

ANTON BĂTĂTORESCU

**METODE
DE
OPTIMIZARE LINIARĂ**

Editura Universității din București

ANTON BĂTĂTORESCU

**METODE DE
OPTIMIZARE LINIARĂ**

ED 60197


**EDITURA UNIVERSITĂȚII DIN BUCUREȘTI
2003**

UNIVERSITATEA DIN BUCUREȘTI
DOCUMENTE
COTA: III 476063

560103

Referenți științifici: Prof. dr. **Vasile Preda**
Prof. dr. **Monica Dumitrescu**

B.C.U. Bucuresti



C20032641

© 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
BĂTĂTORESCU, ANTON
Metode de optimizare liniară/ Anton Bătătorescu -
București: Editura Universității din București, 2003
Bibliografie
ISBN 973-575-720-6

519.863

Prefață

De la primele publicații ale lui Dantzig cu privire la algoritmul simplex a trecut aproximativ o jumătate de secol. În acest interval de timp, teoria și metodele de optimizare liniară au cunoscut o evoluție considerabilă, în prezent existând un număr impresionant de lucrări consacrate acestui domeniu.

În aceeași perioadă a avut loc și apariția, iar apoi "explozia" calculatoarelor electronice, care au permis implementarea algoritmilor în programe performante, capabile să rezolve probleme economice reale. Dimensiunea din ce în ce mai mare a acestor probleme a impus rafinarea și adaptarea variantei inițiale a algoritmului simplex pentru a face față dificultăților ce se întâmpină la prelucrarea volumului mare de date. O direcție în acest sens a constat în elaborarea unor metode de gestionare judicioasă a elementelor nenule pe parcursul iterațiilor, numite *metode compacte*, însă ele nu vor face obiectul de studiu al acestei cărți. O altă direcție a fost de a găsi principii noi de abordare a rezolvării problemelor, fie prin exploatarea structurii speciale în care se prezintă de regulă datele în astfel de cazuri, fie prin adaptarea unor metode de optimizare neliniară.

Scopul acestei cărți este de a prezenta anumite aspecte din vasta problematică a optimizărilor liniare, punându-se accentul asupra rezultatelor teoretice, care justifică metodele și algoritmii ce sunt utilizați în practică.

Primul capitol este destinat teoremelor clasice ale programării liniare. Pe baza acestora este enunțat algoritmul simplex primal și apoi, după expunerea rezultatelor de dualitate, algoritmul simplex dual.

De asemenea, pentru a face o deschidere spre implementarea practică a algoritmului simplex, sunt deduse formulele de schimbare a bazei prin intermediul Lemei substituției și se prezintă două modalități de organizare a calculelor: tabloul simplex standard și cel revizuit. Pe de altă parte, într-un paragraf separat, este prezentată adaptarea algoritmului simplex pentru rezolvarea mai eficientă, din punct de vedere a dimensiunii, a problemelor cu variabile mărginite.

Cel de-al doilea capitol prezintă câteva metode de optimizare liniară care sunt concepute pentru rezolvarea problemelor de dimensiuni mari. Astfel de probleme au în mod necesar o structură particulară a res-

triecțiilor, în care coeficienții nenuli sunt grupați de regulă în blocuri (submatrice). Structura care rezultă este de formă "bloc-unghiulară" sau "bloc-triunghiulară". Metodele prezentate aici exploatează într-un mod ingenios această structură astfel încât, în loc de a rezolva o singură problemă de programare liniară, care este de dimensiune foarte mare, se rezolvă un șir de probleme liniare, dar care sunt de dimensiuni cu mult mai mici. Pentru aceasta sunt folosite două principii de abordare. Primul este principiul de descompunerele Dantzig-Wolfe, iar al doilea, cel de relaxare și partiționare. Ceea ce trebuie subliniat este faptul că aceste metode se bazează în ultimă instanță tot pe teoremele algoritmului simplex, care prin intermediul acestor principii este adaptat să beneficieze de structura "în blocuri" a datelor problemei. Cele două exemple numerice ilustrează modul de aplicare a metodelor expuse în acest capitol.

În ultimele două decenii, după publicarea în 1984 a algoritmului lui Karmarkar, studiul rezolvării problemelor de programare liniară de dimensiuni mari s-a orientat spre investigarea unor metode alternative. Ultimul capitol este consacrat prezentării unor astfel de metode, care își au originea în metodele de optimizare neliniară și se bazează pe construirea unor șiruri de puncte recurente din interiorul, respectiv exteriorul domeniului de admisibilitate. Aceste metode au o caracteristică comună și anume, ele rezolvă problemele "în timp polinomial", adică, efortul de calcul este mărginit de valoarea unui polinom ce se calculează în raport cu "mărimea" problemei. În cazul algoritmilor de punct interior, șirul de puncte recurente se află în vecinătatea unei "traectorii continue", care este descris de un sistem de ecuații diferențiale.

Cartea se adresează în special studenților care urmează cursuri de optimizare matematică, dar ea poate fi utilă în egală măsură și tuturor celor care sunt confrunțați în activitatea practică cu rezolvarea unor probleme de optimizare liniară, deoarece, prin aprofundarea teoretică a acestor metode, se pot înțelege și interpreta mai bine rezultatele ce se obțin prin utilizarea diferitor programe software.

București, decembrie 2002.

Autorul

C U P R I N S

1. Programare liniară	1
1.1. Notății și proprietăți ale sistemelor liniare	1
1.1.1. Lema Farkas-Minkowski	6
1.1.2. Forme ale problemelor de programare liniară	10
1.1.3. Teorema fundamentală a programării liniare	13
1.2. Teoremele algoritmului simplex	16
1.2.1. Determinarea unei baze primal admisibile	23
1.2.2. Formule pentru schimbarea bazei și organizarea calculului	27
1.3. Adaptarea algoritmului simplex la probleme cu variabile mărginite	33
1.4. Dualitate în programarea liniară	42
1.4.1. Reguli de asociere a problemelor duale	44
1.4.2. Teoreme de dualitate	46
1.5. Algoritmul simplex dual	51
2. Metode de descompunere	57
2.1. Introducere	57
2.2. Principiul de descompunere Dantzig-Wolfe	58
2.2.1. Rezultate preliminare	58
2.2.2. Principiul de descompunere	60
2.2.3. Exemplu de aplicare a principiului de descompunere	69
2.3. Metode de partiționare și relaxare	73
2.3.1. Principiul de relaxare	75
2.3.2. Algoritmul lui Ritter	79
2.3.3. Algoritmul lui Rosen	85
2.3.4. Exemplu de aplicare a algoritmului lui Rosen	95
3. Metode cu șiruri recurente	99
3.1. Introducere	99

3.2. Algoritmul elipsoidal	101
3.2.1. Probleme liniare echivalente	102
3.2.2. Transformări afine și elipsoizi	108
3.2.3. Algoritmul elipsoidal	112
3.3. Algoritmul proiectiv	120
3.3.1. Problema în forma standard Karmarkar	121
3.3.2. Minimizarea pe sferă	122
3.3.3. Evaluări de regularitate a domeniului de admisibilitate	123
3.3.4. Transformări proiective	129
3.3.5. O funcție potențial aproape invariantă	132
3.3.6. Algoritmul lui Karmarkar	134
3.3.7. Conversia la forma standard Karmarkar	144
3.4. Algoritmul afin	146
3.4.1. Prezentarea algoritmului	147
3.4.2. Teorema de convergență	150
3.5. Traiectorii continue	158
Bibliografie	164
Index	168

Capitolul 1

Programare liniară

1.1. Notății și proprietăți ale sistemelor liniare

Vom nota cu $A \in \mathbb{R}^{m \times n}$ o matrice cu m linii și n coloane:

$$A = \begin{pmatrix} a_{11} & a_{12} & a_{1n} \\ a_{21} & a_{22} & a_{2n} \\ \vdots & \vdots & \vdots \\ a_{m1} & a_{m2} & a_{mn} \end{pmatrix} = (a_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}$$

unde $a_{ij} \in \mathbb{R}$, $1 \leq i \leq m$, $1 \leq j \leq n$, sunt elementele ei. Vom spune că matricea A este de dimensiune $m \times n$.

Transpusa matricei A o vom nota cu A^\top și este matricea:

$$A^\top = \begin{pmatrix} a_{11} & a_{12} & a_{1n} \\ a_{21} & a_{22} & a_{2n} \\ \vdots & \vdots & \vdots \\ a_{m1} & a_{m2} & a_{mn} \end{pmatrix} = (a_{ji})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}$$

Evident, A^\top este de dimensiune $n \times m$.

Dacă $m = n$, atunci $A \in \mathbb{R}^{n \times n}$ se numește matrice pătratică de ordinul n .

Pe mulțimea matricelor de aceeași dimensiune se definește operația de adunare astfel: pentru $A \in \mathbb{R}^{m \times n}$ și $B \in \mathbb{R}^{m \times n}$, avem:

$$A + B = (a_{ij} + b_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}}$$

Înmulțirea unei matrice $B \in \mathbb{R}^{m \times n}$ cu un scalar $\alpha \in \mathbb{R}$ este:

$$\alpha B = (\alpha b_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} = B\alpha$$

În raport cu aceste operații, mulțimea matricelor de aceeași dimensiune formează un spațiu vectorial peste corpul numerelor reale.

Dacă $A \in \mathbb{R}^{m \times k}$ și $B \in \mathbb{R}^{k \times n}$, atunci se poate defini produsul

$$A \cdot B = C \in \mathbb{R}^{m \times n},$$

unde elementele matricei produs C se calculează astfel:

$$c_{ij} = \sum_{l=1}^k a_{il}b_{lj}, \quad 1 \leq i \leq m, \quad 1 \leq j \leq n.$$

Determinantul unei matrice pătratice $A \in \mathbb{R}^{n \times n}$ este numărul

$$\det A = \sum_{\sigma \in \mathcal{S}_n} \varepsilon(\sigma) a_{1\sigma(1)} a_{2\sigma(2)} \cdots a_{n\sigma(n)}$$

unde \mathcal{S}_n este mulțimea permutărilor σ de ordinul n , iar $\varepsilon(\sigma)$ este signatura permutării σ .

Dacă $\det A \neq 0$, matricea A se numește nesingulară, iar în acest caz, există o unică matrice $A^{-1} \in \mathbb{R}^{n \times n}$, numită "matrice inversă", cu proprietatea:

$$A \cdot A^{-1} = A^{-1} \cdot A = \mathbf{I}_n$$

unde $\mathbf{I}_n \in \mathbb{R}^{n \times n}$ este matricea unitate de dimensiune $n \times n$:

$$\mathbf{I}_n = \begin{pmatrix} 1 & 0 & \cdots & 0 \\ 0 & 1 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 1 \end{pmatrix}$$

Dacă în matricea $A \in \mathbb{R}^{m \times n}$ alegem k linii: i_1, i_2, \dots, i_k și k coloane: j_1, j_2, \dots, j_k , elementele care se găsesc la intersecția acestor linii și coloane formează o matrice pătratică de ordinul k :

$$M = \begin{pmatrix} a_{i_1 j_1} & a_{i_1 j_2} & \cdots & a_{i_1 j_k} \\ a_{i_2 j_1} & a_{i_2 j_2} & \cdots & a_{i_2 j_k} \\ \vdots & \vdots & \ddots & \vdots \\ a_{i_k j_1} & a_{i_k j_2} & \cdots & a_{i_k j_k} \end{pmatrix}$$

Determinantul $\det M$ este un "minor de ordin k " al matricei A .

O matrice $A \in \mathbb{R}^{m \times n}$ are "rangul r ", și scriem $\text{rang}(A) = r$, dacă A are un minor nenul de ordin r , iar toți minorii lui A de ordin mai mare decât r (dacă există) sunt nuli. Evident, $\text{rang}(A) \leq \min\{m, n\}$.

Un vector $v \in \mathbb{R}^n$ este considerat ca fiind o matrice $v \in \mathbb{R}^{n \times 1}$, adică, având n linii și o coloană. Din această cauză spunem că $v \in \mathbb{R}^n$ este un **vector coloană**, iar în reprezentarea sa pe componente vom omite scrierea indicelui de coloană:

$$v = \begin{pmatrix} v_1 \\ v_2 \\ \vdots \\ v_n \end{pmatrix} = (v_1, v_2, \dots, v_n)^\top$$

În mod similar, vectorul transpus $v^\top \in \mathbb{R}^{1 \times n}$, se va numi **vector linie**.

Produsul scalar a doi vectori $x \in \mathbb{R}^n$ și $y \in \mathbb{R}^n$ este:

$$x^\top \cdot y = \sum_{i=1}^n x_i y_i = y^\top \cdot x$$

Pe mulțimea vectorilor de aceeași dimensiune vom defini următoarele relații: dacă $x \in \mathbb{R}^n$ și $y \in \mathbb{R}^n$, atunci

$$x = y \iff x_i = y_i \text{ pentru orice } i = \overline{1, n};$$

$$x \leq y \iff x_i \leq y_i \text{ pentru orice } i = \overline{1, n}.$$

(Notăția $i = \overline{1, n}$ este echivalentă cu $i \in \{1, 2, \dots, n\}$.)

În particular, $x \geq \mathbf{0}$ înseamnă $x_i \geq 0$ pentru orice $i = \overline{1, n}$, iar " $\mathbf{0}$ " este vectorul cu toate componentele zero (vectorul nul), de aceeași dimensiune ca x .

