 5.33. și au forma:

$$S^0 = [i \ 0 \ 0 \ 0 \ 0 \ i] \text{ și } Q^0 = \begin{matrix} & \begin{matrix} V & & & & V \end{matrix} \\ \begin{matrix} 0 & x2 & 0 & 0 & 2 & 0 \\ x4 & 0 & 0 & 4 & 0 & 0 \\ 0 & 0 & 0 & x1 & 0 & 0 \\ 0 & 0 & x5 & 0 & 0 & 0 \\ 0 & 0 & 4 & 0 & 0 & x4 \\ 0 & 3 & 0 & 0 & x3 & 0 \end{matrix} \end{matrix}.$$

Pasul 2. Se identifică coloanele candidate în matrice, inițial numai coloanele 1 și 6, și sunt marcate cu "V".

Pasul 3. Se asignează nodurile 1 și 6, adică se anulează elementele $q_{2,1}$ și $q_{5,6}$ din coloanele marcate. Drept rezultat se obține matricea Q^1 .

$$Q^1 = \begin{matrix} & \begin{matrix} W & V & & & V & W \end{matrix} \\ \begin{matrix} V \\ 0 \\ 0 \\ 0 \\ 0 \\ V \end{matrix} \begin{matrix} (0 & x2 & 0 & 0 & 2 & 0) \\ (0 & 0 & 0 & 4 & 0 & 0) \\ (0 & 0 & 0 & x1 & 0 & 0) \\ (0 & 0 & x5 & 0 & 0 & 0) \\ (0 & 0 & 4 & 0 & 0 & 0) \\ (0 & 3 & 0 & 0 & x3 & 0) \end{matrix} \end{matrix},$$

Pasul 4. Se repetă pașii 2 și 3 până când se obține o secvență realizabilă. Se asignează nodurile 2 și 5, adică $q_{1,2}$ ia valoarea 2 și $q_{6,5}$ ia valoarea 3. Se obține matricea Q^2 .

$$Q^2 = \begin{matrix} & \begin{matrix} W & W & V & & W & W \end{matrix} \\ \begin{matrix} V \\ V \\ 0 \\ 0 \\ V \\ V \end{matrix} \begin{matrix} (0 & 2 & 0 & 0 & 2 & 0) \\ (0 & 0 & 0 & 4 & 0 & 0) \\ (0 & 0 & 0 & x1 & 0 & 0) \\ (0 & 0 & x5 & 0 & 0 & 0) \\ (0 & 0 & 4 & 0 & 0 & 0) \\ (0 & 3 & 0 & 0 & 3 & 0) \end{matrix} \end{matrix}.$$

Nodurile 3 și 4 fiind în conflict, urmează să li se calculeze marginile lor. Efectuând calculele, se obține $L(3)=8+\max(0,5,5)=13$ și $L(4)=12+\max(0,1,1)=13$. Cele două margini fiind egale, se alege nodul 3. Efectuând asignările rezultă matricea Q^3 . În încheiere se asignează nodul 4 și se obține matricea Q^4 .

Pasul 5. Se evaluează secvența. Multiplicând matricea finală Q^4 cu vectorul inițial S^0 rezultă patru vectori, al treilea și al patrulea fiind identici și egali cu:

$$S = (i \ 3 \ 7 \ 8 \ 3 \ i)$$

$$Q^3 = \begin{matrix} & W & W & W & V & W & W \\ \begin{matrix} V \\ V \\ V \\ V \\ V \\ V \end{matrix} & \begin{pmatrix} 0 & 2 & 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 4 & 0 & 0 \\ 0 & 0 & 0 & x1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 4 & 0 & 0 & 0 \\ 0 & 3 & 0 & 0 & 3 & 0 \end{pmatrix} \end{matrix},$$

$$Q^4 = \begin{matrix} & W & W & W & W & W & W \\ \begin{matrix} V \\ V \\ V \\ V \\ V \\ V \end{matrix} & \begin{pmatrix} 0 & 2 & 0 & 0 & 2 & 0 \\ 0 & 0 & 0 & 4 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 4 & 0 & 0 & 0 \\ 0 & 3 & 0 & 0 & 3 & 0 \end{pmatrix} \end{matrix}.$$

Prin urmare timpul de lucru este egal cu 13 unități. ■

5.4.7. Analiza euristiciilor pentru programări stohastice

În activitatea de planificare managerială apar frecvent probleme cu mai multe etape de decizie. Drept exemplu se poate considera problema procesării activităților, în cadrul căreia există măcar două etape de decizie. În prima etapă se decide achiziționarea resurselor. De obicei nu se știe cu precizie cât de largă trebuie să fie alocarea resurselor, din cauza necunoașterii exacte a dezvoltărilor viitoare, sau această problemă este în mod intenționat ignorată, în vederea facilitării luării deciziei. În continuare, la nivelul *detalierii* se decide alocarea resurselor în timp, atunci când se cunosc informațiile relevante.

Să considerăm mai întâi cazul procesării pe mașini identice. În prima etapă se decide numărul m de mașini *paralele identice* ce trebuiesc achiziționate, cunoscând *costul* c al unei mașini, numărul n de *activități* I_1, \dots, I_n ce urmează a fi procesate și *distribuția probabilității* vectorului $\bar{t} = (\bar{t}_1, \dots, \bar{t}_n)$ al *timpilor de procesare* a activităților. În a doua etapă, după ce a fost determinat m și este cunoscută o realizare t a lui \bar{t} , se decide ordinea activităților astfel încât fiecare mașină să fie ocupată cu cel mult o activitate, orice activitate I_j fiind procesată fără întreruperi într-un timp de mărime t_j și nu înaintea momentului 0.

Obiectivul celei de a doua etape constă în minimizarea timpului de procesare, cunoscând valorile m și t . Fie $C^*(m, t)$ valoarea minimă a timpului ce urmează a fi calculată. Obiectivul global constă în minimizarea, pe mulțimea realizărilor lui \bar{t} , a valorii medii a costului total $\bar{z}^*(m) = cm + C^*(m, \bar{t})$, adică determinarea unui m^* astfel încât să aibă loc relația:

$$Ez^*(m^*) = \min_m \{cm + EC^*(m, \bar{t})\}.$$

Calculul lui $C^*(m, t)$, pentru valori date m și t , constituie o problemă NP-dificilă, astfel încât determinarea mediei $EC^*(m, \bar{t})$ ca funcție de m și o distribuție arbitrară a probabilității vectorului \bar{t} pare imposibilă. În cadrul elaborării euristicii pentru prima etapă a problemei, se aplică o idee care este fundamentală pentru toate sistemele de planificare ierarhică și care constă în ignorarea structurii combinatoriale fine a celei de-a doua etape și înlocuirea lui $C^*(m, t)$ cu *marginea inferioară* T/m , unde $T = \sum_{j=1}^n t_j$. Problema rezultată constă în minimizarea valorii medii a marginii inferioare a lui $z^*(m)$ definită prin $\bar{z}^{LB} = cm + \bar{T}/m$, adică euristica acceptată pentru m valoarea $m = m^{LB}$, unde:

$$Ez^{LB}(m^{LB}) = \min_m \left\{ cm + \frac{E\bar{T}}{m} \right\}.$$

Derivata funcției obiectiv se anulează pentru $m = \sqrt{E\bar{T}/c}$. Deoarece m trebuie să fie un întreg pozitiv, valoarea lui m^{LB} se determină pe calea minimizării lui $cm + E\bar{T}/m$, cu condiția că:

$$m \in \left\{ \left\lfloor \sqrt{E\bar{T}/c} \right\rfloor \left\lceil \sqrt{E\bar{P}/c} \right\rceil \right\} \cap \mathbb{N}.$$

Euristica celei de a doua etape constă în procesarea activităților I_1, I_2, \dots, I_n cu timpi de lucru t_1, t_2, \dots, t_n pe m^{LB} mașini în conformitate cu regula: activitățile sunt ordonate arbitrar și la fiecare pas următoarea activitate din listă este asignată primei mașini devenită liberă (ca în figura 5.35.). Fie $C^{LS}(m, t)$ timpul minim în care toate activitățile sunt procesate în conformitate cu regula descrisă, pentru valori date ale lui m și t și fie $\bar{z}^{LS}(m) = cm + C^{LS}(m, \bar{t})$. Euristica în două etape generează o soluție de cost total $z^{LS}(m^{LB})$.




Fig. 5.35.

Valoarea medie în cel mai rău caz a euristicii propuse este caracterizată de rezultatul teoremei 5.29. Fie $t_{\max} = \max_j \{t_j\}$.

Teorema 5.29.

$$\frac{E\bar{z}^{LS}(m^{LB})}{Ez^*(m^*)} \leq 1 + \frac{E\bar{t}_{\max}}{2\sqrt{cET}}.$$

Demonstrație. Fie o procesare obținută în conformitate cu regula descrisă mai sus, utilizând m^{LB} mașini pentru realizarea t a lui \bar{t} . Fie L cel mai lung timp cât sunt ocupate toate mașinile și I_k lucrarea cel mai târziu terminată. Din felul în care este realizată procesarea (vezi figura 5.35.) rezultă că:

$$C^{LS}(m^{LB}, t) \leq L + t_k \leq T / m^{LB} + t_{\max}$$

și prin urmare:

$$z^{LS}(m^{LB}) \leq z^{LB}(m^{LB}) + t_{\max}.$$

Într-adevăr, din relațiile $\bar{z}^{LS}(m) = cm + C^{LS}(m, \bar{t})$ și $\bar{z}^{LB} = cm + \bar{T} / m$, pentru un vector T dat și $m = m^{LB}$, rezultă:

$$z^{LS}(m^{LB}) = cm^{LB} + C^{LS}(m^{LB}, t), \quad z^{LB}(m^{LB}) = cm^{LB} + T / m^{LB} \quad \text{și}$$

$$z^{LS}(m^{LB}) - z^{LB}(m^{LB}) = C^{LS}(m^{LB}, t) - T / m^{LB} \leq t_{\max}.$$

Luând mediile rezultă că:

$$E\bar{z}^{LS}(m^{LB}) \leq E\bar{z}^{LB}(m^{LB}) + E\bar{t}_{\max} \leq E\bar{z}^{LB}(m^*) + E\bar{t}_{\max} \leq E\bar{z}^*(m^*) + E\bar{t}_{\max}.$$

A doua inegalitate rezultă din definiția lui m^{LB} și ultima deoarece $T / m^* \leq C^*(m^*, t)$ pentru că $\bar{z}^*(m^*) = cm^* + C^*(m^*, \bar{t})$, $\bar{z}^{LB}(m^*) = cm^* + \bar{T} / m^*$ și T / m^* este margine inferioară pentru $C^*(m^*, t)$.

Pe de altă parte:

$$E\bar{z}^*(m^*) \geq E\bar{z}^{LB}(\sqrt{ET} / c) = 2\sqrt{cET}.$$

Din inegalitatea de mai înainte rezultă:

$$E\bar{z}^{LS}(m^{LB}) \leq E\bar{z}^*(m^*) + E\bar{t}_{\max}$$

și din cea precedentă se deduce:

$$\frac{E\bar{z}^{LS}(m^{LB})}{Ez^*(m^*)} \leq \frac{E\bar{z}^*(m^*) + E\bar{t}_{\max}}{Ez^*(m^*)} = 1 + \frac{E\bar{t}_{\max}}{Ez^*(m^*)} \leq 1 + \frac{E\bar{t}_{\max}}{2\sqrt{cE\bar{t}}}. \blacksquare$$

O altă proprietate interesantă este următoarea:

$$\lim_{n \rightarrow \infty} \frac{E\bar{z}^{LS}(m^{LB})}{E\bar{z}^*(m^*)} = 1.$$

Se poate considera o extensie a modelului studiat mai înainte, pentru cazul unei mulțimi date de mașini neuniforme, pentru fiecare dintre ele cunoscându-se *costul* c_j și *viteza* v_j . Atunci când în etapa a doua o activitate I_i este asignată mașinii j , ea trebuie procesată într-un interval de timp de mărime t_i / v_j .

5.4.8. Planificări preemptive și cu divizarea procesorilor

Unele sisteme de procesoare permit întreruperea execuției unei activități și reluarea acesteia ulterior, eventual pe un alt procesor. Aceste planificări se numesc *planificări preemptive*. Dacă timpul necesar pentru efectuarea unei întreruperi (conservarea stării la întrerupere și restabilirea condițiilor la reluare) este neglijabil, programările preemptive pot să fie mai eficiente decât cele nepreemptive, după cum se vede din exemplul următor.

Exemplul 5.48. Să considerăm 3 activități independente de durate 2 fiecare programate pe două procesoare. O planificare optimală nepreemptivă este arătată în figura 5.36.a) fiind de durată 4 și o planificare optimală preemptivă este dată în figura 5.36.b) fiind de durată 3. ■




Fig. 5.36.

Planificarea preemptivă a n activități independente cu timpii de execuție t_1, t_2, \dots, t_n pe m procesoare identice se poate face aplicând algoritmul următor.

Algoritmul 5.36. (Planificare preemptivă)

- [Timp probabil] Se calculează $T = \frac{1}{m} \sum_{i=1}^n t_i$.
- [Depășiri] Dacă există o activitate i astfel încât $t_i > T$, atunci se planifică activitatea i pe procesorul m , se face $m = m - 1$, se elimină activitatea i din mulțimea activităților, se face $n = n - 1$ și se trece la pasul 1.
- [Inițializări] Se face $j = 1$, $\tau = T$ și $i = 1$.
- [Terminare] Dacă $i > n$, atunci STOP.
- [Testare procesor] Dacă $t_i \leq \tau$, atunci se planifică activitatea i pe procesorul j , se face $\tau = \tau - t_i$, $i = i + 1$ și se trece la pasul 4.
- [Preemțiune] Se face $t'_i = \tau$, $t''_i = t_i - \tau$. Dacă $\tau \neq 0$, se planifică t'_i din activitatea i pe procesorul j .
- [Procesorul următor] Se face $j = j + 1$, $\tau = T - t''_i$, se planifică t''_i din activitatea i pe procesorul j . Se face $i = i + 1$ și se trece la pasul 4. ■

Teorema 5.30. Algoritmul 5.36. determină o planificare optimă preemptivă a unui sistem de activități independente pe m procesoare, timpul total al planificării fiind dat de expresia:

$$t_{\min} = \max \left\{ \max_i \{t_i\}, \frac{1}{m} \sum_{i=1}^n t_i \right\}.$$

O demonstrație a acestei teoreme se poate găsi în [BĂS89]. ■

Exemplul 5.49. Pentru un sistem cu 7 activități care au timpii de execuție respectiv 3, 7, 2, 4, 2, 5, 2, care trebuie planificate pe 4 procesoare, aplicând algoritmul 5.36. se obține planificarea din figura 5.37. de valoare 7 în care activitățile 4 și 6 sunt întrerupte după ce execută 3, respectiv 4, unități de timp, urmând ca o unitate de timp să o execute fiecare pe un alt procesor. Pe figură apare numerotarea inițială. Se poate determina aici o programare nepreemptivă de aceeași durată. ■




Fig. 5.37.

În planificarea cu divizarea procesorilor, se consideră că în același timp pe un procesor sunt asignate mai multe activități, fiecare activitate i folosind o anumită fracție β_i , cu $0 < \beta_i \leq 1$. Pentru a acoperi timpul t_i de execuție corespunzător activității i , în acest caz, trebuie să treacă un timp fizic t_i / β . Diagrama Gantt se extinde pentru aceste planificări prin introducerea unor subdiviziuni orizontale pentru a nota asignările de factor β . Factorul β nu se schimbă pe tot parcursul execuției unei activități.

Exemplul 5.50. Pentru un sistem cu 5 activități ce necesită o unitate de timp pentru fiecare și care au graful de precedență din figura 5.38.a), se poate determina programarea cu divizarea procesorilor pe 2 procesoare din figura 5.38.b) de valoare 3.5. O programare optimă fără divizarea procesorilor a acestui sistem este dată în figura 5.38.c), fiind de valoare 4. ■




Fig. 5.38.

Dacă este permisă modificarea în timp a factorului de alocare a unui procesor la o activitate se obține o *planificare generală*. Planificările cu preemțiune și cu divizarea procesorilor pot fi considerate cazuri particulare ale planificării generale.

Exemplul 5.51. Să considerăm un sistem cu 8 activități care au timpii de execuție 1,1,2,2,3,1,1,1 și sunt planificate pe doi procesoare. Graful de precedență este dat în figura 5.39.a) și o planificare generală optimă în figura 5.39.b). ■




Fig. 5.39.

Pentru compararea unor strategii de planificare vom considera că strategia S_1 este mai eficientă decât strategia S_2 dacă și numai dacă pentru fiecare planificare P_2 obținută aplicând strategia S_2 unui sistem de activități cu o relație de precedență dată se poate obține o planificare P_1 prin strategia S_1 de durată cel mult egală cu durata lui P_2 și există sisteme de activități pentru care strategia S_1 conduce la programări de durată mai mică decât cele obținute aplicând strategia S_2 . Două strategii S_1 și S_2 sunt de aceeași eficiență dacă planificările generate de ele au aceeași durată.

Exemplul 5.50. arată că planificarea cu divizarea procesorilor, deci și planificarea generală, este mai eficientă decât planificarea nepreemptivă. Exemplul 5.48. arată că planificarea preemptivă, deci și planificarea generală, este mai eficientă decât cea nepreemptivă.

Teorema 5.31. Planificarea generală și planificarea preemptivă sunt de aceeași eficiență.

Demonstrație. Este suficient de a demonstra că pentru orice planificare generală se poate determina o planificare preemptivă de aceeași durată. Se vede imediat că aplicând algoritmul următor pentru orice planificare generală pe m procesori pentru un sistem de activități cu o relație de precedență dată se obține o programare preemptivă, validă în raport cu relația de precedență de aceeași durată. Validitatea programării rezultă din observația că activitățile planificate pe o perioadă de timp pe care nu se schimbă asignările sunt independente între ele, altfel una dintre ele ar trebui să fie terminată înainte de a începe cealaltă. ■

Algoritmul 5.37. (Transformare general-preemptiv)

1. [Inițializări] Se face $t_0 = 0$ și $i = 0$.
2. [Terminare] Dacă t_i este egal cu timpul programării generale, atunci STOP.
3. [Interval următor] Se face $i = i + 1$ și se determină momentul următor t_i din planificarea generală când au loc modificări în asignări (terminări, întreruperi sau modificarea coeficientului de atribuire a cel puțin unei activități).
4. [Echivalare timp] Pentru toate activitățile i_1, i_2, \dots, i_k ce se execută în intervalul de timp $[t_{i-1}, t_i]$ cu factorii de ocupare $\beta_1, \beta_2, \dots, \beta_k$ se consideră timpii efectivi de execuție dați de expresiile $t'_j = \beta_j (t_i - t_{i-1}), j = 1, 2, \dots, k$.

5. [Planificare preemtivă] Se aplică algoritmul 5.36. de planificare preemtivă a activităților i_1, i_2, \dots, i_k ce se execută în intervalul de timp $[t_{i-1}, t_i]$ cu timpii $t'_j, j = 1, 2, \dots, k$.
6. [Ciclare] Se trece la pasul 2. ■

Exemplul 5.52. Aplicând algoritmul 5.37. la programarea obținută în exemplul 5.51. se obține planificarea din figura 5.40, unde $t_0=0, t_1=1.5, t_2=2.5, t_3=5$ și $t_4=6$. ■




Fig. 5.40.

Teorema 5.32. Planificarea preemtivă, deci și planificarea generală este mai eficientă decât planificarea cu divizarea procesorilor.

Demonstrație. Deoarece planificarea cu divizarea procesorilor este un caz particular de planificare generală, aplicând proprietatea din teorema 5.31., rezultă că este suficient de dat un exemplu în care planificarea preemtivă dă un timp mai bun decât planificarea optimă cu divizarea procesoarelor. Aceasta este dovedită de exemplul 5.53. ■





Fig. 5.41.

Exemplul 5.53. Pentru un sistem de 6 activități având timpii de execuție respectiv 1,1,1,1,1,3, cu graful de precedență din figura 5.41.a) și care trebuie planificate pe 2 procesori, o planificare optimă cu divizarea procesorilor are forma din figura 5.41.b). Valoarea lui β se determină din condiția ca activitățile 5 și 6 să se termine în același timp. Pentru toate celelalte variante valide se pot da contraexemple de programări de durate mai scurte. Se obține astfel ecuația $2+1/\beta=3/(2-3\beta)$. Din aceasta rezultă ecuația de gradul al II-lea $3\beta^2+\beta-1=0$, care are soluția pozitivă

$\beta = \frac{\sqrt{13} - 1}{6}$. De aici rezultă timpul programării $\frac{5 + \sqrt{13}}{2} > 4$. În figura 5.41.c) este dată soluția generală optimală de valoare 4 și în figura 5.41.d) este dată soluția preemtivă corespunzătoare de aceeași durată. ■

Teorema 5.33. Fie t_N și t_P duratele planificărilor obținute la planificarea nepreemtivă, respectiv preemtivă, a unui sistem de activități pe $m > 1$ procesoare. Atunci are loc relația:

$$t_N / t_P \leq 2 - 1 / m.$$

În plus, $2 - 1 / m$ este cea mai mică limită superioară a raportului duratelor celor două programări pentru orice sistem de activități.

O demonstrație a acestei proprietăți se poate găsi în [BĂS89]. ■

Determinarea unei planificări generale pentru un sistem de activități se poate face cu euristica descrisă în algoritmul 5.38. Se folosește aici noțiunea de nivel al unei activități i , notat $niv(i)$ și definit în felul următor:

$niv(i) = t_i$, pentru orice activitate i terminală;

$niv(i) = t_i + \max\{niv(j) \mid j \text{ succesori direcți ai lui } i\}$, pentru orice activitate i pentru care au fost determinate nivelurile succesorilor ei direcți.

Algoritmul 5.38. (Programare pe nivele)

- [Inițializări] Se face $s_0 = 0$, $i = 0$ și se consideră toate activitățile *neexecutate*.
- [Nivel] Se calculează $niv(j)$, pentru activitățile sistemului. Dacă există activități pentru care nu se poate face calculul, atunci STOP. (Graful are cel puțin un ciclu).
- [Terminare] Dacă toate activitățile au fost *executate*, atunci STOP; altfel, se face $p = m$ și se consideră că nu sunt activități în execuție.
- [Alegere nivel] Se determină mulțimea B a activităților pentru care au fost executate predecesoarele directe, neprogramate la execuție și de nivel maxim cu aceste proprietăți. Dacă $B = \emptyset$, atunci se merge la pasul 7.
- [Caz fără divizare] Dacă $|B| \leq p$, atunci se programează din momentul s_i activitățile din B cu factorul 1, acestea fiind considerate în execuție, se face $p = p - |B|$ și dacă $p > 0$, atunci se trece la pasul 4; altfel se trece la pasul 7.
- [Caz cu divizare] Se programează din momentul s_i activitățile din B cu factorul $p / |B|$, acestea fiind considerate în execuție.
- [Moment realocare] Se face $i = i + 1$ și se determină $s_i = s_{i-1} + \tau$, unde τ este dat de formula:

$$\tau = \min\{\tau_1, \tau_2, \tau_3\}, \text{ cu}$$

$$\tau_1 = \min\{t_j / \beta_j \mid j \text{ activitate în execuție}\} \text{ și}$$

$$\tau_2 = \min\{(niv(j) - niv(k)) / (\beta_k - \beta_j) \mid j \neq k \text{ activități în execuție pentru care } niv(j) > niv(k) \text{ și } \beta_j < \beta_k\}, \text{ (dacă mulțimea e vidă se ia } \tau_2 = +\infty).$$

$\tau_3 = \min\{(niv(j) - niv(k)) / \beta_j \mid j \text{ activitate în execuție și } k \text{ activitate neprogramată, cu toți predecesorii executați și } niv(j) > niv(k)\},$
(dacă mulțimea e vidă se ia $\tau_3 = +\infty$).

8. [Ajustări] Pentru activitățile j în execuție se face $niv(j) = niv(j) - \tau \cdot \beta_j$ și $t_j = t_j - \tau \cdot \beta_j$; activitățile j pentru care se obține $t_j = 0$ se consideră executate și celelalte se consideră că nu sunt executate.
9. [Ciclare] Se merge la pasul 3. ■

Exemplul 5.54. Pentru un sistem de 7 activități având timpii de execuție respectiv 2,2,2,4,1,1,2, cu graful de precedență din figura 5.42.a) și care trebuie planificate pe 2 procesori, o planificare optimală generală a procesorilor care se obține aplicând algoritmul precedent este dată în figura 5.42.b). Valorile factorilor β sunt indicate pe figură numai pentru valorile subunitare. Momentele de schimbare a asignărilor sunt $s_0=0$, moment inițial, $s_1=2$, moment în care activitatea 4 ajunge la același nivel cu activitățile 1 și 2, $s_3=3.5$, moment în care se termină activitățile 1 și 2, $s_4=4.5$, moment în care se termină activitatea 4, $s_5=5.5$, moment în care se termină activitatea 3, și $s_6 = 7$, moment în care se termină activitățile 5, 6 și 7. Planificarea este de durată totală 7. ■





Fig. 5.42.

Teorema 5.34. Dacă se face planificare pe 2 procesori sau dacă graful asociat sistemului de activități este o antiarborescență, atunci soluția rezultată prin aplicarea algoritmului 5.38. este optimală.

O demonstrație a acestor proprietăți se poate găsi în [MUN69] și [MUN70]. ■


Faptul că algoritmul 5.38. nu furnizează soluția optimală pentru orice precedență și $m > 2$ se deduce din următorul exemplu.

Exemplul 5.55. Fie sistemul cu $4m$ activități, fiecare dintre ele executându-se într-o unitate de timp și având graful de precedență din figura 5.43.a), planificate pe m procesori. Pentru o mai ușoară descriere am notat activitățile cu litere cu indici. Aplicarea algoritmului 5.38. conduce la soluția din figura 5.43.b) de durată totală $5-2/m$. O programare optimală este arătată în figura 5.43.c), fiind de durată totală 4. ■

5.4.9. Planificări cu minimizarea timpului mediu

În majoritatea planificărilor prezentate până acum, criteriul de comparare este timpul total de procesare a sistemului de activități. Pot exista unele aplicații în care să

fie considerate și alte criterii de evaluare a planificărilor. Vom studia în acest paragraf un astfel de caz studiind problema de planificare în care criteriul este timpul mediu în sistem al activităților în care intervin atât timpii de execuție cât și timpii de așteptare.



P_1	r_1	β	u_1	x_1	β
	r_2	β		x_2	β
P_2	\vdots		u_2	\vdots	
	r_{m-1}	β		x_{m-1}	β
P_m	s_1	β		y_1	β
	s_2	β		y_2	β
P_m	\vdots			\vdots	
	s_m	β		y_m	β
	0	1	$2-1/m$	$3-1/m$	$5-2/m$

b) $\beta = m/(2m-1)$

P_1	s_1	u_2	u_1	y_1
P_2	s_2	r_1	x_1	y_2
	s_2	r_2	x_2	y_2
	\vdots	\vdots	\vdots	\vdots
	s_{m-1}	r_{m-2}	x_{m-2}	y_{m-1}
P_m	s_m	r_{m-1}	x_{m-1}	y_m
	0	1	2	3

c)

Fig. 5.43.

Dacă c_i este momentul terminării execuției activității i și presupunând că toate activitățile sunt disponibile în momentul inițial de programare, atunci timpul mediu în sistem, notat \bar{t} , este dat de următoarea expresie:

$$\bar{t} = \sum_{i=1}^n c_i.$$

Se poate stabili o legătură între timpul mediu în sistem și numărul mediu de activități neterminate din intervalul $(0, t_{\max})$, unde $t_{\max} = \max\{c_i\}$, notat cu \bar{n} . Numărul de activități neterminate este o variabilă discretă care ia valoarea n la momentul $t=0$ și valoarea 0 la momentul $t=t_{\max}$. Pentru o planificare dată, considerăm activitățile ordonate crescător în raport de momentul de terminare a execuției, adică $c_1 \leq c_2 \leq \dots \leq c_n$. Dacă se consideră $c_0=0$, atunci:

$$\bar{n} = \frac{1}{t_{\max}} \sum_{i=0}^{n-1} (n-i)(c_{i+1} - c_i).$$

Această relație se mai poate scrie sub forma:

$$\bar{n} = \frac{1}{t_{\max}} \left\{ \sum_{i=1}^n (n-i+1)c_i - \sum_{i=1}^n (n-i)c_i \right\} = \frac{1}{t_{\max}} \sum_{i=1}^n c_i$$

și, deoarece $\sum_{i=1}^n c_i = n\bar{t}$, rezultă relația $\frac{\bar{n}}{n} = \frac{\bar{t}}{t_{\max}}$. Aceasta arată că timpul mediu în sistem este direct proporțional cu numărul mediu de activități neterminate.

Pentru o problemă de planificare pe un singur procesor, în orice planificare optimală, nu există timpi de neutilizare a procesorului. Altfel, prin eliminarea acestor timpi, s-ar obține o utilizare mai bună în majoritatea criteriilor folosite. Astfel t_{\max} este o constantă ce reprezintă suma timpilor de execuție și orice procedură care minimizează timpul mediu în sistem va minimiza numărul mediu de activități neterminate și reciproc.

Să considerăm un sistem de activități constituit din r lanțuri independente C_1, C_2, \dots, C_r , fiecare lanț $C_i = \{A_{i1}, A_{i2}, \dots, A_{in_i}\}$, cu A_{ij} precede $A_{i,j+1}$ pentru $j=1, 2, \dots, n_i-1$.

Să notăm cu t_{ij} timpul de execuție a activității A_{ij} . Vom nota $n = \sum_{i=1}^r n_i$.

Algoritmul 5.39. (*Timp mediu minim*)

- [Timpi medii parțiali] Se face $p_i = 0$, pentru $i = 1, 2, \dots, r$. Se calculează valorile $\bar{t}_{ij} = \frac{1}{j - p_i} \sum_{h=p_i}^j t_{ih}$, pentru $j = p_i + 1, p_i + 2, \dots, n_i$ și $i = 1, 2, \dots, r$. Pentru fiecare lanț i se calculează $Z_i(h_i) = \min \{\bar{t}_{ij} \mid j = p_i + 1, p_i + 2, \dots, n_i\}$, unde h_i este indicele pentru care este atins minimul; dacă sunt mai mulți indici se ia cel mai mare. Se consideră toate activitățile din toate lanțurile ca neplanificate.
- [Terminare] Dacă toate activitățile din lanțuri au fost planificate, atunci STOP.
- [Alegere] Pentru un procesor care devine liber se alege un lanț C_k pentru care $p_k < n_k$, care nu conține activități ce urmează să se execute pe un alt procesor în același timp și pentru care $Z_k(h_k)$ este minim între activitățile cu aceste proprietăți. Dacă nu există astfel de lanțuri, atunci se trece la pasul 2.
- [Planificare] Se planifică pe procesorul liber activitățile $A_{kp_k+1}, \dots, A_{kh_k}$ din lanțul C_k și se face $p_k = h_k$.
- [Ajustări] Dacă $p_k < n_k$, atunci se recalculază $Z_k(h_k)$ pentru lanțul C_k cu formulele date la pasul 1.
- [Ciclare] Se merge la pasul 2. ■

Exemplul 5.56. Să considerăm lanțurile $C_1 = \{A_{11}, A_{12}, A_{13}, A_{14}\}$, cu timpii de execuție 4, 2, 3, 5, $C_2 = \{A_{21}, A_{22}, A_{23}\}$, cu timpii de execuție 1, 4, 2, $C_3 = \{A_{31}, A_{32}, A_{33}, A_{34}, A_{35}\}$, cu timpii de execuție 3, 2, 3, 4, 6 și $C_4 = \{A_{41}, A_{42}\}$, cu timpii de execuție 2, 5, executate pe 2 procesori cu minimizarea timpului mediu în sistem. Aplicând algoritmul 5.39. se obține în pasul 1, $p_1 = p_2 = p_3 = p_4 = 0$ și timpii medii următori: 4, 3, 3, 3, 5 cu $Z_1(3) = 3$ pentru lanțul C_1 , 1, 2, 5, 2, 3, 3... cu $Z_2(1) = 1$ pentru lanțul C_2 , 3, 2, 5, 2, 6, 6..., 3, 3, 6 cu $Z_3(2) = 2.5$ pentru lanțul C_3 și 2, 3, 5 cu $Z_4(1) = 2$ pentru lanțul C_4 .