Fiind dată o matrice $A \in \mathbb{R}^{m \times n}$ și un vector $b \in \mathbb{R}^m$, putem considera următorul sistem de ecuații liniare:

$$A \cdot x = b \tag{1.1.1}$$

unde variabila vectorială $x \in \mathbb{R}^n$ are drept componente necunoscutele x_i , $i = \overline{1, n}$, ale sistemului. Vom nota:

$$A_i = (a_{i1}, a_{i2}, \dots, a_{in}) \text{ linia "i" a matricei } A;$$

$$A^j = (a_{1j}, a_{2j}, \dots, a_{mj})^\top \text{ coloana "j" a matricei } A.$$

Astfel, sistemul de ecuații (1.1.1) poate fi rescris în următoarele forme echivalente:

$$A_i \cdot x = b_i, \quad i = \overline{1, m}$$

sau

$$\sum_{j=1}^n A^j x_j = b.$$

Sistemul de ecuații (1.1.1) are soluții dacă și numai dacă $\text{rang}(A) = \text{rang}(A : b)$ (teorema Kronecker-Capelli).

Fie $\text{rang}(A) = \text{rang}(A : b) = r$. Vom numi **ecuații principale**, respectiv **variabile principale**, acelea ale căror coeficienți intră în compunerea unui minor de ordin r nenul; celelalte vor fi numite **ecuații secundare**, respectiv **variabile secundare**.

Deoarece orice vector $x \in \mathbb{R}^n$, care satisface sistemul de ecuații format din ecuațiile principale, satisface și ecuațiile secundare, acestea din urmă pot fi omise fără a influența natura sistemului inițial. Din această cauză, în cele ce urmează, vom considera că ecuațiile secundare sunt eliminate din sistemul (1.1.1) și deci avem

$$\text{rang}(A) = m \leq n.$$

Dacă $m = n$, sistemul (1.1.1) are o soluție unică $x = A^{-1} \cdot b$, iar dacă $m < n$, atunci el are o infinitate de soluții.

Deoarece $\text{rang}(A) = m$, există m coloane liniar independente $A^{s_1}, A^{s_2}, \dots, A^{s_m}$ ale matricei A . Aceste coloane formează o bază în spațiul liniar generat de coloanele lui A . Din această cauză, matricea pătratică de ordin m , formată cu aceste coloane, o vom nota

$$B = (A^{s_1} A^{s_2} \dots A^{s_m})$$

și o vom numi **matrice de bază**. Matricea formată din coloanele lui A , care nu fac parte din B , va fi notată cu R . Astfel, coloanele matricei A pot fi partiționate în două și vom scrie:

$$A = \left(B : R \right).$$

Vom nota mulțimea de indici corespunzătoare coloanelor lui B cu

$$\mathcal{B} = \{s_1, s_2, \dots, s_m\},$$

iar mulțimea de indici corespunzătoare coloanelor lui R cu

$$\mathcal{R} = \{1, 2, \dots, m\} \setminus \mathcal{B}.$$

În concordanță cu partiționarea coloanelor lui A , componentele variabilei vectoriale $x \in \mathbb{R}^n$ a sistemului de ecuații (1.1.1) se partiționează în mod corespunzător:

$$x = \begin{pmatrix} x_{\mathcal{B}} \\ x_{\mathcal{R}} \end{pmatrix}$$

unde $x_{\mathcal{B}} = (x_i)_{i \in \mathcal{B}} = (x_{s_1}, x_{s_2}, \dots, x_{s_m})^T \in \mathbb{R}^m$ conține variabilele principale ale sistemului, numite și **variabile de bază**, iar $x_{\mathcal{R}} = (x_j)_{j \in \mathcal{R}} \in \mathbb{R}^{n-m}$ conține variabilele secundare.

Utilizând notațiile introduse mai sus, sistemul de ecuații (1.1.1) poate fi rescris în modul următor

$$B \cdot x_{\mathcal{B}} + R \cdot x_{\mathcal{R}} = b$$

de unde se obține expresia soluției generale:

$$x_{\mathcal{B}} = B^{-1} \cdot b - B^{-1} \cdot R \cdot x_{\mathcal{R}} \quad (1.1.2)$$

Vectorul $v \in \mathbb{R}^n$ se numește **soluție** a sistemului (1.1.1) dacă verifică $A \cdot v = b$. O soluție a sistemului (1.1.1) este numită **soluție de bază**, dacă componentele ei diferite de zero corespund unor coloane liniar independente ale lui A . Deoarece $\text{rang}(A) = m$, cel mult m componente ale unei soluții de bază pot fi nenule. Dacă soluția de bază are exact m componente nenule, ea se numește **nedegenerată**; în caz contrar ea este **degenerată**.

Pentru orice bază B , din relația (1.1.2) se poate obține o soluție de bază a sistemului (1.1.1) astfel: se anulează variabilele secundare $x_{\mathcal{R}} = \mathbf{0}$, iar variabilele principale primesc valoarea $x_{\mathcal{B}} = B^{-1} \cdot b$. Evident, vectorul $v = \begin{pmatrix} [B^{-1} \cdot b]_{\mathcal{B}} \\ \mathbf{0}_{\mathcal{R}} \end{pmatrix}$ este o soluție de bază, deoarece verifică $A \cdot v = b$, iar componentele sale nenule corespund coloanelor lui B , care sunt liniar independente.

1.1.1. Lema Farkas-Minkowski

Să considerăm următoarele sisteme liniare:

$$\begin{cases} A \cdot x = b \\ x \geq \mathbf{0} \end{cases} \quad (1.1.3)$$

și

$$\begin{cases} A^T \cdot u \geq \mathbf{0} \\ b^T \cdot u < 0 \end{cases} \quad (1.1.4)$$

unde $A \in \mathbb{R}^{m \times n}$ iar $b \in \mathbb{R}^m$.

Lema 1.1 (Farkas-Minkowski) *Dintre sistemele (1.1.3) și (1.1.4), doar unul, și numai unul poate avea soluții.*

Demonstrație. Vom demonstra mai întâi că cele două sisteme nu pot avea simultan soluții. Dacă presupunem prin absurd că sistemul (1.1.3) are soluția $x_0 \in \mathbb{R}^n$ iar sistemul (1.1.4) are soluția $u_0 \in \mathbb{R}^m$, atunci avem $x_0 \geq \mathbf{0}$ și $A^T \cdot u_0 \geq \mathbf{0}$. De aici rezultă

$$u_0^T \cdot b = u_0^T \cdot A \cdot x_0 \geq 0$$

ceea ce contrazice relația a doua a sistemului (1.1.4).

Prin urmare, dacă sistemul (1.1.3) are o soluție, atunci sistemul (1.1.4) nu poate avea soluție.

Rămâne să arătăm că, dacă sistemul (1.1.3) nu are soluție, atunci sistemul (1.1.4) are o soluție. Două cazuri sunt posibile.

Cazul 1. Sistemul de ecuații $A \cdot x = b$ este incompatibil. Asta înseamnă că, dacă $\text{rang}(A) = r$, atunci $\text{rang}(A : b) = r + 1$. Să considerăm sistemul de ecuații

$$\begin{aligned} A^T \cdot u &= \mathbf{0} \\ b^T \cdot u &= c \end{aligned}$$

unde constanta $c < 0$. Se constată cu ușurință că acest sistem este compatibil:

$$\text{rang} \begin{pmatrix} A^T \\ b^T \end{pmatrix} = r + 1 = \text{rang} \begin{pmatrix} A^T & \mathbf{0} \\ b^T & c \end{pmatrix}$$

și prin urmare, soluția acestuia este o soluție pentru (1.1.4).

Cazul 2. Sistemul de ecuații $A \cdot x = b$ este compatibil, dar nu admite o soluție $x \geq 0$. Pentru a construi o soluție a sistemului (1.1.4), vom folosi un raționament prin inducție, după numărul coloanelor lui $A = (A^1, A^2, \dots, A^n)$.

Dacă matricea este formată dintr-o singură coloană A^1 , atunci, în această situație trebuie ca $b \neq 0$ și există $x_1 < 0$ astfel încât $A^1 x_1 = b$. Se verifică cu ușurință că vectorul $u = -b$ este o soluție a lui (1.1.4):

$$\begin{aligned} u^\top \cdot A^1 &= (-b)^\top \cdot \begin{pmatrix} 1 \\ x_1 \end{pmatrix} b = \frac{-1}{x_1} \|b\|^2 > 0 \\ u^\top \cdot b &= (-b)^\top \cdot b = -\|b\|^2 < 0. \end{aligned}$$

Fie $k \geq 1$ și presupunem că, dacă sistemul

$$\sum_{i=1}^k A^i x_i = b \text{ nu admite soluție } x_i \geq 0, \quad i = \overline{1, k}, \quad (1.1.5)$$

atunci există un vector $u_0 \in \mathbb{R}^m$, astfel încât

$$\begin{aligned} u_0^\top \cdot A^i &\geq 0, \quad i = \overline{1, k}, \\ u_0^\top \cdot b &< 0. \end{aligned}$$

Pentru cazul când A are $k + 1$ coloane, dacă $u_0^\top \cdot A^{k+1} \geq 0$, atunci vectorul u_0 este o soluție a lui (1.1.4) și problema este rezolvată. Vom presupune deci

$$u_0^\top \cdot A^{k+1} < 0$$

și vom construi un vector \tilde{u} care să verifice sistemul (1.1.4).

Definim următorii vectori:

$$\bar{A}^i = A^i + \lambda_i A^{k+1} \quad \text{unde} \quad \lambda_i = -\frac{u_0^\top \cdot A^i}{u_0^\top \cdot A^{k+1}} \geq 0, \quad i = \overline{1, k}, \quad (1.1.6)$$

$$\bar{b} = b + \lambda_0 A^{k+1} \quad \text{unde} \quad \lambda_0 = -\frac{u_0^\top \cdot b}{u_0^\top \cdot A^{k+1}} < 0. \quad (1.1.7)$$

Sistemul $\sum_{i=1}^k \bar{A}^i y_i = \bar{b}$ nu admite soluție $y_i \geq 0, i = \overline{1, k}$. Prin absurd, dacă ar exista o soluție $\bar{y}_i \geq 0, i = \overline{1, k}$, atunci, din (1.1.6) și (1.1.7)

putem scrie:

$$\sum_{i=1}^k (A^i + \lambda_i A^{k+1}) \bar{y}_i = b + \lambda_0 A^{k+1}$$

sau,

$$\sum_{i=1}^k A^i \bar{y}_i + \left(\sum_{i=1}^k \lambda_i \bar{y}_i - \lambda_0 \right) A^{k+1} = b$$

Deoarece pentru orice $i = \overline{1, k}$ avem $\lambda_i \geq 0$ și $\lambda_0 < 0$, rezultă $\sum_{i=1}^k \lambda_i \bar{y}_i - \lambda_0 > 0$, adică sistemul (1.1.3) ar admite o soluție nenegativă, contrar ipotezei noastre de la care am plecat.

Prin urmare, folosind ipoteza de inducție (1.1.5) pentru sistemul definit de vectorii \bar{A}^i și \bar{b} , rezultă că există un vector $\bar{u} \in \mathbb{R}^m$, care verifică relațiile:

$$\bar{u}^\top \cdot \bar{A}^i \geq 0, \quad i = \overline{1, k}, \quad (1.1.8)$$

$$\bar{u}^\top \cdot \bar{b} < 0. \quad (1.1.9)$$

Din (1.1.8), pentru fiecare $i = \overline{1, k}$, folosind (1.1.6), avem:

$$\begin{aligned} 0 &\leq \bar{u}_0^\top \cdot \bar{A}^i = \bar{u}^\top \cdot (A^i + \lambda_i A^{k+1}) = \\ &= \bar{u}^\top \cdot \left(A^i - \frac{u_0^\top \cdot A^i}{u_0^\top \cdot A^{k+1}} A^{k+1} \right) = \left(\bar{u} - \frac{\bar{u}^\top \cdot A^{k+1}}{u_0^\top \cdot A^{k+1}} u_0 \right)^\top \cdot A^i \end{aligned} \quad (1.1.10)$$

Vom defini

$$\tilde{u} = \bar{u} - \frac{\bar{u}^\top \cdot A^{k+1}}{u_0^\top \cdot A^{k+1}} u_0$$

și din (1.1.10) rezultă

$$\tilde{u}^\top \cdot A^i \geq 0, \quad i = \overline{1, k}.$$

În plus, avem:

$$\tilde{u}^\top \cdot A^{k+1} = \left(\bar{u} - \frac{\bar{u}^\top \cdot A^{k+1}}{u_0^\top \cdot A^{k+1}} u_0 \right)^\top \cdot A^{k+1} = 0.$$

Folosind (1.1.9) și (1.1.7), obținem:

$$\tilde{u}^\top \cdot b = \left(\bar{u} - \frac{\bar{u}^\top \cdot A^{k+1}}{u_0^\top \cdot A^{k+1}} u_0 \right)^\top \cdot b =$$

$$= \bar{u}^\top \cdot \left(b - \frac{u_0^\top \cdot b}{u_0^\top \cdot A^{k+1}} A^{k+1} \right) = \bar{u}^\top \cdot \bar{b} < 0.$$

Prin urmare, \bar{u} este o soluție a sistemului (1.1.4) când A are $k + 1$ coloane și lema este demonstrată. ■

Observația 1.1 *Sistemele (1.1.3) și (1.1.4) pot fi considerate sisteme duale în sens Farkas-Minkowski.*

Lema Farkas-Minkowski se poate aplica și la alte perechi de sisteme liniare. Spre exemplu, dacă considerăm sistemul

$$\begin{cases} A \cdot x \leq b \\ x \geq 0 \end{cases} \quad (1.1.11)$$

acesta este echivalent cu

$$\begin{cases} A \cdot x + \mathbf{I} \cdot y = b \\ x \geq 0, y \geq 0 \end{cases}$$

iar acestuia din urmă, având matricea $(A : \mathbf{I})$, îi corespunde următorul sistem dual în sens Farkas-Minkowski:

$$\begin{cases} A^\top \cdot u \geq 0 \\ u \geq 0 \\ b^\top \cdot u < 0 \end{cases} \quad (1.1.12)$$

Teorema 1.2 *Fie $S \in \mathbb{R}^{n \times n}$ o matrice antisimetrică ($S = -S^\top$).*

Sistemul $\begin{cases} S \cdot x \geq 0 \\ x \geq 0 \end{cases}$ are o soluție $\bar{x} \geq 0$ cu proprietatea: $S \cdot \bar{x} + \bar{x} > 0$.