La momentul $t = 0$, se consideră că procesorul P_1 devine liber și se selectează dintre toate lanțurile pentru programare lanțul C_2 din care se programează

activitatea A_{21} până la momentul 1. Se recalculează timpii medii: 4, 3 cu $Z_2(3) = 3$. Tot la momentul $t = 0$, se consideră că și procesorul P_2 devine liber și se selectează pentru programare dintre C_1 , C_3 și C_4 (C_2 are activități planificate în același timp pe P_1) lanțul C_4 din care se programează activitatea A_{41} până la momentul 2. Se recalculează timpii medii: 5 cu $Z_4(2) = 5$.

La momentul $t=1$, procesorul P_1 devine liber și se selectează dintre C_1 , C_2 și C_3 (C_4 are activități planificate în același timp pe P_2) pentru programare lanțul C_3 din care se programează activitățile A_{31} și A_{32} până la momentul 6. Se recalculează timpii medii: 3, 3.5, 4.33... cu $Z_3(3)=3$.

La momentul $t=2$, procesorul P_2 devine liber și se selectează dintre C_1 , C_2 și C_4 (C_3 are activități planificate în același timp pe P_2) pentru programare lanțul C_1 din care se programează activitățile A_{11} , A_{12} și A_{13} până la momentul 11. Se recalculează timpii medii: 5 cu $Z_1(4) = 5$.

Procedând în același fel în continuare se obține planificarea din figura 5.44. care dă un timp mediu în sistem de $155 / 14 = 11.07... \blacksquare$




Fig. 5.44.

Teorema 5.35. Aplicând algoritmul 5.39. pentru planificarea pe un procesor se obține un timp mediu în sistem minim.

O demonstrație a acestei proprietăți se găsește în [BÂS89]. \blacksquare

Un caz particular este cel în care fiecare lanț conține o singură activitate. Un astfel de sistem este cu activități independente. Algoritmul 5.39. se poate simplifica după cum se arată în continuare și se numește *cel mai scurt timp de execuție*, prescurtat *SPT*.

Algoritmul 5.40. (SPT)

- [Inițializări] Se consideră toate activitățile neplanificate.
- [Terminare] Dacă toate activitățile au fost planificate, atunci STOP.
- [Planificare] Când un procesor este liber, se planifică pe el o activitate care are cel mai scurt timp de execuție dintre activitățile neplanificate. Dacă sunt mai multe activități de acest fel, atunci se alege oricare dintre ele.
- [Ciclare] Se trece la pasul 2. \blacksquare

SPT este, într-un anumit fel, opusă planificării *LPT* (vezi paragraful 1.1.2.3.1). Dacă se notează cu t_{SPT} timpul total obținut aplicând planificarea *SPT* și cu t_{LPT} timpul total obținut aplicând planificarea *LPT*, atunci din teorema 5.33., rezultă inegalitățile:

$$1 \leq t_{SPT} / t_{LPT} \leq 2 - 1 / m.$$

Un alt caz particular este cel în care unele subșiruri din sublanțuri trebuie să fie executate fără a se putea întrerupe execuția între două activități consecutive din subșirul respectiv. Se poate obține un algoritm pentru determinarea soluției din algoritmul 5.39. făcându-se calculele pentru timpii medii din pașii 1 și 3 numai pentru indicii care corespund la activități, după care este posibilă o întrerupere a executării activităților din lanțul respectiv.

5.5. Aplicații

5.5.1. Algoritm efectiv de asamblare a lucrărilor

Punerea problemei. O linie de asamblare constă dintr-o succesiune de stații de lucru. Fiecare stație efectuează o mulțime de operații: fiecare operație este efectuată fără preempțiune. Timpul de execuție t_i al fiecărei operații i , unde $i = 1, 2, \dots, n$, este cunoscut și nu depinde de stația care îl efectuează, nici de operațiile care o preced sau o succed. Datorită restricțiilor tehnologice, unele operații trebuiesc efectuate înainte ca altele să fi început. Aceste condiții de precedență se presupun cunoscute. Fiecărei stații i se alocă o valoare predeterminată a timpului de lucru c , numită *durata ciclului*, în vederea operațiilor atribuite. Lucrările sunt terminate după ce toate operațiile au fost efectuate, $1 / c$ fiind productivitatea sistemului. ■

În continuare se consideră două variante ale problemei enunțate, numite *SALB-I* și *SALB-II*. Prima problemă constă în determinarea numărului minim al stațiilor, necesar pentru asigurarea ratei de producție ținând seama de restricțiile de precedență. A doua problemă constă în asignarea operațiilor unui număr dat de stații în vederea maximizării ratei de producție ținând seama de condițiile de precedență.

5.5.1.1. Euristici pentru problema *SALB-I*

O primăuristică pentru prima problemă se numește *euristica încărcării primei stații accesibile* și este exprimată prin următorul algoritm:

Algoritmul 5.41. (Prima stație accesibilă)

1. [Scoruri] Se atribuie un scor $s(i)$ fiecărei operații i .
2. [Actualizare] Se actualizează mulțimea operațiilor accesibile, adică a operațiilor a căror predecesori au fost atribuiți.

3. [Asignare] Se asignează operația cu cel mai înalt scor în prima stație în care capacitatea și restricțiile de precedență sunt satisfăcute.
4. [Ciclare] Dacă sunt operații neasignate, atunci se trece la pasul 2, altfel STOP. ■

Rezultatele sunt influențate de modul de alegere a funcției scor. Mai multe definiții ale funcției scor $s(i)$ sunt date în tabelul 5.22.

Nr.	Nume	Descrierea
1.	Pondere pozițională	Suma duratelor operației i și a celor care o urmează
2.	Pondere pozițională inversă	Suma duratelor operației i și a celor care o preced
3.	Numărul urmașilor	Numărul operațiilor ce urmează după i
4.	Numărul urmașilor imediați	Numărul operațiilor ce urmează imediat după i
5.	Numărul predecesorilor	Numărul operațiilor ce preced pe i
6.	Timpu de lucru	Durata operației i
7.	Pondere pozițională amonte	Suma duratei operației i și a tuturor operațiilor de pe drumuri având pe i ca rădăcină
8.	Arce amonte	Numărul de arce având drept rădăcină pe i

Tabelul 5.22.

Rezultatele experimentale privind eficiența euristicii *SALB-I* pentru diferite funcții $s(i)$ arată că pentru funcțiile numerice 1, 3, 4, 6, 7, 8 mai mult de 50% din soluțiile furnizate de euristica sunt optime.

O altă euristica pentru prima problemă se numește *euristica ordonare și asignare* și este exprimată prin următorul algoritm:

Algoritm 5.42. (Ordonare și asignare)

1. [Scoruri] Se atribuie un scor $s(i)$ fiecărei operații i .
2. [Ordonare] Se ordonează operațiile în ordinea necrescătoare a scorului.
3. [Asignare] Se asignează operația cu cel mai înalt scor în prima stație în care capacitatea și restricțiile de precedență sunt satisfăcute.
4. [Ciclare] Dacă sunt operații neasignate, atunci se trece la pasul 3, altfel STOP. ■

Această euristica a fost testată pentru funcțiile numerice 1, 3, 6, 7, 8, în toate cazurile, mai mult de 50% din soluțiile furnizate fiind optime.

Euristicele prezentate au următoarele două proprietăți:

1. Fiecare pereche de stații consecutive însumează un timp de lucru care este mai mare decât c , unde timpul de lucru al unei stații este definit ca fiind suma duratelor operațiilor ce i-au fost asignate.
2. Fiecare stație, eventual cu excepția ultimei stații, funcționează un timp mai mare decât $c - t^*$, unde $t^* = \max_i t_i$.

Fie S^* numărul optimal de stații. În teorema ce urmează sunt deduse marginile superioare ale performanței euristiciilor propuse.

Teorema 5.36. Fie S numărul de stații identificat de un algoritm, euristic sau optimal, ce au proprietățile 1. și 2. Atunci:

$$a) S \leq 2S^* - 1, b) S < c / (c - t^*) S^* + 1.$$

Demonstrație. Fie $S(j)$ mulțimea operațiilor asignate de euristica stației j . Deoarece timpul de lucru al unei stații nu depășește pe c , rezultă că:

$$S^* c \geq \sum_i t_i = \sum_{j=1}^S \sum_{i \in S(j)} t_i. \quad (5.28)$$

Din proprietățile 1. și 2. rezultă că:

$$\sum_{j=1}^S \sum_{i \in S(j)} t_i > \begin{cases} \frac{S}{2} \cdot c, & \text{dacă } S \text{ este par} \\ \frac{S-1}{2} \cdot c, & \text{dacă } S \text{ este impar} \end{cases} \quad (5.29)$$

$$\sum_{j=1}^S \sum_{i \in S(j)} t_i > (S-1)(c - t^*). \quad (5.30)$$

Ținând seama că dacă $a > b$, $a (=2S^*)$ și $b (=S \text{ sau } S-1)$ sunt întregi pari, atunci $a \geq b+2$, (5.28) și (5.29) implică $S \leq 2S^* - 1$ și din (5.28) și (5.30) rezultă $S < c/(c-t^*)S^* + 1$. ■

5.5.1.2. Euristici pentru problema SALB-II

În continuare arătăm felul în care metodele folosite pentru soluționarea problemei SALB-I pot fi adaptate la problema SALB-II. Fie $g(k)$, $k = 1, 2, \dots$ valoarea optimală a soluției problemei SALB-II dacă numărul de stații este k și $f(c)$, $c \geq t^*$ valoarea optimală furnizată de SALB-I pentru un c dat. Pentru determinarea lui $g(k)$ sunt propuse două metode.

În *metoda marginii inferioare* se începe cu o valoare cunoscută c_L a marginii inferioare și se determină $f(c_L)$. Dacă $f(c_L)$ nu întrece pe k , atunci valoarea optimală este c_L ; altfel, valoarea c_L nu este realizabilă și procesul de identificare a soluției se reia pentru $c_L + 1$.

În *metoda marginii superioare* se începe cu valoarea cunoscută c_U a marginii superioare, se face $c_m = \infty$ și se determină $f(c_U)$. Dacă $f(c_U)$ este mai mare decât k , atunci soluția optimală este c_m . Altfel se atribuie lui c_m valoarea timpului maxim de lucru al stațiilor ce corespunde marginii superioare curente c_U , se înlocuiește valoarea marginii superioare cu $c_m - 1$ și se continuă procesul.

În continuare se indică metoda de calcul a marginilor c_L și c_U , cu $T = \sum_i t_i$ fiind notat timpul total de lucru.

Teorema 5.37. $c_L(k) \leq g(k) \leq c_U(k)$, unde:

$$c_L(k) = \max \left\{ \left\lfloor \frac{T}{k} \right\rfloor^+, t^* \right\}$$

și

$$c_U(k) = \max \left(t^*, \begin{cases} \frac{2T}{k} & \text{dacă } k \text{ este par} \\ \frac{2T}{k+1} & \text{dacă } k \text{ este impar și } k \geq 3 \\ T & \text{dacă } k = 1. \end{cases} \right) \quad (5.31)$$

Demonstrație. Valoarea marginii inferioare este evidentă. Valoarea marginii superioare este evident corectă dacă $g(k) = t^*$ sau $k = 1$. Fie atunci $g(k) > t^*$ și $k \geq 2$. Din (5.29) rezultă că:

$$c \leq \begin{cases} \frac{2T}{f(c)} & \text{dacă } f(c) \text{ este par} \\ \frac{2T}{f(c)-1} & \text{dacă } f(c) \text{ este impar, } f(c) \geq 3. \end{cases} \quad (5.32)$$

Fie $\varepsilon = \min_i t_i$. Din definițiile lui f și g și din faptul că $g(k) > t^*$, rezultă că $f(g(k)-\varepsilon) \geq k+1$. Dacă $f(g(k)-\varepsilon) = k+1$, atunci înlocuim pe c cu $g(k)-\varepsilon$ și pe $f(g(k)-\varepsilon)$ cu $k+1$ în (5.32) și făcând pe ε să tindă către 0 rezultă (5.31). Dacă $f(g(k)-\varepsilon) > k+1$ și ținând seama că $f(g(k)-\varepsilon)$ este întreg, rezultă că $f(g(k)-\varepsilon) \geq k+2$. Înlocuind pe c cu $g(k)-\varepsilon$ și pe $f(g(k)-\varepsilon)$ cu $k+2$ în (5.32) și făcând pe ε să tindă către 0, se observă că $g(k) \leq 2T/(k+1)$ independent de paritatea lui $f(g(k)-\varepsilon)$. Prin urmare are loc (5.31). ■

↳ **Observație.** Din (5.29) și (5.28) rezultă că $S < 2S^*$ dacă S este par, respectiv, $S < 2S^*+1$ dacă S este impar. În primul caz $S < 2S^*+1$ și în al doilea caz $S \leq 2S^*-1$, deci $S \leq 2S^*-1$ în toate cazurile.

5.5.2. Performanța unor euristici pentru linii de asamblare

Într-o linie de asamblare întreaga producție este distribuită pe o mulțime $A = \{1, 2, \dots, i, \dots, n\}$ de elemente ale produsului. Fiecare element al produsului necesită un timp de lucru t_i și i se asigură un beneficiu pe unitatea de timp egal cu w_i . Între unele sau toate elementele produsului există relații de precedență ce trebuie respectate în procesul de fabricare a unei unități a produsului. Elementele produsului sunt executate de sisteme de producție numite stații. Aceste stații sunt aranjate secvențial și alcătuiesc o linie de asamblare corespunzătoare ordinii de executare a elementelor produsului. Timpul atribuit fiecărei stații este limitat la o valoare c , egală cu durata producției împărțită la măsura (valoarea) ei. Beneficiul pe unitatea de timp W_j al unei stații j este egal cu valoarea maximă a beneficiului realizat de elementele aparținând stației, adică $W_j = \max\{w_i \mid i \in A_j\}$, unde A_j este submulțimea lui A ce conține elementele asiguate stației j .

Problema planificării unei lucrări pe o linie de asamblare (PLA) constă în asignarea elementelor produsului diferitelor stații astfel încât să fie respectate relațiile de precedență și să fie minimizat costul produsului. Cu presupunerile:

α - ordinea parțială definită pe A ,

$i \alpha i'$ - i este predecesorul lui i' ,

$i \alpha i' \Rightarrow i < i'$, adică elementele lui A sunt sortate topologic,

problema PLA poate fi formulată astfel:

Să se găsească o partiție $P = \{A_1, A_2, \dots, A_m\}$ a lui A astfel încât:

$$Z = \sum_{i=1}^m W_i \cdot c \text{ este minimizată} \quad (5.33)$$

cu condițiile:

$$\sum_{i \in A_j} t_i \leq c, \text{ pentru } j = 1, 2, \dots, m$$

și

dacă $i \in A_j, k \in A_{j'}$ și $i \alpha k$, atunci $j \leq j'$.

Deoarece c din (5.33) este constantă, funcția obiectiv poate fi înlocuită cu:

$$\text{minimizează } W = \sum_{i=1}^m W_i. \quad (5.34)$$

Deoarece toate elementele produsului au același beneficiu pe unitatea de timp, adică același α_i , atunci funcția obiectiv (5.34) poate fi înlocuită cu minimizarea numărului de stații.

Exemplul 5.57. Fie $A = \{1, 2, 3, 4\}$; $t_1 = 1, t_2 = 2, t_3 = 1, t_4 = 2$; $W_1 = 2.1, W_2 = 1, W_3 = 2.1, W_4 = 1$; $1 \alpha 2, 1 \alpha 3, 2 \alpha 4, 3 \alpha 4$; $c = 3$. Două partiții împreună cu valorile corespunzătoare ale lui m și Z sunt următoarele:

$$P_1 = \{\{1, 2\}, \{3, 4\}\}; m = 2, Z = 2.1 \cdot 3 + 2.1 \cdot 3 = 12.6,$$

$$P_2 = \{\{1, 3\}, \{2\}, \{4\}\}; m = 3, Z = 2.1 \cdot 3 + 1 \cdot 3 + 1 \cdot 3 = 12.3.$$

Partiția P_1 minimizează numărul de stații și P_2 minimizează pe Z . ■

Principiile elaborării euristiciilor pot fi descrise după cum urmează. Unul sau mai multe criterii de prioritate sunt luate în considerare pentru asignarea elementelor produsului la stații, în raport de valoarea lui c și relațiile de precedență. Diferențele dintre euristici se datorează în special regulilor de prioritate, care sunt de forma:

- reguli bazate pe duratele de execuție t_i ale elementelor produsului,
- reguli bazate pe beneficiul pe unitatea de timp w_i al elementelor produsului,
- reguli de prioritate ce combină cele două reguli anterioare.

Pentru studiul performanței în cazul cel mai defavorabil vom defini mai întâi noțiunea de *euristică rezonabilă*. O euristică H este *rezonabilă* dacă are loc condiția:

$$\sum_{i \in A_j} t_i + \sum_{i \in A_{j+1}} t_i > c, j = 1, \dots, m - 1, \quad (5.35)$$

pentru toate soluțiile generate de euristica H . Dacă nu are loc condiția (5.35), atunci elemente ale produsului din stația $j + 1$ pot fi asignate stației j , drept rezultat obținându-se o soluție mai bună a problemei PLA studiate.

Fie W^* valoarea funcției obiectiv a unei PLA , W^H valoarea funcției obiectiv generată de euristica H , $w_{\max} = \max\{w_i \mid i \in A\}$ și $w_{\min} = \min\{w_i \mid i \in A\}$.

Teorema 5.38. Pentru orice euristică H pentru rezolvarea PLA , raportul performanțelor în cazul cel mai defavorabil este dat de:

$$W^H / W^* \leq 2 \cdot w_{\max} / w_{\min}.$$

Demonstrație. În soluția optimală a PLA , ce conține m^* stații, măcar pentru una dintre ele $W_j = w_{\max}$ și pentru toate celelalte are loc $W_j \geq w_{\min}$. În consecință:

$$w_{\max} + (m^* - 1) \cdot w_{\min} \leq W^*. \quad (5.36)$$

Pentru toate soluțiile generate de euristica H are loc relația:

$$m^H \cdot w_{\max} \geq W^H, \quad (5.37)$$

unde m^H este numărul de stații furnizat de euristica H .

Fie $m^{\min} = \lceil \sum_{i \in A} t_i / c \rceil$; atunci $m^* \geq m^{\min}$. Într-adevăr, numărul de stații nu poate fi mai mic decât cel realizat în cazul când timpul de funcționare al tuturor stațiilor este același și egal cu valoarea de mai sus a lui m^{\min} .

Deoarece $\sum_{i \in A_j} t_i + \sum_{i \in A_{j+1}} t_i > c$, $j = 1, 2, \dots, m - 1$, (vezi (5.35)) pentru toate soluțiile generate de o euristică rezonabilă H are loc următoarea inegalitate:

$$(m^H - 1) \cdot c < \sum_{i \in A_1} t_i + \sum_{i \in A_1} t_i + \sum_{i \in A_2} t_i + \dots + \sum_{i \in A_{m^H-1}} t_i + \sum_{i \in A_{m^H}} t_i + \sum_{i \in A_{m^H}} t_i = 2 \cdot \sum_{i \in A} t_i \leq 2 \cdot m^{\min} \cdot c.$$

Rezultă că $m^H < 2 \cdot m^{\min} + 1$. Deoarece $m^H, m^{\min} \in \mathbb{N}$, rezultă $m^H \leq 2 \cdot m^{\min}$, deci:

$$m^H < 2 \cdot m^*. \quad (5.38)$$

Din (5.36), (5.37) și (5.38) se deduce:

$$\frac{W^H}{W^*} \leq \frac{W^H}{w_{\max} + (m^* - 1)w_{\min}} \leq \frac{m^H w_{\max}}{w_{\max} + (m^* - 1)w_{\min}} \leq \frac{2m^* w_{\max}}{m^* w_{\min}} = 2 \frac{w_{\max}}{w_{\min}}. \blacksquare$$

5.5.3. Desvoltarea capacității cu mai multe tipuri de facilități

Punerea problemei. Modelele de desvoltare ale capacității sunt folosite pentru planificarea extinderii în timp a facilităților. ■

Aplicații posibile: industriile ce necesită investiții substanțiale de capital, rețele de comunicație, servicii de energie electrică, sisteme de alimentare cu apă, procese din industria grea, servicii.

Se studiază un model determinist de dezvoltare a capacității cu $n \geq 2$ tipuri de facilități. O facilitate i reprezintă un anumit nivel de calitate. Facilitățile sunt numerotate astfel încât facilitatea i este de calitate mai bună decât facilitatea j dacă $i < j$. Aceste facilități sunt multiplicare în timp pentru satisfacerea a n tipuri de comenzi (cereri), numerotate ca mai înainte. Fiecare dintre aceste comenzi necesită o facilitate de o anumită calitate. O facilitate i este prevăzută să satisfacă în mod preferențial comanda i , dar poate de asemenea deservi orice cerere j cu $j > i$.

Costurile considerate includ costurile de dezvoltare pentru fiecare facilitate și costurile de stocare a capacităților nefolosite. Funcțiile cost sunt nedescrescătoare și concave și reflectă strategia economiei sortimentelor. Fiind date comenzile în timp dealungul a T perioade, obiectivul problemei studiate constă în elaborarea unei dezvoltări ce satisface comenzile la un cost minimal.

Modelul studiat presupune un număr finit de perioade temporale. Cererile de creștere, dezvoltările capacităților și conversiile capacităților apar instantaneu, imediat după începutul fiecărei perioade. Sunt folosite următoarele notații:

i, j, k, l, m - Indicii facilităților. Cele n facilități sunt ordonate de la 1 la n în ordinea descrescătoare a calității.

t, u, v - Indicii perioadelor temporale. Orizontul planificării constă din T perioade.

r_{it} - Creșterile comenzii i pentru capacitate adițională în perioada t ; $r_{it} \geq 0$. Comanda i poate fi efectuată de facilitatea k , $k \leq i$. Prin convenție, r_{it} se presupun întregi.

$$R_{ij}(u, v) = \sum_{t=uk=i}^v \sum_{k=i}^j r_{kt}$$

x_{it} - Creșterea dezvoltării facilității i în perioada t .

y_{ijt} - Mărimea capacității convertită din facilitatea i în facilitatea j , $i < j$, în perioada t .

O dată convertită, capacitatea devine parte integrantă a facilității j .

I_{it} - Mărimea capacității în exces a facilității i la începutul perioadei t sau, echivalent, la sfârșitul perioadei $t - 1$. Se presupune că $I_{i1} = 0$ și că lipsurile de capacitate nu sunt permise, adică $I_{it} > 0$.

I_t - Vectorul capacităților în exces, $I_t = (I_{1t}, I_{2t}, \dots, I_{nt})$, $I_t > 0$ ($I_t = 0$) reprezintă situațiile $I_{it} > 0$ ($I_{it} = 0$) pentru toți i .

$c_{it}(x_{it})$ - Funcția cost a creșterii capacității.

$h_{ij}(I_{i,k+1})$ - Funcția costului de înmagazinare în cadrul transferării capacității în exces a facilității i din perioada t în perioada $t + 1$.

Pentru simplificare se presupune că funcțiile de cost satisfac condițiile $c_{it}(0) = h_{it}(0) = 0$. În afară de aceasta, toate funcțiile de cost se presupun nedescrescătoare și concave.

Problema dezvoltării capacității (PDC) este formulată astfel:

$$\text{minimizează} \left(\sum_{i=1}^n \sum_{j=i}^n \left[c_{ij}(x_{ij}) + h_{ij}(I_{i,t+1}) \right] \right)$$

astfel încât:

$$\left. \begin{aligned} I_{i,t+1} &= I_{it} + x_{it} + \sum_{k=1}^{i-1} y_{kit} - \sum_{k=i+1}^n y_{ikt} - r_{it}, & t &= 1, 2, \dots, T \\ I_{it} &\geq 0, & i &= 1, 2, \dots, n \\ I_n &= I_{i,T+1} = 0, & j &= i+1, \dots, n \\ x_{it} &\geq 0, y_{ijt} \geq 0, \end{aligned} \right\}$$

unde $\sum_1^0(\bullet)$ și $\sum_{n+1}^n(\bullet)$ sunt prin definiție nule. Obiectivul PDC constă în minimizarea costului total pe durata a T perioade. Prima condiție descrie capacitatea în exces a facilității i la începutul perioadei $t + 1$ ca funcție de capacitatea în exces la începutul perioadei t și schimbarea capacității în perioada t . Constrângerile $I_{it} \geq 0$ și $I_{i1} = 0$ sunt luate ca ipoteze. În afară de aceasta, deoarece funcțiile cost sunt nedescrescătoare, se poate presupune că $I_{i,T+1} = 0$ fără a crește costurile totale. Notăția PDC_{ij} , $j \geq i$, se va referi în continuare la o PDC cu facilitățile $i, i + 1, \dots, j$. Rezultă că formularea precedentă se referă la PDC_{1n} .




Fig. 5.45.

Schema reprezentativă a PDC pentru $n = 3$ și $T = 3$ este arătată în figura 5.45. Deoarece funcțiile cost sunt concave, există o soluție optimă reprezentată printr-un punct extremal. În reprezentarea pe schemă, aceasta înseamnă că există o soluție optimă cu nu mai mult de un flux pozitiv incident în fiecare nod.

Ideea metodei constă în rezolvarea repetată a unei probleme cu o singură perioadă. Fie $SPDC_{ij}(u; D_i, D_{i+1}, \dots, D_j)$ o problemă de dezvoltare cu perioada u pentru

facilitățile $i, i + 1, \dots, j$ și creșterile corespunzătoare D_i, D_{i+1}, \dots, D_j ale cererii. Problema se formulează astfel:

$$S_{ij}(u; D_i, D_{i+1}, \dots, D_j) = \underset{x_{ku}, y_{kmu}}{\text{minimum}} \left[\sum_{k=i}^j c_{ku}(x_{ku}) \right],$$

astfel încât:

$$x_{ku} + \sum_{l=i}^{k-1} y_{lku} - \sum_{l=k+1}^j y_{klu} = D_k, x_{ku} \geq 0, y_{kmu} \geq 0, k = i, \dots, j, m = k+1, \dots, j,$$

unde $\sum_i^{i-1} (\bullet)$ și $\sum_{j+1}^j (\bullet)$ sunt nule prin definiție.

Schema reprezentativă a SPDC este arătată în figura 5.46.




Fig. 5.46.

Algoritmul 5.43. (Euristica de bază)

Creșterile capacităților și conversiile sunt considerate numai în perioadele în care $I_t = 0$. Fie $PDC_{1n}(u, v)$ problema dezvoltării pentru facilitățile $1, 2, \dots, n$ pe perioadele u, \dots, v știind că $I_u = I_{v+1} = 0, I_t > 0$, pentru $t = u + 1, \dots, v$ și presupunând că toate creșterile și conversiile au loc în perioada u . Soluția optimă $PDC_{1n}(u, v)$, notată $d(u, v)$, se obține rezolvând problema $SPDC_{1n}(u; D_i, \dots, D_j)$. Mai precis:

$$d(u, v) = S_{1n}(u; D_i, \dots, D_j) + C(I_u, I_{v+1}),$$

unde:

$$D_i = R_{ii}(u, v), i = 1, 2, \dots, n, I_u = I_{v+1} = 0 \text{ și } C(I_u, I_{v+1}) = \sum_{t=u}^v \sum_{i=1}^n h_{it}(I_{i,t+1}). \blacksquare$$

Euristica calculează toate cele $T(T+1)/2$ valori posibile ale lui $d(u, v)$ și identifică secvența optimă a problemelor PDC utilizând programarea dinamică.

6 PROGRAMARE LINIARĂ ÎNTREAGĂ

6.1. Algoritmi euristici pentru programarea liniară întreagă

Punerea problemei. Se cere maximizarea lui x_0 dat de expresia:

$$x_0 = \sum_{j=1}^n c_j x_j$$

cu restricțiile:

$$\sum_{j=1}^n a_{ij} x_j \leq b_i, \text{ pentru } i = 1, 2, \dots, m, \quad (6.1)$$

$$x_j \geq 0, \text{ pentru } j = 1, 2, \dots, n, \quad (6.2)$$

$$x_j \text{ este întreg, pentru } j = 1, 2, \dots, n.$$

Se presupune că regiunea din spațiul n -dimensional a punctelor ce satisfac condițiile (6.1) și (6.2) conține cel puțin un punct interior. ■

Fiecare dintre procedurile de rezolvare propuse conțin trei faze. Scopul primei faze constă în identificarea unei regiuni în interiorul căreia se caută soluții suficient de bune. În acest scop se selectează mai întâi un punct reprezentând o soluție optimală neîntreagă. În continuare se identifică un al doilea punct, suficient de apropiat de primul și satisfăcând condiția că segmentul ce îl unește cu primul punct aparține regiunii ce conține soluții ale problemei. În cadrul fazei a doua se încearcă identificarea unei soluții cât mai apropiată de o soluție întreagă, prin deplasarea dealungul segmentului anterior menționat. Scopul fazei a treia constă în încercarea de îmbunătățire a soluției obținute în faza anterioară pe calea schimbării valorii uneia sau simultan a două variabile până când nu se mai poate obține o îmbunătățire a soluției determinate la un moment dat.

Pentru unele dintre metodele din fazele 1 și 2, este necesară normalizarea restricțiilor. Pentru aceasta se introduc notațiile:

$$a'_{ij} = a_{ij} / \sqrt{\sum_{j=1}^n a_{ij}^2}, \text{ pentru } i = 1, 2, \dots, m; j = 1, 2, \dots, n$$

și

$$b'_i = b_i / \sqrt{\sum_{j=1}^n a_{ij}^2}, \text{ pentru } i = 1, 2, \dots, m,$$

cu ajutorul cărora restricțiile (6.1) iau forma:

$$\sum_{j=1}^n a'_{ij} x_j \leq b'_i, \text{ pentru } i = 1, 2, \dots, m.$$

Rezultă că b'_i reprezintă distanța euclidiană de la origine la planul $\sum_{j=1}^n a_{ij} x_j = b_i$.

În continuare, se vor folosi notațiile a_{ij} și b_i , numai în cazul în care faptul că restricțiile au fost normalizate nu este relevant.

6.1.1. Metodele fazei 1

Primul pas al *fazei 1* constă în utilizarea metodei simplex pentru a găsi o soluție optimală neîntregă. Fie $\bar{x}^{(1)}$ vectorul cu n componente reprezentând soluția, $B = \{j \mid x_j^{(1)} \text{ este o variabilă de bază}\}$ și N numărul de elemente din B . În continuare se identifică o nouă soluție $\bar{x}^{(2)}$, suficient de apropiată de soluția $\bar{x}^{(1)}$.