Demonstrație. Luăm o valoare arbitrară fixată a indicelui i , $1 \leq i \leq n$. Vom considera perechea de sisteme duale în sens Farkas-Minkowski (1.1.11) și (1.1.12), în care $A = -S$ și $b = -e^i$, unde e^i este vectorul unitar cu 1 în poziția "i" și zero în rest. Conform lemei Farkas-Minkowski, putem avea doar două situații:

Cazul 1. Sistemul (1.1.11) are o soluție x^i . Prin urmare, putem scrie:

$$\begin{cases} S \cdot x^i \geq e^i \\ x^i \geq 0 \end{cases}$$

Dacă notăm cu S_i linia "i" a matricei S , atunci avem: $S_i \cdot x^i \geq 1 > 0$, și deoarece componenta "i" a soluției x^i este $x_i^i \geq 0$, avem

$$S_i \cdot x^i + x_i^i > 0.$$

Cazul 2. Sistemul (1.1.12) are o soluție x^i . În acest caz, vom avea:

$$\begin{cases} S \cdot x^i \geq 0 \\ x^i \geq 0 \\ (e^i)^\top \cdot x^i > 0 \end{cases}$$

de unde deducem: $S_i \cdot x^i \geq 0$ și $x_i^i > 0$, deci și în acest caz vom avea:

$$S_i \cdot x^i + x_i^i > 0.$$

În concluzie, pentru orice i fixat, există o soluție $x^i \geq 0$ astfel încât $S_i \cdot x^i + x_i^i > 0$. Dacă luăm acum $\bar{x} = \sum_{i=1}^n x^i$, avem evident $\bar{x} \geq 0$ și $S \cdot \bar{x} + \bar{x} > 0$. ■

1.1.2. Forme ale problemelor de programare liniară

Problemele de programare liniară se pot descrie în diferite forme, în funcție de condițiile și scopul în care sunt folosite. Astfel, dacă ele sunt în faza de modelare matematică a unor probleme reale, atât variabilele cât și restricțiile vor fi exprimate într-o formă cât mai apropiată de descrierea fenomenului real. Pentru elaborarea unor metode de rezolvare și a studiului teoretic, problemele de programare liniară se prezintă într-o formă mai simplificată, în care datele problemei, restricțiile și variabilele își pierd semnificația inițială, fiind elemente abstracte, care însă moștenesc structura fenomenului real de la care s-a plecat. În cele ce urmează, vom prezenta cele mai importante forme "matematice" ale acestor probleme.

Trebuie subliniat faptul că, o problemă de optimizare constă din *minimizarea* sau *maximizarea* unei anumite funcții - numită funcție obiectiv - în prezența unor restricții care trebuie satisfăcute. Deoarece

$$\inf \{f(x) \mid x \in \mathcal{P}\} = - \max \{-f(x) \mid x \in \mathcal{P}\},$$

este suficient să studiem doar un singur tip de problemă, care în cazul nostru va fi cea de **minimizare**. Cu ajutorul relației de mai sus, toate rezultatele care se obțin, se pot transpune cu ușurință și pentru problemele de maximizare.

Fie $\alpha \in \mathbb{R}^n$ și $\beta \in \mathbb{R}$.

Definiția 1.1 Vom spune că o restricție este **concordantă** în raport cu o problemă de minimizare, dacă ea este de forma $\alpha^\top \cdot x \geq \beta$, și **neconcordantă** dacă $\alpha^\top \cdot x \leq \beta$.

Vom spune că o restricție este **concordantă** în raport cu o problemă de maximizare, dacă ea este de forma $\alpha^\top \cdot x \leq \beta$, și **neconcordantă** dacă $\alpha^\top \cdot x \geq \beta$.

Forma generală.

O problemă de programare liniară în formă generală conține toate tipurile de restricții și variabile care pot apare în descrierea ei. Ea se enunță astfel:

$$\inf \{c_1^\top \cdot x_1 + c_2^\top \cdot x_2 + c_3^\top \cdot x_3\}$$

în raport cu

$$\begin{cases} A_{11} \cdot x_1 + A_{12} \cdot x_2 + A_{13} \cdot x_3 \geq b_1 \\ A_{21} \cdot x_1 + A_{22} \cdot x_2 + A_{23} \cdot x_3 = b_2 \\ A_{31} \cdot x_1 + A_{32} \cdot x_2 + A_{33} \cdot x_3 \leq b_3 \\ x_1 \geq 0 & x_3 \leq 0 \end{cases}$$

unde datele problemei sunt matricele $A_{ij} \in \mathbb{R}^{m_i \times n_j}$ și vectorii $b_i \in \mathbb{R}^{m_i}$, $c_j \in \mathbb{R}^{n_j}$, $1 \leq i \leq 3$, $1 \leq j \leq 3$.

Necunoscutele problemei sunt grupate în trei variabile vectoriale $x_j \in \mathbb{R}^{n_j}$, $1 \leq j \leq 3$, astfel încât asupra componentelor lui x_1 și x_3 sunt impuse condiții de semn, în timp ce componentele lui x_2 sunt fără condiții, ele putând primi valori oarecare. De asemenea, observăm că sunt prezente toate formele de restricții: concordante, de tip egalitate și neconcordante.

Forma standard.

O problemă de programare liniară în formă standard este:

$$\inf \{c^T \cdot x \mid A \cdot x = b, x \geq 0\}$$

unde datele problemei sunt $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$, $c \in \mathbb{R}^n$. Observăm că în acest caz, toate restricțiile sunt de tip egalitate și toate componentele necunoscutei x sunt supuse condiției de nenegativitate.

Forma canonică.

Forma canonică a unei probleme de programare liniară conține doar restricții concordante și variabile nenegative:

$$\inf \{c^T \cdot x \mid A \cdot x \geq b, x \geq 0\}$$

iar datele problemei sunt $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$, $c \in \mathbb{R}^n$.

Forma mixtă.

O problemă de programare liniară în formă mixtă conține restricții concordante și de tip egalitate, iar variabilele sunt supuse condiției de nenegativitate.

$$\inf \left\{ c^T \cdot x \mid \begin{array}{l} A_1 \cdot x \geq b_1 \\ A_2 \cdot x = b_2 \end{array}, x \geq 0 \right\}$$

Dacă o problemă de programare liniară este prezentată într-o anumită formă, ea poate fi transformată cu ușurință în oricare altă formă dorită, folosind următoarele *transformări echivalente*:

- Sensul unei inegalități se schimbă prin înmulțire cu -1 .
- Transformarea unei inegalități într-o ecuație: o inegalitate de forma $\alpha^T \cdot x \leq \beta$ este echivalentă cu ecuația $\alpha^T \cdot x + y = \beta$ și $y \geq 0$, unde variabila y se numește *variabilă ecart* (sau *variabilă de compensare*); inegalitatea $\alpha^T \cdot x \geq \beta$ este echivalentă cu $\alpha^T \cdot x - y = \beta$ și $y \geq 0$.
- Transformarea unei ecuații în inegalități: o ecuație $\alpha^T \cdot x = \beta$ este echivalentă cu perechea de inegalități $\alpha^T \cdot x \leq \beta$ și $\alpha^T \cdot x \geq \beta$.

- O variabilă supusă condiției $x \leq 0$ se transformă într-o variabilă nenegativă prin substituția $x' = -x$.
- O variabilă x care nu este supusă unor condiții de semn (oarecare), se transformă într-o pereche de variabile nenegative $x^+ \geq 0$ și $x^- \geq 0$, prin substituția: $x = x^+ - x^-$.

Din cele de mai sus rezultă că atât studiul teoretic cât și metodele de rezolvare pot fi abordate utilizând oricare dintre formele problemelor de programare liniară menționate. Deoarece în teoria sistemelor de ecuații liniare dispunem de metode de rezolvare, vom folosi cu precădere forma standard a problemelor de programare liniară pentru a elaborarea algoritmi. În schimb, la studiul proprietăților de dualitate se va dovedi mai adecvate problemele în forma canonică.

1.1.3. Teorema fundamentală a programării liniare

Considerăm problema de programare liniară în forma standard:

$$\inf \{c^T \cdot x \mid A \cdot x = b, x \geq 0\} \quad (P)$$

Vectorul $v \in \mathbb{R}^n$ se va numi **soluție admisibilă** a problemei (P), dacă $A \cdot v = b$ și $v \geq 0$.

O soluție admisibilă $v \in \mathbb{R}^n$ este o **soluție optimă** a problemei (P), dacă oricare ar fi soluția admisibilă y , avem: $c^T \cdot v \leq c^T \cdot y$.

Fără a restrânge generalitatea, vom presupune că

$$\text{rang}(A) = m < n.$$

În cazul în care $m = n$, sistemul de ecuații ar avea o soluție unică și problema (P) ar deveni banală.

Teorema 1.3 (Teorema fundamentală a programării liniare)

- (a) Dacă problema (P) are o soluție admisibilă, atunci ea are și o soluție admisibilă de bază.
- (b) Dacă problema (P) are o soluție optimă, atunci ea are și o soluție optimă de bază.

Demonstrație. (a) Fie $v \in \mathbb{R}^n$ o soluție admisibilă a problemei (P). Fără a restrânge generalitatea, putem considera că primele k componente ale lui v sunt nenule, adică, $v = (v_1, v_2, \dots, v_k, 0, \dots, 0)^\top$, unde $v_i > 0$, $i = \overline{1, k}$.

Dacă $k = 0$, atunci $v = \mathbf{0}$ și evident aceasta este o soluție de bază. Fie deci $k \geq 1$.

Dacă $\{A^1, A^2, \dots, A^k\}$ sunt coloane liniar independente, atunci din nou v este o soluție de bază și afirmația este demonstrată.

Dacă $\{A^1, A^2, \dots, A^k\}$ sunt coloane liniar dependente, atunci există numerele $y_i \in \mathbb{R}$, $i = \overline{1, k}$, nu toate nule, deci $\sum_{i=1}^k |y_i| > 0$, astfel încât $\sum_{i=1}^k A^i y_i = \mathbf{0}$. Vom considera vectorul $y \in \mathbb{R}^n$ format din primele k componente cu numerele y_i și zero în rest: $y = (y_1, y_2, \dots, y_k, 0, \dots, 0)^\top$. Prin urmare, putem scrie:

$$y \neq \mathbf{0}, \quad \text{și} \quad A \cdot y = \mathbf{0}. \quad (1.1.13)$$

Pentru $\lambda \in \mathbb{R}$, definim vectorul $x(\lambda) = v + \lambda y$. Deoarece avem evident

$$A \cdot x(\lambda) = A \cdot (v + \lambda y) = A \cdot v + \lambda A \cdot y = A \cdot v = b,$$

rezultă că $x(\lambda)$ este o soluție a sistemului $A \cdot x = b$ pentru orice $\lambda \in \mathbb{R}$.

Vom determina în continuare valorile lui λ pentru care să fie îndeplinită și condiția $x(\lambda) \geq \mathbf{0}$. Deoarece $x_i(\lambda) = 0$ pentru $i = \overline{k+1, n}$, trebuie ca

$$x_i(\lambda) = v_i + \lambda y_i \geq 0, \quad \text{pentru} \quad i = \overline{1, k}.$$

De aici rezultă

$$\lambda \geq \frac{-v_i}{y_i} \quad \text{dacă} \quad y_i > 0,$$

$$\lambda \leq \frac{-v_i}{y_i} \quad \text{dacă} \quad y_i < 0.$$

Prin urmare, dacă definim

$$\lambda' = \begin{cases} \max_{1 \leq i \leq k} \left\{ \frac{-v_i}{y_i} \mid y_i > 0 \right\} & \text{dacă există } y_i > 0, \\ -\infty & \text{dacă nu există } y_i > 0, \end{cases}$$

$$\lambda'' = \begin{cases} \min_{1 \leq i \leq k} \left\{ \frac{-v_i}{y_i} \mid y_i < 0 \right\} & \text{dacă există } y_i < 0, \\ -\infty & \text{dacă nu există } y_i < 0, \end{cases}$$

atunci, pentru $\lambda \in [\lambda', \lambda'']$ avem $x(\lambda) \geq \mathbf{0}$, și $x(\lambda)$ este soluție admisibilă pentru problema (P). Deoarece numerele y_i , $i = \overline{1, k}$, nu sunt toate nule, rezultă că cel puțin una din valorile lui λ' sau λ'' este finită. Fie λ_0 una din valorile finite ale lui λ' sau λ'' . Atunci, există un indice i_0 , $1 \leq i_0 \leq k$, astfel încât $v_{i_0} + \lambda y_{i_0} = 0$. De aici rezultă că vectorul $x(\lambda_0)$ este o soluție admisibilă a problemei (P) și are cel mult $k - 1$ componente nenule. În această situație, dacă coloanele corespunzătoare sunt liniar independente, problema este rezolvată. În caz contrar, se reia raționamentul cu cele $k - 1$ coloane liniar dependente. Astfel, într-un număr finit de pași vom ajunge fie la situația $k = 0$, sau vom obține o soluție admisibilă de bază.