În cadrul *metodei 1* se efectuează mai întâi înlocuirea lui b_i cu:

$$b_i^{(2)} = b_i - \frac{1}{2} \sum_{j \in B} |a_{ij}|,$$

după care se identifică soluția $\bar{x}^{(2)}$ satisfăcând condiția:

$$\sum_{j=1}^n a_{ij} x_j^{(2)} = b_i^{(2)}.$$

În virtutea acestei condiții rezultă că valoarea tuturor variabilelor din $\bar{x}^{(2)}$ poate fi modificată cu cel mult $1/2$ fără a contrazice versiunea inițială a restricțiilor:

$$\sum_{j=1}^n a_{ij} x_j \leq b_i.$$

Mai mult, $\bar{x}^{(1)}$ și $\bar{x}^{(2)}$ au aceleași variabile de bază (principale) astfel încât condițiile de nenegativitate pentru $\bar{x}^{(1)}$, ignorând variabilele de bază degenerare, sunt satisfăcute și de $\bar{x}^{(2)}$. Rezultă că $\bar{x}^{(2)}$ poate fi modificat pe calea rotunjirii fiecăreia din componentele sale neîntregi până la cel mai apropiat întreg fără a viola condițiile funcționale sau de nenegativitate. În cadrul *fazei 2*, căutarea lui $\bar{x}^{(2)}$ plecând de la $\bar{x}^{(1)}$ furnizează măcar o soluție rotunjită care satisface condițiile problemei, deoarece $\bar{x}^{(2)}$ le satisface.

În mod asemănător, în cadrul *metodei 2* are loc înlocuirea fiecărui b'_i cu:

$$b_i^{(2)} = b_i - \sqrt{N} / 2,$$

în cazul când condiția funcțională i are loc pentru $\bar{x}^{(1)}$, după care se calculează noua soluție $\bar{x}^{(2)}$ pentru această bază. Motivarea pentru această alegere a lui $\bar{x}^{(2)}$ este dublă. Mai întâi, această soluție are aceeași proprietate ca și în metoda 1 și anume variabilele ei de bază pot fi rotunjite până la cel mai apropiat întreg, fără a viola nici una dintre condițiile funcționale pentru $\bar{x}^{(1)}$. Acest lucru are loc datorită faptului că distanța dintre hiperplanul:

$$\sum_{j=1}^n a'_{ij} = b'_i$$

și planul corespunzător pe care este situată extremitatea vectorului $\bar{x}^{(2)}$ este egală cu $\sqrt{N} / 2$, deoarece fiecare dintre cele N variabile de bază se schimbă cu cel mult $1/2$. A doua motivare constă în faptul că punctul $\bar{x}^{(2)}$ este echidistant la hiperplanurile:

$$\sum_{j=1}^n a'_{ij} x_j = b'_j,$$

la intersecția cărora se află extremitatea vectorului $\bar{x}^{(1)}$.

6.1.2. Metodele fazei 2

Metoda 1 a fazei 2 constă în deplasarea continuă dealungul segmentului de la $\bar{x}^{(1)}$ la $\bar{x}^{(2)}$ efectuând rotunjirea către cea mai apropiată soluție întregă, până când se obține o soluție a problemei. Obținerea soluțiilor succesive întregi are loc pe calea identificării punctelor, de pe segmentul menționat, în care soluțiile rotunjite se schimbă. În acest scop, fiecare punct \bar{x} al segmentului se reprezintă sub forma:

$$\bar{x} = (1 - \alpha) \bar{x}^{(1)} + \alpha \bar{x}^{(2)}, \text{ unde } 0 \leq \alpha \leq 1.$$

Pentru componenta x_j a vectorului \bar{x} rezultă expresia:

$$x_j = (1 - \alpha) x_j^{(1)} + \alpha x_j^{(2)} = x_j^{(1)} + \alpha (x_j^{(2)} - x_j^{(1)}),$$

cu ajutorul căreia se pot calcula valorile succesive ale lui α pentru care x_j este coordonata de indice j a mijlocului segmentului definit de două valori întregi succesive. Metoda se încheie când α a atins o valoare mai mică sau egală cu 0 sau dacă depășește valoarea 1. Datorită modului în care a fost ales punctul $\bar{x}^{(2)}$, soluția rotunjită ce satisface condițiile la limită satisfăcute de $\bar{x}^{(1)}$ se obține pentru o valoare a lui $\alpha \leq 1$. Nu este însă sigur că o asemenea soluție satisface și celelalte condiții, așa încât metoda propusă nu garantează obținerea unei soluții corecte.

În cadrul metodei 2 se efectuează creșterea succesivă a lui α cu pas constant. Pentru fiecare valoare a lui α , începând cu $\alpha = 0$, primul pas în căutarea soluției constă în aplicarea unei rotunjiri în componentele lui \bar{x} în vederea identificării unei

cele mai apropiate soluții întregi nenegative. Dacă o astfel de soluție rotunjită nu este realizabilă, se încearcă dacă, în urma creșterii sau descreșterii unei variabile oarecare cu 1, are loc descreșterea, în modul definit mai jos, a *nerealizabilității* q . Dacă nu există asemenea variabile, se trece la o nouă valoare a lui α . Dacă însă există o singură asemenea variabilă, atunci se efectuează schimbarea cu 1 a valorii ei. Dacă soluția obținută nu este realizabilă, se repetă încercarea precedentă pentru celelalte variabile. Este posibil să existe mai multe asemenea variabile, caz în care se efectuează schimbarea care maximizează *îmbunătățirea*, definită mai jos; dacă soluția obținută este în continuare nerealizabilă, se reia parcurgerea celorlalte variabile. Metoda se încheie când s-a obținut o soluție realizabilă sau dacă α a depășit 1.

O măsură cu o singură valoare a gradului de nerealizabilitate a unei soluții \bar{x} se poate obține plecând de la două definiții distincte ale *nerealizabilității* q . Prima dintre ele este:

$$q = \sum_{i=1}^m \left(\sum_{j=1}^n a'_{ij} x_j - b'_i \right)_+$$

adică suma distanțelor euclidiene dintre \bar{x} și fiecare dintre hiperplanurile pentru care condiția (6.1) nu este respectată. O a doua definiție este:

$$q = \max_{i \in \{1, \dots, m\}} \left\{ \sum_{j=1}^n a'_{ij} - b'_i \right\},$$

adică distanța euclidiană maximă dintre \bar{x} și hiperplanurile pentru care condiția (6.1) nu este respectată. Pentru o valoare aleasă a lui q , o măsură naturală a *îmbunătățirii*, obținută pe calea schimbării valorii variabilei x_j , este:

$$p = -\Delta q,$$

unde Δq este schimbarea lui q datorată schimbării lui x_j . O altă alternativă este:

$$p = c_j \Delta x_j / (-\Delta q),$$

unde Δx_j este schimbarea efectuată a valorii x_j .

Definițiile precedente generează patru criterii distincte pentru alegerea variabilei a cărei valoare urmează să fie schimbată. Aceste criterii sunt:

Criteriul A: prima definiție a lui p , prima definiție a lui q .

Criteriul B: prima definiție a lui p , a doua definiție a lui q .

Criteriul C: a doua definiție a lui p , prima definiție a lui q .

Criteriul D: a doua definiție a lui p , a doua definiție a lui q .

Alte două metode au la bază ideea rotunjirii componentelor lui $\bar{x}^{(l)}$. Prima dintre ele, folosită numai în cazul în care toate valorile a_{ij} sunt nenegative, constă în înlocuirea lui x_j cu $\lceil x_j^{(l)} \rceil$, pentru $j = 1, 2, \dots, m$, unde $\lceil y \rceil$ este cel mai mare întreg mai mic sau egal cu y . Cealaltă metodă constă în parcurgerea tuturor variantelor de

rotunjire a componentelor lui $\bar{x}^{(1)}$ folosind atât rotunjirea precedentă cât și rotunjirea $\lfloor x_j^{(1)} \rfloor$, pentru $j = 1, 2, \dots, m$, unde $\lfloor y \rfloor$ este cel mai mic întreg mai mare sau egală cu y .

6.1.3. Metodele fazei 3

Scopul fazei 3 constă în căutarea unei soluții mai bune decât soluția $\bar{x}^{(F)}$ obținută în faza 2. Această căutare se efectuează în două moduri. Primul dintre ele constă în creșterea sau descreșterea succesivă cu 1 a valorii unei variabile astfel încât noua soluție să fie realizabilă și mai bună, adică să corespundă la o valoare mai mare a lui x_0 . Al doilea mod constă în căutarea unei soluții mai bune pe calea schimbării succesive a valorilor a două variabile. Aceste două strategii se aplică alternativ până când nu se poate realiza o soluție mai bună.

În cazul primului mod sunt folosite două criterii privind alegerea variabilei a cărei valoare urmează să fie schimbată. Primul criteriu se bazează pe ideea de a evita apropierea de mulțimea frontieră a soluțiilor, în vederea asigurării unor șanse mai mari următoarelor îmbunătățiri. Al doilea criteriu de alegere constă în determinarea variabilelor ce asigură o apropiere cât mai mare de valoarea x_0 a funcției obiectiv.

Cele două metode utilizate în faza 3 se deosebesc prin aceea că în prima dintre ele se impune restricția ca valorile mărimilor ce participă la procesul de ameliorare a soluției $\bar{x}^{(F)}$ să fie întregi.

6.1.4. Exemplu de programare liniară întregă

Exemplul 6.1. Se cere maximizarea lui

$$x_0 = x_1 + 5x_2,$$

cu restricțiile:

$$x_1 + 10x_2 \leq 20, \quad (6.3)$$

$$x_1 \leq 2, \quad (6.4)$$

$$x_1 \geq 0, x_2 \geq 0,$$

$$x_1 \text{ și } x_2 \text{ sunt întregi.} \quad (6.5)$$

Reprezentarea grafică a restricțiilor, dată în figura 6.1., permite identificarea soluției optimale a problemei date, care este $(x_1, x_2) = (0, 2)$, cu $x_0 = 10$.

În vederea aplicării fazei 1 a algoritmului, restricția (6.5) este eliminată, soluția neîntregă furnizată fiind $\bar{x}^{(1)} = (2, 9/5)$. Rezultă că baza este $B = \{1, 2\}$ și $N = 2$. În cadrul metodei 1 de identificare a lui $\bar{x}^{(2)}$, termenii din dreapta ai restricțiilor (6.3) și (6.4) sunt înlocuiți cu $b_1^{(2)} = 20 - (1/2)(1 + 10) = 14.5$, respectiv $b_2^{(2)} = 2 - (1/2)(1) = 3/2$. Noua soluție obținută este $\bar{x}^{(2)} = (3/2, 13/10)$.




Fig. 6.1.

Dacă se aplică metoda 2, este necesar să se normalizeze restricțiile (6.3) și (6.4), care au acum forma:

$$\begin{aligned} (1/\sqrt{101})x_1 + (10\sqrt{101})x_2 &\leq 20/\sqrt{101} - \sqrt{2}/2, \\ x_1 &\leq 2 - 2/\sqrt{2} \end{aligned}$$

și soluția optimală neîntregă este:

$$\bar{x}^{(2)} = (2 - \sqrt{2}/2, 9/5 - (\sqrt{202} - \sqrt{2})/20) \approx (1.29, 1.16).$$

Cu aceasta se încheie faza 1.

Toate trei metodele fazei 2 încep cu rotunjirea soluției $\bar{x}^{(1)} = (2, 9/5)$ la cea mai apropiată soluție întregă care este $(x_1, x_2) = (2, 2)$ și nu satisface condițiile date. În continuare, metoda 1 identifică o nouă soluție plecând de la $\bar{x}^{(2)} = (3/2, 13/10)$. Pentru valori succesive ale lui α , obținute din $\alpha = 0$ cu pasul 0.1, se constată că pentru $\alpha = 0.6$, valorile lui x_1 și x_2 sunt respectiv egale cu:

$$x_1 = (1 - 0.6)2 + (0.6)3/2 = 17/10, \quad x_2 = (1 - 0.6)9/5 + (0.6)13/10 = 3/2.$$

O nouă soluție rotunjită, diferită de cea precedentă, este $(x_1, x_2) = (2, 1)$. Deoarece această soluție satisface restricțiile problemei, metoda 1 se încheie.

În cadrul metodelor 2 și 3, soluția rotunjită inițială $(2, 2)$ nu este abandonată și se încearcă obținerea din ea a uneia ce satisface condițiile. Această soluție rotunjită nu satisface doar restricția (6.3) și valoarea corespunzătoare a lui q este $2/\sqrt{101}$. Dacă valoarea lui x_1 se micșorează cu 1, atunci valoarea lui q scade cu $1/\sqrt{101}$ și $c_1 \Delta x_1 = -1$. Dacă se scade x_2 cu 1, atunci q scade cu $2/\sqrt{101}$ și $c_2 \Delta x_2 = -5$. Deoarece în al doilea caz se obține o scădere mai mare pentru q , criteriile A și B vor alege scăderea lui x_2 cu 1, drept rezultat obținându-se soluția realizabilă $(x_1, x_2) = (2, 1)$. Deoarece $-1 / (1/\sqrt{101}) > -5 / (2/\sqrt{101})$, criteriile C și D vor alege scăderea cu 1 a lui x_1 , drept rezultat obținându-se soluția nerealizabilă $(x_1, x_2) = (1, 2)$.

Faza 3 începe cu soluția realizabilă $(2, 1)$ obținută în faza 2. Încercările bazate pe schimbarea valorii unei singure variabile nu conduc la obținerea unei soluții mai bune. Dacă se încearcă schimbarea valorilor a două variabile, se obține soluția $\bar{x} = (0, 2)$ care este și cea optimală. Dacă în faza 3 se începe cu soluția realizabilă $(1, 2)$ se obține soluția optimală schimbând o singură valoare. ■

6.2. Algoritm aproximativ pentru programarea 0-1

În cele ce urmează vom folosi următoarele notații:

m - numărul de proiecte (lucrări),

n - numărul resurselor restrânse,

P_i - proiectul i , $i = 1, 2, \dots, m$,

R_j - resursa restrânsă j , $j = 1, 2, \dots, n$,

K_i - profitul proiectului P_i ,

L_j - limita superioară a resursei R_j ,

H_{ij} - cantitatea din R_j solicitată de P_i ,

F_{ij} - raportul dintre H_{ij} și L_j , adică $F_{ij} = H_{ij} / L_j$,

Z - funcția obiectiv ce trebuie maximizată,

X_i - variabile binare, adică $X_i = 0$ sau 1 ,

T - mulțimea tuturor proiectelor,

T_u - mulțimea proiectelor acceptate,

T_D - mulțimea proiectelor ce nu aparțin lui T_u , adică $T_D = T - T_u$,

\bar{P}_i - vectorul cantităților de resurse pentru P_i , adică $\bar{P}_i = (F_{i1}, F_{i2}, \dots, F_{in})$,

C_j - cantitatea din R_j cerută de mulțimea proiectelor acceptate, adică $C_j = \sum_{P_i \in T_u} F_{ij}$,

\bar{P}_u - vectorul cumulativ total, adică $\bar{P}_u = (C_1, C_2, \dots, C_n)$,

$|\bar{P}_u|$ - modulul (lungimea) lui \bar{P}_u , adică $|\bar{P}_u| = \left(\sum_{j=1}^n C_j^2 \right)^{1/2}$,

\bar{B} - vectorul limită normalizat al resurselor, adică $\bar{B} = (1, 1, \dots, 1)$,

T_C - mulțimea proiectelor candidat, adică $T_C = \{P_i \mid P_i \in T_D, \bar{P}_i \leq \bar{B} - \bar{P}_u\}$,

\bar{E} - vectorul unitate al lui \bar{P}_u ,

U_i - proiecția lui \bar{P}_i pe \bar{E} , adică $U_i = \bar{P}_i \cdot \bar{E}$,

G_i - gradientul efectiv al lui \bar{P}_i (definit în textul algoritmului).

Punerea problemei. Problema programării 0-1 are enunțul:

Problema 1:

$$\text{Maximizează } Z = \sum_{i=1}^m K_i X_i,$$

cu condițiile:

$$\sum_{i=1}^m H_{ij} X_i \leq L_j, \text{ pentru } j = 1, 2, \dots, n,$$

$$X_i = 0 \text{ sau } 1, \text{ pentru } i = 1, 2, \dots, m. \blacksquare$$

În continuare se presupune $K_i > 0$, $H_{ij} \geq 0$ și $L_j > 0$. O metodă pentru rezolvarea Problemei 1 este prezentată în lucrarea [SEN68] și este numită *metoda duală a gradientului efectiv*, deoarece începe cu o soluție nerealizabilă, urmată de

identificarea unei soluții realizabile. Metoda descrisă în continuare se numește *metoda primală a gradientului efectiv*, deoarece începe cu o soluție realizabilă urmată de îmbunătățirea ei.

Metoda primală a gradientului efectiv. Problema 1 poate fi reformulată astfel:

Problema 2:

$$\text{Maximizează } Z = \sum_{i=1}^m K_i X_i,$$

cu condițiile:

$$\sum_{i=1}^m F_{ij} X_i \leq 1, \text{ pentru } j = 1, 2, \dots, n, \quad (6.6)$$

$$X_i = 0 \text{ sau } 1 \text{ pentru } i = 1, 2, \dots, m.$$

În procesul de selectare a unui proiect, este necesar să se selecteze un proiect cât mai profitabil. În cazul când proiectele considerate necesită o singură resursă, profiturile dorite se pot calcula ușor, acceptând drept indice de profitabilitate profitul pe unitatea de resursă. Problema devine dificilă în cazul a mai multor resurse limitate. În acest caz se introduce noțiunea de *vector de penalizare*, care furnizează un singur indice, adică un indice global, calculat cu ajutorul mai multor resurse limitate. Drept vector de penalizare se consideră vectorul \bar{P}_u .

Exemplul 6.2. Fie cazul $n=2$ cu $\bar{P}_u=(0.6;0.3)$, $\bar{P}_1=(0.1;0.4)$ și $\bar{P}_2=(0.4;0.1)$. Penalizările (totale) ale proiectelor P_1 și P_2 sunt:

$$\text{pentru } P_1 : 0.1 \cdot 0.6 + 0.4 \cdot 0.3 = 0.18,$$

$$\text{pentru } P_2 : 0.4 \cdot 0.6 + 0.1 \cdot 0.3 = 0.27,$$

deci $P_1 < P_2$. După cum se vede, cele două penalizări reprezintă produsele scalare $\bar{P}_1 \cdot \bar{P}_u$, respectiv $\bar{P}_2 \cdot \bar{P}_u$. Ținând seama că vectorul unitate al lui \bar{P}_u este $\bar{E} = \bar{P}_u / |\bar{P}_u|$, rezultă că:

$$(\bar{P}_i \cdot \bar{P}_u) / |\bar{P}_u| = \bar{P}_i \cdot (\bar{P}_u / |\bar{P}_u|) = \bar{P}_i \cdot \bar{E} = U_i,$$

deci U_i reprezintă proiecția lui \bar{P}_i pe direcția lui \bar{P}_u . Figura 6.2. ilustrează pe U_1 și U_2 pentru cazul $\bar{P}_u=(0.6;0.3)$, $\bar{P}_1=(0.4;0.1)$ și $\bar{P}_2=(0.1;0.4)$. În cazul când se calculează probabilitatea unui proiect, se poate folosi gradientul efectiv al resursei definit prin:

$$G_i = K_i / U_i. \blacksquare$$




Fig. 6.2.

Ideea de bază a euristicii pentru rezolvarea Problemei 2 constă în calculul profitabilității fiecărui proiect și acceptarea celui mai profitabil, reluând procedura cât timp are loc (6.6). Soluțiile obținute în acest mod reprezintă, de obicei, aproximații foarte bune, fără a fi optime.

Algoritmul pentru metoda primală a gradientului efectiv este următorul:

Algoritmul 6.1. (Metoda primală a gradientului)

1. [Inițializări] Se face $T_u = \emptyset$, $T_D = T$, $\bar{P}_u = (0, 0, \dots, 0)$, $Z = 0$ și $X_i = 0$, pentru $i = 1, 2, \dots, m$.

2. [Proiecte candidat] Se determină mulțimea proiectelor candidat:

$$T_C = \{P_i \mid P_i \in T_D, \bar{P}_i \leq \bar{B} - \bar{P}_u\}.$$

3. [Terminare] Dacă $T_C = \emptyset$, atunci STOP (nu mai există proiecte candidat).

4. [Calcul gradienti] Se calculează gradientii efectivi ai proiectelor din T_C astfel:

Dacă $\bar{P}_u = \bar{0}$, atunci \bar{E} nu poate fi calculat și se calculează $G_i = K_i \cdot n^{1/2} / \sum_{j=1}^n F_{ij}$,

pentru $P_i \in T_C$. (Această variantă de calcul corespunde cazului $\bar{P}_u = (1, 1, \dots, 1)$, adică situației în care toate resursele au aceeași penalizare. Această situație apare, de cele mai multe ori, numai la inițializarea procedurii.) Altfel se calculează:

$$|\bar{P}_u| = \left(\sum_{j=1}^n C_j^2 \right)^{1/2}, \quad \bar{E} = \bar{P}_u / |\bar{P}_u|, \quad U_i = \bar{P}_i \cdot \bar{E} = (\bar{P}_i \cdot \bar{P}_u) / |\bar{P}_u| = \left(\sum_{j=1}^n F_{ij} C_j \right) / \left(\sum_{j=1}^n C_j^2 \right)^{1/2},$$

$$G_i = K_i / U_i = K_i \left(\sum_{j=1}^n C_j^2 \right)^{1/2} / \left(\sum_{j=1}^n F_{ij} C_j \right), \text{ pentru } P_i \in T_C; \text{ în cazul când } \sum_{j=1}^n F_{ij} C_j = 0,$$

se atribuie lui G_i o valoare foarte mare, deoarece un asemenea proiect nu are o penalizare și deci este foarte profitabil.

5. [Alegere] Se alege un P_k cu cel mai mare gradient efectiv.

6. [Modificări] Se face $T_u = T_u + \{P_k\}$, $\bar{P}_u = \bar{P}_u + \bar{P}_k$, $Z = Z + K_k$, $T_D = T_D - \{P_k\}$ și $X_k = 1$.

7. [Ciclare] Se trece la pasul 2. ■

Exemplul 6.3. Fie o mulțime de 8 proiecte cu datele din tabelul 6.1. care folosesc două resurse limitate. Resursele pot fi de orice tip ca de exemplu bani, numărul de ore de procesare, numărul specialiștilor, numărul mașinilor și altele. Aplicând algoritmul prezentat, rezultă:

Pasul 1. $T = \{P_1, P_2, \dots, P_8\}$, $T_u = \emptyset$, $T_D = T = \{P_1, P_2, \dots, P_8\}$, $\bar{P}_u = \{0, 0\}$, $Z = 0$, $X_i = 0$, pentru $i = 1, 2, \dots, 8$.

P_i	H_{i1}	H_{i2}	K_i	F_{i1}	F_{i2}
P_1	6	2	100	0.250	0.067
P_2	2	8	400	0.083	0.267
P_3	6	5	600	0.250	0.167
P_4	4	6	800	0.167	0.200
P_5	9	3	300	0.375	0.100
P_6	3	2	200	0.125	0.067
P_7	5	6	400	0.208	0.200
P_8	1	7	500	0.042	0.233
Total	36	49		1.500	1.300
Limita superioară	24	30		1.000	1.000

Tabelul 6.1.

Pasul 2. $T_C = \{P_i \mid P_i \in T_D, \bar{P}_i \leq \bar{B} - \bar{P}_u\} = \{P_1, P_2, \dots, P_8\}$.

Pasul 3. Deoarece $T_C \neq \emptyset$, se trece la pasul 4.

Pasul 4. Deoarece $\bar{P}_u = \{0, 0\}$, gradientul efectiv se calculează după prima variantă, obținându-se: $G_1 = K_1 \cdot n^{1/2} / \sum_{j=1}^n F_{1j} = 100 \cdot 2^{1/2} / (0.250 + 0.067) = 446$. În mod analog se obțin $G_2 = 1616$, $G_3 = 2036$, $G_4 = 3085$, $G_5 = 893$, $G_6 = 1475$, $G_7 = 1386$ și $G_8 = 2571$.

Pasul 5. Proiectul cu gradientul efectiv maxim este P_4 , deoarece $G_4 = 3085$ este valoarea maximă calculată în pasul 4.

Pasul 6. Se efectuează atribuirile: $T_u = T_u + \{P_4\} = \emptyset + \{P_4\} = \{P_4\}$, $\bar{P}_u = \bar{P}_u + \bar{P}_4 = (0, 0) + (0.167, 0.200) = (0.167, 0.200)$, $Z = Z + K_4 = 0 + K_4 = 800$, $T_D = T_D - \{P_4\} = \{P_1, P_2, P_3, P_5, P_6, P_7, P_8\}$, $X_4 = 1$.

Pasul 7. Se trece la pasul 2.

Pasul 2. $T_C = \{P_i \mid P_i \in T_D, \bar{P}_i \leq \bar{B} - \bar{P}_u\} = \{P_1, P_2, P_3, P_5, P_6, P_7, P_8\}$.

Pasul 3. Deoarece $T_C \neq \emptyset$, se trece la pasul 4.

Pasul 4. Deoarece $\bar{P}_u \neq 0$, gradientii efectivi se calculează după varianta a doua:

$$G_i = K_i \left(\sum_{j=1}^n C_j^2 \right)^{1/2} / \left(\sum_{j=1}^n F_{ij} C_j \right) = 100 / (0.167^2 + 0.200^2)^{1/2} / (0.250 \cdot 0.167 + 0.067 \cdot 0.200) = 473.$$

În mod analog se obțin: $G_2 = 1549$, $G_3 = 2083$, $G_5 = 947$, $G_6 = 1524$, $G_7 = 1394$ și $G_8 = 2429$.

Pasul 5. Proiectul cu gradientul efectiv maxim este P_8 .

Pasul 6. Se efectuează atribuirile: $T_u = T_u + \{P_8\} = \{P_4, P_8\}$, $\bar{P}_u = \bar{P}_u + \bar{P}_8 = (0.167, 0.200) + (0.042, 0.233) = (0.209, 0.433)$, $Z = Z + K_8 = 1300$, $T_D = T_D - \{P_8\} = \{P_1, P_2, P_3, P_5, P_6, P_7\}$, $X_8 = 1$.

Pasul 7. Se trece la pasul 2.

După patru reluări ale procedurii, T_C devine vidă și algoritmul se încheie. Soluția finală este: $Z = 2600$, $X_1 = X_2 = X_3 = X_4 = X_6 = X_8 = 1$, $X_5 = X_7 = 0$, $T_u = \{P_1, P_2, P_3, P_4, P_6, P_8\}$, $T_D = \{P_5, P_7\}$ și $\bar{P}_4 = (0.917, 1.000)$. Tabelul 6.2. și figura 6.3. ilustrează procesul acceptării proiectelor la fiecare iterație.

G_i	1	2	3	4	5	6
G_1	446	473	596	488	446	501
G_2	1616	1549	1447	1524	1565	
G_3	2036	2083	2320			
G_4	3085					
G_5	893	947	1187			
G_6	1475	1524	1750	1552		
G_7	1386	1394	1479	1402	1390	
G_8	2571	2429				
\bar{P}_u	(0.167,0.2)	(0.209,0.433)	(0.455,0.6)	(0.583,0.667)	(0.667,0.933)	(0.917,1.0)

Tabelul 6.2.




Fig. 6.3.

Soluția obținută coincide cu cea optimală, găsită prin enumerarea totală. ■

6.3. Programarea liniară a comenzilor cu variabile 0-1

Punerea problemei. Fiind date mai multe comenzi, fiecare dintre ele putând fi acceptată sau neacceptată, se caută identificarea unei ordini de efectuare optimă a acestor comenzi, unele dintre ele putând fi efectuate parțial. ■

Pentru formalizarea problemei, se folosesc următoarele notații:

- m - numărul de comenzi;
- n - numărul de resurse;

K_i - creșterea profitului asigurată de comanda i , $i = 1, 2, \dots, m$;

L_j - capacitatea limită a resursei j , $j = 1, 2, \dots, n$;

H_{ij} - cantitatea necesară din resursa j pentru satisfacerea comenzii i ;

X_i - variabile ce urmează a fi determinate ($X_i = 0$ sau 1);

Z - funcția obiectiv ce urmează a fi maximizată (minimizată).

1

Problema de rezolvat constă în identificarea unei ordini de efectuare a comenzilor care maximizează valoarea:

$$Z = K_1 X_1 + K_2 X_2 + \dots + K_m X_m,$$

satisfăcând restricțiile:

$$X_i = 0 \text{ sau } 1,$$

$$\sum_i H_{ij} X_i \leq L_j.$$

Acesta este un caz special al problemei 0-1 a rucsacului.

Exemplul 6.4. Fie cazul a două procesoare ce urmează să furnizeze produsele comandate de opt clienți. Duratele efectuării comenzilor și profiturile corespunzătoare sunt prezentate în tabelul 6.3., capacitățile limită ale celor două procesoare fiind 24, respectiv, 30 de ore de lucru.

Ordinea propusă	Procesorul I (ore)	Procesorul II (ore)	Profitul
p_1	6	2	100
p_2	2	8	400
p_3	3	2	200
p_4	4	6	800
p_5	9	3	300
p_6	6	5	600
p_7	5	6	400
p_8	1	7	500
Total	36	39	3300
Capacități limită	24	30	
Depășirea capacității	12	9	

Tabelul 6.3.

Având în vedere faptul că există două procesoare, este convenabil să se folosească în calitate de notații vectori bidimensionali. Cu aceste notații, comenzilor p_1, p_2 etc. le corespund vectorii $(6, 2)$, $(2, 8)$ etc.

Notând cu \bar{R} vectorul rezultat al tuturor comenzilor, cu \bar{L} vectorul capacitate maximală și cu \bar{S} surplusul de ore pe cele două procesoare, rezultă următoarele ecuații vectoriale:

$$\begin{aligned}\bar{R} &= \bar{p}_1 + \bar{p}_2 + \dots + \bar{p}_8, \\ \bar{S} &= \bar{R} - \bar{L}, \\ \bar{L} &= (24, 30),\end{aligned}$$

ilustrate pe figura 6.4. Zona dreptunghiulară definită de punctele O, L_1, L, L_2 conține puncte cărora le corespund extremități ale vectorilor \bar{R} ce definesc comenzi efectuabile de către cele două procesoare.




Fig. 6.4.

Dacă se elimină comanda p_8 , punctul R se deplasează în extremitatea vectorului \bar{p}_7 și are loc o pierdere egală cu 500. Contribuția comenzii p_8 la procesul de apropiere de punctul L (dealungul vectorului \bar{S}) este egală cu lungimea proiecției vectorului \bar{p}_8 pe vectorul \bar{S} . Este preferabil să se elimine acele comenzi a căror profit este mic față de lungimea proiecției pe vectorul \bar{S} a vectorului corespunzător comenzii considerate. Drept măsură a contribuției unei comenzi, numită în continuare *gradient efectiv*, se consideră raportul dintre profitul comenzii p_i și proiecția pe \bar{S} a vectorului corespunzător \bar{p}_i .