(b) Fie $\bar{v} \in \mathbb{R}^n$ o soluție optimă a problemei (P). La fel ca la punctul (a), putem considera că primele k componente ale lui \bar{v} sunt neneule.

Dacă $k = 0$, atunci $\bar{v} = \mathbf{0}$ este o soluție optimă de bază. Vom considera deci $k \geq 1$.

Dacă $\{A^1, A^2, \dots, A^k\}$ sunt coloane liniar independente, atunci evident \bar{v} este o soluție optimă de bază și afirmația este demonstrată.

Dacă $\{A^1, A^2, \dots, A^k\}$ sunt coloane liniar dependente, atunci, raționând ca la punctul (a), există un vector $y \in \mathbb{R}^n$ neneul, astfel încât relația (1.1.13) să fie îndeplinită iar vectorul $x(\lambda) = \bar{v} + \lambda y$ să fie o soluție admisibilă a problemei (P), pentru orice $\lambda \in [\lambda', \lambda'']$. Deoarece \bar{v} este o soluție optimă, avem

$$c^\top \cdot \bar{v} \leq c^\top \cdot x(\lambda) = c^\top \cdot \bar{v} + \lambda c^\top \cdot y$$

de unde obținem:

$$\lambda c^\top \cdot y \geq 0 \quad \text{pentru orice } \lambda \in [\lambda', \lambda'']. \quad (1.1.14)$$

Din definiția lui λ' și λ'' rezultă $\lambda' < 0$ și $\lambda'' > 0$. Din această cauză, nu putem avea $c^\top \cdot y \neq 0$, deoarece, în caz contrar, alegând pe λ de semn contrar lui $c^\top \cdot y$, am obține $\lambda c^\top \cdot y < 0$, ceea ce este în contradicție cu relația (1.1.14). Prin urmare, $c^\top \cdot y = 0$ și deci,

pentru orice $\lambda \in [\lambda', \lambda'']$, vectorul $x(\lambda)$ este o soluție optimă. Ca și în demonstrația punctului (a), dând lui λ_0 una din valorile finite ale lui λ' sau λ'' , vectorul $x(\lambda_0)$ este o soluție optimă cu cel mult $k - 1$ componente nenule. Dacă $x(\lambda_0)$ nu este o soluție optimă de bază, atunci, reluând raționamentul, într-un număr finit de pași vom obține o soluție optimă de bază. ■

În general, mulțimea soluțiilor admisibile a problemei (P) este infinită, spre deosebire de cea a soluțiilor admisibile de bază, care are cel mult C_n^m elemente. Importanța teoremei fundamentale a programării liniare constă în aceea că, pentru determinarea unei soluții optime, dacă ea există, căutarea este redusă de la o mulțime infinită, la una finită, fiind suficientă investigarea doar a soluțiilor de bază.

1.2. Teoremele algoritmului simplex

Rezolvarea problemelor de programare liniară a fost dominată timp de decenii (1950-1985) de algoritmul simplex. Această metodă a fost elaborată de G.B. Dantzig în jurul anului 1950 și a cunoscut de-a lungul timpului o serie de îmbunătățiri, mai ales în ceea ce privește implementarea ei pentru rezolvarea eficientă a problemelor de dimensiuni din ce în ce mai mari.

În esența sa, algoritmul simplex explorează în mod sistematic mulțimea soluțiilor admisibile de bază în așa fel încât, prin trecerea de la o soluție la alta, valoarea corespunzătoare a funcției obiectiv să fie cel puțin la fel de bună ca cea precedentă.

Să considerăm problema de programare liniară

$$\inf \{c^T \cdot x \mid A \cdot x = b, x \geq 0\} \quad (P)$$

unde $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$ și $c \in \mathbb{R}^n$. Fără a restrânge generalitatea, vom presupune $\text{rang}(A) = m < n$. Fie $B = (A^{s_1} A^{s_2} \dots A^{s_m})$ o matrice de bază și în raport cu ea, partiționăm matricea $A = \begin{pmatrix} B & R \end{pmatrix}$. Folosind notațiile introduse la pagina 5, sistemul de ecuații $A \cdot x = b$ se poate rescrie astfel:

$$x_B = B^{-1} \cdot b - B^{-1} \cdot R \cdot x_R$$

Dacă introducem notațiile:

$$\bar{x} = B^{-1} \cdot b \quad \text{și} \quad Y^j = B^{-1} \cdot A^j, \quad 1 \leq j \leq n,$$

atunci putem scrie:

$$x_{\mathcal{B}} = \bar{x} - \sum_{j \in \mathcal{R}} Y^j x_j \quad (1.2.1)$$

Observația 1.2 Trebuie să se țină seama de ordinea coloanelor lui A care intră în compunerea matricei de bază B , aceasta fiind descrisă de secvența elementelor mulțimii indicilor de bază $\mathcal{B} = \{s_1, s_2, \dots, s_m\}$. Valoarea unui anumit indice $s_i \in \mathcal{B}$ nu corespunde neapărat cu poziția lui din secvență. Pentru a indica această poziție, vom folosi notația: $loc(s_i)$. Prin urmare, dacă indicele s_i este în poziția i , vom scrie: $i = loc(s_i)$.

Scrisă pe componente, relația (1.2.1) devine:

$$x_{s_i} = \bar{x}_i - \sum_{j \in \mathcal{R}} y_{ij} x_j, \quad s_i \in \mathcal{B}, \quad i = loc(s_i).$$

O soluție de bază corespunzătoare lui B este: $x_{\mathcal{B}} = \bar{x}$ și $x_{\mathcal{R}} = \mathbf{0}$. Pentru ca aceasta să fie o soluție de bază admisibilă a problemei (P), trebuie ca $\bar{x} = B^{-1} \cdot b \geq \mathbf{0}$.

Definiția 1.2 Matricea de bază B se numește **primal admisibilă**, dacă $B^{-1} \cdot b \geq \mathbf{0}$.

Folosind relația (1.2.1), funcția obiectiv $z = c^T \cdot x$ se poate exprima astfel:

$$\begin{aligned} z &= c_{\mathcal{B}}^T \cdot x_{\mathcal{B}} + c_{\mathcal{R}}^T \cdot x_{\mathcal{R}} = c_{\mathcal{B}}^T \cdot \left(\bar{x} - \sum_{j \in \mathcal{R}} Y^j x_j \right) + c_{\mathcal{R}}^T \cdot x_{\mathcal{R}} = \\ &= c_{\mathcal{B}}^T \cdot \bar{x} - \sum_{j \in \mathcal{R}} (c_{\mathcal{B}}^T \cdot Y^j - c_j) x_j \end{aligned}$$

Dacă introducem notațiile $\bar{z} = c_{\mathcal{B}}^T \cdot \bar{x}$ și $z_j = c_{\mathcal{B}}^T \cdot Y^j$, $1 \leq j \leq n$, atunci,

$$z = \bar{z} - \sum_{j \in \mathcal{R}} (z_j - c_j) x_j \quad (1.2.2)$$

Evident, \bar{z} reprezintă valoarea funcției obiectiv corespunzătoare soluției de bază $x_B = \bar{x}$ și $x_R = 0$.

În cele ce urmează, convenim să ne referim la soluția de bază $x_B = B^{-1} \cdot b$, subînțelegând că $x_R = 0$.

Teorema 1.4 (de optimalitate) Fie B o bază primal admisibilă. Dacă

$$(z_j - c_j) \leq 0, \quad \text{pentru orice } j \in \mathcal{R}, \quad (1.2.3)$$

atunci baza B este optimă (adică, soluția de bază $x_B = B^{-1} \cdot b$ este optimă) pentru problema (P).

Demonstrație. Fie $v \in \mathbb{R}^n$ o soluție admisibilă a problemei (P). Deoarece $v \geq 0$, iar funcția obiectiv se poate exprima conform relației (1.2.2), avem:

$$z = c^\top \cdot v = \bar{z} - \sum_{j \in \mathcal{R}} (z_j - c_j) v_j \geq \bar{z}$$

■

Teorema 1.5 (de optim infinit) Fie B o bază primal admisibilă. Dacă există $k \in \mathcal{R}$ astfel încât $z_k - c_k > 0$ și $Y^k = B^{-1} \cdot A^k \leq 0$, atunci problema (P) are optimul infinit.

Demonstrație. Fie $\lambda \in \mathbb{R}$, $\lambda \geq 0$. Definim vectorul $x(\lambda) = \begin{pmatrix} x_B(\lambda) \\ x_R(\lambda) \end{pmatrix}$ în felul următor:

$$\begin{aligned} x_B(\lambda) &= \bar{x} - \lambda Y^k \\ x_R(\lambda) &= \lambda e^{loc(k)} \end{aligned}$$

unde $e^{loc(k)} \in \mathbb{R}^{n-m}$ este un vector unitar, având 1 pe poziția $loc(k)$ a indicelui k din \mathcal{R} .

Deoarece baza B este primal admisibilă, $\lambda \geq 0$ și $Y^k \leq 0$, rezultă evident $x(\lambda) \geq 0$. Pe de altă parte, avem:

$$\begin{aligned} A \cdot x(\lambda) &= B \cdot x_B(\lambda) + R \cdot x_R(\lambda) = \\ &= b - \lambda A^k + \lambda A^k = b. \end{aligned}$$

Prin urmare, pentru orice $\lambda \geq 0$, vectorul $x(\lambda)$ este o soluție admisibilă.

Valoarea corespunzătoare a funcției obiectiv este:

$$\begin{aligned} c^\top \cdot x(\lambda) &= c_B^\top \cdot x_B(\lambda) + c_R^\top \cdot x_R(\lambda) = \\ &= c_B^\top \cdot (\bar{x} - \lambda Y^k) + \lambda c_k = \bar{z} - \lambda(z_k - c_k) \end{aligned}$$

Deoarece $z_k - c_k > 0$, rezultă: $\lim_{\lambda \rightarrow \infty} c^\top \cdot x(\lambda) = -\infty$. ■

Observația 1.3 În condițiile Teoremei de optim infinit, vectorul $v \in \mathbb{R}^n$, definit prin $v_B = -Y^k$, $v_R = e^{\text{loc}(k)}$, este o soluție nenulă a sistemului omogen $\{A \cdot x = 0, x \geq 0\}$. El definește o direcție (rază) de-a lungul căreia soluțiile admisibile $x(\lambda)$ sunt nemărginite. Deoarece el reprezintă o muchie a domeniului de admisibilitate, vectorul v se mai numește **rază extremă**.

Lema 1.6 (Lema substituției) Fie $B = (A^{s_1} A^{s_2} \dots A^{s_m}) \in \mathbb{R}^{m \times m}$ o matrice pătratică nesingulară și vectorul $A^k \in \mathbb{R}^m$, cu indicele $k \notin \{s_1, s_2, \dots, s_m\} \stackrel{\text{not}}{=} B$. Considerăm matricea

$$\tilde{B} = (A^{s_1} \dots A^{s_{r-1}} A^k A^{s_{r+1}} \dots A^{s_m}),$$

obținută din B prin înlocuirea lui A^{s_r} cu A^k . Notăm vectorul $Y^k = B^{-1} A^k = (y_{1k}, y_{2k}, \dots, y_{mk})^\top$. Au loc următoarele afirmații:

- (a) Condiția necesară și suficientă pentru ca matricea \tilde{B} să fie nesingulară este ca elementul $y_{rk} \neq 0$, unde $r = \text{loc}(s_r)$.
- (b) Pentru $y_{rk} \neq 0$, dacă notăm vectorul

$$\eta = \left(\frac{-y_{1k}}{y_{rk}}, \dots, \frac{-y_{r-1,k}}{y_{rk}}, \frac{1}{y_{rk}}, \frac{-y_{r+1,k}}{y_{rk}}, \dots, \frac{-y_{mk}}{y_{rk}} \right)^\top$$

și matricea pătratică $E_r(\eta) = (e^1 \dots e^{r-1} \eta e^{r+1} \dots e^m)$, unde $e^j \in \mathbb{R}^m$ este vectorul unitar cu 1 în poziția j , atunci

$$\tilde{B}^{-1} = E_r(\eta) \cdot B^{-1} \tag{1.2.4}$$

Demonstrație. Deoarece $Y^k = B^{-1} A^k$, rezultă

$$A^k = B \cdot Y^k = \sum_{j=1}^m A^{s_j} y_{jk} \tag{1.2.5}$$

Pentru a demonstra necesitatea, fie \tilde{B} nesingulară și presupunem prin absurd că $y_{rk} = 0$. În acest caz însă, din (1.2.5) rezultă că coloanele lui \tilde{B} sunt liniar dependente, ceea ce contrazice faptul că \tilde{B} este nesingulară. Deci, trebuie să avem $y_{rk} \neq 0$.

Pentru a demonstra suficiența, fie $y_{rk} \neq 0$ și presupunem prin absurd că \tilde{B} este singulară, adică are coloanele liniar dependente. Prin urmare, există coeficienții λ_j , $j = \overline{1, m}$, nu toți nuli $\left(\sum_{j=1}^m |\lambda_j| > 0 \right)$, astfel încât:

$$\sum_{j=1, j \neq r}^m A^{sj} \lambda_j + A^k \lambda_r = \mathbf{0}.$$

Observăm că în această relație trebuie să avem $\lambda_r \neq 0$, deoarece, în caz contrar, obținem o combinație liniară de coloane ale matricii B ca fiind egală cu zero, ceea ce contrazice nesingularitatea lui B .

Înlocuind pe A^k din (1.2.5), obținem:

$$\sum_{j=1, j \neq r}^m A^{sj} (\lambda_j + y_{jk} \lambda_r) + A^{sr} y_{rk} \lambda_r = \mathbf{0}, \quad (1.2.6)$$

adică o combinație liniară de coloane ale matricii B , care este egală cu zero și deci toți coeficienții trebuie să fie nuli. Din ipoteză, $y_{rk} \neq 0$, iar $\lambda_r \neq 0$, din observația făcută mai înainte. Rezultă $y_{rk} \lambda_r \neq 0$ și astfel relația (1.2.6) contrazice nesingularitatea lui B . Prin urmare, \tilde{B} trebuie să fie nesingulară.

Pentru a stabili cea de a doua afirmație a lemei, să observăm că pentru $j \neq r$, coloanele "j" ale lui B coincid cu cele ale lui \tilde{B} . Deci,

$$A^{sj} = \tilde{B} \cdot e^j, \quad \text{pentru } j \neq r.$$

Deoarece $y_{rk} \neq 0$, din (1.2.5) obținem:

$$A^{sr} = \sum_{j=1, j \neq r}^m A^{sj} \left(\frac{-y_{jk}}{y_{rk}} \right) + A^k \frac{1}{y_{rk}} = \tilde{B} \cdot \eta$$

Prin urmare, putem scrie:

$$B = \tilde{B} \cdot E_r(\eta)$$

$\bar{x}_i \geq 0$, pentru orice $i = \overline{1, m}$, și deci $\frac{\bar{x}_r}{y_{rk}} \geq 0$. Dacă $y_{ik} \leq 0$, atunci evident $\bar{x}_i - y_{ik} \frac{\bar{x}_r}{y_{rk}} \geq 0$. Dacă $y_{ik} > 0$, din (1.2.7) avem $\frac{\bar{x}_r}{y_{rk}} \leq \frac{\bar{x}_i}{y_{ik}}$ și deci,

$$\bar{x}_i - \frac{y_{ik}}{y_{rk}} \bar{x}_r = y_{ik} \left(\frac{\bar{x}_i}{y_{ik}} - \frac{\bar{x}_r}{y_{rk}} \right) \geq 0.$$

În concluzie, $\tilde{B}^{-1} \cdot b \geq \mathbf{0}$, adică \tilde{B} este bază primal admisibilă.

În continuare, ținând seama că pentru $k \in \tilde{\mathcal{B}}$ avem $\text{loc}(k) = r$, obținem:

$$\begin{aligned} \bar{z} &= c_{\tilde{\mathcal{B}}}^T \cdot \tilde{B}^{-1} \cdot b = c_{\tilde{\mathcal{B}}}^T \cdot E_r(\eta) \cdot B^{-1} \cdot b = c_{\tilde{\mathcal{B}}}^T \cdot E_r(\eta) \cdot \bar{x} = \\ &= (\dots, c_{s_i}, \dots, c_k, \dots) \cdot \begin{pmatrix} \dots & \dots & \dots & \dots & \dots \\ \dots & 1 & \dots & \dots & \dots \\ \dots & \dots & \frac{-y_{ik}}{y_{rk}} & \dots & \dots \\ \dots & \dots & \dots & \dots & \dots \\ \dots & 0 & \dots & \frac{1}{y_{rk}} & \dots \\ \dots & \dots & \dots & \dots & \dots \end{pmatrix} \cdot \bar{x} = \\ &= \left(\dots, c_{s_i}, \dots, \sum_{i \neq r} \frac{-c_{s_i} y_{ik}}{y_{rk}} + \frac{c_k}{y_{rk}}, \dots \right) \cdot \bar{x} = \\ &= \sum_{i \neq r} c_{s_i} \bar{x}_i - \left(\sum_{i \neq r} c_{s_i} y_{ik} - c_k \right) \frac{\bar{x}_r}{y_{rk}} + c_{s_r} \bar{x}_r - c_{s_r} \bar{x}_r \frac{y_{rk}}{y_{rk}} = \\ &= \sum_{i=1}^m c_{s_i} \bar{x}_i - \left(\sum_{i=1}^m c_{s_i} y_{ik} - c_k \right) \frac{\bar{x}_r}{y_{rk}} = \bar{z} - (z_k - c_k) \frac{\bar{x}_r}{y_{rk}} \leq \bar{z} \end{aligned}$$

deoarece $\sum_{i=1}^m c_{s_i} y_{ik} = c_{\tilde{\mathcal{B}}}^T \cdot Y^k = z_k$, iar $(z_k - c_k) \frac{\bar{x}_r}{y_{rk}} \geq 0$. ■

Observația 1.5 Precizăm faptul că, în urma unei schimbări de bază, avem: $\tilde{\mathcal{B}} = \mathcal{B} \setminus \{s_r\} \cup \{k\}$ și $\text{loc}(k) = r$.

Teoremele prezentate mai sus justifică următoarea metodă de rezolvare a problemelor de programare liniară, metodă cunoscută sub denumirea de "algoritmul simplex primal", sau pe scurt, "algoritmul simplex".

Algoritmul simplex primal.

Pasul 0. Se determină (dacă există) o bază **primal admisibilă** B .

Se calculează B^{-1} .

Pasul 1. Se calculează: $\bar{x} = B^{-1} \cdot b$, $\bar{z} = c_B^\top \cdot \bar{x}$, $Y = B^{-1} \cdot A$,
 $z^\top - c^\top = c_B^\top \cdot Y - c^\top$.

Pasul 2. (testul de optimalitate) Dacă $z^\top - c^\top \leq 0$, atunci \bar{z} este valoarea optimă, iar $x_B = \bar{x}$ și $x_{\mathcal{R}} = 0$ este soluția de bază optimă. STOP.

Pasul 3. (testul de optim infinit) Dacă există $k \in \mathcal{R}$ pentru care $z_k - c_k > 0$ și $Y^k \leq 0$, atunci problema are optim infinit. STOP.

Pasul 4. (schimbarea bazei) Se alege $k \in \mathcal{R}$ cu $z_k - c_k > 0$ și se determină $s_r \in \mathcal{B}$, cu $loc(s_r) = r$, astfel încât:

$$\frac{\bar{x}_r}{y_{rk}} = \min_{1 \leq i \leq m} \left\{ \frac{\bar{x}_i}{y_{ik}} \mid y_{ik} > 0 \right\}.$$

Se formează matricea \tilde{B} , care se obține din B prin înlocuirea coloanei A^{s_r} cu A^k , se calculează \tilde{B}^{-1} cu formula (1.2.4), și cu această inversă a noii matrice de bază se revine la Pasul 1.

1.2.1. Determinarea unei baze primal admisibile

În prezentarea algoritmului simplex, "Pasul 0" lasă deschisă problema determinării unei baze primal admisibile. Găsirea unei astfel de baze se poate face în mai multe moduri. Una dintre metodele cele mai naturale constă în asocierea unei "probleme artificiale", în așa fel încât, folosind algoritmul simplex pentru rezolvarea acesteia, să obținem fie o bază primal admisibilă pentru (P), fie răspunsul că problema (P) nu admite soluție, adică, nu există nici o bază primal admisibilă pentru ea. Această metodă este numită "**metoda celor două faze**", deoarece, în prima fază se rezolvă problema artificială, iar în cazul că s-a obținut o bază primal admisibilă pentru (P), în cea de-a doua fază se rezolvă problema inițială (P).

Să considerăm din nou problema:

$$\inf \{ c^\top \cdot x \mid A \cdot x = b, x \geq 0 \} \quad (\text{P})$$

în care, rangul matricei A nu mai este specificat și presupunem $b \geq 0$. Acest lucru nu restrânge generalitatea, deoarece, dacă există o componentă $b_i < 0$, restricția respectivă se poate înmulți cu -1 .

Acestei probleme îi asociem **problema artificială**:

$$\min \{ \mathbf{e}^\top \cdot x^a \mid A \cdot x + \mathbf{I}_m \cdot x^a = b, x \geq 0, x^a \geq 0 \} \quad (P_a)$$

unde vectorul $\mathbf{e} \in \mathbb{R}^m$ are toate componentele egale cu 1, iar \mathbf{I}_m este matricea unitate de ordinul m . Componentele variabilei "artificiale" $x^a \in \mathbb{R}^m$ le vom nota în continuarea celor lui x , adică, $x^a = (x_{n+1}, x_{n+2}, \dots, x_{n+m})^\top$.

Problema artificială asociată lui (P) are câteva proprietăți importante. În primul rând, matricea restricțiilor problemei (P_a) este $(A : \mathbf{I}_m) \in \mathbb{R}^{m \times (n+m)}$ și astfel,

$$\text{rang} \left(A : \mathbf{I}_m \right) = m < n + m.$$

Pe de altă parte, matricea unitate \mathbf{I}_m este evident o bază primal admisibilă pentru (P_a), deoarece $\mathbf{I}_m^{-1} \cdot b = b \geq 0$. În fine, cerința $x^a \geq 0$ implică $\mathbf{e}^\top \cdot x^a = \sum_{i=1}^m x_{n+i} \geq 0$, adică, problema (P_a) va avea întotdeauna un minim nenegativ.

Prin urmare, pentru rezolvarea problemei (P_a), se poate aplica algoritmul simplex, luând ca bază primal admisibilă inițială matricea \mathbf{I}_m .

Fie B baza optimă care se obține la rezolvarea problemei (P_a), B mulțimea corespunzătoare a indicilor de bază și vom nota cu z_a valoarea optimă (minimă) a problemei (P_a). Avem evident $z_a \geq 0$.

Propoziția 1.8 Dacă $z_a > 0$, atunci problema inițială (P) nu are soluție.

Demonstrație. Presupunem prin absurd că (P) ar avea o soluție admisibilă. Atunci, în baza Teoremei fundamentale a programării liniare, (P) are și o soluție admisibilă de bază. Fie B_* matricea de bază corespunzătoare. Aceasta este constituită doar din coloane ale matricei A și evident $B_*^{-1} \cdot b \geq 0$. Astfel, B_* este o bază primal admisibilă și

pentru (P_a) , iar soluția de bază corespunzătoare va conține printre variabilele secundare toate componentele lui x^a . Prin urmare, $x^a = \mathbf{0}$, ceea ce contrazice faptul că valoarea optimă a lui (P_a) este $z_a > 0$. ■

Propoziția 1.9 *Dacă $\mathcal{B} \cap \{n+1, \dots, n+m\} = \emptyset$, atunci $z_a = 0$ și B este o bază primal admisibilă pentru problema inițială (P) .*

Demonstrație. Deoarece $\mathcal{B} \cap \{n+1, \dots, n+m\} = \emptyset$, în soluția de bază optimă toate componentele lui x^a sunt componente secundare, deci au valoarea egală cu zero și evident $z_a = 0$. Pe de altă parte, toate coloanele matricei de bază B sunt formate din coloane ale lui A , și deoarece în (P_a) avem $B^{-1} \cdot b \geq \mathbf{0}$, matricea B este o matrice de bază primal admisibilă și pentru problema (P) . ■

Propoziția 1.10 *Dacă $z_a = 0$ și există $n+i_0 \in \mathcal{B}$ pentru care $y_{i_0j} = 0, \forall j = \overline{1, n}$, unde $(y_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} = B^{-1} \cdot A$ și $i_0 = \text{loc}(n+i_0)$, atunci, $\text{rang}(A) \leq m-1$ și restricția i_0 este o combinație liniară de celelalte restricții.*

Demonstrație. Deoarece $Y^j = B^{-1} \cdot A^j$, pentru orice $j = \overline{1, n}$, avem:

$$A^j = B \cdot Y^j = \sum_{s_i \in \mathcal{B}} A^{s_i} y_{ij}, \quad \text{unde } i = \text{loc}(s_i).$$

Prin faptul că $n+i_0 \in \mathcal{B}$ și $y_{i_0j} = 0, \forall j = \overline{1, n}$, rezultă că orice coloană A^j a matricei A se poate scrie ca o combinație liniară de cel mult $m-1$ vectori liniari independenți, ce intră în compunerea bazei B :

$$A^j = \sum_{s_i \in \mathcal{B} \setminus \{n+i_0\}} A^{s_i} y_{ij}$$

și prin urmare, $\text{rang}(A) \leq m-1$.

În această situație, liniile matricei A , pe care le vom nota cu A_i , $i = \overline{1, m}$, vor fi liniar dependente: există numerele $\lambda_i \in \mathbb{R}$, nu toate nule, astfel încât:

$$\sum_{i=1}^m A_i \lambda_i = \mathbf{0}.$$

Se observă că trebuie să avem $\lambda_{i_0} \neq 0$. În caz contrar, deoarece matricea de bază B conține vectorul unitar e^{i_0} , ar rezulta că în problema

(P_a) avem $\text{rang} \left(A : I_m \right) < m$, ceea ce este absurd. Prin urmare, putem scrie:

$$A_{i_0} = \sum_{\substack{i=1 \\ i \neq i_0}}^m \frac{-\lambda_i}{\lambda_{i_0}} A_i$$

și deoarece sistemul de ecuații $A \cdot x = b$ este compatibil, trebuie să aibe loc și relația:

$$b_{i_0} = \sum_{\substack{i=1 \\ i \neq i_0}}^m \frac{-\lambda_i}{\lambda_{i_0}} b_i$$

de unde concluzia că restricția i_0 este o combinație liniară de celelalte restricții. ■

Observația 1.6 Dacă valoarea optimă a problemei (P_a) este $z_a = 0$, atunci toate variabilele artificiale care au mai rămas în bază vor avea valoarea zero.

Pe de altă parte, din problema (P) pot fi eliminate toate restricțiile care corespund condițiilor din Propoziția 1.10. Astfel, dimensiunea problemei va fi redusă, iar matricea rezultată va avea rangul egal cu numărul de linii.