Dacă se notează cu \bar{u} versorul vectorului \bar{S} , atunci proiecția u_i a vectorului $-\bar{p}_i$ pe $-\bar{u}$ este definită de produsul scalar:

$$u_i = (-\bar{p}_i) \cdot (-\bar{u}),$$

unde, în cazul exemplului studiat, \bar{u} are expresia:

$$\bar{u} = \bar{S} / |\bar{S}| = \left(12 / (12^2 + 9^2)^{1/2}, 9 / (12^2 + 9^2)^{1/2} \right).$$

Pentru u_1 se obține:

$$u_1 = \bar{p}_1 \cdot \bar{u} = 6 \cdot 12 / (12^2 + 9^2)^{1/2} + 2 \cdot 9 / (12^2 + 9^2)^{1/2} = 90 / (12^2 + 9^2)^{1/2}.$$

Gradientul efectiv G_i al vectorului \bar{p}_i are expresia:

$$G_i = K_i / u_i = K_i / (\bar{p}_i \cdot \bar{u}), i = 1, 2, \dots, m.$$

Pentru exemplul studiat, se obțin următoarele valori ale gradientilor efectivi:

$$G_1 = 1.1 \cdot S, G_2 = 4.2 \cdot S, G_3 = 3.7 \cdot S, G_4 = 7.8 \cdot S,$$

$$G_5 = 2.2 \cdot S, G_6 = 5.1 \cdot S, G_7 = 3.5 \cdot S, G_8 = 6.6 \cdot S.$$

Ordonând comenzile p_i crescător față de gradientii efectivi, se obține șirul:

$$p_1, p_5, p_7, p_3, p_2, p_6, p_8, p_4.$$

Identificarea unei soluții a problemei studiate constă în eliminarea succesivă a comenzilor până când depășirile capacităților celor două procesoare devin negative, urmată de adăugarea, dacă e posibil, a unor comenzi cu gradient efectiv mic astfel încât depășirile capacității procesoarelor să nu devină pozitive. Modul în care se obține o soluție pentru exemplul dat este ilustrat în tabelul 6.4. Rezultă că dacă se elimină comenzile p_5 și p_7 se obține un profit egal cu: $3300 - 300 - 400 = 2600$.

	Procesorul 1	Procesorul 2
Surplusul inițial de ore	12	9
Eliminarea comenzii $p_1(6, 2)$	6	7
Eliminarea comenzii $p_5(9, 3)$	-3	4
Eliminarea comenzii $p_7(5, 6)$	-8	-2
Adăugarea comenzii $p_1(6, 2)$	-2	0

Tabelul 6.4.

Altă soluție cu același profit se obține eliminând comenzile p_1, p_3 și p_7 . ■

Vom prezenta în continuare unele îmbunătățiri și generalizări ale acestei proceduri pentru planificare.

Se observă mai întâi că:

$$G_i = K_i / (\bar{p}_i \cdot \bar{u}) = K_i / (\bar{p}_i \cdot \bar{S} / S) = K_i \cdot S / (\bar{p}_i \cdot \bar{S}),$$

unde S figurează ca factor comun în toți gradientii efectivi. Rezultă că este convenabilă utilizarea în calcule în locul lui G_i a valorii G'_i definită prin:

$$G'_i = K_i / (\bar{p}_i \cdot \bar{S}), i = 1, 2, \dots, m.$$

Valoarea G'_i reprezintă *gradientul efectiv relativ* și este numită tot *gradient efectiv*.

Dacă punctul rezultat R este situat în modul ilustrat pe figura 6.5., calculul gradientului efectiv trebuie efectuat dealungul direcției S_1 și nu S_2 , deoarece punctul reprezentativ al soluției optime nu poate avea o ordonată mai mare decât cea a lui R .

Uneori, procesul de eliminare a unora dintre comenzi aduce succesiv punctul R într-o regiune (vezi figura 6.6.) în care restricțiile relative la procesorul I nu mai sunt aplicabile. Această situație are loc dacă punctul figurativ A al soluției optime are poziția din figura 6.6.




Fig. 6.5.

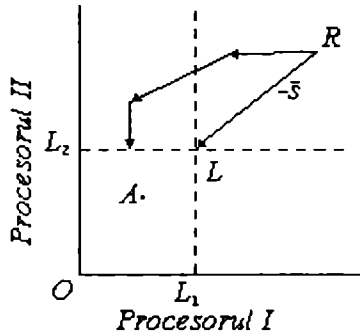


Fig. 6.6.

În asemenea cazuri se poate încerca reluarea eliminării, plecând de la punctul R , a altor comenzi astfel încât intrarea în zona dreptunghiulară d. f. înită de punctele O, L_1, L, L_2 să se efectueze pe un drum cât mai apropiat de L . Această strategie nu conduce însă întotdeauna la o îmbunătățire a soluției. În afară de aceasta, atunci când punctul R este apropiat de L , direcția vectorului \bar{s} poate deveni instabilă, schimbându-se mult după fiecare eliminare a comenzilor. Pentru evitarea dificultăților menționate, în cazul unui număr mare de procesoare și comenzi, se recomandă următoarele strategii de recalculare a gradientilor efectivi:

Metoda I: Când are loc eliminarea depășirii capacității măcar a unui procesor.

Metoda II: Când are loc eliminarea a d sau sau mai multe depășiri, unde d este un număr mic față de numărul total de procesoare.

Metoda III: Când a avut loc eliminarea unei comenzi.

Metoda IV: Când a avut loc eliminarea a c comenzi, unde c este un număr mic față de numărul total de comenzi.

Rezultatele experimentale dovedesc o foarte bună eficiență a euristicii propuse, în multe cazuri fiind obținute soluții optimale sau aproape optimale.

6.4. Problema depozitării

Punerea problemei. Se consideră depozitarea unor produse în depozite cu capacitate nelimitată. Trebuie să se minimizeze $Z = \sum_{i,j} C_{ij} X_{ij} + \sum_i F_i Y_i$ cu condițiile $\sum_i X_{ij} = 1$, pentru $j = 1, 2, \dots, n$; $0 \leq X_{ij} \leq Y_i \leq 1$, $Y_i = 0$ sau 1 , pentru $i = 1, 2, \dots, m$ și $j = 1, 2, \dots, n$, unde m este numărul depozitelor; n este numărul clienților; $C_{ij} = t_{ij} D_j$; t_{ij} este cost ce include costul utilizării depozitului i , costul operațiilor de depozitare și transportul de la depozit la clientul j ; D_j este cererea consumatorului j ; X_{ij} este fracțiunea din D_j furnizată de depozitul i ; F_i este costul fix asociat depozitului i . ■

Termenii de depozit *deschis*, *închis* și *liber* au semnificațiile de depozit ce poate fi folosit, depozit ce nu poate fi folosit, respectiv depozit potențial, nedeclarat încă deschis sau închis.

Euristica propusă are la bază ideea identificării unui drum în arborele generat de metoda B&B (Branch and Bound) utilizând mai multe reguli de ramificare. Cea mai bună dintre soluțiile identificate este acceptată drept soluție a problemei.

Problema este mai întâi rezolvată ca o problemă de programare liniară, fără restricții privind integritatea valorilor Y_i . Fie Z_0 o soluție obținută astfel. Dacă toți Y_i sunt întregi, atunci problema este rezolvată. Altfel Z_0 devine marginea inferioară a problemei. În continuare se alege un Y_k neîntreg și se rezolvă două probleme auxiliare cu $Y_k = 0$, adică depozitul k este închis, respectiv $Y_k = 1$, adică depozitul k este deschis. În reprezentarea pe arbore aceasta corespunde la două arce divergente din nodul asociat soluției Z_0 . Dacă Z_1 și Z_2 sunt cele două noi soluții (evident că $Z_1 \geq Z_0$ și $Z_2 \geq Z_0$) atunci $\bar{Z} = \min(Z_1, Z_2)$ este noua margine inferioară pentru problema studiată. Procedura continuă până ce marginea superioară curentă devine egală cu marginea inferioară curentă.

Pentru accelerarea procesului de identificare a soluției se folosesc trei simplificări descrise în continuare.

Prima simplificare determină o margine minimală pentru a decide un depozit ca fiind deschis. Dacă această margine este pozitivă, depozitul respectiv este declarat deschis. Cu K_0 , K_1 și K_2 se notează mai jos mulțimile de indici ale depozitelor declarate închise, deschise, respectiv libere. Marginea menționată Δ_i se calculează cu formula următoare:

$$\Delta_i = \sum_{j \in P_i} \left\{ \min_k \left[\max(C_{kj} - C_{ij}, 0) \right] \right\} - F_i,$$

unde $i \in K_2$, $k \in K_1 \cup K_2$, $k \in N_j$, $k \neq i$, cu N_j se notează mulțimea depozitelor ce pot deservi clientul j , P_i este mulțimea clienților ce pot fi deserviți de depozitul i și numărul de elemente din P_i se notează în continuare cu n_i .

A doua simplificare constituie un mijloc de reducere a lui n_i în felul următor: dacă pentru $i \in K_2$, $j \in P_i$ are loc $\min(C_{kj} - C_{ij}) < 0$, unde $k \in K_1 \cap N_j$, atunci n_i se reduce cu 1. Dacă inegalitatea are loc pentru toți $j \in P_i$, atunci $n_i = 0$ și $Y_i = 0$, pentru toate ramurile divergente din nodul corespunzător.

A treia simplificare determină o margine maximă a reducerii costului deschiderii unui depozit. Pentru $i \in K_2$, $j \in P_i$ această margine este calculată cu formula următoare:

$$\Omega_i = \sum_{j \in P_i} \left\{ \min_k \left[\max(C_{kj} - C_{ij}, 0) \right] \right\} - F_i,$$

unde $k \in K_1$, $k \in N_j$. Dacă $\Omega_i < 0$, atunci $Y_i = 0$, adică depozitul i se consideră închis pentru toate ramurile divergente din modul examinat.

Cele opt reguli de ramificare sunt:

- | | |
|--------------------------|--------------------------|
| 1. Regula Delta maxim | 5. Regula Delta minim |
| 2. Regula Omega maxim | 6. Regula Omega minim |
| 3. Regula Cererii maxime | 7. Regula Cererii minime |
| 4. Regula Y maxim | 8. Regula Y minim |

Regulile 1 ÷ 4 (respectiv 5 ÷ 8) se numesc de *tip 1* (respectiv de *tip 2*).

Regula 1 (respectiv 5) alege depozitul liber cu cel mai mare (cel mai mic) Δ_i din mulțimea de depozite libere din nodul în care $\Delta_i < 0$.

Regula 2 (respectiv 6) alege depozitul liber cu cel mai mare (cel mai mic) Ω_i din mulțimea de depozite libere din nodul în care $\Omega_i < 0$.

Regula 3 (respectiv 7) alege depozitul liber cu cel mai mare (cel mai mic) Y_i din mulțimea de depozite libere din nodul în care Y_i nu este întreg.

Regula 4 (respectiv 8) alege depozitul liber care poate satisface cererea totală maximă (cererea totală minimă) corespunzătoare nodului considerat.

Corespunzător celor opt reguli de ramificare sunt utilizate opt euristici. Fiecareuristică alege un depozit k liber (cu Y_k neîntreg), după care acest depozit este declarat atât deschis ($Y_k = 1$) cât și închis ($Y_k = 0$), celor două declarații corespunzându-le două noduri adiționale, ramurile corespunzătoare fiind numite ramură *deschisă*, respectiv *închisă*. Ideea de bază a euristicii poate fi formulată astfel: se trasează drumul preferat

ce rezultă din aplicarea unei reguli de ramificare particulare. Această idee este ilustrată în figura 6.7.




Fig. 6.7.

Euristica propusă are structura ce urmează.

Algoritmul 6.2. (*Depozitare*)

1. [Inițializare] Se inițializează mulțimile N_j , P_i , K_0 , K_1 , K_2 pentru primul nod al arborelui.
2. [Simplificări] Se parcurg ciclic simplificările pentru nodul inițial cu metodele de simplificare. Dacă $K_2 = \emptyset$, atunci se trece la pasul 3, altfel se trece la pasul 4.
3. [Soluția reală] Rezolvă problema de programare liniară PL . Dacă problema PL nu are soluție, atunci STOP. Dacă problema PL are o soluție terminală ($Y_k = 0$ sau $Y_k = 1$, pentru orice k), atunci aceasta este soluția optimală și STOP.
4. [Terminare] Dacă au fost aplicate toate regulile de ramificare (regulile 1÷8), atunci s-a obținut o soluție euristică a problemei și STOP.
5. [Alegere regulă] Se selectează o regulă R de ramificare încă nefolosită. Dacă nodul curent este cel inițial, se rezolvă problema PL pentru a găsi mulțimea Y .
6. [Alegere depozit] Se alege un depozit conform cu regula selectată. Dacă regula este de tip 1, atunci se consideră depozitul ales deschis; altfel (regulă de tip 2) se consideră depozitul ales închis.
7. [Simplificări] Se parcurg ciclic simplificările utilizând metodele de simplificare. Dacă s-a întâlnit o condiție nerealizabilă, atunci se trece la pasul 4. (O condiție nerealizabilă are loc dacă un depozit deschis este constrâns să fie închis fie datorită tipului regulii de ramificare fie în ciclul de ramificare).
8. [Determinare Y] Dacă a fost utilizată regula de ramificare R , atunci se identifică mulțimea Y .
9. [Ajustări] Dacă $K_2 = \emptyset$, se rezolvă problema PL și se schimbă soluția euristică dacă este necesar, adică dacă această soluție este mai bună decât soluția obținută anterior, apoi se trece la pasul 4. Altfel se trece la pasul 6. ■

Metodele de simplificare pot fi sistematizate ca în următorul algoritm.

Algoritmul 6.3. (*Simplificare*)

1. [Test rădăcină] Dacă nodul curent nu este rădăcina arborelui, atunci se trece la pasul 4.
2. [Calculare Δ_i] Se calculează Δ_i pentru depozitele libere. Se alege un depozit i cu $\Delta_i > 0$. Dacă nu există un astfel de depozit, atunci STOP.
3. [Poziționare] Se consideră depozitul i deschis, se reinițializează mulțimile K_1 și K_2 și se trece la pasul 5.
4. [Test ramură închisă] Dacă ramura este închisă, atunci se trece la pasul 6.
5. [Simplificările 2 și 3] Dacă $K_2 = \emptyset$, atunci STOP. Altfel, se reinițializează P_i , n_i , K_0 , K_2 și dacă $K_2 = \emptyset$, atunci STOP. Altfel se calculează Ω_i pentru toate depozitele libere și se alege un depozit i pentru care $\Omega_i \leq 0$. Dacă nu există un astfel de depozit, atunci STOP. Altfel se consideră depozitul i închis și se reinițializează K_0 și K_2 .
6. [Eliminări clienți] Dacă $K_2 = \emptyset$, atunci STOP. Altfel, dacă există clienți deserviți de depozite ce au fost închise care să fie mai bine deserviți de depozite deschise, atunci se elimină acei clienți din mulțimile P_i de depozite libere.
7. [Ciclare] Se trece la pasul 2. ■

Subrutina de simplificare este descrisă în [KHU72].

6.5. Euristică liniară de procesare pe mașini paralele independente

Punerea problemei. Fiecare dintre cele n lucrări trebuie procesată fără întrerupere pe unul din cele m procesoare paralele independente, obiectivul fiind minimizarea timpului maxim de încheiere. ■

Este evident că dacă o procesare dată este modificată pe calea reordonării lucrărilor pe oricare dintre mașini, timpul maxim de încheiere nu se modifică. Rezultă că problema procesării se reduce la asignarea lucrărilor pe mașini.

O formulare a problemei utilizează variabile x_{ij} ce iau valorile 0, 1, pentru $i = 1, 2, \dots, n; j = 1, 2, \dots, m$, unde:

$$x_{ij} = \begin{cases} 1 & \text{dacă lucrarea } i \text{ este atribuită mașinii } j, \\ 0 & \text{altfel,} \end{cases}$$

și variabila C_{\max} ce reprezintă timpul maxim de încheiere. Variabilele x_{ij} se numesc *variabile de asignare*. Problema poate fi formulată astfel:

să se minimizeze C_{\max} ,

cu condițiile:

$$\sum_{i=1}^n t_{ij} x_{ij} \leq C_{\max}, \text{ pentru } j = 1, 2, \dots, m, \quad (6.7)$$

$$\sum_{j=1}^m x_{ij} = 1, \text{ pentru } i = 1, 2, \dots, n, \quad (6.8)$$

$$x_{ij} \in \{0, 1\}, \text{ pentru } i = 1, 2, \dots, n; j = 1, 2, \dots, m, \quad (6.9)$$

unde t_{ij} reprezintă timpul de procesare a lucrării i pe procesorul j .

Din condițiile (6.7) rezultă că C_{\max} este cel puțin egală cu timpul total de procesare pe orice mașină și condițiile (6.8) și (6.9) asigură procesarea fiecărei lucrări pe o singură mașină. În continuare, se notează cu C_{\max}^* valoarea unei soluții optimale.

Fie *programarea liniară relaxată* în care condițiile (6.9) sunt eliminate și înlocuite cu:

$$x_{ij} \geq 0, x_{ij} \leq 1, \text{ pentru } i = 1, 2, \dots, n; j = 1, 2, \dots, m,$$

unde restricția $x_{ij} \leq 1$ rezultă din (6.8). Efectul relaxării constă în posibilitatea procesării unei lucrări simultan pe mai multe mașini. O *programare parțială* poate fi obținută din soluția programării liniare relaxate pe calea asignării lucrării i mașinii j dacă $x_{ij} = 1$, pentru $i = 1, 2, \dots, n$ și $j = 1, 2, \dots, m$. Lucrările ce nu figurează în această programare parțială sunt numite *lucrări fracționate*, datorită valorii neîntregi a variabilelor de asignare. În caz favorabil, soluția programării liniare poate coincide cu cea a problemei originale, atunci când variabilele x_{ij} iau valori întregi. În continuare se deduce o margine superioară a numărului lucrărilor fracționate.

Problema programării liniare conține $m + n$ restricții în plus față de condițiile privind nenegativitatea. Rezultă că există o soluție optimală având $m + n$ variabile de bază ce pot lua valori pozitive în timp ce celelalte variabile, care nu sunt de bază, iau valoarea zero. Totuși, dacă se aplică un algoritm de programare liniară pentru obținerea unei soluții optimale în care mai mult de $m + n$ variabile iau valori pozitive, se poate folosi o procedură în timp polinomial [HAD62] pentru a transforma soluția obținută într-o soluție optimală de bază. Într-o soluție optimală de bază $C_{\max} > 0$, deci C_{\max} este o variabilă de bază. Rezultă că cel mult $m + n - 1$ variabile de asignare sunt de bază. Deoarece nici o pereche de condiții (6.8) nu conține o aceeași variabilă, este posibilă selectarea unei mulțimi B de n variabile de asignare de bază, astfel încât fiecare restricție (6.8) să conțină exact o variabilă de bază din această mulțime.

Numărul de variabile de asignare de bază este $m - 1$, mulțimea lor fiind notată în continuare cu B' . Dacă $n \geq m - 1$, cel mult $m - 1$ restricții din (6.8) conțin o variabilă din B' în plus față de o variabilă de bază din B , în timp ce $n - m + 1$ dintre

ele conțin o variabilă de bază din B și nici una din B' . În restricțiile ce conțin o singură variabilă de bază, această variabilă are valoarea unu deoarece celelalte variabile, care nu sunt de bază, iau valoarea zero. Rezultă că, pentru $n \geq m - 1$, cel puțin $n - m + 1$ variabile iau valoarea unu și în consecință cel puțin $n - m + 1$ lucrări figurează în programarea parțială și $m - 1$ lucrări sunt neprogramate.

Ideea unui algoritm euristic este următoarea. Mai întâi se rezolvă problema programării liniare relaxate și, dacă este necesar, soluția obținută este transformată într-o soluție optimală de bază. Programarea parțială este definită de variabilele de asignare ce iau valoarea unu. Pentru $n \leq m - 1$ soluția parțială poate fi vidă. Programarea completă se obține adăugând lucrările fracționate la programarea parțială. Sunt considerate toate asignările posibile ale lucrărilor fracționate și se alege asignarea ce asigură cel mai mic timp maximal de procesare. Această euristică, ce constă din programare liniară și apoi enumerare, este notată în continuare cu *PLE*.

Pentru deducerea complexității euristicii propuse se poate observa, mai întâi, că problema programării liniare cu $m \cdot n + 1$ variabile și $m + n$ restricții, poate fi rezolvată polinomial cu algoritmul lui Khachian [KHA79]. Orice transformare a soluției într-una de bază necesită de asemenea un timp polinomial. Deoarece există cel mult $m - 1$ lucrări fracționate ce urmează să fie asignate mașinilor, pe calea enumerării complete, rezultă că sunt generate cel mult m^{m-1} programări ce sunt apoi comparate în etapa a doua a algoritmului. În consecință, pentru un m fixat, complexitatea euristicii este polinomială și pentru m arbitrar complexitatea este exponențială.

Teorema 6.1. Pentru $m \geq 3$, $C_{\max}^{PLE} / C_{\max}^* \leq 2$ și această margine este cea mai bună posibil.

Demonstrație. Fie C_{\max}^{PL} valoarea soluției optime a programării liniare relaxate și C_{\max}^E timpul maxim de elaborare a programării lucrărilor fracționate, considerate separat. Deoarece programarea liniară relaxată furnizează o margine inferioară, rezultă că:

$$C_{\max}^* \geq C_{\max}^{PL}. \quad (6.10)$$

De asemenea și programarea optimală a lucrărilor fracționate furnizează o margine inferioară a timpului maxim de încheiere a programării. Prin urmare:

$$C_{\max}^* \geq C_{\max}^E. \quad (6.11)$$

O programare posibilă ce poate fi generată de *PLE* constă în adăugarea la programarea optimală a lucrărilor fracționate, considerată independent, a programării parțiale obținută drept soluție a programării liniare relaxate. Rezultă atunci că:

$$C_{\max}^{PLE} \leq C_{\max}^{PL} + C_{\max}^E. \quad (6.12)$$

Din (6.10), (6.11) și (6.12) rezultă că $C_{\max}^{PLE} / C_{\max}^* \leq 2$.

Faptul că marginea este cea mai bună posibil rezultă din exemplul 6.5. ■

Exemplul 6.5. Fie un exemplu în care cele m mașini sunt uniforme. Numărul de lucrări este m și $t_{ij} = t_i / q_j$, pentru $i, j = 1, 2, \dots, m$, unde $q_1 = m - 1$, $q_j = 1$, pentru $j = 2, 3, \dots, m$, $t_1 = (m - 1)t$ și $t_i = t$, pentru $i = 2, 3, \dots, m$, pentru orice t : pozitiv. O programare optimală se obține dacă lucrarea i este asignată mașinii i , pentru $i = 1, 2, \dots, m$, în acest caz rezultând $C_{\max}^* = t$. O soluție, nu unica, a programării liniare relaxate este $x_{11} = 0$, $x_{i1} = 1$, $i = 2, \dots, m$, $x_{1j} = 1 / (m - 1)$, pentru $j = 2, 3, \dots, m$, și $x_{ij} = 0$, pentru $i, j = 2, 3, \dots, m$. Pentru cazul particular $m = 3$, cele două matrici definite de t_{ij} și x_{ij} sunt:

$$i \begin{array}{c} \begin{array}{ccc} & \begin{array}{c} j \\ t \quad t/2 \quad t/2 \end{array} \\ \begin{array}{c} 2t \\ 2t \end{array} & \begin{array}{c} t \\ t \end{array} & \begin{array}{c} t \\ t \end{array} \end{array} \\ t_{ij} \end{array} \quad i \begin{array}{c} \begin{array}{ccc} & \begin{array}{c} j \\ 0 \quad 1 \quad 1 \end{array} \\ \begin{array}{c} 1/2 \\ 1/2 \end{array} & \begin{array}{c} 0 \\ 0 \end{array} & \begin{array}{c} 0 \\ 0 \end{array} \end{array} \\ x_{ij} \end{array}.$$

Programarea parțială asignează lucrările 2, 3, ..., m mașinii 1 și lucrarea 1 este lucrarea fracționată. Enumerarea arată că lucrarea 1 este programată pe mașina 1 de unde rezultă $C_{\max}^{PLE} = 2t$ și în consecință $C_{\max}^{PLE} / C_{\max}^* = 2$. ■

7 ALTE APLICAȚII

7.1. Euristici de ajustare a costurilor în cazul incertitudinii cererilor

Punerea problemei. Pentru problema alegerii dinamice a valorii loturilor se propune o euristică bazată pe ajustarea stabilirii costurilor în cazul când timpul la care se efectuează cererile este incert. ■

Algoritmul lui Zangwill [ZAN69] rezolvă problema alegerii dinamice a valorii loturilor ținând seama de rezerve sau lipsuri. În cadrul extensiei acestei probleme, prezentate în continuare, se consideră că producția este planificată pentru n perioade în vederea satisfacerii comenzilor L_1, L_2, \dots, L_m , fiecare dintre ele fiind efectuată într-o singură perioadă, definită de o distribuție de probabilități pe cele n perioade. Costul producerii cantității X_t în perioada t este dat de $a_t X_t + b_t \delta(X_t)$, unde $\delta(x) = 0$ dacă $x = 0$ și $\delta(x) = 1$ dacă $x \neq 0$. Constantele a_t și b_t sunt cunoscute pentru fiecare perioadă. Cantitatea D_t comandată în fiecare perioadă este o variabilă aleatoare ce depinde de distribuția comună a perioadelor în care apare comanda L_k . Inventarul inițial I_0 este cunoscut și inventarul de la sfârșitul fiecărei perioade este dat de $I_t = I_{t-1} + X_t - D_t$. Valoarea inventarului pentru fiecare perioadă are expresia $h_t I_t^+ + s_t I_t^-$, unde $I_t^+ = \max(I_t, 0)$ și $I_t^- = I_t^+ - I_t$. Costurile depozitării h_t și pierderile provocate de lipsa de materiale s_t sunt cunoscute pentru fiecare perioadă. Deoarece decizia producției pentru fiecare perioadă este luată conform cererilor din toate perioadele anterioare, X_t poate depinde de toate cererile din perioadele 1 până la $t-1$.

Sunt propuse pentru rezolvarea acestei probleme trei euristici bazate pe *algoritmul Zangwill*. Pentru fiecare dintre ele, problema dată este modificată într-una fără incertitudini, în cadrul căreia fiecare cerere L_k apare într-o perioadă specificată, după care se aplică algoritmul Zangwill, care este optimal.

Soluția deterministă ignoră efectiv incertitudinea pe calea atribuirii fiecărei cereri L_k cu o perioadă scadentă, mai precis, cererea L_k este programată în prima

perioadă t , pentru care probabilitatea ca această cerere să apară în timpul sau înaintea perioadei scadente este cel puțin $1/2$. *Euristica deterministă* este o procedură cu următorii doi pași:

1. Se specifică faptul că fiecare cerere apare în perioada scadentă.
2. Se aplică *algoritmul Zangwill* pentru obținerea soluției deterministe, adică un plan de producție fix. ■

Euristica timpului de asignare a priorității cuprinde următorii trei pași:

1. Se caută perioada scadentă pentru fiecare cerere, ca și în cazul euristicii deterministe.
2. Se verifică faptul că fiecare cerere apare cu s perioade înaintea perioadei scadente sau în prima perioadă mai mare (mai lungă).
3. Se aplică *algoritmul Zangwill* în vederea obținerii unei soluții cu timp de asignare a priorității. ■

Euristica ajustării costului cuprinde următorii trei pași:

1. Se specifică faptul că fiecare cerere apare în perioada scadentă, definită ca și în cazul euristicii deterministe.
2. Se definește un nou cost de furnizare b_t^* pentru fiecare perioadă, acest cost fiind egal cu costul de furnizare original plus costul așteptat al lipsei de materiale provocate de cererea scadentă (cererile scadente) într-o perioadă t anterioară (definiția lui b_t^* este dată mai jos).
3. Se aplică *algoritmul Zangwill* pentru obținerea soluției euristicii de ajustare a costului. ■

În vederea definirii costului ajustat b_t^* , fie variabila aleatoare H_{kt} ce ia valoarea 1 dacă cererea L_k apare în perioada t și valoarea 0 în caz contrar. Costul ajustat are expresia:

$$b_t^* = b_t + \sum_i \left(\sum_{j=1}^{t-1} s_j \cdot E \left[\sum_{k=1}^j H_{ik} \right] \right),$$

unde i parcurge toate comenzile programate în perioada t .

Euristiciile descrise au fost testate pe mai multe exemple, unul dintre ele fiind descris în continuare.

Exemplul 7.1. Considerăm un număr de 12 perioade, în fiecare dintre ele fiind programată câte o cerere, conform tabelului 7.1.

Perioada	1	2	3	4	5	6	7	8	9	10	11	12
Cererea	31	68	32	81	40	35	32	70	91	30	30	34

Tabelul 7.1.

Fiecare cerere apare cu următoarele probabilități: 0.2 cu două perioade mai devreme, 0.2 cu o perioadă mai devreme, 0.3 în perioada programată, 0.3 cu o perioadă mai târziu. Tabelul 7.2. cuprinde costurile, care sunt propuse staționare.

Costul de producție (a_i):	0
Costul de furnizare (b_i):	100
Costul pierderilor (s_i):	5
Costul depozitării (h_i):	1

Tabelul 7.2.

Tabelul 7.3. cuprinde soluțiile pentru exemplul studiat. Tabelul 7.4. cuprinde rezultatele furnizate de cele trei euristici și un algoritm optimal [BUR84]. ■

	Perioada											
	1	2	3	4	5	6	7	8	9	10	11	12
Soluția deterministă	31	100	0	121	0	67	0	70	121	0	64	0
Asigurarea priorității	131	0	121	0	67	0	70	121	0	64	0	0
Ajustarea costului	99	0	188	0	0	0	193	0	0	94	0	0

Tabelul 7.3.

Metoda	Costul așteptat
Deterministă	1799
Asigurarea priorității	1342
Ajustarea costului	1298
Optimală	1237

Tabelul 7.4.

7.2. Euristici pentru problema localizării deservirii

Punerea problemei. Fiind dată o mulțime localizată de consumatori, se cere localizarea punctelor de deservire a lor astfel încât să se minimizeze costurile. ■

Forma generală a problemei localizării deservirii are enunțul:

$$\min_{S \subseteq J} Z(S), \text{ unde } Z(S) = \sum_{i \in I} \min_{j \in S} d_{ij} + \sum_{j \in S} f_j,$$

unde $I = \{1, 2, \dots, n\}$ este mulțimea consumatorilor, $J = \{1, 2, \dots, m\}$ este mulțimea facilităților, d_{ij} reprezintă costul deservirii consumatorului i de facilitatea j .

Orice soluție S a problemei localizării deservirii induce o partiție a mulțimii I după cum urmează:

$$i \in P_s \text{ dacă } d_{is} = \min_{j \in S} d_{ij}, I = \bigcup_{s \in S} P_s.$$

Reciproc, orice partiție $\{P_s\}_{s \in S}$ a mulțimii I induce o soluție a problemei localizării deservirii și anume, pentru fiecare mulțime P_s se rezolvă problema:

$$C_s = \min_{j^* \in J} \left(\sum_{i \in P_s} d_{ij^*} + f_{j^*} \right) \quad (7.1)$$




Fig. 7.1.


Rezolvarea optimală a problemei localizării deservirii este echivalentă cu rezolvarea optimală a problemei partiționării cu ajutorul mulțimilor $P = \{P_j\}_{j=1}^N$, adică mulțimea putere a lui I , unde $N = 2^n - 1$. Fiecărei mulțimi P_j i se asociază o pondere C_j definită de (7.1). Problema studiată constă în identificarea unei acoperiri a mulțimii I de cost minim. O acoperire de cost minim este de fapt o partiție deoarece $P_1 \subset P_2 \Rightarrow C_1 \leq C_2$. Figura 7.1. ilustrează medianele induse de partiție.

În termeni de *acoperire cu mulțimi* problema localizării deservirii poate fi formulată astfel:

$$\min \sum_{j=1}^N C_j x_j, \text{ cu condiția } \sum_{j=1}^N a_{ij} x_j \geq 1, i \in I, \text{ unde } x_j \in \{0, 1\}, j \in P.$$

Definiția 7.1. O mulțime $S \subset I$ este *circular convexă* dacă $\exists j' \in J$ astfel încât pentru toate perechile s, t cu $s \in S, t \in I, d_{j's} > d_{j't} \Rightarrow t \in S$. ■

Pentru cazul în care costurile sunt egale cu distanțele euclidiene în plan, în figura 7.2. sunt reprezentate două mulțimi, prima fiind circular convexă și a doua nu.