Propoziția 1.11 Dacă $z_a = 0$ și există $n + i_0 \in \mathcal{B}$ astfel încât pentru un anumit $k = \overline{1, n}$, avem $y_{i_0 k} \neq 0$, unde $(y_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} = Y = B^{-1} \cdot A$ și $i_0 = \text{loc}(n + i_0)$, atunci, se poate efectua o schimbare de bază prin care vectorul unitar e^{i_0} din B să fie înlocuit de coloana A^k .

Demonstrație. Deoarece $y_{i_0 k} \neq 0$, din Lema substituției deducem că noua matrice \tilde{B} astfel obținută este nesingulară. Pe de altă parte, deoarece $\bar{x}_{i_0} = 0$, din (1.2.8) (pentru $r = i_0$) deducem că $\tilde{B}^{-1} \cdot b = B^{-1} \cdot b$, adică \tilde{B} este o bază primal admisibilă, așa cum a fost și B . ■

Din rezultatele prezentate mai sus rezultă că, prin rezolvarea problemei artificiale (P_a), obținem una din situațiile următoare:

1. Problema (P_a) are optimul $z_a > 0$. În cazul acesta, problema inițială (P) nu are soluție.
2. Problema (P_a) are optimul $z_a = 0$ și $\mathcal{B} \cap \{n + 1, \dots, n + m\} = \emptyset$, adică, toate variabilele artificiale au fost eliminate din bază. În

acest caz, baza optimă B a problemei (P_a) este primal admisibilă pentru problema inițială (P) .

3. Problema (P_a) are optimul $z_a = 0$ și $\mathcal{B} \cap \{n + 1, \dots, n + m\} \neq \emptyset$, adică, în baza optimă sunt încă prezente variabile artificiale. Acestea pot fi eliminate, conform Propozițiilor 1.10 și 1.11, astfel încât, noua bază rezultată să conțină doar coloane ale matricei A și astfel, ea este primal admisibilă pentru problema (P) .

1.2.2. Formule pentru schimbarea bazei și organizarea calculelor

Fiecare iterație a algoritmului simplex este caracterizată de inversa B^{-1} a unei baze primal admisibile. Cu ajutorul acesteia sunt calculate toate celelalte elemente necesare pentru efectuarea pașilor algoritmului. Aceste elemente sunt următoarele:

$$\begin{aligned} \bar{x} &= B^{-1} \cdot b; & u^\top &= c_B^\top \cdot B^{-1}; \\ \bar{z} &= c_B^\top \cdot \bar{x} = c_B^\top \cdot B^{-1} \cdot b = u^\top \cdot b; \\ Y &= B^{-1} \cdot A; \\ z^\top - c^\top &= c_B^\top \cdot Y - c^\top = u^\top \cdot A - c^\top \end{aligned} \tag{1.2.9}$$

Componentele vectorului u se mai numesc și ”*multiplicatori simplex*”, deoarece, cu ajutorul lor se poate calcula atât valoarea funcției obiectiv, corespunzătoare soluției de bază curente, cât și componentele lui $z - c$, care, la rândul lor, se mai numesc și ”*costuri reduce*”. Această denumire din urmă provine din faptul că unii autori folosesc vectorul $c - z$ în elaborarea algoritmului simplex.

Dacă testul de optimalitate, sau de optim infinit, nu este îndeplinit, atunci, conform teoremei de schimbare a bazei, putem găsi o nouă bază primal admisibilă \tilde{B} cu inversa căreia se calculează din nou elementele de mai sus. Trecerea de la B^{-1} la \tilde{B}^{-1} se poate face cu ajutorul Lemei substituției: cunoscând indicele k pentru coloana A^k care intră în bază, indicele $r = \text{loc}(s_r)$ pentru coloana A^{s_r} care iese din bază și vectorul $Y^k = B^{-1} \cdot A^k$, se formează matricea $E_r(\eta)$ și atunci putem folosi relația (1.2.4).

Dacă notăm $B^{-1} = (\beta_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq m}}$ și $\tilde{B}^{-1} = (\tilde{\beta}_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq m}}$, atunci din (1.2.4) obținem:

$$\begin{aligned} \tilde{\beta}_{ij} &= \beta_{ij} - \frac{\beta_{rj} y_{ik}}{y_{rk}} \quad \text{pentru } i = \overline{1, m}, i \neq r, j = \overline{1, m}; \\ \tilde{\beta}_{rj} &= \frac{\beta_{rj}}{y_{rk}} \quad \text{pentru } j = \overline{1, m}. \end{aligned} \quad (1.2.10)$$

De asemenea, folosind relația (1.2.4), putem deduce niște formule care permit calcularea noilor valori ale elementelor din (1.2.9), corespunzătoare lui \tilde{B} , direct din cele vechi, corespunzătoare lui B . Avem:

$$\begin{aligned} \tilde{x} &= \tilde{B}^{-1} \cdot b = E_r(\eta) \cdot B^{-1} \cdot b = E_r(\eta) \cdot \bar{x} = \\ &= \begin{pmatrix} \ddots & & \vdots \\ & 1 & -\frac{y_{ik}}{y_{rk}} \\ & & \vdots \\ 0 & & \frac{1}{y_{rk}} \\ & & \vdots \\ & & \ddots \end{pmatrix} \cdot \begin{pmatrix} \vdots \\ \bar{x}_i \\ \vdots \\ \bar{x}_r \\ \vdots \end{pmatrix} = \begin{pmatrix} \vdots \\ \bar{x}_i - \frac{y_{ik}}{y_{rk}} \bar{x}_r \\ \vdots \\ \bar{x}_r \\ y_{rk} \\ \vdots \end{pmatrix} \end{aligned}$$

adică

$$\begin{aligned} \tilde{x}_i &= \bar{x}_i - \frac{y_{ik}}{y_{rk}} \bar{x}_r \quad \text{pentru } i \neq r; \\ \tilde{x}_r &= \frac{\bar{x}_r}{y_{rk}} \quad \text{unde } r = \text{loc}(k) \text{ pentru } k \in \tilde{\mathcal{B}}. \end{aligned} \quad (1.2.11)$$

Vectorul multiplicatorilor simplex u , se calculează astfel:

$$\tilde{u}^\top = c_B^\top \cdot \tilde{B}^{-1} = (\dots, c_{s_i}, \dots, c_k, \dots) \cdot E_r(\eta) \cdot B^{-1}$$

unde $\text{loc}(s_i) = i$, $1 \leq i \leq m$, $i \neq r$, iar pentru $k \in \tilde{\mathcal{B}}$, avem $\text{loc}(k) = r$.

Componenta "j" a lui \tilde{u} capătă expresia:

$$\begin{aligned}\tilde{u}_j &= \left(\cdots, c_{s_i}, \cdots, \sum_{i \neq r} \frac{-c_{s_i} y_{ik}}{y_{rk}} + \frac{c_k}{y_{rk}}, \cdots \right) \cdot \begin{pmatrix} \vdots \\ \beta_{ij} \\ \vdots \\ \beta_{rj} \\ \vdots \end{pmatrix} = \\ &= \sum_{i \neq r} c_{s_i} \beta_{ij} - \left(\sum_{i \neq r} c_{s_i} y_{ik} - c_k \right) \frac{\beta_{rj}}{y_{rk}} + c_{s_r} \beta_{rj} - c_{s_r} \beta_{rj} \frac{y_{rk}}{y_{rk}}\end{aligned}$$

deci,

$$\boxed{\tilde{u}_j = u_j - (z_k - c_k) \frac{\beta_{rj}}{y_{rk}}, \quad 1 \leq j \leq m.} \quad (1.2.12)$$

Pentru matricea $\tilde{Y} = \tilde{B}^{-1} \cdot A$, coloana \tilde{Y}^j , $1 \leq j \leq n$, este

$$\tilde{Y}^j = \tilde{B}^{-1} \cdot A^j = E_r(\eta) \cdot B^{-1} \cdot A^j = E_r(\eta) \cdot Y^j = \begin{pmatrix} \vdots \\ y_{ij} - \frac{y_{ik}}{y_{rk}} y_{rj} \\ \vdots \\ \frac{y_{rj}}{y_{rk}} \\ \vdots \end{pmatrix}$$

prin urmare,

$$\boxed{\begin{aligned}\tilde{y}_{ij} &= y_{ij} - \frac{y_{ik}}{y_{rk}} y_{rj} \quad \text{pentru } i = \overline{1, m}, i \neq r; \\ \tilde{y}_{rj} &= \frac{y_{rj}}{y_{rk}}\end{aligned}} \quad (1.2.13)$$

Valoarea funcției obiectiv se poate exprima astfel:

$$\tilde{z} = c^T \cdot \tilde{B}^{-1} \cdot b = \tilde{u}^T \cdot b = \sum_{j=1}^m \tilde{u}_j b_j$$

Folosind relația (1.2.12) obținem:

$$\tilde{z} = \sum_{j=1}^m \left(u_j - (z_k - c_k) \frac{\beta_{rj}}{y_{rk}} \right) b_j = \sum_{j=1}^m u_j b_j - \frac{(z_k - c_k)}{y_{rk}} \sum_{j=1}^m \beta_{rj} b_j$$

deci,

$$\boxed{\bar{z} = \bar{z} - \frac{(z_k - c_k)}{y_{rk}} \bar{x}_r} \quad (1.2.14)$$

Pentru orice j , $1 \leq j \leq n$, coeficienții costurilor reduse se calculează în mod asemănător:

$$\begin{aligned} \bar{z}_j - c_j &= c_B^T \cdot \bar{B}^{-1} \cdot A^j - c_j = \bar{u}^T \cdot A^j - c_j = \\ &= \sum_{i=1}^m \bar{u}_i a_{ij} - c_j = \sum_{i=1}^m \left(u_i - (z_k - c_k) \frac{\beta_{ri}}{y_{rk}} \right) a_{ij} - c_j = \\ &= \left(\sum_{i=1}^m u_i a_{ij} - c_j \right) - \frac{(z_k - c_k)}{y_{rk}} \sum_{i=1}^m \beta_{ri} a_{ij} \end{aligned}$$

prin urmare,

$$\boxed{\bar{z}_j - c_j = (z_j - c_j) - \frac{(z_k - c_k) y_{rj}}{y_{rk}}, \quad 1 \leq j \leq n.} \quad (1.2.15)$$

Tabloul simplex standard.

Dacă problema de programare liniară nu este prea mare, ea poate fi rezolvată și manual cu ajutorul algoritmului simplex. Pentru aceasta, în raport cu o bază curentă B , elementele necesare calculelor se pot așeza într-un tablou de forma următoare:

x_B	\bar{x}	Y
	\bar{z}	$z^T - c^T$

Într-o descriere mai detaliată, tabloul de mai sus se prezintă astfel:

	\vdots		\vdots		\vdots
x_{s_i}	\bar{x}_i	\cdots	y_{ij}	\cdots	$y_{ik} \cdots$
	\vdots		\vdots		\vdots
x_{s_r}	\bar{x}_r	\cdots	y_{rj}	\cdots	$y_{rk} \cdots$
	\vdots		\vdots		\vdots
	\bar{z}	\cdots	$z_j - c_j$	\cdots	$z_k - c_k \cdots$

Se constată cu ușurință că, pentru orice $j \in \mathcal{B}$, cu $loc(j) = i$, avem $Y^j = B^{-1} \cdot A^j = e^i$, unde $e^i \in \mathbb{R}^m$ este vectorul unitar cu 1 în poziția i . Astfel, în tabloul simplex, pentru coloanele j corespunzătoare bazei avem: $y_{lj} = 0$, pentru $l \neq i$, și $y_{ij} = 1$. În plus, avem:

$$z_j - c_j = c_B^\top \cdot B^{-1} \cdot A^j - c_j = c_B^\top \cdot e^i - c_j = c_j - c_j = 0, \quad \forall j \in \mathcal{B}.$$

Pentru testul de optimalitate, se analizează costurile reduse $z_j - c_j$ din ultima linie a tabloului. Dacă acestea sunt toate mai mici sau egale cu zero, atunci baza curentă B este optimă. Vectorul \bar{x} este soluția de bază optimă și \bar{z} este valoarea optimă a problemei.

Dacă există un $z_k - c_k > 0$, pentru care $y_{ik} \leq 0, \forall i = \overline{1, m}$, atunci problema are optim infinit.

Dacă există $z_k - c_k > 0$, pentru care avem cel puțin un element $y_{ik} > 0$, atunci alegem indicele r conform relației (1.2.7). Elementul $y_{rk} \neq 0$, se numește **pivot**, iar linia, respectiv coloana corespunzătoare din tabloul simplex, se va numi "*linia pivotului*", respectiv "*coloana pivotului*".

Pivotul y_{rk} joacă un rol important la calcularea elementelor unui tablou simplex nou, care va corespunde bazei primal admisibile \tilde{B} . Vom nota elementele acestui tablou cu $\tilde{t}_{ij}, i = \overline{1, m+1}$ și $j = \overline{0, n}$, unde coloana $j = 0$ corespunde lui \bar{x} și \bar{z} . Elementele tabloului simplex corespunzător lui B le vom nota cu t_{ij} . Analizând formulele de schimbare a bazei obținute mai sus, (1.2.11), (1.2.13), (1.2.14) și (1.2.15), putem enunța următoarele reguli pentru calcularea noilor valori ale tabloului simplex, folosind pe cele vechi:

1. Linia pivotului se împarte la pivot:

$$\tilde{t}_{rj} = \frac{t_{rj}}{y_{rk}}, \quad \forall j = \overline{0, n}.$$

2. Coloana pivotului devine un vector unitar:

$$\tilde{t}_{rk} = 1 \quad \text{și} \quad \tilde{t}_{ik} = 0, \quad \forall i = \overline{1, m+1}, i \neq r.$$

3. Restul elementelor din tablou, se calculează după "*regula dreptunghiului*", adică:

$$\tilde{t}_{ij} = t_{ij} - \frac{t_{rj} t_{ik}}{y_{rk}}, \quad \begin{cases} \forall i = \overline{1, m+1}, i \neq r \\ \forall j = \overline{0, n}, j \neq k \end{cases}$$

Denumirea provine din faptul că, fiecare element t_{ij} formează cu pivotul y_{rk} extremitățile unei diagonale a unui dreptunghi din tabloul simplex, în timp ce elementele t_{rj} și t_{ik} , se află pe cealaltă diagonală.

Tabloul simplex revizuit.

Formulele de schimbare a bazei permit organizarea calculelor și în alt mod. Deoarece se constată cu ușurință că toate elementele necesare în aplicarea algoritmului simplex sunt calculate cu ajutorul matricii B^{-1} , se poate considera următorul tablou:

x_B	\bar{x}	B^{-1}	
	\bar{z}	u^\top	

unde ultima coloană se completează doar înainte de a efectua o schimbare de bază. O iterație a algoritmului simplex constă din următoarele operații:

- Cu ajutorul multiplicatrilor simplex u , se calculează costurile reduse: $z_j - c_j = u^\top \cdot A^j - c_j$, pentru $j \in \mathcal{R}$. Dacă toate aceste valori sunt mai mici sau egale cu zero, atunci baza B este optimă. STOP.
- Dacă testul de optimalitate nu este trecut, se alege un $z_k - c_k > 0$. Se calculează $Y^k = B^{-1} \cdot A^k$. Dacă avem $Y^k \leq 0$, atunci problema are optim infinit. STOP.
- În caz contrar, se completează ultima coloană a tabloului simplex revizuit cu Y^k și $z_k - c_k$. Într-o prezentare mai detaliată, dacă notăm elementele matricii $B^{-1} = (\beta_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq m}}$, acesta va arăta

astfel:

	\vdots		\vdots		\vdots
x_{s_i}	\bar{x}_i	\cdots	β_{ij}	\cdots	y_{ik}
	\vdots		\vdots		\vdots
x_{s_r}	\bar{x}_r	\cdots	β_{rj}	\cdots	y_{rk}
	\vdots		\vdots		\vdots
	\bar{z}	\cdots	u_j	\cdots	$z_k - c_k$

Aplicând relația (1.2.7), se determină pivotul y_{rk} .

- Din formulele de schimbare a bazei (1.2.10), (1.2.11), (1.2.12) și (1.2.14), rezultă că și în acest caz, pentru a calcula noile valori ale tabloului simplex revizuit, corespunzător matricei de bază \bar{B} , se poate proceda similar ca la tabloul simplex standard, cu observația că ultima coloană va rămâne liberă pentru iterația următoare:

- Linia pivotului se împarte la y_{rk} .
- Elementele care nu se află pe linia pivotului se calculează folosind "regula dreptunghiului".

Observația 1.7 Acest procedeu de efectuare a calculelor mai este cunoscut și sub denumirea de "**algoritmul simplex revizuit**", fără a fi de fapt o metodă distinctă de algoritmul simplex primal.

1.3. Adaptarea algoritmului simplex la probleme cu variabile mărginite

În modelarea matematică a problemelor care provin din activități economice, apare în mod natural necesitatea de a impune restricții de mărginire asupra unor variabile. Spre exemplu, dacă variabila x reprezintă numărul de pâini care urmează să fie produs într-o brutărie, atunci există evident un număr minim l_{\min} de pâini care trebuie să fie produs, deoarece altfel procesul de fabricație nu ar mai fi eficient. Pe de altă parte, din motive tehnologice, cum ar fi spre exemplu capacitatea cuptoarelor, există și o limitare maximă l_{\max} de pâini care se pot

produce. Prin urmare, restricții de forma

$$l_{\min} \leq x \leq l_{\max} \quad (1.3.1)$$

pot apare frecvent iar numărul acestora este adesea chiar egal cu cel al variabilelor din problemă.

Condițiile de acest fel pot fi incluse foarte ușor în sistemul de restricții a problemei, și anume, (1.3.1) se poate rescrie într-un mod echivalent astfel:

$$\begin{aligned} x + y_1 &= l_{\max} \\ x - y_2 &= l_{\min} \\ y_1 &\geq 0, \quad y_2 \geq 0. \end{aligned}$$

Transformarea condițiilor de mărginire a variabilelor prin utilizarea acestor operații elementare conduce însă inevitabil la creșterea dimensiunilor sistemului de restricții, atât în ceea ce privește numărul de ecuații, cât și cel al numărului de variabile.

Forma particulară a condițiilor (1.3.1) permite însă evitarea introducerii lor efective în sistemul de restricții a problemei, dar acest lucru impune ca în algoritmul simplex să se facă o analiză specială cu privire la testul de optimalitate și la operațiile de schimbare a bazei.

Să considerăm următoarea problemă, în care toate variabilele sunt inferior și superior mărginite:

$$\inf_{y \in \mathbb{R}^n} \{c^T \cdot y \mid A \cdot y = b_0, \quad l_{\min} \leq y \leq l_{\max}\} \quad (1.3.2)$$

unde $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$, $c \in \mathbb{R}^n$ și $l_{\min} \in \mathbb{R}^n$, $l_{\max} \in \mathbb{R}^n$. Dacă facem schimbarea de variabilă:

$$x = y - l_{\min}$$

problema (1.3.2) se poate rescrie într-o formă echivalentă astfel:

$$c^T \cdot l_{\min} + \inf_{x \in \mathbb{R}^n} \{c^T \cdot x \mid A \cdot x = b, \quad \mathbf{0} \leq x \leq \beta\}$$

unde $b = b_0 - A \cdot l_{\min}$ și $\beta = l_{\max} - l_{\min}$. Prin urmare, fără a restrânge generalitatea, este suficient să considerăm doar probleme de forma:

$$\inf_{x \in \mathbb{R}^n} \{c^T \cdot x \mid A \cdot x = b, \quad \mathbf{0} \leq x \leq \beta\} \quad (1.3.3)$$

unde $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$, $c \in \mathbb{R}^n$, $\beta \in \mathbb{R}^n$ și $\text{rang}(A) = m \leq n$. Mulțimea soluțiilor admisibile pentru problema (1.3.3) o vom nota astfel:

$$\mathcal{P} = \{x \in \mathbb{R}^n \mid A \cdot x = b, \mathbf{0} \leq x \leq \beta\}.$$

Să considerăm din nou o partiție a coloanelor matricei A de forma $A = \begin{pmatrix} B & R \end{pmatrix}$, unde $B \in \mathbb{R}^{m \times m}$ este o matrice de bază formată din coloane ale matricei A , iar $R \in \mathbb{R}^{m \times (n-m)}$ este constituită din restul coloanelor matricei A . În raport cu această partiționare, folosind notațiile introduse la pagina 5, componentele variabilei x și cele ale vectorului c se grupează astfel: $x = \begin{pmatrix} x_B \\ x_{\mathcal{R}} \end{pmatrix}$, $c = \begin{pmatrix} c_B \\ c_{\mathcal{R}} \end{pmatrix}$.

Reluând calculele de la pagina 17, valoarea funcției obiectiv se exprimă astfel:

$$c^\top \cdot x = \bar{z} - \sum_{j \in \mathcal{R}} (z_j - c_j) x_j$$

unde $\bar{z} = c^\top \cdot B^{-1} \cdot b$ iar $z_j = c^\top \cdot B^{-1} \cdot A^j$.

Definiția 1.3 Pentru problema (1.3.3), un vector $x \in \mathbb{R}^n$ este o **soluție de bază extinsă** în raport cu B , dacă $x_B = B^{-1} \cdot b \geq \mathbf{0}$, și oricare ar fi $j \in \mathcal{R}$ avem $x_j = 0$ sau $x_j = \beta_j$.

Observația 1.8 Pot exista mai multe soluții de bază extinse care să fie asociate la aceeași matrice de bază B .

Dacă $x \in \mathbb{R}^n$ este o soluție de bază extinsă în raport cu B , vom nota:

$$\begin{aligned} \mathcal{R}^+ &= \{j \in \mathcal{R} \mid x_j = 0\} \\ \mathcal{R}^- &= \{j \in \mathcal{R} \mid x_j = \beta_j\} \end{aligned}$$

Teorema 1.12 (de optimalitate) Fie $x \in \mathbb{R}^n$ o soluție de bază extinsă în raport cu B . Dacă pentru orice $j \in \mathcal{R}^+$ avem $z_j - c_j \leq 0$ și pentru orice $j \in \mathcal{R}^-$ avem $z_j - c_j \geq 0$, atunci x este o soluție optimă a problemei (1.3.3).

Demonstrație. Fie $y \in \mathcal{P}$ o soluție admisibilă pentru (1.3.3). Avem:

$$\begin{aligned} c^\top y &= c^\top B^{-1}b - \sum_{j \in \mathcal{R}^+} (z_j - c_j) y_j - \sum_{j \in \mathcal{R}^-} (z_j - c_j) y_j \geq \\ &\geq c^\top B^{-1}b - \sum_{j \in \mathcal{R}^-} (z_j - c_j) \beta_j = c^\top x. \end{aligned}$$

■

În continuare vom analiza modul în care se poate schimba o soluție de bază extinsă care nu îndeplinește condiția de optimalitate. În raport cu baza B , soluția generală a sistemului $A \cdot x = b$ se scrie astfel:

$$x_B = \bar{x} - B^{-1} \cdot R \cdot x_{\mathcal{R}}$$

unde $\bar{x} = B^{-1} \cdot b$, sau, pe componente:

$$x_{s_i} = \bar{x}_i - \sum_{j \in \mathcal{R}} y_{ij} x_j \quad \text{pentru } i = \text{loc}(s_i) \text{ și } s_i \in \mathcal{B},$$

unde matricea $Y = (y_{ij})_{\substack{1 \leq i \leq m \\ 1 \leq j \leq n}} = B^{-1} \cdot A$.

Fie $x \in \mathcal{P}$ o soluție de bază extinsă în raport cu B . Prin urmare, componentele secundare x_j , $j \in \mathcal{R}$, au una din cele două valori extreme impuse variabilei, adică $x_j = 0$ sau $x_j = \beta_j$. Dacă testul de optimalitate nu este satisfăcut, atunci prin modificarea valorii unei anumite variabile secundare x_j putem obține o nouă soluție pentru care valoarea funcției obiectiv să fie mai mică sau cel mult egală cu vechea valoare. Evident, modificarea valorii lui x_j se poate face în sens crescător, de la 0 până la cel mult β_j , dacă $j \in \mathcal{R}^+$, sau în sens descrescător, de la β_j până la cel mai puțin 0, dacă $j \in \mathcal{R}^-$. Pentru a putea considera mereu $x_j = 0$, indiferent de sensul de variație pe care îl poate avea variabila secundară, vom rescrie expresia soluției de bază extinse $x \in \mathcal{P}$, în raport cu B , în felul următor:

$$x_{s_i} = \bar{x}_i - \sum_{j \in \mathcal{R}^+} y_{ij} x_j - \sum_{j \in \mathcal{R}^-} y_{ij} (\beta_j - x_j), \quad s_i \in \mathcal{B}, \quad i = \text{loc}(s_i) \quad (1.3.4)$$

adică,

$$x_{s_i} = \bar{x}_i - \sum_{j \in \mathcal{R}^+} y_{ij} x_j + \sum_{j \in \mathcal{R}^-} y_{ij} x_j, \quad s_i \in \mathcal{B}, \quad i = \text{loc}(s_i) \quad (1.3.5)$$

unde am notat:

$$\tilde{x}_i = \bar{x}_i - \sum_{j \in \mathcal{R}^-} y_{ij} \beta_j.$$

De asemenea, expresia funcției obiectiv devine:

$$\begin{aligned} c^\top \cdot x &= \bar{z} - \sum_{j \in \mathcal{R}^+} (z_j - c_j) x_j - \sum_{j \in \mathcal{R}^-} (z_j - c_j) (\beta_j - x_j) = \\ &= \bar{z} - \sum_{j \in \mathcal{R}^+} (z_j - c_j) x_j + \sum_{j \in \mathcal{R}^-} (z_j - c_j) x_j \end{aligned} \quad (1.3.6)$$

unde am notat:

$$\tilde{z} = \bar{z} - \sum_{j \in \mathcal{R}^-} (z_j - c_j) \beta_j.$$

Vom analiza următoarele două cazuri posibile de încălcare a condițiilor de optimalitate.

Cazul 1: există $k \in \mathcal{R}^+$ pentru care $z_k - c_k > 0$.