• punct $\in I$, \times punct $\in S$.

Fig.7.2.

În cazul când mulțimea J este discretă, o clasă restrictivă de mulțimi circular convexe se generează astfel: pentru fiecare $j \in J$ se identifică șirul $d_{j_1} \leq d_{j_2} \leq \dots \leq d_{j_n}$,

unde $i_k \in I$; în cazul egalității a două elemente ordinea este arbitrară; pentru $j \in J$ se generează secvențial mulțimile circular convexe pentru care j este centru: $\{i_1\}$, $\{i_1, i_2\}$, ..., $\{i_1, \dots, i_{n-1}\}$, $\{i_1, \dots, i_n\}$.

Rezultă că numărul de mulțimi convexe centrate în j este n .

Pentru rezolvarea problemei acoperirii cu mulțimi se folosește, în calitate de procedură, *algoritmul Chvatal* [CHV79] prezentat în continuare.

Algoritmul 7.1. (Chvatal)

- [Inițializare] Se face $ACOPERIRE = \emptyset$.
- [Terminare] Dacă $P_j = \emptyset$ pentru orice $j \in \{1, 2, \dots, N\}$, atunci STOP.
- [Alegere] Se determină k astfel încât: $\frac{|P_k|}{C_k} = \max_{j \in \{1, \dots, N\}} \frac{|P_j|}{C_j}$.
- [Ajustare] Se face $ACOPERIRE = ACOPERIRE \cup \{k\}$, $P_j = P_j - P_k$ pentru orice j .
- [Ciclare] Se trece la pasul 2. ■

Pașii 2 - 5 necesită un număr de operații proporțional cu N . Acești pași se repetă până când sunt acoperite toate cele n puncte ale mulțimii I . Deoarece la fiecare iterație mulțimea selectată conține măcar un element, rezultă că numărul maxim de iterații este n , deci complexitatea temporală a algoritmului este $O(n \cdot N)$.

Ținând seama că $|J| = m$ și că numărul de mulțimi circular convexe centrate în $j \in J$ este $n = |I|$, rezultă că numărul total de mulțimi circular convexe este $m \cdot n$.

Un prim algoritm pentru rezolvarea problemei acoperirii cu mulțimi este prezentat în continuare.

Algoritmul 7.2. (Acoperire)

- [Inițializare] Se identifică toate mulțimile circular convexe $P_j \subset I$ și se face $I' = I$ și $ACOPERIRE = \emptyset$.
- [Terminare] Dacă $I' = \emptyset$ sau $P_j = \emptyset$, pentru orice $j \in \{1, 2, \dots, N\}$, atunci STOP.
- [Alegere] Se determină k astfel încât: $\frac{|P_k|}{C(P_k)} = \max_{P_j \neq \emptyset} \frac{|P_j|}{C(P_j)}$.
- [Ajustare] Se face $ACOPERIRE = ACOPERIRE \cup \{k\}$, $P_j = P_j - P_k$ și $C(P_j) = C(P_j - P_k)$, pentru orice j , $I' = I' - P_k$.
- [Ciclare] Se trece la pasul 2. ■

Complexitatea algoritmului este $O(n^2 \cdot m)$.

O altă formă de implementare a problemei acoperirii cu mulțimi se deosebește de cea precedentă prin aceea că la fiecare iterație sunt generate toate mulțimile circular convexe.

În cel mai nefavorabil caz, pentru Algoritmul 7.3., timpul de lucru are același ordin. Memoria necesară pentru Algoritmul 7.3. este matricea punctelor ordonate ale lui I și matricea distanțelor, adică $O(m \cdot n)$. Pentru Algoritmul 7.2. este necesară memorarea matricei distanțelor și a tuturor mulțimilor circular convexe. Deoarece fiecare mulțime circular convexă poate conține până la n puncte, rezultă că memoria necesară este $O(n^2 m)$. Rezultă că Algoritmul 7.3. este mai eficient.

Algoritmul 7.3. (Acoperire eficientă)

1. [Inițializare] Pentru orice $j \in J$, se sortează elementele lui I față de distanța crescătoare la j și se face $I' = I$ și $ACOPERIRE = \emptyset$.
2. [Terminare] Dacă $I' = \emptyset$, atunci STOP.
3. [Evaluare] Pentru orice $j \in J$, se evaluează toate submulțimile circular convexe ale lui I' în conformitate cu ordinea din pasul 1. Pentru fiecare mulțime se calculează $|P|/C(P)$. Se memorează numai P_k și $C(P_k)$ care maximizează valoarea de mai sus.
4. [Ajustare] Se face $ACOPERIRE = ACOPERIRE \cup \{k\}$ și $I' = I' - P_k$.
5. [Ciclare] Se trece la pasul 2. ■

Complexitatea algoritmului este cel mult $O(n^2 \cdot m)$.

7.3. Problema reprovizionării comune

Punerea problemei. Se cere identificarea unei strategii eficiente de reprovizionare a unei firme furnizoare pentru satisfacerea tuturor cererilor mai multor clienți. ■

Pentru problema reprovizionării comune se poate arăta (vezi [VEI69]) că o strategie optimală constă în comanda fiecărui articol într-un interval de timp t , dacă inventarul lui la sfârșitul perioadei $(t - 1)$ este nul. Se presupune că intervalele de timp succesive au o durată egală cu 1. Fie un articol i pentru care se efectuează două comenzi succesive în perioadele s și t , unde $1 \leq s < t \leq T + 1$, T fiind orizontul temporal al reprovizionării. Rezultă că reprovizionarea trebuie să acopere cererile din perioadele s până la $(t - 1)$. Fie în continuare următoarele definiții:

C_{ist} - costul articolului i solicitat în perioadele s până la $(t - 1)$, dacă acest articol este comandat numai în perioadele s și $t = K_i + H_i \sum_{\tau=s+1}^{t-1} (\tau - s)d_{i\tau}$, unde K_i este costul comenzii articolului i , H_i este costul inventarierii pe unitatea de timp a articolului i și $d_{i\tau}$ este cererea articolului i în perioada de timp τ ,

$$X_{ist} = \begin{cases} 1 & \text{dacă articolul } i \text{ este comandat numai în perioadele } s \text{ și } t, \\ 0 & \text{altfel,} \end{cases}$$

$$X_i = \begin{cases} 1 & \text{dacă orice articol este comandat în perioada } t, \\ 0 & \text{altfel.} \end{cases}$$

Fie de asemenea notațiile:

K_0 - costul comun de efectuare a unei comenzi,

N - numărul total de articole.

Cu aceste definiții și notații, problema reaprovizionării comune poate fi formulată în termeni de programare liniară astfel:

$$\text{Minimizează } \sum_{i=1}^N \sum_{t=s+1}^T \sum_{s=1}^{T+1} C_{ist} X_{ist} + \sum_{t=1}^T K_0 X_t,$$

cu condițiile:

$$\sum_{t>s} X_{ist} - \sum_{k<s} X_{iks} = 0, \text{ pentru } i = 1, 2, \dots, N, s = 2, 3, \dots, T,$$

$$\sum_{s>1} X_{i1s} = 1, \text{ pentru } i = 1, 2, \dots, N,$$

$$X_t - \sum_{t>s} X_{ist} \geq 0, \text{ pentru } i = 1, 2, \dots, N, s = 1, 2, \dots, T,$$

$$X_{ist}, X_t = 0 \text{ sau } 1.$$

O metodă eficientă de obținere a unei soluții optimale a problemei enunțate mai sus este prezentată în continuare.

Ideea de bază a euristicii constă în echilibrarea costului individual de inventariere a unui articol cu costul necesar comenzii acestui articol. Mai precis, ori de câte ori costul total de inventariere a unui articol, începând cu ultima sa comandă, depășește costul individual al comenzii acestui articol, el devine candidat pentru efectuarea unei noi comenzi. O comandă comună este efectuată atunci când costul total de inventariere a tuturor articolelor candidat depășește costul total al comenzii lor plus costul comun al comenzii.

Fie t_i ultima perioadă în care a fost comandat articolul i și T_{it} costul total de inventariere al acestui articol în perioadele t_i, t_{i+1}, \dots, t , presupunând că nici o comandă nu a fost efectuată în perioada t . Atunci:

$$T_{it} = H_i \sum_{j=1}^{t-t_i} j d_{i,t_i+j}.$$

În fiecare perioadă t în cadrul euristicii se calculează T_{it} pentru fiecare articol. Dacă T_{it} depășește pe K_i , atunci articolul i devine candidat al comenzii lui. Totuși, comanda nu este efectuată decât dacă acești candidați pot acoperi costul comenzii comune. Rezultă că în perioada t se aplică următoarea regulă.

Regula 1. Se comandă toate articolele candidat, adică cele pentru care $T_{it} \geq K_i$, în perioada t dacă $\sum_{i=1}^N (T_{it} - K_i)^+ \geq K_0$. În continuare are loc trecerea la următoarea perioadă de timp.

Fie t perioada în care a fost efectuată o comandă comună în conformitate cu regula 1. Este posibil ca un articol, care nu este un candidat, să impună o nouă

comandă, foarte curând după perioada t . În acest caz, poate fi mai avantajos să se comande acest articol în perioada t în vederea evitării costului suplimentar în cazul unei comenzi separate. Pentru ilustrarea acestei idei considerăm următorul exemplu.

Exemplul 7.2. Fie două articole cu $H_1 = H_2 = 1$ și comenzile:

$$d_{1,t} = 0, \text{ pentru } t = 1, 2, \dots, (m - 1),$$

$$d_{1,m} = (K_0 + K_1) / (m - 1),$$

$$d_{2,t} = 0, \text{ pentru } t = 1, 2, \dots, m,$$

$$d_{2,m+1} = (K_0 + K_2) / m.$$

În conformitate cu regula 1 articolul 1 va fi comandat în perioada m și articolul 2 în perioada $m + 1$. Dacă însă cele două articole sunt comandate în perioada m , atunci pentru articolul 2 rezultă un extracost de inventariere egal cu $(K_0 + K_2) / m$ însoțit de o reducere în costul comun K_0 . Dacă m este destul de mare, reducerea va fi mai mare decât extracostul de inventariere. Pe lângă aceasta, dacă numărul N de articole este mare, atunci într-un exemplu similar, euristica va comanda fiecare articol într-o perioadă distinctă, astfel încât costul comun va trebui achitat de N ori. Dacă toate articolele sunt comandate în aceeași perioadă cu primul, atunci se asigură o economie egală cu $(N - 1) K_0$ în costul comenzilor cu prețul unei creșteri mici a costului inventarierii. Rezultă că, în forma descrisă, euristica poate avea o performanță oricât de rea dacă numărul de articole este mare. ■

Fie t_0 perioada în care a fost efectuată o comandă comună și i un articol ce nu a fost candidat să fie comandat în această perioadă deoarece $T_{i,t_0} < K_i$. Pentru acest articol, ultima perioadă t_i în care a fost comandat satisface condiția $t_i < t_0$. Fie S_{ii} mărimea definită prin:

$$S_{ii} = H_i (t_0 - t_i) \sum_{j=t_0}^{t_i} d_{ij},$$

care reprezintă economia în inventarierea articolului i dacă o comandă a acestui articol este plasată în intervalul t_0 . Evident că efectuarea acestei comenzi este indicată dacă economia în inventariere este mai mare decât costul comenzii K_i a articolului i . De aici rezultă:

Regula 2. Dacă la momentul t ultima comandă comună a avut loc în intervalul t_0 și articolul i n-a fost comandat în acest interval și $S_{ii} \geq K_i$, atunci și articolul i este comandat în intervalul t_0 .

Reflectarea acestei reguli constă în recalcularea lui T_{ii} . Adică T_{ii} se calculează începând cu t_0 , în loc de t_i .

Exemplul 7.3. Pentru a vedea de ce schimbarea ordinii, descrisă mai sus, previne comportarea neeficientă a euristicii, fie din nou datele din exemplul 7.2.

La momentul $m+1$, pentru articolul 2 cantitatea $S_{2,m+1}$ este $(m-1)(K_0+K_2)/m$. Rezultă că $S_{2,m+1} \leq K_2$ dacă $K_0 \leq K_2/(m-1)$ și, în consecință, euristica nu schimbă ordinea comenzii articolului 2 dacă fie K_0 , fie m au valori mici. Dacă însă K_0 sau m au valori mari, atunci euristica schimbă ordinea articolului 2 și asigură o strategie optimală. ■

În continuare se prezintă euristica cu observația că, pentru simplificare, se introduce intervalul fictiv $T + 1$ de la sfârșitul orizontului temporal, în cazul căruia comanda pentru fiecare articol este nulă.

Algoritmul 7.4. (Euristica acoperirii costului)

- [Inițializări] Se face $t = 1$, $T_{it} = S_{it} = 0$, pentru orice i , și $t_0 = t_i = 1$, pentru orice i . Se comandă în prima perioadă fiecare articol.
- [Terminare] Se face $t = t + 1$ și dacă $t > T$, atunci STOP.
- [Determină candidați] Pentru fiecare articol i se calculează S_{it} și dacă $S_{it} \geq K_i$ (Regula 2: schimbă comanda articolului i), atunci se plasează comanda articolului i în intervalul t_0 și se efectuează atribuirea $t_i = t_0$. Pentru fiecare articol i se calculează T_{it} și se consideră drept candidați acei i pentru care $T_{it} \geq K_i$.
- [Regula 1] Dacă $\sum_{i=1}^N (T_{it} - K_i)^+ \geq K_0$ se plasează o comandă a tuturor candidaților în intervalul t . Se face $t_0 = t$ și pentru toate articolele candidat se face $t_i = t$.
- [Ciclare] Se trece la pasul 2. ■

Este ușor de văzut că T_{it} și S_{it} se calculează în timp constant cu ajutorul lui $T_{i,t-1}$ și $S_{i,t-1}$. Deci complexitatea temporală a algoritmului este $O(NT)$.

Se poate demonstra că raportul dintre soluțiile furnizate de euristica propusă și cea optimală este cel mult 3. Problema studiată este NP-completă.

Exemplul 7.4. Aplicând algoritmul precedent pentru datele $K_0 = 1$, $K_1 = 1$, $K_2 = 4$; $H_1 = H_2 = 1$; $d_{11} = 2$, $d_{12} = 4$, $d_{13} = 1$, $d_{21} = 3$, $d_{22} = 2$, $d_{23} = 2$; $T = 3$; $N = 2$ se obțin următoarele rezultate intermediare.

Pasul 1: Se face $t = 1$, $T_{11} = S_{11} = T_{21} = S_{21} = 0$, $t_0 = t_1 = t_2 = 1$. Se efectuează comenzile $d_{11} = 2$ și $d_{21} = 3$.

Pasul 2: Se face $t = 2$ și deoarece $t < T$ algoritmul continuă.

Pasul 3: Se calculează:

$$S_{12} = H_1 (t_0 - t_1) \sum_{j=1}^2 d_{1j} = 0 < K_1 = 1 \text{ și } S_{22} = H_2 (t_0 - t_2) \sum_{j=1}^2 d_{2j} = 0 < K_2 = 4,$$

deci nu au loc plasări conform Regulei 2. Se calculează:

$$T_{12} = H_1 \sum_{j=1}^1 j \cdot d_{1,1+j} = 1 \cdot d_{12} = 4 > K_1 = 1, \text{ rezultă că } 1 \text{ este candidat, și}$$

$$T_{22} = H_2 \sum_{j=1}^1 j \cdot d_{2,1+j} = 1 \cdot d_{22} = 2 < K_2 = 4, \text{ rezultă că } 2 \text{ nu este candidat.}$$

Pasul 4: Deoarece $\sum_{i=1}^2 (T_{i2} - K_i)^+ = (4-1)^+ + (2-4)^+ = 3+0=3 > K_0=1$, se plasează comanda candidat $d_{12}=4$ în intervalul $t=2$ și se face $t_0=2$ și $t_1=2$.

Pasul 2: Se face $t = 3$ și deoarece $t = T$ algoritmul continuă.

Pasul 3: Se găsesc: $S_{13}=H_1(t_0-t_1) \sum_{j=2}^3 d_{1j}=0 < K_1=1$ și $S_{23}=H_2(t_0-t_2) \sum_{j=2}^3 d_{2j}=d_{22}+d_{23}=4=K_2$, deci, conform Regulei 2, se plasează comanda $d_{22}=2$ în intervalul $t=2$ și se face $t_2=2$. Se calculează $T_{13}=H_1 \sum_{j=1}^2 j \cdot d_{1,2+j}=1 \cdot d_{13}=1=K_1$, rezultă că 1 este candidat, și

$T_{23}=H_2 \sum_{j=1}^2 j \cdot d_{2,2+j}=1 \cdot d_{22}+2 \cdot d_{23}=6 > K_2=4$, rezultă că și 2 este candidat.

Pasul 4: Deoarece $\sum_{i=1}^2 (T_{i3} - K_i)^+ = (1 - 1)^+ + (6 - 4)^+ = 0 + 2 = 2 > K_0 = 1$, se plasează comenzile candidat $d_{13} = 1$ și $d_{23} = 2$ în intervalul $t = 3$ și se face $t_0 = 3$ și $t_1 = t_2 = 3$.

Pasul 2: Se face $t = 4$ și deoarece $t > T$ algoritmul se termină.

Toate comenzile au fost plasate conform tabelului 7.5.

Interval	1	2	3
Comenzi	d_{11}, d_{21}	d_{12}, d_{22}	d_{13}, d_{23}

Tabelul 7.5.

Soluția obținută este optimală deoarece toate cele șase comenzi au fost plasate în intervale succesive. ■

7.4. Plasarea optimală a băncilor de conturi

Punerea problemei. Numărul de zile necesar pentru eliberarea unui CEC într-o bancă din orașul j depinde de orașul i în care ceul este încasat. Rezultă că, pentru maximizarea fondurilor disponibile, o companie ce achită note de plată la mai mulți clienți din localități diferite, poate considera ca fiind avantajos să dețină conturi în mai multe bănci, alese în mod strategic. Achitățile notelor de plată clienților din orașul i se efectuează de către o bancă din orașul $j(i)$ ce dispune de cel mai mare timp de eliberare. ■

Fie $I = \{1, 2, \dots, n\}$ mulțimea locațiilor clienților, $J = \{1, 2, \dots, n\}$ mulțimea locațiilor de conturi, d_j costul fix de menținere a unui cont în orașul j , f_i volumul în dolari a cecurilor achitate în orașul i , p_{ij} numărul de zile, tradus în valori monetare, pentru eliberarea unui CEC în orașul j și încasat în orașul i și K numărul maxim de conturi ce poate fi menținut. Toate aceste informații se presupun cunoscute și $c_{ij} = f_i p_{ij}$ reprezintă valoarea achitată clienților din orașul i dintr-un cont din orașul j .

Fie:

$$y_j = \begin{cases} 1 & \text{dacă un cont este menținut în orașul } j, \\ 0 & \text{altfel.} \end{cases}$$

Plata tuturor clienților din orașul i dintr-un singur cont se consideră optimală. Fie $x_{ij}=1$ dacă clienții din orașul i sunt deserviți de contul j , și $x_{ij} = 0$ altfel. Dacă $y_j=0$, atunci $x_{ij}=0$, pentru toți $i \in I$. Rezultă că problema locațiilor conturilor (a băncilor de conturi), numită în continuare (P), poate fi formulată în termeni de programare liniară întregă (IP) astfel:

$$z = \max \sum_{i \in I} \sum_{j \in J} c_{ij} x_{ij} - \sum_{j \in J} d_j y_j$$

$$\sum_{j \in J} x_{ij} = 1, i \in I \quad (7.2)$$

$$1 \leq \sum_{j \in J} y_j \leq K \quad (7.3)$$

$$0 \leq x_{ij} \leq y_j \leq 1, i \in I, j \in J \quad (7.4)$$

$$x_{ij} \text{ și } y_j \text{ întregi, } i \in I, j \in J \quad (7.5)$$

În lucrarea [GEO74] se propune o relaxare lagrangeană a problemei (P) în care restricțiile (7.2) sunt ponderate cu multiplicatori și introduse în funcția obiectiv. Fie x și y vectorii $x_{ij}, i \in I, j \in J$ și $y_j, j \in J$. Fie apoi $u = (u_1, u_2, \dots, u_m)$ multiplicatorii restricțiilor (7.2) și

$$L(x, y, u) = \sum_{i \in I} \sum_{j \in J} c_{ij} x_{ij} - \sum_{j \in J} d_j y_j - \sum_{i \in I} u_i \left(\sum_{j \in J} x_{ij} - 1 \right) =$$

$$= \sum_{j \in J} \left[\sum_{i \in I} (c_{ij} - u_i) x_{ij} - d_j y_j \right] + \sum_{i \in I} u_i.$$

Problema lagrangeană este definită de $z_D(u) = \max_{(x,y)} L(x, y, u)$, condițiile (7.3), (7.4) și (7.5) și problema duală este $z_D = \min_u z_D(u)$. Se cunoaște că $z_D \geq z$.

Pentru u fixat, problema determinării lui $z_D(u)$ poate fi rezolvată după cum urmează. Din a doua expresie a lui $L(x, y, u)$ și (7.4) rezultă că valorile optime ale lui x_{ij} în problema lagrangeană sunt date de:

$$x_{ij} = y_j, \text{ dacă } c_{ij} - u_i \geq 0,$$

$$x_{ij} = 0, \text{ altfel.}$$

Definind:

$$\rho_j(u) = \sum_{i \in I} \max(0, c_{ij} - u_i) - d_j,$$

se deduce că valorile optime ale lui y_j rezolvă problema:

$$\max \sum_{j \in J} \rho_j(u) y_j \text{ cu condițiile } 1 \leq \sum_{j \in J} y_j \leq K, y_j = 0 \text{ sau } 1, j \in J.$$

În cadrul euristicii de tip Greedy propuse, se identifică mai întâi o locație ce rezolvă problema (P) pentru $K = 1$ și apoi se procedează recursiv. Fie $k < K$ locații selectate. Dacă există o locație neselectată care crește valoarea funcției obiectiv, atunci se caută una care asigură o creștere maximală; altfel STOP.

Algoritmul 7.5. (Plasare)

- [Inițializări] Se face $k = 1$, $J^* = \emptyset$ și $u_i^1 = \min_{j \in J} c_{ij}$, pentru $i \in I$.
- [Alegere] Se face $\rho_k(u^k) = \sum_{i \in I} \max(0, c_{ij} - u_i^k) - d_j$, $j \notin J^*$. Se alege $j_k \in J^*$ astfel încât $\rho_k = \rho_{j_k}(u^k) = \max_{j \in J^*} \rho_j(u^k)$. Dacă $\rho_k < 0$ și $|J^*| \geq 1$, se face $k = k - 1$ și se trece la pasul 4. Altfel se face $J^* = J^* \cup \{j_k\}$.
- [Progresare] Dacă $|J^*| \neq K$, se face $k = k + 1$, $u_i^k = \max_{j \in J^*} c_{ij} = u_i^{k-1} + \max(0, c_{ij_{k-1}} - u_i^{k-1})$, pentru $i \in I$, și se trece la pasul 2.
- [Terminare] STOP. (Soluția Greedy este dată de $y_j = 1$, pentru $j \in J^*$ și $y_j = 0$ altfel. Valoarea lui $|J^*|$ este k și valoarea soluției este $z_g = \sum_{i=1}^m u_i^1 + \sum_{j=1}^k \rho_j$.) ■

Exemplul 7.5. Fie $d = 0$, $K = 2$ și

$$C = \begin{bmatrix} 0 & 11 & 6 & 9 \\ 7 & 0 & 8 & 2 \\ 7 & 3 & 0 & 3 \\ 10 & 9 & 4 & 0 \end{bmatrix}.$$

Calculule pentru exemplul dat sunt următoarele.

Pasul 1. $k = 1$, $J^* = \emptyset$, $u^1 = (0, 0, 0, 0)$.

Pasul 2. $\rho_1(u^1) = \sum_{i \in I} \max(0, c_{i1} - u_i^1) - d_1 = \max(0, 0-0) + \max(0, 7-0) + \max(0, 7-0) + \max(0, 10-0) = 24$, $\rho_2(u^1) = \sum_{i \in I} \max(0, c_{i2} - u_i^1) - d_2 = \max(0, 11-0) + \max(0, 0-0) + \max(0, 7-0) + \max(0, 9-0) = 23$, $\rho_3(u^1) = \sum_{i \in I} \max(0, c_{i3} - u_i^1) - d_3 = \max(0, 6-0) + \max(0, 8-0) + \max(0, 0-0) + \max(0, 4-0) = 18$, $\rho_4(u^1) = \sum_{i \in I} \max(0, c_{i4} - u_i^1) - d_4 = \max(0, 9-0) + \max(0, 7-0) + \max(0, 3-0) + \max(0, 0-0) = 19$, $\max_{j \in J^*} \rho_j(u^1) = \rho_1(u^1) = 24$, $j_1 = 1$ și $J^* = \{1\}$.

Pasul 3. $u_i^2 = u_i^1 + \max(0, c_{ij_1} - u_i^1)$. $u_1^2 = 0 + \max(0, c_{11} - 0) = 0$, $u_2^2 = 0 + \max(0, c_{12} - 0) = 7$, $u_3^2 = 0 + \max(0, c_{13} - 0) = 7$, $u_4^2 = 0 + \max(0, c_{14} - 0) = 10$; $u^2 = (0, 7, 7, 10)$.

Pasul 2. $\rho_1(u^2)$ nu se calculează deoarece $J^* = \{1\}$. $\rho_2(u^2) = \sum_{i \in I} \max(0, c_{i2} - u_i^2) = \max(0, 11-0) + \max(0, 0-7) + \max(0, 3-7) + \max(0, 10-10) = 11$, $\rho_3(u^2) = \sum_{i \in I} \max(0, c_{i3} - u_i^2) = \max(0, 6-0) + \max(0, 8-7) + \max(0, 0-7) + \max(0, 4-10) = 7$, $\rho_4(u^2) = \sum_{i \in I} \max(0, c_{i4} - u_i^2) = \max(0, 9-0) + \max(0, 2-7) + \max(0, 3-7) + \max(0, 0-10) = 9$. $\max_{j \in \{1\}} \rho_j(u^2) = 11$, $j_2 = 2$, $J^* = \{1, 2\}$, $|J^*| = 2$.

Pasul 4. $z_g = \sum_{i=1}^4 u_i^1 + \sum_{j=1}^2 \rho_j = 0 + 24 + 11 = 35$. ■

7.5. Descompunerea euristică a matricilor de trafic în comunicarea sateliților

Punerea problemei. Fiind dată o matrice $n \times n$ a traficului informațional între n stații radio ce recepționează emisiunile unui satelit și intercomunică între ele, se cere descompunerea matricei de mai sus într-o sumă ponderată a unui număr mic de matrici de permutare astfel încât suma ponderilor să fie minimală. O matrice de permutare $n \times n$ conține n elemente nenule, așezate în linii și coloane distincte. ■

Aplicații posibile: comunicații, televiziune, radio, rețele de calculatoare.

Problema descompunerii matricii traficului (*PDMT*) se enunță formalizat în felul următor.

Fiind dată o matrice $n \times n$, $T = (t_{ij})$ cu intrări nenegative, să se găsească o descompunere a matricei T , adică o secvență de matrici de permutare p^1, p^2, \dots, p^q și o secvență de ponderi nenegative l_1, l_2, \dots, l_q astfel încât:

$$T \leq \sum_{k=1}^q l_k p^k \quad (\text{cu sumare pe elemente}). \quad (7.6)$$

Durata totală d a descompunerii este egală cu:

$$d = \sum_{k=1}^q l_k.$$

Problema constă în efectuarea unei descompuneri în care d să fie minimizată cu condiția ca valoarea lui q să nu fie prea mare.

Algoritmul propus are la bază ideea rotunjirii elementelor matricei T la valori întregi și rezolvarea problemei puse pentru matricea întregă astfel obținută. Pentru o matrice T nenegativă de dimensiune $n \times n$ structura algoritmului este următoarea.

Algoritmul 7.6. (*Descompunere*)

- [Căutare] Se caută o unitate $F > 0$.
- [Rotunjire] Se rotunjesc superior intrările matricei la multipli ai lui F :

$$\bar{t}_{ij} = F \cdot \left\lceil \frac{t_{ij}}{F} \right\rceil.$$

- [Soluție întregă] Se rezolvă problema descompunerii pentru matricea rezultată \bar{T} (sau echivalent, pentru matricea întregă U având ca elemente $(u_{ij}) = \left(\left\lceil t_{ij} / F \right\rceil \right)$ obținută prin împărțirea acestor elemente la F).
- [Rectificare soluție] Se ajustează descrescător descompunerea obținută în vederea compensării rotunjirii de la pasul 2. ■

Baza algoritmului o constituie pasul 2 pentru rezolvarea căruia se consideră două metode pe care le expunem în continuare.

Prima metodă, simplă și rapidă, folosește *colorarea arcelor*. Fie u^* suma maximă pe linii și coloane a unei matrici U și cazul particular al descompunerii de la pasul 3 dacă $l_k = 1$ în (7.6). Această problemă coincide cu problema colorării unui graf bipartit având vârfulurile r_i și c_j , $i, j = 1, 2, \dots, n$ și câte u_{ij} arce paralele între r_i și c_j . Problema colorării constă în atribuirea de culori tuturor arcelor astfel încât să nu existe două arce de aceeași culoare convergente în același vârf. Arcele de aceeași culoare formează o împerechere și matricea de adiacență corespunzătoare, de dimensiune $n \times n$, poate fi completată arbitrar în vederea obținerii unei permutări complete de tipul celor din formularea (7.6). Metoda descrisă furnizează descompunerea în u^* matrici de permutare, dar nu poate fi adaptată în vederea micșorării numărului acestor matrici.

Problema determinării valorii lui F constă în determinarea unei valori minimele a lui F astfel încât suma maximă pe linii și coloane a matricii $|t_{ij} / F|$ să nu depășească o valoare M dată. Pentru aceasta se parcurg succesiv toate liniile și coloanele matricii T și se alege cea mai mare valoare a lui F . Fie pentru precizare primul rând al matricii T , pentru care se caută cel mai mic F astfel încât:

$$\sum_{j=1}^n \left[t_{1j} / F \right] \leq M.$$

Pentru aceasta se consideră tabelul:

$$\begin{array}{cccc} t_{11}, & t_{11} / 2, & t_{11} / 3, & t_{11} / 4, \\ t_{12}, & t_{12} / 2, & t_{12} / 3, & t_{12} / 4, \\ \vdots & & & \\ t_{1n}, & t_{1n} / 2, & t_{1n} / 3, & t_{1n} / 4, \end{array}$$

Dacă un element t_{lj} este egal cu 0, el este eliminat deoarece nu poate contribui la identificarea valorii F . Altfel, dacă F este cuprinsă între intrările $(l - 1)$ și l ale rândului j (sau egală cu intrarea l), atunci $|t_{lj} / F| = l$. Cu alte cuvinte, $|t_{lj} / F|$ este egală cu 1 plus numărul de elemente din rând mai mari decât F . Prin urmare:

$$\sum_{j=1}^n \left[t_{lj} / F \right] = n' + \text{numărul de elemente din tabel mai mari decât } F,$$

unde n' este numărul de elemente nenule. În continuare se identifică cel mai mic F astfel încât cel mult $M - n'$ elemente să fie mai mari decât F , adică F este al $(M - n' + 1)$ -lea mai mare element din tabel.

O margine superioară a lui F este:

$$\bar{F} = \frac{r_1}{M - n + 1}, \text{ unde } r_1 = \sum_{j=1}^n t_{1j} / j,$$

deoarece:

$$\sum_{j=1}^n \left[t_{1j} / \bar{F} \right] < \sum_{j=1}^n \left(t_{1j} / \bar{F} + 1 \right) = r_1 / \bar{F} + n = (M - n + 1) + n = M + 1$$

și prin urmare $\sum_{j=1}^n \left[t_{1j} / F \right] \leq M$.

Dacă din fiecare rând j al tabelului se elimină primele $\lceil t_{1j} / \bar{F} \rceil - 1$ elemente, atunci ele coincid cu toate elementele mai mari decât \bar{F} , numărul lor fiind $\underline{M} = \sum_{j=1}^n \lceil t_{1j} / \bar{F} \rceil - n'$, care este cuprins între $M - 2n' + 1$ și $M - n'$. Rezultă că F , care este al $(M - n' + 1)$ -lea mai mare element din tabelul inițial este al k -lea cel mai mare element din tabelul redus, unde $k = (M - n' + 1) - \underline{M}$ este cuprins între 1 și n .

Procedeul descris se reia pentru toate rândurile și coloanele matricii T și furnizează valoarea căutată a lui F .

În a doua metodă, pentru a reduce numărul q al matricelor componente ale matricii U , se poate aplica următoarea strategie *Greedy*: Se selectează prima matrice ponderată a permutării $l_1 p^1$ astfel încât suma maximă pe linii și coloane a matricii trafic rămasă, egală cu $\max(U - l_1 p^1, 0)$ să fie redusă cât mai mult. Drept rezultat, are loc reducerea marginii u^* a numărului matricilor următoare care participă la descompunere. Modul în care se determină p^1 și l_1 este prezentat în continuare.

Fie r_i și c_j sumele elementelor din rândul i și coloana j ale matricii U , obținută după aplicarea pasului 3 al euristicii descrise mai înainte. Pentru rândurile (coloanele) critice, adică rândurile (coloanele) pentru care $r_i = u^*$ ($c_j = u^*$) trebuie satisfăcută condiția $l_1 \leq u_{ij}$, dacă $p_{ij}^1 = 1$. Pentru rândurile și coloanele necritice, valorile r_i , respectiv c_j , satisfac condițiile $r_i < u^*$, respectiv $c_j < u^*$. Pentru aceste rânduri trebuie satisfăcute condițiile:

$$l_1 \leq u_{ij} + (u^* - r_i), \text{ respectiv } l_1 \leq u_{ij} + (u^* - c_j), \text{ dacă } p_{ij}^1 = 1.$$

Rezultă atunci că, pentru un rând oarecare (critic sau necritic), trebuie satisfăcută condiția:

$$\text{Dacă } p_{ij}^1 = 1, \text{ atunci } l_1 \leq u_{ij} + (u^* - \max\{r_i, c_j\}). \quad (7.7)$$

După determinarea lui p^1 și l_1 , $\min(l_1 p^1, U)$ se scade din U . În continuare se determină p^2 și l_2 etc.

Exemplul 7.6. Fie matricea:

$$U = \begin{matrix} & \begin{matrix} 16 & 15 & 14 \end{matrix} \\ \begin{matrix} 14 \\ 15 \\ 16 \end{matrix} & \begin{bmatrix} 3 & 5 & 6 \\ 8 & 6 & 1 \\ 5 & 4 & 7 \end{bmatrix} \end{matrix} \text{ cu } u^* = 16,$$

sumele pe linii și coloane fiind notate lângă matrice. Să presupunem că se încearcă descompunerea matricii începând cu $l_1 = 7$, ceea ce ar reduce pe u^* la 9. Parcurgând succesiv elementele matricii U se deduce că singurele elemente ce satisfac condiția (7.7) sunt cele ce urmează:

$$\begin{bmatrix} \bullet & \bullet & 6 \\ 8 & 6 & \bullet \\ \bullet & \bullet & 7 \end{bmatrix}$$

Se observă că nici un triplet al elementelor nenule din matricea precedentă nu definește o matrice ce descrie o permutare. Dacă se încearcă însă $l_1 = 6$, se obține matricea:

$$\begin{bmatrix} \bullet & \mathbf{5} & 6 \\ 8 & 6 & \bullet \\ \bullet & \bullet & 7 \end{bmatrix}$$

în care elementele îngroșate definesc o permutare (p^1). Matricea definită de partea din dreapta a condiției (7.7) se obține adăugând la fiecare intrare în U a minimului diferenței dintre u^* și sumele de pe linia și coloana corespunzătoare intrării considerate. Rezultă:

$$\begin{bmatrix} 3 & 5 & 6 \\ 8 & 6 & 1 \\ 5 & 4 & 7 \end{bmatrix} + \begin{matrix} 2 \\ 1 \\ 0 \end{matrix} \begin{matrix} 0 & 1 & 2 \\ 0 & 1 & 2 \\ 0 & 0 & 0 \end{matrix} = \begin{bmatrix} 3 & 6 & 8 \\ 8 & 7 & 2 \\ 5 & 4 & 7 \end{bmatrix},$$

unde diferențele menționate sunt notate pe lângă cea de a doua matrice.

Ținând seama că $l_1 = 6$ și că permutarea p^1 este cea menționată, rezultă descompunerea:

$$\begin{bmatrix} 3 & 5 & 6 \\ 8 & 6 & 1 \\ 5 & 4 & 7 \end{bmatrix} = \begin{bmatrix} 0 & 5 & 0 \\ 6 & 0 & 0 \\ 0 & 0 & 6 \end{bmatrix} + \begin{matrix} 9 \\ 9 \\ 10 \end{matrix} \begin{matrix} 10 & 10 & 8 \\ 3 & 0 & 6 \\ 2 & 6 & 1 \\ 5 & 4 & 1 \end{matrix}.$$

Reluând procedura pentru $l_2 = 5$ și ținând seama de (7.7) se obține:

$$\begin{bmatrix} 3 & 0 & \mathbf{6} \\ 2 & \mathbf{6} & 1 \\ \mathbf{5} & 4 & 1 \end{bmatrix} + \begin{matrix} 1 \\ 1 \\ 0 \end{matrix} \begin{matrix} 0 & 0 & 2 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{matrix} = \begin{bmatrix} 3 & 0 & 7 \\ 2 & 6 & 2 \\ 5 & 4 & 1 \end{bmatrix}.$$

și descompunerea:

$$\begin{bmatrix} 3 & 0 & 6 \\ 2 & 6 & 1 \\ 5 & 4 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 5 \\ 0 & 5 & 0 \\ 5 & 0 & 0 \end{bmatrix} + \begin{bmatrix} 3 & 0 & 1 \\ 2 & 1 & 1 \\ 0 & 4 & 1 \end{bmatrix}.$$

Continuând procesul rezultă:

$$\begin{bmatrix} 3 & 0 & 1 \\ 2 & 1 & 1 \\ 0 & 4 & 1 \end{bmatrix} = \begin{bmatrix} 0 & 0 & 1 \\ 2 & 0 & 0 \\ 0 & 2 & 0 \end{bmatrix} + \begin{bmatrix} 2 & 0 & 0 \\ 0 & 0 & 1 \\ 0 & 2 & 0 \end{bmatrix} + \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix}.$$

Prin urmare, $q = 5$ matrici cu $(l_1, l_2, l_3, l_4, l_5) = (6, 5, 2, 2, 1)$. ■

Observație. După cum se vede din exemplul prezentat, este preferabil ca pentru același l_k să existe mai multe matrici p^k . Pentru identificarea lor simultană se poate aplica o metodă *Greedy*.

7.6. Problema monedelor

Punerea problemei. Fiind date n monede, pentru care se bănuiește că ar exista una falsă printre ele, mai grea sau mai ușoară decât celelalte, se cere identificarea acestei monede, dacă există, și eventual o monedă nefalsă din cât mai puține cântăriri cu o balanță, fără greutateți. Se presupune că abaterea de la greutatea comună a monedei false este suficient de mică astfel încât informația furnizată de mulțimi cu număr diferit de monede să fie neesențială. ■

Problema nu are sens pentru $n \leq 2$. Să considerăm cazul particular $n = 4$. Ținând seama că fiecare dintre cele patru monede poate fi mai grea sau mai ușoară decât celelalte sau să nu existe o monedă falsă, rezultă că algoritmul de rezolvare trebuie să furnizeze $2 \cdot 4 + 1 = 9$ rezultate posibile. Deoarece fiecare cântărire poate să furnizeze trei decizii (mulțimea din stânga mai grea, mulțimi de greutateți egale sau mulțimea din dreapta mai grea), rezultă că problema poate fi descrisă, în cel mai bun caz, cu ajutorul unui arbore ternar cu două nivele. Soluția acestei probleme, în cazul în care există la dispoziție și o monedă care nu e falsă, notată în continuare cu 0, este prezentată în figura 7.3. Cu 1, 2, 3 sunt notate cele trei monede și G , U și I reprezintă respectiv deciziile: *mai grea*, *mai ușoară* și *monede identice*.




Fig. 7.3.

Se observă că existența monedei 0 permite efectuarea primei cântăriri folosind trei dintre cele patru monede date, fapt ce asigură, intuitiv, scăderea frecvenței participării monedelor în cântăririle ce urmează. Această observație este confirmată de faptul că, pentru cazul când moneda 0 lipsește sunt necesare, în cel mai rău caz, trei cântăriri (vezi figura 7.4.).




Fig. 7.4.

Fie în continuare cazul $n = 12$. O primă problemă în vederea elaborării algoritmului o constituie alegerea convenabilă a primei cântăriri. Pentru acesta se observă că pentru rezolvarea cazului cu patru monede sunt suficiente două cântăriri, dacă este disponibilă o monedă nefalsă. Rezultă că, pentru a asigura rezolvarea problemei studiate cu trei cântăriri, cele 12 monede trebuie împărțite în trei loturi de câte patru monede, două dintre loturi participând la prima cântărire. Dacă aceste două loturi au greutatea egală, atunci toate cele opt monede participante sunt nefalsă și oricare dintre ele poate fi folosită pentru rezolvarea problemei cu monedele din al treilea lot, în conformitate cu figura 7.3.

Rămâne de văzut modul în care poate fi rezolvat cazul în care primele două loturi au greutatea neegală. Să presupunem că aceste loturi conțin monedele numerotate 1, 2, 3, 4 și respectiv 5, 6, 7, 8 și că în urma primei cântăriri s-a constatat că cele două loturi au greutatea diferite. Urmează să se precizeze câte monede trebuie să participe în a doua cântărire astfel încât trei cântăriri să fie suficiente pentru rezolvarea problemei. Pentru aceasta se observă că este necesar ca în a doua cântărire să participe 6 monede, câte trei pe fiecare taler al balanței.

Dacă cele două loturi au greutatea egală, atunci rămân două monede dubioase și pentru identificarea celei false este suficientă o singură cântărire, dacă se știe că suma greutăților lor este mai mică (mai mare) decât greutatea a două monede nefalsă.

Rămâne de precizat modul în care urmează să fie alese cele două loturi de câte trei monede. Dacă notăm cu g_i greutatea monedei de număr i , să presupunem că rezultatul primei cântăriri este $g_1 + g_2 + g_3 + g_4 < g_5 + g_6 + g_7 + g_8$. Pentru a asigura condiția că suma greutăților celor două monede rămase, după alegerea celor două loturi de câte trei monede, este mai mică decât greutatea a două monede nefalsă, este suficient ca cele două monede să aparțină uneia dintre mulțimile $\{1, 2, 3, 4\}$,

respectiv $\{5, 6, 7, 8\}$. Să presupunem că s-a decis ca în loturile de câte trei monede să participe monedele 1, 2, 5, 6, 7, 8. Rămâne de văzut cum pot fi grupate aceste monede în două loturi de câte trei monede. Este natural ca această grupare să nu acorde prioritate la oricare dintre monedele ce figurează în același lot al primei cântăriri. Două loturi ce satisfac această condiție sunt $\{1, 5, 6\}$ și respectiv $\{2, 7, 8\}$.

Să presupunem că rezultatul celei de a doua cântăriri este $g_1+g_5+g_6 < g_2+g_7+g_8$. Se verifică ușor că singurele cazuri în care sunt satisfăcute rezultatele celor două cântăriri sunt $1U, 7G$ și $8G$. Prin urmare, ori una dintre monedele 7 sau 8 este mai grea ori moneda 1 este mai ușoară. Rezultă că în a treia cântărire trebuie să participe monedele 7 și 8. Dacă rezultatul celei de a doua cântăriri este $g_1+g_5+g_6 = g_2+g_7+g_8$, atunci rezultă că una dintre monedele 3 sau 4 este mai ușoară, deci ele trebuie să participe la a treia cântărire.

Cazul în care $g_1+g_5+g_6 > g_2+g_7+g_8$ se tratează asemănător cu primul caz, rezultatul fiind ilustrat pe figura 7.5.

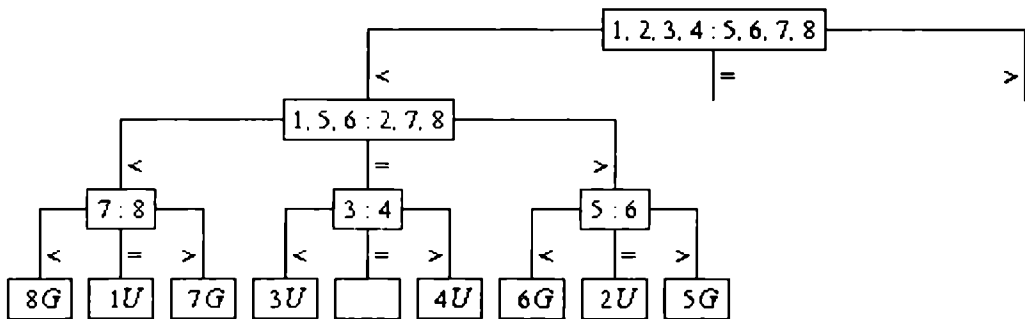


Fig. 7.5.

În cazul când rezultatul primei cântăriri este $g_1+g_2+g_3+g_4 = g_5+g_6+g_7+g_8$, rezultă că toate monedele participante sunt nefalse și problema se reduce la identificarea, conform figurii 7.3. a monedei false dintre monedele 9, 10, 11, 12, folosind una dintre monedele nefalse.

Cazul în care $g_1+g_2+g_3+g_4 > g_5+g_6+g_7+g_8$ se rezolvă în mod asemănător cu primul caz și furnizează rezultate contrare celor menționate în figura 7.5. Numărul total al rezultatelor obținute este egal cu $8+9+8=25=2 \cdot 12+1$, adică numărul tuturor variantelor privind existența sau nu a unei monede false.

Pentru cazul în care numărul de monede K_l este egal cu $(3^l - 1) / 2$, se poate demonstra (vezi [REI77]) că sunt suficiente l cântăriri pentru identificarea monedei false, utilizând o monedă nefalsă. În cadrul algoritmului se folosește strategia prezentată în exemplul cu 12 monede. Acest algoritm furnizează rezultatul după l

pași, deoarece $l = \log_3(2K_l + 1)$, unde $2K_l + 1$ este numărul de decizii necesare pentru identificarea faptului dacă există sau nu o monedă falsă.

În cadrul algoritmului se consideră trei stări, descrise mai departe, și o funcție de transfer f care decide care este comparația următoare, pentru o stare dată. Algoritmul este:

Algoritmul 7.7. (*Moneda Falsă*)

1. [Inițializare] Se face $i = l$ și $s = stare_1$.
2. [Evoluție] Atâta timp cât $i > 1$ se face $s = f(s)$ și $i = i - 1$.
3. [Terminare] STOP. ■

Funcția de transfer f are următoarea structură.

Starea 1. Au rămas de făcut i cântăriri, K_i monede dubioase și $2K_i + 1$ decizii. Se așează pe talerul din stânga K_{i-1} monede și moneda nefalsă și pe talerul din dreapta $K_{i-1} + 1$ monede dubioase. Nu se folosesc K_{i-1} monede. Dacă balanța este echilibrată se rămâne în *starea 1*. Altfel se trece în *starea 2* dacă monedele de pe talerul stâng cântăresc mai puțin decât cele de pe talerul drept și în *starea 3* în caz contrar.

Starea 2. Au rămas de făcut i cântăriri și moneda falsă se află ori în mulțimea U cu K_i monede dubioase ori în mulțimea G cu $K_i + 1$ monede dubioase, numărul de decizii fiind $2K_i + 1$. Se așează pe fiecare taler K_{i-1} monede din mulțimea U și $K_{i-1} + 1$ monede din mulțimea G . Nu se folosesc $2K_{i-1} + 1$ monede. Dacă balanța este neechilibrată, atunci se rămâne în *starea 2*. Altfel se trece în *starea 3*.

Starea 3. Au rămas de făcut i cântăriri și moneda falsă se află ori în mulțimea G cu K_i monede dubioase ori în mulțimea U cu $K_i + 1$ monede dubioase, numărul de decizii fiind $2K_i + 1$. Se așează pe fiecare taler K_{i-1} monede din mulțimea G și $K_{i-1} + 1$ monede din mulțimea U . Nu se folosesc $2K_{i-1} + 1$ monede. Dacă balanța este neechilibrată, atunci se rămâne în *starea 3*. Altfel se trece în *starea 2*.

În cazul în care numărul n de monede date nu satisface condiția de a fi egal cu un K_i , pentru un l dat, se determină o valoare l astfel încât $(3^{l-1} - 1) / 2 < n < (3^l - 1) / 2$ și algoritmul descris poate fi modificat puțin în modul ilustrat pe exemplul cu 12 monede. Dacă este permisă utilizarea unui număr oricât de mare de monede nefalse, atunci este evident că algoritmul poate fi utilizat în forma prezentată.

În cadrul algoritmului descris și a exemplurilor prezentate se folosește strategia de reducere succesivă a problemei date într-un număr mai mare de probleme mai simple, adică micșorarea numărului de monede ce participă la cântăriri. În lucrarea [STE61] este prezentată o strategie de identificare a unei monede false dintr-o mulțime de 13 monede. Pentru aceasta se încearcă identificarea monedei false printre 12 din cele 13 monede. Atunci moneda falsă este ori una dintre cele 12, ori, dacă în

toate cântăririle efectuate balanța a fost echilibrată, a treisprezecea monedă, care nu a participat la cântăriri. Problema studiată se reduce deci la identificarea, dacă există, a unei monede false dintr-o mulțime de 12 monede folosind trei cântăriri.

În cadrul algoritmului propus, se consideră numai cântăriri cu câte 4 monede pe fiecare taler. Atunci, dacă balanța este înclinată către stânga (dreapta), ori pe talerul stâng (drept) este o monedă mai grea, ori pe celălalt este o monedă mai ușoară. O monedă poate participa la una, două sau trei cântăriri. În cazul când ea rămâne pe același taler și este falsă, balanța va avea de fiecare dată aceeași înclinare. Altfel, dacă o monedă falsă este mutată, într-o cântărire următoare, de pe un taler pe altul, înclinarea balanței se schimbă. Este evident că schimbarea înclinării balanței constituie o informație utilă în vederea depistării monedei false. Trebuie observat însă că schimbarea de două ori a locului unei monede false de pe un taler pe altul nu crește informația necesară identificării, deoarece are loc revenirea la aceeași înclinare a balanței. Ținând seamă de observațiile precedente, se pot deduce rezultatele, în număr de 25, a trei cântăriri succesive, prezentate în figura 7.6.




Fig. 7.6.

Să presupunem că rezultatele celor trei cântăriri sunt cele din prima configurație din figura 7.6. În acest caz, moneda falsă a participat numai la prima cântărire. Dacă a fost așezată pe talerul stâng, atunci este mai ușoară și, dacă a fost așezată pe talerul drept, atunci este mai grea. În cazul celei de-a 23-a configurații, rezultă că ori moneda falsă a fost așezată pe talerul drept și este mai grea, ori a fost așezată pe talerul stâng și este mai ușoară.

Fie acum cele 13 monede numerotate 1,2,...,13. Moneda notată cu 13 nu participă la cântăriri. Se poate observa pe figura 7.6. că rezultatele primelor 24 de cântăriri sunt grupate în 12 perechi de cântăriri simetrice. Fiecărei asemenea perechi i se poate asocia una dintre cele douăsprezece monede ce participă la cântărire, deoarece dacă aceasta este moneda falsă, ea a contribuit la dezechilibrarea balanței în cele două moduri ilustrate.

Urmărind figura 7.6. se vede că la prima cântărire pot să participe cele 8 monede numerotate respectiv 1,5,6,7,8,10,11 și 12. Presupunem că au fost așezate pe cele două talere monedele 5,6,8,10, respectiv 1,7,11,12. Se constată, urmărind figura 7.6., că monedele 6,8,10,11 și 12 trebuie să participe și la a doua cântărire și

monedele 8 și 11 trebuie să treacă pe celălalt taler. Tot din figura 7.6. rezultă că la această cântărire trebuie să mai participe monedele 2,4 și 9. Toate monedele participante sunt așezate astfel pe talere: 2,6,10,11, respectiv, 4,8,9,12. În continuare se constată că moneda 3 participă numai la o ultimă cântărire și trebuie așezată pe talerul drept, rezultând așezările 5,7,9,11, respectiv, 3,4,10,12. Urmărind din nou figura 7.6., se deduce că în urma cântăririlor alese, monedele false sunt mai grele sau mai ușoare, după cum săgețile corespunzătoare sunt orientate în jos sau în sus.

7.7. Organizarea memoriilor liniare

Un factor important în utilizarea memoriilor auxiliare îl constituie *timpul de acces* care are două componente principale: *timpul de localizare* și *timpul de transfer* . Prin timp de localizare se înțelege timpul necesar poziționării capătului de citire și scriere la înregistrarea implicată în transfer de informație și prin timp de transfer se înțelege timpul necesar efectuării operației efective de citire sau scriere a informației.

Deoarece timpul de transfer depinde, în cea mai mare parte, de caracteristicile fizice ale terminalelor și de modul de acces, nu se pot obține îmbunătățiri ale acestui timp la nivel de sistem de operare. De aceea, majoritatea metodelor de organizare și gestionare a memoriilor auxiliare au în vedere optimizări ale timpului de localizare.

Memoriile liniare sau *memoriile unidimensionale* sunt memoriile în care informația este dispusă sub formă de listă liniară secvențială. Exemplul specific de memorie liniară îl constituie banda magnetică. Uneori și discul magnetic poate fi considerat ca o memorie liniară, fiecare cilindru fiind considerat un element al acestei memorii liniare. În cazul memoriilor liniare, deplasarea capătului de citire și scriere se poate măsura folosind o *metrică euclidiană*.

Vom reprezenta memoria liniară ca dreapta reală având înregistrările localizate în punctele cu coordonate numere întregi. Vom presupune că cererile de acces la informație sunt plasate într-o *coadă* și că după executarea fiecărei operații capătul de citire/scriere se oprește la ultima înregistrare la care a avut acces. Vom considera că înregistrările din fișier sunt R_1, R_2, \dots, R_n și probabilitățile cu care sunt accesate sunt respectiv p_1, p_2, \dots, p_n . Funcția obiectiv de minimizat este *distanța medie* de deplasare a capătului de citire/scriere de la o cerere la alta dată de expresia:

$$D(\pi) = \sum_{i=1}^n \sum_{j=1}^n p_i p_j d^{(\pi)}(i, j),$$

unde $d^{(\pi)}(i, j)$ reprezintă distanța între înregistrările R_i și R_j și depinde de permutarea π a înregistrărilor și de metrică. Dacă înregistrările R_i și R_j ocupă pozițiile s și t , atunci:

$$d^{(\pi)}(i, j) = d_2(s, t) = |s - t|,$$

unde d_2 este metrica euclidiană.

Problema care se pune este de a găsi un aranjament π astfel încât $D(\pi)$ să fie minim pentru înregistrările date, având probabilitățile de acces date și pentru o metrică fixată. Problema a fost rezolvată de Hardy, Littlewood și Polya. Soluția este dată de următoarea teoremă a cărei demonstrație poate fi găsită în [BÂS89]. Aranjamentul rezultat aplicând procedeul din teoremă se numește *aranjament orgă*.

Teorema 7.1. Dacă înregistrările sunt numerotate în ordinea necrescătoare a probabilităților asociate lor, se obține o distanță medie minimă parcursă de capătul de citire/scriere dacă se plasează R_1 într-un punct pe axa reală și apoi se plasează în ordine R_2, R_3, \dots, R_n alternativ la stânga și la dreapta înregistrărilor deja plasate, pe locurile libere cele mai apropiate de R_1 . Deci înregistrările de indice par sunt de o parte și cele de indice impar sunt de cealaltă parte a înregistrării R_1 . ■

O altă problemă este *partajarea înregistrărilor* dată de cazul în care din același loc se pot citi/scrie mai multe înregistrări. Este cazul discului magnetic la care unui punct îi corespunde un cilindru care poate să conțină mai multe înregistrări. Problema care se pune este de a împărți fișierul în pagini de câte k înregistrări, cu k dat. Accesul la o înregistrare presupune accesul mai întâi la pagina care conține înregistrarea respectivă. Vom presupune că timpul de localizare a unei înregistrări în pagină este neglijabil.

Considerăm înregistrările R_1, R_2, \dots, R_{mk} cu probabilitățile de acces p_1, p_2, \dots, p_{mk} . Problema constă în partiționarea celor mk înregistrări în m pagini de câte k înregistrări și plasarea celor m pagini într-o memorie liniară care să minimizeze deplasarea capătului de citire/scriere. Mai precis, presupunând că în pagina i sunt plasate înregistrările $R_1^i, R_2^i, \dots, R_k^i$ și notând *probabilitatea de acces a paginii i* cu $q_i = \sum_{j=1}^k p_j^i$, unde p_j^i este probabilitatea de acces la înregistrarea R_j^i , funcția de cost ce trebuie minimizată este:

$$D(\pi, q_1, q_2, \dots, q_m) = \sum_{i=1}^m \sum_{j=1}^m q_i q_j d^{(\pi)}(i, j),$$

unde $d^{(\pi)}(i, j)$ este distanța între paginile i și j .

Dacă valorile q_1, q_2, \dots, q_m ar fi cunoscute, problema plasării paginilor se reduce la problema precedentă de plasare a unor înregistrări de probabilități date pe memoria liniară, de unde rezultă că un aranjament orgă în raport cu q_1, q_2, \dots, q_m minimizează $D(\pi, q_1, q_2, \dots, q_m)$. Deci problema se poate pune sub forma următoare: cum trebuie partiționate cele mk înregistrări în m pagini de câte k înregistrări, paginile având probabilitățile q_1, q_2, \dots, q_m , astfel încât să se minimizeze $D(\pi^*; q_1, q_2, \dots, q_m)$, unde π^* este aranjamentul orgă pentru q_1, q_2, \dots, q_m . Adică se caută minimizarea expresiei:

$$D(q) = \sum_{1 \leq i < j \leq m} q_i q_j d(i, j),$$

unde $d(i, j)$ este distanța dintre paginile i și j în aranjamentul orgă. Dacă paginile sunt numerotate în ordinea necrescătoare a probabilităților lor, atunci $d(i, j) = |j - i| / 2$ dacă i și j au aceeași paritate și $d(i, j) = (j + i - 1) / 2$ dacă au parități diferite.

Pentru rezolvarea problemei se folosește următorul algoritm de tip Greedy.

Algoritmul 7.8. (Aranjare pe pagini)

1. [Ordonare] Se numerotează înregistrările astfel încât $p_1 \geq p_2 \geq \dots \geq p_m$.
2. [Partiționare] Se pun înregistrările R_1, R_2, \dots, R_k în pagina 1, înregistrările $R_{k+1}, R_{k+2}, \dots, R_{2k}$ în pagina 2, înregistrările $R_{2k+1}, R_{2k+2}, \dots, R_{3k}$ în pagina 3 ș. așa mai departe până se completează toate cele m pagini.
3. [Probabilități pagini] Se calculează $q_i = \sum_{j=(i-1)k+1}^{ik} p_j$, pentru $i = 1, 2, \dots, m$.
4. [Aranjare pagini] Se aranjează paginile în aranjament orgă. ■

Teorema 7.2. Partiționarea obținută aplicând algoritmul 7.8. este optimală.

O demonstrație a acestei teoreme se poate găsi în [WON83]. ■

Vom presupune în continuare că nu se cunoaște inițial mulțimea acelor înregistrări care urmează să fie plasate pe memoria liniară, aceste înregistrări sunt plasate una câte una în ordinea sosirii în sistem și ele rămân în locul în care au fost plasate inițial. Acest mod de lucru corespunde tipului de alocare a memoriei pentru utilizarea minicalcutoarelor.

Fie u_1, u_2, \dots, u_n un șir de n utilizatori care sosesc în sistem la momente diferite de timp, fiecărui utilizator u_i fiindu-i asociată o frecvență de acces la memorie f_i . Fiecărui utilizator îi este alocat un loc liber i în memoria liniară. Vom presupune că locațiile sunt numerotate ca în figura 7.7.




Fig. 7.7.

Vom nota cu f_i frecvența de acces a utilizatorului plasat în locația i și cu f^s frecvența utilizatorului sosit la momentul s . Vom considera toate elementele de aceeași lungime. După ce au sosit n utilizatori în sistem ocupând toată memoria, este generat un șir de cereri r_1, r_2, r_3, \dots , fiecare dintre cereri reprezentând un acces la locația j cu probabilitatea $p_j = f_j / \sum_{i=1}^n f_i$.

Problema constă în a determina acele plasări în memorie care minimizează distanța medie $E(D)$ de deplasare pentru două cereri consecutive, unde:

$$E(D) = \sum_{1 \leq i < j \leq n} p_i p_j d(i, j)$$

și $d(i, j) = |j - i| / 2$, pentru i și j de aceeași paritate, și $d(i, j) = (j + i - 1) / 2$, altfel.

Dacă toate probabilitățile ar fi cunoscute înainte de plasare, s-ar putea obține chiar aranjarea optimă care este *aranjamentul orgă*. Cum ele nu sunt cunoscute, se folosesc diverse strategii care permit aproximarea unei plasări optime. Una dintre ele este algoritmul următor.

Algoritmul 7.9. (Plasarea euristică)

- [Plasare u_1] Se plasează utilizatorul u_1 , care sosește la timpul 1 în poziția i dacă și numai dacă $(i - 1) / n < f^1 \leq i / n$; se face $t = 1$.
- [Terminare] Dacă $t = n$, atunci STOP.
- [Plasare element nou] Se face $t = t + 1$. Din cele $n - t + 1$ locații rămase libere, se alocă a i -a în ordinea numerotării inițiale dacă și numai dacă:

$$(i - 1) / (n - t + 1) < f^t \leq i / (n - t + 1).$$

- [Ciclare] Se trece la pasul 2. ■

Dacă se notează cu D_n distanța medie din plasarea euristică, atunci:

$$E(D_n) \approx 7n / 30 + 7H_n / 60 + 14 / 90,$$

unde $H_n = 1 + 1/2 + 1/3 + \dots + 1/n$.

Alte metode care se pot aplica în acest caz pot fi:

- *Plasarea aleatoare* în care se alocă unui utilizator oricare dintre locațiile libere în momentul sosirii în sistem. Dacă se notează cu D_r distanța medie din plasarea aleatoare, atunci:

$$E(D_r) \approx (n^2 - 1) / (3n + 1).$$

- *Plasarea statică optimală* care se poate aplica dacă toate frecvențele sunt cunoscute. Atunci se ordonează crescător utilizatorii în raport de frecvențele de acces asociate lor și se plasează al i -lea utilizator în locația i . Dacă se notează cu D_o distanța medie din plasarea statică optimală, atunci:

$$E(D_o) \approx 7n / 30 + 5 / 36.$$

După cum se vede, plasarea euristică este asimptotic la fel de bună ca plasarea optimală.

Vom aborda în continuare problema *memorării înregistrărilor de lungimi diferite*. Să presupunem că înregistrările R_1, R_2, \dots, R_n au probabilitățile de acces p_1, p_2, \dots, p_n și respectiv lungimile l_1, l_2, \dots, l_n . Problema care se pune este de a determina o alocare a înregistrărilor care să minimizeze distanța medie parcursă de capătul de citire/scriere. Distanța dintre înregistrările i și j depinde acum de lungimile înregistrărilor aflate între ele. Problema este NP-completă.

Numim *alocare* sau *aranjament* al celor n înregistrări o permutare $\pi = (\pi_1, \pi_2, \dots, \pi_n)$ a numerelor $1, 2, \dots, n$, unde π_i este indicele înregistrării alocate celei de-a i -a poziții de la stânga la dreapta. Distanța medie parcursă de capătul de citire/scriere este:

$$D(\pi) = \sum_{i=1}^n \sum_{j=1}^n p_{\pi_i} p_{\pi_j} d(i, j),$$

unde $d(i, j)$ este distanța parcursă pentru a avea acces la înregistrarea din poziția j după ce a avut loc acces la înregistrarea i . Pentru banda magnetică se obține:

$$d_T(i, j) = \begin{cases} \sum_{k=i+1}^{j-1} l_{\pi_k}, & \text{pentru } i < j, \\ \sum_{k=j}^i l_{\pi_k}, & \text{pentru } i \geq j, \end{cases}$$

de unde rezultă:

$$D_T(\pi) = \sum_{i=1}^n p_{\pi_i} l_{\pi_i} + 2 \sum_{i=2}^{n-1} l_{\pi_i} \left(\sum_{j=1}^{i-1} p_{\pi_j} \right) \left(\sum_{j=i+1}^n p_{\pi_j} \right).$$

Pentru discurile magnetice, lungimea înregistrării este dată de numărul de cilindri ocupați de înregistrarea respectivă. În acest caz, distanța este dată de:

$$d_D(i, j) = \begin{cases} \left(\sum_{k=i+1}^{j-1} l_{\pi_k} \right) + 1, & \text{pentru } i < j, \\ \left(\sum_{k=j}^i l_{\pi_k} \right) - 1, & \text{pentru } i \leq j, \end{cases}$$

de unde rezultă:

$$D_D(\pi) = \sum_{i=1}^n p_{\pi_i} (l_{\pi_i} - p_{\pi_i}) + 2 \sum_{i=2}^{n-1} l_{\pi_i} \left(\sum_{j=1}^{i-1} p_{\pi_j} \right) \left(\sum_{j=i+1}^n p_{\pi_j} \right).$$

Deoarece $D_D(\pi) = D_T(\pi) - \sum_{i=1}^n p_{\pi_i}^2$, rezultă că un aranjament optim pentru banda magnetică este optim și pentru discul magnetic. În cele ce urmează ne vom referi de aceea numai la cazul benzilor magnetice.

Dacă renumerotăm înregistrările în ordinea de la stânga la dreapta se obține $\pi_i = i$ și:

$$D(\pi) = \sum_{i=1}^n p_i l_i + 2 \sum_{i=2}^{n-1} l_i \left(\sum_{j=1}^{i-1} p_j \right) \left(\sum_{j=i+1}^n p_j \right),$$

un aranjament optim S_o este un aranjament care satisface inegalitatea $D(S_o) \leq D(S)$, pentru orice aranjament posibil S .

Se poate demonstra (vezi [BĂS89]) că, dacă într-un aranjament se interschimbă două înregistrări vecine t și $t+1$, se obține o micșorare a distanței medii parcurse de capătul de citire/scriere dacă $p_t/l_t < p_{t+1}/l_{t+1}$ și $\sum_{i=1}^{t-1} p_i > \sum_{i=t+2}^n p_i$ sau $p_t/l_t < p_{t+1}/l_{t+1}$ și $\sum_{i=1}^{t-1} p_i < \sum_{i=t+2}^n p_i$. Dacă $p_t/l_t = p_{t+1}/l_{t+1}$, pentru $1 \leq i, j \leq n$, atunci orice aranjament dă aceeași valoare medie a distanței parcurse de capătul de citire/scriere.

Se numește *aranjament* π și un aranjament pentru care există o poziție h , unde $1 \leq h \leq n$, astfel încât $p_1 / l_1 \leq p_2 / l_2 \leq \dots \leq p_h / l_h \geq \dots \geq p_{n-1} / l_{n-1} \geq p_n / l_n$.

Teorema 7.3. Fie π și π' două aranjamente ale unei mulțimi de înregistrări cu probabilitățile de acces p_1, p_2, \dots, p_n și lungimile l_1, l_2, \dots, l_n . Atunci:

$$D(\pi) / D(\pi') \leq (1 + p_{\min}) / (2p_{\min}),$$

unde $p_{\min} = \min_{1 \leq i \leq n} \{p_i\}$. În plus, pentru orice $n \geq 3$ număr impar, există o mulțime de înregistrări pentru care câtul $D(\pi) / D(\pi')$ se poate apropia oricât de mult de $(1 + p_{\min}) / (2p_{\min})$.

O demonstrație a acestei teoreme se găsește în [BÂS89]. ■

Din teorema 7.3. rezultă că un aranjament oarecare poate fi destul de departe de un aranjament optimal. Se poate demonstra o proprietate analoagă pentru aranjamentele π .

Teorema 7.4. Dacă π și π' sunt două aranjamente π și π' ale unei mulțimi de n înregistrări cu probabilitățile de acces p_1, p_2, \dots, p_n și lungimile l_1, l_2, \dots, l_n . Atunci:

$$D(\pi) / D(\pi') \leq 1 + n / 2.$$

O demonstrație a acestei teoreme se găsește în [WON83]. ■

S-a demonstrat de fapt că pentru $n \leq 4$ are loc inegalitatea $D(\pi) / D(\pi') \leq 2$ și se presupune că aceasta ar fi adevărată pentru orice n .

Pentru construirea soluției aproximative se folosesc două euristici:

1. Se construiește aranjamentul orgă față de mulțimea $\{p_i / l_i\}$.
2. Se alege cel mai bun dintre aranjamentele orgă față de $\{p_i\}$ și respectiv $\{1 / l_i\}$.

O ultimă problemă pe care o prezentăm legată de organizarea memoriilor liniare este *prelucrarea pe loturi a cererilor*. Prin prelucrarea pe loturi a cererilor se înțelege tratarea în același timp a unei grupe de cereri, fiecare grupă conținând același număr de cereri. În acest caz se pun două probleme principale:

1. Pentru un aranjament dat, care este ordinea de considerare a cererilor de acces dintr-un lot.
2. Care este cel mai bun aranjament al înregistrărilor.

Răspunsul la a doua problemă este relativ simplu. În majoritatea strategiilor de prelucrare pe loturi a cererilor, aranjamentul optim este aranjamentul orgă. Rămâne de găsit soluții pentru prima problemă.

Să presupunem că locațiile de memorie sunt numerotate cu $1, 2, \dots, n$ de la stânga la dreapta și că pentru fiecare $i=1, 2, \dots, n$, în locația i a fost memorată înregistrarea R_i având probabilitatea de acces p_i . Să presupunem că la momentul t au fost generate b cereri de acces $1 \leq L_1 \leq L_2 \leq \dots \leq L_b \leq n$, unde L_i indică înregistrarea implicată în cerere.

Dacă în momentul sosirii cererilor capătul de citire/scriere este poziționat la locația x , o strategie specifică ordinea în care se trece plecând din x prin locațiile L_1, L_2, \dots, L_b . Capătul de citire/scriere se oprește la ultima locație y la care a avut acces, aceasta devenind locația de plecare pentru următorul lot. Notând cu $d(x, y)$ distanța parcursă de capătul de citire/scriere de când pleacă din x până ajunge în y , costul C poate fi evaluat prin valoarea medie a lui $d(x, y)$. În continuare vom nota cu S pe L_1 , pe care o numim *marginea stângă*, și cu D pe L_b , pe care o numim *marginea dreaptă*.

Se pot defini următoarele strategii:

- *Strategia stângă (S)*: Din locația curentă x se merge la S după care se prelucrează cererile în ordinea crescătoare a locațiilor până la D și se oprește procesul.
- *Strategia dreaptă (D)*: Din locația curentă x se merge la D după care se prelucrează cererile în ordinea descrescătoare a locațiilor până la S și se oprește procesul.
- *Strategia alternantă (A)*: Se folosește strategia stângă pentru un lot de ordin impar și strategia dreaptă pentru un lot de ordin par.

Dacă se notează cu $COST_S$, $COST_D$ și $COST_A$ costurile celor trei strategii,

$$\lambda_i = Pr(S \geq i) = \left(\sum_{j=i}^n p_j \right)^b \quad \text{și} \quad \rho_i = Pr(D \leq i) = \left(\sum_{j=1}^i p_j \right)^b,$$

se pot demonstra următoarele proprietăți (vezi [BĂS89]):

Lema 7.1. Notând cu d_b distanța dintre S și D , valoarea medie a lui d_b este:

$$E(d_b) = E(D - S) = \sum_{i=1}^{n-1} (1 - \lambda_{i+1} - \rho_i). \blacksquare$$

Teorema 7.5. Au loc egalitățile:

$$\begin{aligned} COST_S &= E(d_b) + \sum_{i=1}^{n-1} (1 + \lambda_{i+1})(1 - \rho_i) + \sum_{i=1}^{n-1} \lambda_{i+1} \rho_i = 2E(d_b) + 2 \sum_{i=1}^{n-1} \lambda_{i+1} \rho_i = \\ &= 2 \sum_{i=1}^{n-1} (1 - \lambda_{i+1})(1 - \rho_i). \blacksquare \end{aligned}$$

Consecință. $COST_S$ este simetric, adică nu se schimbă dacă se pune p_{n-i+1} în loc de p_i , pentru $i = 1, 2, \dots, n$. De aici rezultă $COST_S = COST_D$.

Teorema 7.6. Au loc egalitățile:

$$COST_A = E(d_b) + \sum_{i=1}^{n-1} \rho_i (1 - \rho_i) + \sum_{i=1}^{n-1} \lambda_{i+1} (1 - \lambda_{i+1}) = \sum_{i=1}^{n-1} (1 - \rho_i^2 - \lambda_{i+1}^2) = E(d_{2b}). \blacksquare$$

Definim *operația de interschimbare* prin trecerea de la un aranjament (R_1, R_2, \dots, R_n) la un alt aranjament ce se obține interschimbând între ele R_i și R_{n-i+1} dacă și numai dacă $p_i > p_{n-i+1}$, pentru $1 \leq i \leq [n/2]$. În mod similar, definim *operația de interschimbare inversă* cea prin care se obține un nou aranjament interschimbând R_{i+1} și R_{n-i+1} dacă și numai dacă $p_{i+1} < p_{n-i+1}$ (R_1 rămâne pe loc).

Lema 7.2. Aranjamentul orgă minimizează costul C al unei strategii dacă pentru orice $n \geq 1$ sunt satisfăcute următoarele condiții:

1. C este simetric, adică $C(R_1, R_2, \dots, R_n) = C(R_n, R_{n-1}, \dots, R_1)$.
2. Dacă $p_n = 0$, atunci $C(R_1, R_2, \dots, R_{n-1}, R_n) = C(R_1, R_2, \dots, R_{n-1})$.
3. Dacă $(R'_1, R'_2, \dots, R'_n)$ este aranjamentul obținut din (R_1, R_2, \dots, R_n) prin operația de interschimbare, atunci $C(R_1, R_2, \dots, R_n) \geq C(R'_1, R'_2, \dots, R'_n)$. ■

Teorema 7.7. Aranjamentul orgă minimizează $COST_S$. ■

Teorema 7.8. Aranjamentul orgă minimizează $COST_A$. ■

Teorema 7.9. Aranjamentul orgă minimizează $E(d_b)$. ■

Teorema 7.10. $E(d_{2b}) \leq 2 E(d_b)$. ■

Consecințe: 1. $COST_A \leq COST_S = COST_D$ pentru orice aranjament.

2. $C_{\min} \leq C_A \leq 2C_{\min}$, unde C_{\min} este costul minim pentru orice strategie și orice aranjament și C_A este $COST_A$ pentru aranjamentul orgă.

- **Strategia cea mai apropiată extremitate (N).** Din locația curentă se mută capătul de citire/scriere în cea mai apropiată extremitate după care se parcurg locațiile lotului și se oprește în cealaltă extremitate. Dacă cele două extremități sunt la egală distanță, se alege oricare dintre ele.

Modelul matematic de analiză a acestei strategii utilizează lanțurile Markov. Notând cu $COST_N$ costul acestei strategii, în general, $COST_N \leq COST_A$. Există contraexemple pentru care inegalitatea nu este satisfăcută.

- **Strategii B -optimale (B).** Strategii care minimizează distanța medie totală de deplasare a capătului de citire/scriere plecând dintr-o poziție x și parcurgând B loturi de cereri.

Costul unei strategii B -optimale este distanța totală medie împărțită la numărul loturilor B . Pentru $B=1$ se obține strategia N . La stabilirea unei strategii B -optimale se ține seama de următoarele proprietăți ușor de demonstrat.

Lema 7.3. Într-o strategie B -optimală, imediat după accesul tuturor înregistrărilor unui lot, capătul de citire/scriere se află la una din extremități. ■

Lema 7.4. Într-o strategie B -optimală, un lot se prelucrează mutând capătul de citire/scriere direct la una din extremitățile lotului și prelucrând cererile cu mișcarea capătului de citire/scriere către cealaltă extremitate a lotului. ■

Lema 7.5. Pentru orice strategie ale cărei decizii depind de loturile anterioare, există o strategie de același cost ale cărei decizii depind numai de lotul curent. ■

O strategie care satisface lema 7.5. se poate da sub forma unui șir $d_B(x; s, d)$, $d_{B-1}(x; s, d)$, ..., $d_1(x; s, d)$ de funcții de decizie, unde $d_i(x; s, d)$ este probabilitatea cu

care capătul de citire/scriere se mută la stânga din poziția curentă x pentru prelucrarea lotului i , ultimul lot având extremele s și d . O strategie este *deterministă* dacă pentru orice i, x, s și d valorile $d_i(x; s, d)$ sunt 0 sau 1. În cazul în care $d_i(x; s, d)$ poate lua orice valori din $[0, 1]$ spunem că strategia este *nedeterministă*.

Lema 7.6. Pentru orice strategie nedeterministă există o strategie deterministă de cost cel mult egal cu costul strategiei nedeterministe. ■

Ținând seama de lema 7.6., se poate deduce că strategiile B -optimale se află printre cele 2^B posibilități de a construi funcții de decizie cu valori 0 sau 1.

Lema 7.7. O strategie optimală este optimală pentru orice poziție inițială a capătului de citire/scriere. ■

Pentru a defini clasa strategiilor B -optimale, se construiește un șir de funcții $C_B(x)$, pentru $B = 0, 1, \dots$ date de formulele:

$$C_0(x) = 0, \text{ pentru } 1 \leq x \leq n,$$

$$C_B(x) = \sum_{s \leq d} Pr(S = s, D = d) \min[|x - s| + C_{B-1}(d), |x - d| + C_{B-1}(s)] + E(d_b),$$

pentru $1 \leq x \leq n$ și $B = 1, 2, \dots$

• **Strategia recursivă.** Fie i numărul loturilor ce mai sunt de prelucrat și x poziția curentă a capătului de citire/scriere. Pentru prelucrarea lor se procedează astfel:

1. Se merge în extrema stângă, apoi se prelucrează cererile până la extrema dreaptă dacă $|x - S| + C_{i-1}(D) < |x - D| + C_{i-1}(S)$.
2. Se merge în extrema dreaptă, apoi se prelucrează cererile până la extrema stângă dacă $|x - S| + C_{i-1}(D) > |x - D| + C_{i-1}(S)$.
3. Dacă $|x - S| + C_{i-1}(D) = |x - D| + C_{i-1}(S)$, se poate executa 1. sau 2. la alegere. ■

Teorema 7.11. Cu notațiile de mai sus, $C_B(x)$ este costul optimal pentru prelucrarea a B loturi cu poziția inițială x și strategia recursivă este o strategie B -optimală având costul $C_B(x) / B$. ■

• **Strategia ∞ -optimală.** Dacă $COST_B^r(x)$ este costul prelucrării a B loturi plecând din poziția x și folosind strategia r , atunci *costul asimptotic* mediu al strategiei r , notat $COST(r)$, se definește prin $\lim_{B \rightarrow \infty} COST_B^r(x) / B$. O strategie ∞ -optimală are costul asimptotic mediu mai mic sau egal decât oricare altă strategie.

Algoritmul 7.10. (∞ -optimal)

1. [Inițializare] Se consideră strategia *cea mai apropiată extremitate* drept strategie *curentă*.
2. [Evaluare] Se calculează $f_B(x)$, costul prelucrării a B loturi plecând din poziția x , pentru strategia *curentă*, pentru $B = 1, 2, \dots, f_0(x) = 0$;

$f_B(x) = \sum_{s \leq d} Pr(S = s, D = d) \delta(x, s, d)$, unde:

$$\delta(x, s, d) = \begin{cases} |x - s| + (d - s) + f_{B-1}(d), & \text{dacă în strategia curentă se merge mai întâi} \\ & \text{în } s \text{ din poziția } x \text{ cu extremele } s \text{ și } d, \\ |x - d| + (d - s) + f_{B-1}(s), & \text{dacă se merge întâi în } d. \end{cases}$$

Calcululele continuă până când se obține un B pentru care $f_B(x) - f_{B-1}(x)$ este aproximativ constant în raport cu x .

3. [Rectificare] Se calculează strategia nouă astfel: pentru orice x , s și d , dacă $|x - d| - |x - s| + \lim_{B \rightarrow \infty} [f_B(s) - f_B(d)] < 0$ (limita poate fi aproximată cu $f_B(s) - f_B(d)$, pentru B suficient de mare), strategia nouă mută capătul de citire/scriere mai întâi în extrema dreaptă plecând din x și având extremele s și d , altfel se mută mai întâi la stânga.
4. [Terminare sau ciclare] Dacă strategia nouă coincide cu strategia curentă, atunci STOP. (Aceasta este strategia ∞ -optimală.) Altfel strategia nouă devine strategia curentă și se trece la pasul 2. ■

n	B	Strategia stângă	Strategia alternantă	Strategia cea mai apropiată extremitate	Strategia ∞ -optimală
100	5	133.389	81.802	80.753	80.713
	10	163.603	90.443	90.408	90.394
	15	174.950	93.498	93.498	93.496
200	5	266.803	163.628	161.529	161.452
	10	327.256	180.936	180.869	180.839
	15	349.976	187.072	187.070	187.067

Tabelul 7.6.

În tabelul 7.6. sunt date costurile asimptotice în cazul strategiilor stângă, alternantă, cea mai apropiată extremitate, respectiv ∞ -optimală pentru distribuția uniformă cu $n = 100$ și $n = 200$ de înregistrări, cu un număr de 5, 10 și 15 loturi. După cum se poate observa, diferențele între ultimile trei strategii sunt ne semnificative. Deci strategia alternantă și strategia cea mai apropiată extremitate sunt euristici care aproximează suficient de bine soluția optimală.

7.8. Arbori binari optimi pentru căutare

Arborii binari pentru căutare sunt arborii binari etichetați în care eticheta atribuită unui nod este mai mare decât etichetele atribuite nodurilor din subarborele stâng și mai mică decât etichetele atribuite nodurilor din subarborele drept. Dacă se

consideră că rădăcina este de *nivelul* 1 și fiecare alt nod al arborelui are *nivelul* cu 1 mai mare decât *nivelul* tatălui său, numărul de comparații pentru a determina un element dintre cele care se găsesc în arborele binar pentru căutare este egal cu *nivelul* nodului asociat.

Eficiența unui arbore binar pentru căutare este dată de numărul mediu de comparații necesare pentru determinarea unui element. Dacă elementele sunt echiprobabile, eficiența cea mai bună se obține pentru *arborii binari echilibrați*, aceștia fiind arbori binari în care nodurile ce nu au câte doi fii se găsesc pe cel mult două niveluri consecutive.

Să considerăm acum cazul în care etichetele sunt căutate cu frecvențe date. De exemplu, în figura 7.8. este dat arborele optim de căutare pentru cele mai frecvent utilizate 31 de cuvinte din limba engleză și anume (în paranteze sunt date frecvențele): *the* (15568), *of* (9767), *and* (7638), *to* (5739), *a* (5074), *in* (4312), *he* (3727), *that* (3017), *is* (2509), *I* (2292), *it* (2255), *for* (1869), *as* (1853), *with* (1849), *was* (1761), *his* (1732), *be* (1535), *not* (1496), *by* (1392), *but* (1379), *have* (1344), *you* (1336), *which* (1291), *are* (1222), *on* (1155), *or* (1101), *her* (1093), *had* (1062), *at* (1053), *from* (1039) și *this* (1021). Pentru o căutare cu succes sunt necesare în medie 3.437 comparații.

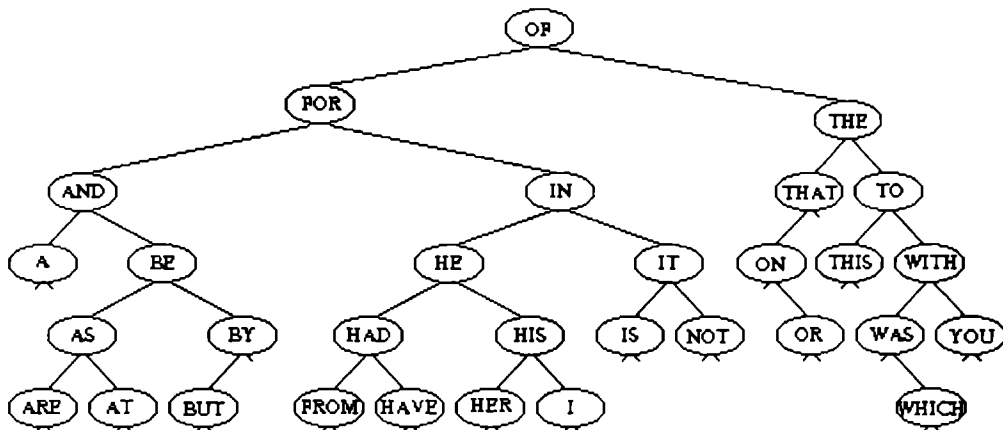


Fig. 7.8.

De multe ori trebuie considerat și cazul căutării fără succes. De exemplu, cele 31 de cuvinte din figura 7.8. reprezintă circa 36% dintr-un text obișnuit în limb. engleză. Evident, restul de 64% pot influența stuctura arborelui optim de căutare.

Pentru înregistrările R_1, R_2, \dots, R_n având cheile K_1, K_2, \dots, K_n vom considera probabilitățile p_1, p_2, \dots, p_n și $q_0, q_1, q_2, \dots, q_n$, unde p_i este probabilitatea cu care este

căutată înregistrarea cu cheia K_i și q_i este probabilitatea de a fi căutată o valoare cuprinsă între K_i și K_{i+1} . Se consideră că q_0 este probabilitatea de a căuta o valoare mai mică decât K_1 și q_n este probabilitatea de a căuta o valoare mai mare decât K_n . În locul probabilităților se pot considera și frecvențele de apariție ale valorilor. Obiectivul este de a determina un arbore binar de căutare care să minimizeze numărul sperat de comparații în timpul căutării, numit *costul căutării*, adică valoarea dată de expresia:

$$\sum_{i=1}^n p_i \text{ nivel}(i) + \sum_{k=0}^n q_k (\text{nivel}(k) - 1).$$

Construirea arborelui binar optim de căutare se bazează pe proprietatea că orice subarbore al unui arbore binar optim de căutare este un arbore binar optim pentru căutare. Acest principiu sugerează o procedură de calcul care va găsi în mod sistematic subarbori optimi din ce în ce mai mari până când se determină un arbore care conține toate elementele.

Fie $c(i, j)$ costul unui subarbore optim cu ponderile $(p_{i+1}, \dots, p_j; q_i, \dots, q_j)$ și suma ponderilor $w(i, j) = p_{i+1} + \dots + p_j + q_i + \dots + q_j$. Acestea sunt definite pentru $0 \leq i \leq j \leq n$. Rezultă:

$$c(i, i) = 0, \text{ pentru } i = 0, 1, \dots, n,$$

$$c(i, j) = w(i, j) + \min_{i \leq k < j} (c(i, k-1) + c(k, j)), \text{ pentru } 0 \leq i < j \leq n,$$

deoarece costul minim posibil al unui arbore cu rădăcina k este $w(i, j) + c(i, k-1) + c(k, j)$. Vom nota cu $r(i, j)$ acea valoare a lui k pentru care se atinge minimumul în formula anterioară; dacă sunt mai multe se alege una dintre ele. Acestea sunt posibilele rădăcini din arborele optimal. Evaluarea valorilor $c(i, j)$ se face pentru $j = 1, 2, \dots, n$. Sunt aproximativ $n^2 / 2$ astfel de valori și pentru determinarea lor sunt necesare circa $n^3 / 6$ valori ale lui k . Deci complexitatea algoritmului este $O(n^3)$ în timp și $O(n^2)$ în spațiu. Cum se poate demonstra că:

$$r(i, j-1) \leq r(i, j) \leq r(i+1, j),$$

se poate reduce mulțimea valorilor posibile pentru k la intervalul $[r(i, j-1), r(i+1, j)]$. Algoritmul de construire a arborelui binar optimal este următorul.

Algoritmul 7.11. (Arbore optim de căutare)

- [Inițializări] Se face $c(i, i) = 0$, $w(i, i) = q_i$ și $w(i, j) = w(i, j-1) + p_j + q_j$, pentru $i = 0, 1, \dots, n$ și $j = i+1, \dots, n$. Apoi se face $c(j-1, j) = w(j-1, j)$ și $r(j-1, j) = j$, pentru $j = 1, 2, \dots, n$.
- [Ciclare după d] Se execută pasul 3 pentru $d = 2, 3, \dots, n$, apoi STOP.
- [Ciclare după j] Se execută pasul 4 pentru $j = d, d+1, \dots, n$.
- [Calcul c și r] Se face $i = j-d$, $c(i, j) = w(i, j) + \min_{r(i, j-1) \leq k \leq r(i+1, j)} (c(i, k-1) + c(k, j))$ și se stabilește $r(i, j)$ egal cu un k pentru care se realizează minimumul precedent. ■

În urma aplicării algoritmului precedent, se poate reconstitui arborele optimal. Să notăm cu $t(i,j)$ subarboarele care conține ponderile $(p_{i+1}, \dots, p_j; q_i, \dots, q_j)$. Arborele optim este $t(0,n)$. Dacă $i=j$, subarboarele $t(i,j)$ conține numai un nod extern (subarboare vid) de pondere q_i . Altfel subarboarele $t(i,j)$ are rădăcina $r(i,j)$, subarboarele din stânga este $t(i, r(i,j)-1)$ și subarboarele din dreapta este $t(r(i,j), j)$.

Deoarece algoritmul 7.11. necesită timp de execuție și spațiu de memorare proporționale cu n^2 , devine nepractică utilizarea lui când n este foarte mare. În acest caz se pot aplica diferite euristici cum sunt și cele care urmează.

- Inserarea elementelor în arborele binar în ordinea descrescătoare a fr. vențelor asociate elementelor. De foarte multe ori această strategie produce un arbore destul de avantajos. Totuși el poate fi diferit de arborele optimal în primul rând pentru că nu ține seama de probabilitățile nodurilor externe.
- Alegerea rădăcinii în așa mod încât subarboarele din stânga ei să aibă o pondere cât mai apropiată de cea a subarboarelui din dreapta. Acest procedeu poate să nu fie eficient dacă probabilitatea asociată rădăcinii este destul de mică.
- Se combină cele două metode anterioare. Se încearcă să se egalizeze ponderile din subarboarele din stânga și cel din dreapta însă se acceptă posibilitatea de a deplasa rădăcina cu câteva poziții la stânga sau la dreapta pentru a găsi un element cu probabilitatea suficient de mare. Când se ajunge la un subarboare cu un număr suficient de mic de noduri, se aplică algoritmul 7.11.

7.9. Euristici în jocul de șah

Necesitatea utilizării unor euristici este exemplificată sugestiv de jocul de șah. În acest joc, un algoritm exact poate să dea răspuns la următoarele întrebări:

- *Problema 1:* Poate să câștige jucătorul care joacă cu piesele albe indiferent de strategia utilizată de adversar?
- *Problema 2:* Poate să câștige jucătorul care joacă cu piesele negre indiferent de strategia utilizată de adversar?
- *Problema 3:* Poate să câștige sau cel puțin să remizeze un jucător indiferent de strategia adversarului?

Evident că, dacă s-ar cunoaște răspunsul la aceste întrebări, jocul de șah ar pierde mult din interesul fanilor lui. Algoritmi care să rezolve problemele anterioare există. Vom prezenta și noi aici unele variante. Acești algoritmi se bazează pe existența unui arbore finit care să dea toate posibilitățile de desfășurare ale unei partide de șah. Nodurile arborelui sunt etichetate cu poziții posibile de pe tabla de șah.

Rădăcina arborelui corespunde poziției de începere a partidei. Se consideră că rădăcina are nivelul 1. Pentru fiecare nod a de pe un nivel de ordin impar, se consideră succesoare directe toate nodurile ce corespund la poziții de pe tabla de șah ce se obțin din poziția asociată lui a prin efectuarea unei mutări de către jucătorul care joacă cu piesele albe. Analog, pentru fiecare nod a de pe un nivel de ordin par, se consideră succesoare directe toate nodurile ce corespund la poziții de pe tabla de șah ce se obțin din poziția asociată lui a prin efectuarea unei mutări de către jucătorul care joacă cu piesele negre.

Arborele construit după modelul anterior este finit după cum vom justifica în continuare. Numărul configurațiilor posibile pe tabla de șah este finit, o limitare superioară a numărului lor fiind de exemplu 13^{64} , deoarece pe oricare din cele 64 de pătrățele ale tablei de șah există cel mult 13 posibilități, să fie liber sau să se afle pe el una din cele 12 tipuri de piese (câte 6 pentru fiecare culoare). Numărul de nivele este finit deoarece într-o partidă de șah, o poziție nu se poate repeta decât de un număr finit de ori (la a treia repetare a unei poziții partida se termină remiză). Fiecare nod are un număr finit de succesori direcți deoarece numărul de mutări posibile ale fiecărui jucător pentru o poziție dată este limitat (de exemplu cele mai multe posibilități de mutare le poate avea dama care poate fi mutată în cel mult 27 moduri).

Răspunsul la prima problemă poate fi dat de următorul algoritm.

Algoritmul 7.12. (*Câștigă albul*)

1. [Terminare] Dacă nu mai există noduri terminale de nivel par și care să nu corespundă la poziții de remiză, atunci STOP. Dacă toate nodurile au fost eliminate, atunci albul poate să câștige întotdeauna.
2. [Alegere] Se alege un nod terminal a care nu corespunde la o poziție de remiză și este de nivel par.
3. [Eliminare] Se elimină toate nodurile ce aparțin subarborelui cu rădăcina tatăl nodului a .
4. [Ciclare] Se trece la pasul 1. ■

Deoarece arborele este finit și la fiecare ciclare sunt eliminate cel puțin două noduri (nodul ales și tatăl său) algoritmul se termină după un număr finit de pași.

Un algoritm analog poate da răspunsul la cea de-a doua problemă.

Algoritmul 7.13. (*Câștigă negrul*)

1. [Terminare] Dacă nu mai există noduri terminale de nivel impar și care să nu corespundă la poziții de remiză, atunci STOP. Dacă toate nodurile în afară de rădăcina arborelui au fost eliminate, atunci negrul poate să câștige întotdeauna.

2. [Alegere] Se alege un nod terminal a care nu corespunde la o poziție de remiză și este de nivel impar.
3. [Eliminare] Se elimină toate nodurile ce aparțin subarborelui cu rădăcina tatăl nodului a .
4. [Ciclare] Se trece la pasul 1. ■

Deoarece arborele este finit și la fiecare ciclare sunt eliminate cel puțin două noduri (nodul ales și tatăl său) algoritmul se termină după un număr finit de pași.

Pentru rezolvarea celei de-a treia probleme se poate aplica algoritmul:

Algoritmul 7.14. (Strategia optimă comună)

1. [Inițializare] Se marchează cu 1 pozițiile în care câștigă albul (negrul este mat), cu 2 pozițiile în care câștigă negrul (albul este mat) și cu 3 pozițiile de remiză; restul nodurilor se consideră inițial nemarcate.
2. [Terminare] Dacă rădăcina a fost marcată, atunci STOP. Dacă marcajul rădăcinii este 1, atunci poate câștiga mereu albul, dacă este 2, atunci poate câștiga tot timpul negru și dacă este 3, cea mai bună strategie este jocul la remiză pentru ambii parteneri.
3. [Alegere] Se alege un nod a nemarcat și care are toți succesorii direcți marcați.
4. [Marcare] Dacă a este de nivel impar, atunci se marchează cu 1 dacă există cel puțin un succesori direct marcat cu 1, se marchează cu 2 dacă toți succesorii direcți sunt marcați cu 2, respectiv se marchează cu 3 dacă nu sunt îndeplinite condițiile anterioare. Analog, dacă a este de nivel par, atunci se marchează cu 2 dacă există cel puțin un succesori direct marcat cu 2, se marchează cu 1 dacă toți succesorii direcți sunt marcați cu 1, respectiv se marchează cu 3 dacă nu sunt îndeplinite condițiile anterioare.
5. [Ciclare] Se trece la pasul 1. ■

Deoarece arborele este finit și la fiecare ciclare se marchează cel puțin un nod, algoritmul se termină după un număr finit de pași.

Deși nu sunt complicați, acești algoritmi nu au putut să fie executați din cauza numărului extraordinar de mare de noduri din arborele descris. De aceea se joacă în continuare șah, aplicându-se diferitele euristici care dau posibilitatea obținerii unor poziții mai avantajoase, cu șanse de câștig. Au fost dezvoltate teorii ale deschiderilor în șah și ale finalurilor de partide dar și tactici sau strategii ale jocului de mijloc de partidă. Euristicile folosite se bazează pe evaluarea pieselor, pe evaluarea posibilităților de mișcare și pe alte funcții care pot să evalueze situațiile create în timpul unei partide. Dar de cele mai multe ori soarta unei partide este decisă de inspirația de moment și de condiții psihologice.

BIBLIOGRAFIE

- [AHO74] Aho A.V., Hopcroft J.E., Ullman J.D. - *The Design and Analysis of Computer Algorithms* - Addison-Wesley, Reading, Mass., 1974.
- [ALE76] Alexandrescu I., Drăguț C., Iambor I.P., Popescu T., Preoteasa P., Rogai E., Sfichi R., Tomescu I. - *Culegere de probleme de matematici aplicate* - Societatea de Științe Matematice din RSR, 1976.
- [ASH71] Ashour S., Parker R.G. - *A Precedence Graph Algorithm for the Shop Scheduling Problem* - Operational Research Quarterly, Vol. 22, Nr. 2, June 1971, 165-176.
- [BAK69] Bakshi M.K., Arora S.R. - *The segmentary problem* - Mgmt Sci, Vol. 16, Nr. 4, 1969, B247-263.
- [BÂS87] Bâscă O.C., Popescu I. - *Sisteme de operare - Volumul I* - Tipografia Universității din București, 1987.
- [BÂS89] Bâscă O.C., Popescu I. - *Sisteme de programe pentru minicalculatoare (Sisteme de operare - Volumul II)* - Tipografia Universității București, 1989.
- [BEA90] Beasley J.E. - *A Lagrangian Heuristic for Set-Covering Problem* - Naval Research Logistics, Vol. 37, Nr. 1, February 1990, 151-164.
- [BER69] Berge C. - *Teoria grafurilor și aplicațiile ei* - Editura Tehnică, 1969.
- [BOR75] Borodin A., Munro I. - *The Computational Complexity of Algebraic and Numeric Problems* - American Elsevier Publishing Company, Inc., 1975.
- [BRA96] Brasard G., Bratley P. - *Fundamentals of Algorithmics* - Prentice Hall, Inc., 1996, 480-482.
- [BUC73] Bucur C.M. - *Metode numerice* - Editura Facla, Timișoara, 1973.
- [BUR84] Burstein M.C., Nevison C.H., Carlson R.C. - *Dynamic Lot-Sizing When Demand Timing is Uncertain* - Oper. Res., Vol. 32, 1984, 362-379.
- [CAR88] Carlier J., Chrétienne P. - *Problèmes d'ordonnancement - Modélisation, Complexité, Algorithmes* - Masson, Paris, Milan, Barcelone, Mexico, 1988.
- [CAR80] Carpaneto G., Toth P. - *Branching and Bounding Criteria for the Asymmetric Travelling Salesman Problem* - Mgmt. Sci., Vol. 26, 1980, 736-743.

- [CAR84] Carpaneto G., Martello S., Toth P. - *An Algorithm for the Bottleneck Traveling Salesman Problem* - Oper. Res., Vol. 32, Nr. 2, March-April 1984, 380-389.
- [CHA90] Chang Shiwei, Matsuo Hirofumi, Tang Guochun - *Worst-Case Analysis of Local Search Heuristics for the One-Machine Total Tardiness Problem* - Naval Research Logistics, Vol. 37, Nr. 1, february 1990, 111-122.
- [CHO78] Choukham E.A. - *Une heuristique pour le problème de l'arbre de Steiner* - RAIRO, Recherche Operationelle, Vol. 12, Nr. 2, mai 1978, 207-212.
- [CHR71] Christofides N., Viola P. - *The Optimum Location of Multi-centres on a Graph* - Operational Research Quarterly, Vol. 22, Nr. 2, June 1971, 145-154.
- [CHV79] Chvátal V. - *A Greedy Heuristic for the Set-Covering Problem* - Mathematics of Operations Research, Vol. 4, Nr. 3, 1979, 233-235.
- [COR77] Cornuejols G., Fisher M.L., Nehmauser G.L. - *Location of Bank Accounts to Optimize Float: An Analytic Study of Exact and Approximate Algorithms* - Management Science, Vol. 23, Nr. 8, April 1977, 789-810.
- [COU69] Courant R., Robbins H. - *Ce este matematica?* - , Editura Științifică, București, 1969.
- [CRA82] Craiu V., Bâscă O. - *Elemente de calcul numeric și programare* - Ediția a II-a revizuită și îmbunătățită, Tipografia Universității din București, 1982.
- [DAN90] Dantzig G.B., Dempster M.A.H., Kallio M. (Ed.) - *Programarea liniară a sistemelor mari* - Editura Tehnică, 1990.
- [DAV81] Davis E., Jaffe J.M. - *Algorithm for Scheduling Tasks on Unrelated Processors* - J. Ass. C. Mach., Vol. 28, Nr. 4. Oct. 1981, 721-736.
- [DEM81] Demidovich B.P., Maron I.A. - *Computational Mathematics* - MIR Publishers, Moscow, 1981.
- [DEM83] Dempster M.A.H., Fisher M.L., Jansen L., Lageweg B.J., Lenstra J.K., Rinnoy Kan A.H.G. - *Analysis of Heuristics for Stochastic Programming: Results for Hierarchical Scheduling Problems* - Math. Oper. Res., Vol. 8, Nr. 4, Nov. 1983, 525-537.
- [DOR76] Dorn W.S., McCracken D.D. - *Metode numerice cu programe în FORTRAN IV* - Editura Tehnică, 1976.
- [DRA72] Dragomirescu M., Malița M. - *Programare neliniară* - Editura Științifică, 1972.
- [DUD64] Dudek R.A., Teuton O.F. - *Development of M-stage decision rule for scheduling n jobs through m machines* - Operational Research, Vol. 12, Nr. 3, 1964, 471-497.

- [EAD82] Eades P., Foulds L.R., Giffin J.W. - *An Efficient Heuristic for Identifying a Maximum Weight Planar Subgraph* - in Lectures Notes in Mathematics, Nr. 952, *Combinatorial Mathematics IX*, Springer-Verlag, Berlin, 1982.
- [FIS80] Fisher M.L. - *Worst Case Analysis of Heuristic Algorithms* - Management Sci., Vol. 26, Nr. 1, Jan. 1980, 1-17.
- [FLO62] Floyd R.W. - *Algorithm 97: Shortest Path* - Comm.ACM, Vol. 5, Nr. 6, 1962, 345.
- [FOR62] Ford L.R.Jr., Fulkerson D.R. - *Flows in Networks* - Princeton Univ. Press, Princeton, NJ, 1962.
- [FOU85] Foulds L.R., Gibbons P.B., Giffin J.W. - *Facilities Layout Adjacency Determination: An Experimental Comparison of Three Graph Theoretic Heuristics* - Operations Research, Vol. 33, Nr. 5, Sept.-Oct. 1985, 1091-1106.
- [FRI83] Frieze A. M. - *An Extension of Christofides Heuristic to the k-Person Travelling Salesman Problem* - Discrete Applied Mathematics, Vol. 6, Nr. 1, May 1983, 79-84.
- [GAR79] Garey M., Johnson D. - *Computers and Intractability* - W.H.Freeman, San Francisco, 1979.
- [GAV65] Gavett W.J. - *Three Heuristic Rules for Sequencing Jobs to a Single Production Facility* - Management Science, Vol. 11, Nr. 8, June 1965, B166-176.
- [GEO74] Geoffrion A.M. - *Lagrangian Relaxation for Integer Programming* - Math. Prog. Study, Vol. 2, 1974, 82-114.
- [GIL85] Gilmore P.C., Lawler E.L., Shmoys D.B. - *Well-Solved Special Case of the Traveling Salesman Problem* - Chap.4 în *The Traveling Salesman Problem*, Lawler E.L., Lenstra J.K., Rinnoy Kan A.M.G., Shmoys D.B. (editori), John Wiley & Sons, New York, 1985.
- [GLO75] Glover F., Klingman D. - *Finding Minimum Spanning Trees with a Fixed Number of Links at a Node* - în *Combinatorial Programming Methods and Applications*, D. Reidel, Dordrecht, 1975, 191-201.
- [GOL87] Golden B.C., Levy L., Vohra R. - *The Orienteering Problem* - Naval Research Logistics, Vol. 34, Nr. 3, June 1987, 307-318.
- [GOL93] Goldberg A.V., Radzik T. - *A Heuristic Improvement of the Bellman-Ford Algorithm* - Computer Science Department, Stanford Univ., California, Report, 1993,1-5.
- [GOO77] Goodman S.E., Hedetniemi S.T. - *Introduction to the Design and Analysis of Algorithms* - McGraw-Hill Book Company, 1977.

- [GRA69] Graham R.L. - *Bounds on Multiprocessing Timing Anomalies* - SIAM Jr. on Appl. Math., Vol. 17, Nr. 2, March 1969, 416-429.
- [GRA90] Grassberger P., Freund H. - *An Efficient Heuristic Algorithm for Minimum Matching* - Zeitschrift für Operations Research, Vol. 34, Issue 4, 1990, 239-254.
- [GUP71] Gupta Jatinder N.D. - *A Functional Heuristic Algorithm for the Flowshop Scheduling Problem* - Operational Research Quarterly, Vol. 22, Nr. 1, March 1971, 39-47.
- [GUP76] Gupta Jatinder N.D. - *A Heuristic Algorithm for the Flowshop Scheduling Problem* - RAIRO, Vol. 10, Nr. 6, Juin 1976, 63-73.
- [HAC89] Hackman S.T., Magazine M.J., Wee T.S. - *Fast, Effective Algorithms for Simple Assembly Line Balancing Problems* - Operations Research, Vol. 37, Nr. 6, Nov.-Dec. 1989, 916-924.
- [HAD62] Hadley G. - *Linear Programming* - Addison-Wesley, Reading, M' 1962.
- [HAI85] Haimovich M., Rinnoy Kan A.M.G. - *Bounds and Heuristics for Capacited Routing Problem* - Math. Oper. Res., Vol. 10, Nr. 4, 1985, 527-542.
- [HAN66] Hanan M. - *On Steiner's Problem with Rectilinear Distance* - SIAM Journal on Applied Mathematics, Vol. 14, Nr. 2, 1966, 255-265.
- [HIL69] Hillier F.S. - *Efficient Heuristic Procedures for Integer Linear Programming with an Interior* - Operations Research, Vol. 17, Nr. 4, July-August 1969, 600-637.
- [HOC82] Hochbaum D.S. - *Heuristics for the Fixed Cost Median Problem* - Mathematical Programming, Vol. 22, Nr. 2, Febr. 1982, 148-162.
- [HOP74] Hopcroft J., Tarjan R. - *Efficient Planarity Testing* - J. Assoc. Comput. Mach., Vol. 21, Nr. 4, 1974, 549-568.
- [HOR78] Horowitz E., Sahni S. - *Fundamentals of Computer Algorithms* - Computer Science Press, Potomac, MD, 1978.
- [HSU84] Hsu When-Lian - *Approximation Algorithms for the Assembly Line Crew Scheduling Problem* - Math. Of Oper. Res., Vol. 9, Nr. 3, Aug. 1984, 376-383.
- [HUY80] Huyn N., Dechter R. Pearl J. - *Probabilistic Analysis of the Complexity of A** - Artificial Intelligence, Vol. 15, 1980, 241-254.
- [IBA75] Ibarra O.H., Kim C.E. - *Fast Approximation Algorithms for the Knapsack and Sum of Subsets Problems* - J. ACM, Vol. 22, 1975, 463-468.
- [IBA77] Ibarra O.H., Kim C.E. - *Heuristic Algorithms for Scheduling Independent Tasks on Nonidentical Processors* - J. ACM, Vol. 24, Nr. 2, April 1977, 280-289.

- [IBA83] Ibaraki T., Muro S., Murakami T., Hasegawa T. - *Using Branch-and-Bound Algorithms to obtain Suboptimal Solutions* - Zeitschrift für Operations Research, Band 27, Heft 5, 1983, A177-202.
- [JOH54] Johnson S.M. - *Optimal two-and three-stage production schedules with setup times included* - Naval Research Logistics Quarterly, 1, 1954, 61-68.
- [JOH74] Johnson D.S. - *Approximation Algorithms for Combinatorial Problems* - Journal of Computer and System Sciences, Vol. 9, Nr. 3, Dec. 1974, 256-278.
- [JOH74a] Johnson D.S., Demers A., Ullman J.D., Garey M.R., Graham R.L. - *Worst-case Performance Bounds for simple one-dimensional Packing Algorithms* - SIAM J. Comput., Nr. 3, 1974, 299-325.
- [JON90] Joneja Dev - *The Joint Replenishment Problem: New Heuristics and Worst Case Performance Bounds* - Operations Research, Vol. 38, Nr. 4, July-August 1990, 711-723.
- [KAR64] Karg R.R., Thompson G.L. - *A Heuristic Approach to Solving Travelling Salesman Problems* - Management Science, Vol. 10, Nr. 2, January 1964, 225-248.
- [KAR77] Karp R. - *Probabilistic Analysis of Partitioning Algorithms for the Travelling Salesman Problems in the Plane* - Math. of Oper. Res., Vol. 2, Nr. 3, 1977, 209-224.
- [KHA79] Khachian L.G. - *A Polynomial Time Algorithm in Linear Programming* - Soviet. Math. Dokl., Vol. 20, 1979, 191-194.
- [KHU72] Khumawala Basheer M. - *An Efficient Branch and Bound Algorithm Warehouse Location* - Mgm. Sci., Vol. 18, Nr. 12, Aug. 1972, 718-731.
- [KHU73] Khumawala Basheer M. - *An Efficient Heuristic Procedure for the Uncapacitated Warehouse Location Problem* - NRLQ, Vol. 20, Nr. 1, March 1973, 109-122.
- [KNU76] Knuth D.E. - *Tratat de programarea calculatoarelor - Sortare și căutare* - Editura Tehnică, București, 1976.
- [LAN70] Lange O. - *Decizii Optimale: Bazele Programării* - Editura Științifică, 1970.
- [LAW76] Lawler E.L. - *Combinatorial Optimisation: Networks and Matroids* - Holt, Rinehart&Winston, New York, 1976.
- [LAZ68] Lazăr S. - *Analiza drumului critic* - Editura Științifică, 1968.
- [LIN73] Lin S., Kernighan B.W. - *An Effective Heuristic Algorithm for Traveling Salesman Problem* - Operations Research, Vol. 21, Nr. 2, March-April 1973, 498-516.



- [LIV85] Livovschi L., Georgescu H. - *Analiza și Sinteza Algoritmilor* - Editura Științifică și Enciclopedică, 1985.
- [LUS86] Luss Hanan - *A Heuristic for Capacity Expansion Planning with Multiple Facility Types* - *Naval Research Logistic Quarterly*, Vol. 33, Nr. 4, Nov. 1986, 685-701.
- [MAH75] McMahon G., Florian M. - *On Scheduling with Ready Times and Due Dates to Minimize Maximum Lateness* - *Op. Res.*, Vol. 23, 1975, 475-482.
- [MAR87] Marinescu Gh., Rizzoli I., Popescu I., Ștefan C. - *Probleme de analiză numerică rezolvate cu calculatorul* - Editura Academiei RSR, 1987.
- [MAR83] Martello S. - *An Enumeration Algorithm for Finding Hamiltonian Circuits in a Directed Graph* - *ACM Trans. on Math Software*, Nr. 9, 1983, 131-138.
- [MĂC72] Măcriș A., Dumitru V. - *Aplicații ale cercetării operaționale în probleme de conducere, organizare și planificare a lucrărilor de investiții, construcții și montaj* - Editura Academiei RSR, 1972.
- [MIC94] Michalewicz Z. - *Genetic Algorithms + Data Structures = Evolution Programs* - Springer-Verlag, 1994.
- [MIH82] Mișu C., Dăneș T. - *Probleme pentru aplicarea matematicii în practică* - Editura Didactică și Pedagogică, 1982.
- [MIL77] Milgram M., Dubuisson B. - *Un Algorithme Heuristique de Décomposition d'un Graphe* - *RAIRO, Recherche Opérationnelle*, Vol.11, Nr. 2, Mai 1977, 175-199.
- [MOR81] Moran S. - *General Approximation Algorithms for Some Arithmetical Combinatorial Problems* - *Theoretical Computer Science*, Vol. 14, Nr. 3, June 1981, 289-303.
- [MÜL76] Müller-Merbach H. - *Darmstadt-Morphologie heuristischer Verfahren* - *Zeitschrift für Operations Research*, Band 20, Heft 3, Juni 1976, 69-87.
- [MUN69] Muntz R.R., Coffman E.G.Jr. - *Optimal Preemptive Scheduling on Two-Processor Systems* - *IEEE Trans. Comp. C-18*, 11, 1969.
- [MUN70] Muntz R.R., Coffman E.G.Jr. - *Preemptive Scheduling of Real Time Tasks on Multiprocessor Systems* - *J. Assoc. Comput. Mach.*, 17, 2, Apr. 1970, 324-338.
- [NEV85] Nevison C.H. - *A Cost Adjustment Heuristic for Dynamic Lot-Sizing with Uncertain Demand Timing* - *Operations Research*, Vol. 33, Nr. 6, Nov.-Dec. 1985, 1342-1352.
- [NIC71] Nicholson T.A.J., Pullen R.D. - *Dynamic Programming Applied to Ship Fleet Management* - *Operational Research Quarterly*, Vol. 22, Nr. 3, 1971, 211-220.

- [NIL82] Nilsson N.J. - *Principles of Artificial Intelligence* - Springer-Verlag, Berlin Heidelberg New York, 1982.
- [NIS83] Nishizeki T., Asano T., Watanabe T. - *An Approximation Algorithm for the Hamiltonian Walk Problem on Maximal Planar Graphs* - Discrete Applied Mathematics, Vol. 5, Nr. 2, February 1983, 211-222.
- [PAG61] Page E.S. - *An approach to the scheduling of jobs on machines* - J. R. Statist. Soc., 23, Seria B, 1961, 484-492.
- [PAI88] Pair C., Mohr R., Schott R. - *Construire les algorithmes - les améliorer, les connaître, les évaluer* - Dunod Informatique, Paris, 1988.
- [PAL65] Palmer D.S. - *Sequencing Jobs through a Multi-Stage Process in the Minimum Total Time - A Quick Method of Obtaining a Near Optimum* - Operational Research Quarterly, Vol. 16, Nr. 1, March 1965, 101-107.
- [PEA84] Pearl J. - *Heuristics, Intelligent Search Strategies for Computer Problem Solving* - Addison-Wesley Publishing Company, 1984.
- [PET88] Peters J.G. - *Lower Bounds on Time-Accuracy Trade-offs for the 0-1 Knapsack Problem* - Math. Of Oper. Res., Vol. 13, Nr. 3, Aug. 1988, 497-507.
- [PLA87] Plante R.D., Lowe T.J., Chandrasekaran R. - *The product matrix traveling salesman problem: an application and solution heuristic* - Operations Research, Vol. 35, Nr. 5, Sept-Oct 1987, 772-783.
- [PLA90] Plaisted D.A. - *A Heuristic Algorithm for Small Separators in Arbitrary Graphs* - SIAM Journal on Computing, Vol. 19, Nr. 2, April 1990, 267-280.
- [POS76] Posa L. - *Hamiltonian Circuits in Random Graphs* - Discrete Mathematics, Vol. 14, 1976, 359-364.
- [POS88] Posner M.E. - *The Deadline Constrained Weighted Completion Time Problem: Analysis of a Heuristic* - Operations Research, Vol. 36, Nr. 5, Sept.-Oct. 1988, 742-746.
- [POT80] Potts C.N. - *Analysis of a Heuristics for One Machine Sequencing with Release Dates and Delivery Times* - Oper. Res., Vol. 28, Nr. 6, 1980, 1436-1441.
- [POT85] Potts C.N. - *Analysis of a Linear Programming Heuristic for Scheduling Unrelated Parallel Machines* - Discrete Applied Mathematics, Vol. 10, Nr. 2, 1985, 155-164.
- [POT85a] Potts C.N. - *Analysis of Heuristics for Two-Machine Flow-Shop Sequencing Subject to Release Dates* - Math. Oper. Res., Vol. 10, nr. 4, 1985, 576-584.

- [PUR82] Purcaru I. - *Elemente de algebră și programare liniară* - Editura Științifică și Enciclopedică, 1982.
- [PUR97] Purcaru I. - *Matematici generale & elemente de optimizare. Teorie și aplicații* - Editura Economică, 1997.
- [RAL76] Ralston A. (Ed.), Meek C.L. (Ass.Ed.) - *Encyclopedia of Computer Science* - Petrocelli/Charter, New York, 1976.
- [REI77] Reingold E.M., Nievergelt J., Deo N. - *Combinatorial Algorithms. Theory and Practice* - Prentice-Hall, Inc., 1977.
- [RIC89] Richards D. - *Fast Heuristic Algorithms for Rectilinear Steiner Trees* - *Algorithmica*, Vol. 4, Nr. 2, 1989, 191-208.
- [ROM71] Roman R.J. - *Mine-mill Production Scheduling by Dynamic Programming* - *Operational Research Quarterly*, Vol. 22, Nr. 4, December 1971, 319-328.
- [ROS92] Rosenberg O., Ziegler H. - *A Comparison of Heuristic Algorithms for Cost-Oriented Assembly Line Balancing* - *ZOR*, Nr. 6, 1992, 477-495.
- [ROS77] Rosenkrantz D.J., Stearns R.E., Lewis P.M. - *An Analysis of several Heuristics for the Travelling Salesman Problem* - *SIAM J. Comput.* 6, 1977, 568-581.
- [ROT93] Rote G., Vogel A. - *A Heuristic for Decomposing Traffic Matrices in TDMA Satellite Communication* - *ZOR*, Vol. 38, Nr. 3, 1993, 281-307.
- [SAH75] Sahni S. - *Approximate Algorithms for the 0/1 Knapsack Problem*: *Journal of the Assoc. For Computing Machinery*, Vol. 22, Nr. 1, January 1975, 115-124.
- [SAH77] Sahni S. - *General Techniques for Combinatorial Approximation* - *Oper. Res.*, Vol. 25, Nr. 6, 1977, 920-936.
- [SCH71] Schrage L. - *Obtaining Optimal Solutions to Resource Constrained Network Scheduling Problems* - manuscris nepublicat, martie 1971.
- [SEN68] Senju Shizuo, Toyoda Yoshiaki - *An Approach to Linear Programming with 0-1 Variables* - *Management Science*, Vol. 15, Nr. 4, December 1968, B196-207.
- [SET90] Sethi S.P., Sriskandarajah C., Tayi Giri Kumar, Rao M.R. - *Heuristic Methods for Selection and Ordering of Part-Orienting Devices* - *Oper. Res.*, Vol. 38, Nr. 1, Ian.-Febr. 1990, 84-98.
- [SIM88] Simchi-Levi D., Berman O. - *A Heuristic for the Traveling Salesman Location Problems on Networks* - *Operations Research*, Vol. 36, Nr. 3, 1988, 478-484.

- [SPÄ85] Späth H. - *Heuristically Determining Cliques of Given Cardinality and with Minimal Cost within Weighted Complete Graphs* - Zeitschrift für Operations Research, Vol. 29, Issue 3, June 1985, 125-131.
- [STA81] Stanciu P., Criveanu D., David Gh., Fuchs W. - *Matematici aplicate în economie* - Editura Facla, 1981.
- [STE61] Steinhaus H. - *Caleidoscop matematic* - Editura Tehnică, București, 1961.
- [SUB93] Subhlok J. - *Solving Integer Programs from Dependence and Synchronization Problems* - Carnegie Mellon University Pittsburgh. CMU-CS-93-130, March 1993.
- [SZW87] Szwarc W., Gupta J.N.D. - *A flow-shop problem with sequence dependent additive setup times* - Naval Research Logistics Quarterly, Vol. 34, 1987, 619-627.
- [SZW89] Szwarc W., Liu J.J. - *An Approximate Solution of the Flow-Shop Problem with Sequence Dependent Setup Times* - Zeitschrift für Operations Research, Vol. 33, Issue 6, 1989, 439-451.
- [TEO72] Teodorescu N., Boldur Gh., Stoica M., Stancu-Minasian I., Băncilă I. - *Metode ale cercetării operaționale în gestiunea întreprinderilor* - Editura Tehnică, 1972.
- [TOM78] Tomescu I. - *Combinatorică și teoria grafurilor* - Tipografia Universității din București, 1978.
- [TOY75] Toyoda Yoshiaki - *A Simplified Algorithm for Obtaining Approximate Solutions to Zero-One Programming Problems* - Management Science, Vol. 21, Nr. 12, Aug. 1975, 1417-1427.
- [TSI84] Tsiligirides T. - *Heuristic Methodes Applied to Orienteering* - J. of Op. Res. Soc., Vol. 35, Nr. 9, 1984, 797-809.
- [TUR89] Turner J. S. - *Approximation Algorithms for the Shortest Common Superstring Problem* - Information and Control, Vol. 83, Nr. 1, October 1989, 1-20.
- [VĂD74] Văduva I., Dinescu C., Săvulescu B. - *Modele matematice de organizarea și conducerea producției* - Editura Didactică și Pedagogică, 1974.
- [VEI69] Veinott A.F. - *Minimum Concave Cost Solutions of Leontief Substitution Models of Multi-Facility Inventory Systems* - Oper. Res., Vol. 17, Nr. 2, 1969, 262-291.
- [WEB71] Webb M.H.J. - *Some Methods of Producing Approximate Solutions to Travelling Salesman Problems with Hundreds or Thousands of Cities* - Operational Research Quarterly, Vol. 22, Nr. 1, March 1971, 49-6.

- [WIN92] Winter P., MacGregor Smith J. - *Path-Distance Heuristics for the Steiner Problem in Undirected Networks* - *Algorithmica*, Nr. 7, 1992, 309-327.
- [WRE72] Wren A., Holliday A. - *Computer Scheduling of Vehicles from One or More Depots to a Number of Delivery Points* - *Op. Res. Q.*, Vol. 23, Nr. 3, 1972, 333-344.
- [ZAN69] Zangwill W.I. - *A Backlogging Model and a Multi-echelon Model of a Dynamic Economic Lot Size Production System-A Network Approach* - *Mgmt. Sci.*, Vol. 15, Nr. 9, 1969, 506-527.
- [***80] *** - *Mică enciclopedie matematică* - Editura Tehnică, 1980.



**Tiparul s-a executat sub c-da nr. 1080/2003 la
tipografia Editurii Universității din București**

DATA RESTITUIRII

13. MAR. 2004		
17. MAR. 2004		
17. MAR. 2004		
15. IUN. 2004		
4. FEB. 2005		
27. MAI. 2005		
27. MAI. 2005		
12. DEC. 2005		
10. IUN. 2004		
 	30. IUN. 2009	

BIBLIOTECA CENTRALA
UNIVERSITARA „CAROL I”



DE SPIRITU ET ANIMA

170.000

OCTAVIAN BÂSCĂ – S-a născut la 26 aprilie 1947 la Craiova. A absolvit în 1970 Facultatea de Matematică-Mecanică, secția Mașini de calcul, a Universității din București. A fost asistent universitar (1970-1977), lector universitar (1977-1991) și conferențiar universitar (din 1991) la Facultatea de Matematică a Universității București. A fost prodecan (1992-1996). În 1977 a obținut titlul de doctor în matematici în urma susținerii tezei cu titlul: *Sisteme de stocare și regăsire a informației*. A ținut cursuri de Mașini de calcul, Structuri de date, Sisteme de operare, Baze de date, Calcul distribuit și altele. A obținut premii la Olimpiada Internațională de Matematică (II la Moscova în 1964 și III la Berlin în 1965). Cercetări în domeniile: structuri de date, sisteme de operare, sisteme distribuite, baze de date, teoria algoritmilor. A elaborat, singur sau în colaborare, un număr de 19 monografii și manuale publicate printre altele la Editura Academiei, Editura Albatros, Editura Științifică și Enciclopedică, Editura Economică, Editura All și altele.

LEON LIVOVSKI – S-a născut la 26 mai 1921, în comuna Vărărești, județul Lăpușna. A absolvit Facultatea de electromecanică, secția Aviație, Școala Politehnică din București în 1945 și Facultatea de Fizică-Matematică a Universității din București în 1962. A fost asistent universitar (1951-1954), lector universitar (1954-1967), conferențiar universitar (1967-1971) și profesor universitar (din 1971), actualmente fiind pensionar (din 1986). În 1962 a obținut titlul de doctor în științe fizico-matematice în urma susținerii tezei cu titlul: *Sinteza mecanismelor automate cu aplicații la mecanismele pneumatice și hidraulice*. În 1970 a obținut titlul de doctor inginer în urma susținerii tezei cu titlul: *Circuite cu contacte de relee*. A ținut cursuri la I.P.G.G. și la Universitatea din București de Mecanică teoretică, Teoria elasticității, Bazele informaticii, Matematici speciale și altele. A primit premii ale M.E.Î. în anii 1956, 1960 și 1968. Cercetări în domeniile: teoria automatelor finite, metode și algoritmi de sinteză ale circuitelor combinaționale și secvențiale, teoria programării calculatoarelor, teoria algoritmilor. A elaborat, singur sau în colaborare, un număr de 17 monografii și manuale publicate printre altele la Editura Academiei, Editura Tehnică, Editura Albatros, Editura Didactică și Pedagogică, Editura Științifică și Enciclopedică și altele.

ISBN 973-575-785-0

Lei 170000