În această situație avem $c^\top \cdot x = \tilde{z} - (z_k - c_k) x_k$, iar valoarea funcției obiectiv se va micșora cu atât mai mult, cu cât x_k primește o valoare mai mare. Dar evident, x_k nu poate depăși limita sa superioară, adică trebuie să ținem seama de condiția:

$$x_k \leq \beta_k \quad (1.3.7)$$

Pe de altă parte, din (1.3.5) avem:

$$x_{s_i} = \tilde{x}_i - y_{ik} x_k, \quad s_i \in \mathcal{B}, \quad i = \overline{loc(s_i)} \quad (1.3.8)$$

și deci, valoarea maximă pe care o poate lua x_k trebuie să satisfacă și condițiile de mărginire a variabilelor din bază, adică:

$$0 \leq \tilde{x}_i - y_{ik} x_k \leq \beta_{s_i}, \quad \forall i = \overline{1, m}.$$

De aici rezultă:

$$\begin{aligned} x_k &\leq \frac{\tilde{x}_i}{y_{ik}} \quad \text{dacă } y_{ik} > 0, \\ x_k &\leq \frac{\beta_{s_i} - \tilde{x}_i}{-y_{ik}} \quad \text{dacă } y_{ik} < 0, \end{aligned}$$

prin urmare,

$$x_k \leq \rho'_k \stackrel{\text{not}}{=} \begin{cases} \min_{1 \leq i \leq m} \left\{ \frac{\tilde{x}_i}{y_{ik}} \mid y_{ik} > 0 \right\} \\ +\infty \text{ dacă nu există } y_{ik} > 0 \end{cases} \quad (1.3.9)$$

$$x_k \leq \rho''_k \stackrel{\text{not}}{=} \begin{cases} \min_{1 \leq i \leq m} \left\{ \frac{\tilde{x}_i - \beta_{s_i}}{y_{ik}} \mid y_{ik} < 0 \right\} \\ +\infty \text{ dacă nu există } y_{ik} < 0 \end{cases} \quad (1.3.10)$$

Rezumând relațiile (1.3.7), (1.3.9) și (1.3.10), valoarea maximă pe care o poate lua x_k este:

$$x_k = \min \{ \beta_k, \rho'_k, \rho''_k \} \quad (1.3.11)$$

Schimbarea bazei se va efectua diferențiat, în funcție de minimumul obținut în (1.3.11).

- Dacă $x_k = \beta_k$, atunci baza B va rămâne aceeași, iar $\mathcal{R}_{nou}^- = \mathcal{R}^- \cup \{k\}$ și $\mathcal{R}_{nou}^+ = \mathcal{R}^+ \setminus \{k\}$. Valorile soluției și a funcției obiectiv se vor modifica astfel:

$$\begin{aligned} \tilde{x}_{nou} &= \tilde{x} - Y^k \beta_k, \\ \tilde{z}_{nou} &= \tilde{z} - (z_k - c_k) \beta_k \end{aligned}$$

- Dacă $x_k = \rho'_k = \min_{1 \leq i \leq m} \left\{ \frac{\tilde{x}_i}{y_{ik}} \mid y_{ik} > 0 \right\} = \frac{\tilde{x}_r}{y_{rk}}$, atunci din (1.3.8) rezultă că variabila x_{s_r} devine zero și va părăsi baza în favoarea lui x_k . Prin urmare, $\mathcal{B}_{nou} = \mathcal{B} \setminus \{s_r\} \cup \{k\}$ și $\mathcal{R}_{nou}^+ = \mathcal{R}^+ \setminus \{k\} \cup \{s_r\}$ și toate valorile se recalculază cu formulele obișnuite de schimbare a bazei din algoritmul simplex, având pivotul y_{rk} .
- Dacă $x_k = \rho''_k = \min_{1 \leq i \leq m} \left\{ \frac{\tilde{x}_i - \beta_{s_i}}{y_{ik}} \mid y_{ik} < 0 \right\} = \frac{\tilde{x}_r - \beta_{s_r}}{y_{rk}}$, atunci din (1.3.8) rezultă că variabila x_{s_r} își atinge marginea superioară β_{s_r} și va părăsi baza în favoarea lui x_k . Prin urmare, $\mathcal{B}_{nou} = \mathcal{B} \setminus \{s_r\} \cup \{k\}$ iar $\mathcal{R}_{nou}^- = \mathcal{R}^- \cup \{s_r\}$ și $\mathcal{R}_{nou}^+ = \mathcal{R}^+ \setminus \{k\}$. Recalcularea valorilor soluției și a funcției obiectiv se face în baza Lemei substituției. La aplicarea formulelor de schimbare a bazei va trebui însă ca mai întâi să înlocuim valoarea \tilde{x}_r din tabloul simplex cu $\tilde{x}_r - \beta_{s_r}$ și apoi să efectuăm calculele.

Cazul 2: există $k \in \mathcal{R}^-$ pentru care $z_k - c_k < 0$.

Deoarece în acest caz avem $c^\top \cdot x = \bar{z} + (z_k - c_k) x_k$, valoarea funcției obiectiv va descrește dacă x_k devine mai mare ca zero. Merită să subliniem faptul că, de astă dată, variația în sens crescător a lui x_k reprezintă de fapt descreșterea valorii variabilei k de la marginea ei superioară β_k spre zero, din cauza notației $(\beta_j - x_j)$ introdusă în (1.3.4).

Evident, trebuie să avem $\beta_k - x_k \geq 0$, de unde rezultă din nou condiția (1.3.7).

În cazul de față, din (1.3.5) deducem:

$$x_{s_i} = \bar{x}_i + y_{ik} x_k, \quad s_i \in \mathcal{B}, \quad i = \overline{loc(s_i)} \quad (1.3.12)$$

și ținând seama de condițiile de mărginire a variabilelor din bază, obținem:

$$0 \leq \bar{x}_i + y_{ik} x_k \leq \beta_{s_i}, \quad \forall i = \overline{1, m},$$

de unde rezultă:

$$x_k \leq \gamma'_k \stackrel{\text{not}}{=} \begin{cases} \min_{1 \leq i \leq m} \left\{ \frac{-\bar{x}_i}{y_{ik}} \mid y_{ik} < 0 \right\} \\ +\infty \text{ dacă nu există } y_{ik} < 0 \end{cases} \quad (1.3.13)$$

$$x_k \leq \gamma''_k \stackrel{\text{not}}{=} \begin{cases} \min_{1 \leq i \leq m} \left\{ \frac{\beta_{s_i} - \bar{x}_i}{y_{ik}} \mid y_{ik} > 0 \right\} \\ +\infty \text{ dacă nu există } y_{ik} > 0 \end{cases} \quad (1.3.14)$$

Rezumând relațiile (1.3.7), (1.3.13) și (1.3.14), valoarea maximă pe care o poate lua x_k este:

$$x_k = \min \{ \beta_k, \gamma'_k, \gamma''_k \} \quad (1.3.15)$$

Schimbarea bazei se va efectua diferențiat și de astă dată, în funcție de minimul obținut în (1.3.15).

- Dacă $x_k = \beta_k$, atunci baza B va rămâne aceeași, iar $\mathcal{R}_{nou}^- = \mathcal{R}^- \setminus \{k\}$ și $\mathcal{R}_{nou}^+ = \mathcal{R}^+ \cup \{k\}$. Valorile soluției și a funcției obiectiv se vor modifica astfel:

$$\begin{aligned} \bar{x}_{nou} &= \bar{x} + Y^k \beta_k, \\ \bar{z}_{nou} &= \bar{z} + (z_k - c_k) \beta_k \end{aligned}$$

- Dacă $x_k = \gamma'_k = \min_{1 \leq i \leq m} \left\{ \frac{-\tilde{x}_i}{y_{ik}} \mid y_{ik} < 0 \right\} = \frac{-\tilde{x}_r}{y_{rk}}$, atunci din (1.3.12) rezultă că variabila x_{s_r} devine zero și va părăsi baza în favoarea lui x_k . Prin urmare, $\mathcal{B}_{nou} = \mathcal{B} \setminus \{s_r\} \cup \{k\}$ iar $\mathcal{R}_{nou}^- = \mathcal{R}^- \setminus \{k\}$ și $\mathcal{R}_{nou}^+ = \mathcal{R}^+ \cup \{s_r\}$. Recalcularea valorilor soluției și a funcției obiectiv se face în baza Lemei substituției. La aplicarea formulelor de schimbare a bazei, va trebui ca în tabloul simplex să înlocuim pe \tilde{x}_r cu $(-\tilde{x}_r)$ înainte de a efectua calculele în raport cu pivotul y_{rk} .
- Dacă $x_k = \gamma''_k = \min_{1 \leq i \leq m} \left\{ \frac{\beta_{s_i} - \tilde{x}_i}{y_{ik}} \mid y_{ik} > 0 \right\} = \frac{\beta_{s_r} - \tilde{x}_r}{y_{rk}}$, atunci din (1.3.12) rezultă că variabila x_{s_r} își atinge marginea superioară β_{s_r} și va părăsi baza în favoarea lui x_k . Prin urmare, $\mathcal{B}_{nou} = \mathcal{B} \setminus \{s_r\} \cup \{k\}$ și $\mathcal{R}_{nou}^- = \mathcal{R}^- \cup \{s_r\} \setminus \{k\}$. Recalcularea valorilor soluției și a funcției obiectiv se face în baza Lemei substituției. Aplicarea formulelor de schimbare a bazei în tabloul simplex va fi precedată însă de înlocuirea valorii \tilde{x}_r cu $\beta_{s_r} - \tilde{x}_r$.

Se observă cu ușurință că cele două cazuri de schimbare a bazei analizate mai sus prezintă similitudini foarte mari și prin urmare, se pot trata într-un mod unitar. Pentru aceasta, vom asocia fiecărei variabile x_i un coeficient σ_i definit astfel:

$$\sigma_i = \begin{cases} 0 & \text{dacă } i \in \mathcal{B} \\ 1 & \text{dacă } i \in \mathcal{R}^+ \\ -1 & \text{dacă } i \in \mathcal{R}^- \end{cases}$$

Teorema de optimalitate se poate reformula astfel:

Teorema 1.13 (de optimalitate) *Condiția suficientă ca soluția de bază extinsă $x \in \mathbb{R}^n$, în raport cu B , să fie optimă pentru problema (1.3.3) este ca, pentru orice $j \in \mathcal{R}$ să avem $\sigma_j(z_j - c_j) \leq 0$.*

De asemenea, condițiile (1.3.9) și (1.3.13), respectiv (1.3.10) și (1.3.14) se pot scrie unificat astfel:

$$x_k \leq \rho'_k \stackrel{\text{not}}{=} \begin{cases} \min_{1 \leq i \leq m} \left\{ \frac{\tilde{x}_i}{\sigma_k y_{ik}} \mid \sigma_k y_{ik} > 0 \right\} \\ +\infty \text{ dacă nu există } \sigma_k y_{ik} > 0 \end{cases}$$

$$x_k \leq \rho_k'' \stackrel{\text{not}}{=} \begin{cases} \min_{1 \leq i \leq m} \left\{ \frac{\tilde{x}_i - \beta_{s_i}}{\sigma_k y_{ik}} \mid \sigma_k y_{ik} < 0 \right\} \\ +\infty \text{ dacă nu există } \sigma_k y_{ik} < 0 \end{cases}$$

și atunci, valoarea maximă pe care o poate lua x_k este dată de (1.3.11) pentru ambele cazuri. În mod asemănător se pot prezenta și calculele pentru schimbarea bazei, dar lăsăm acest lucru în seama cititorului.

Exemplul 1.1 *Să considerăm următoarea problemă:*

$$\min \{3x_1 + x_2 + x_3 - 4x_4 + 12x_5\}$$

în raport cu restricțiile

$$\begin{cases} x_1 + x_3 - x_4 + 2x_5 = 5 \\ x_2 - x_3 + x_4 + x_5 = 9 \end{cases}$$

și condițiile de mărginire

$$0 \leq x_1 \leq 8, \quad 0 \leq x_2 \leq 9, \quad 0 \leq x_3 \leq 2, \quad 0 \leq x_4 \leq 6, \quad 0 \leq x_5 \leq 3.$$

Se poate observa cu ușurință că o soluție de bază extinsă corespunzătoare lui $B = (A^1 A^2) = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$ este: $x_1 = 5$, $x_2 = 9$ și $x_3 = x_4 = x_5 = 0$. Tabloul simplex asociat acestei baze este:

x_1	5	1	0	1	-1	2
x_2	9	0	1	-1	1	1
	24	0	0	1	2	-5
σ		0	0	1	1	1

Testul de optimalitate nu este satisfăcut: avem, spre exemplu, $\sigma_4 (z_4 - c_4) = 2 > 0$. Prin urmare, x_4 va primi valoarea:

$$x_4 = \min \{\beta_4, \rho_4', \rho_4''\} = \min \left\{ 6, \frac{9}{1}, \frac{5-8}{-1} \right\} = 3 = \rho_4''$$

În această situație, după ce \tilde{x}_1 se va înlocui cu $\tilde{x}_1 - \beta_1 = -3$, transformarea tabloului simplex se va face cu pivotul $y_{1,4} = -1$. Astfel, tabloul

$x_1 - \beta_1$	-3	1	0	1	-1	2
x_2	9	0	1	-1	1	1
	24	0	0	1	2	-5

devine

x_4	3	-1	0	-1	1	-2
x_2	6	1	1	0	0	3
	18	2	0	3	0	-1
σ		-1	0	1	0	1

Deoarece x_1 este acum o variabilă secundară, având valoarea egală cu marginea ei superioară, avem $x_1 = 8$, iar coeficientul $\sigma_1 = -1$.

Baza curentă este $B = (A^4 A^2)$ și în raport cu ea, soluția de bază extinsă este: $x = (8, 6, 0, 3, 0)$.

Această soluție nu este optimă deoarece avem: $\sigma_3 (z_3 - c_3) = 3 > 0$. Prin urmare, variabila secundară x_3 va primi valoarea

$$x_3 = \min \{ \beta_3, \rho'_3, \rho''_3 \} = \min \left\{ 2, +\infty, \frac{3-6}{-1} \right\} = 2 = \beta_3$$

În acest caz, baza rămâne neschimbată, iar valorile soluției și a funcției obiectiv se modifică astfel:

$$x_B = \begin{pmatrix} x_4 \\ x_2 \end{pmatrix} = \begin{pmatrix} 3 \\ 6 \end{pmatrix} - \sigma_3 Y^3 \beta_3 = \begin{pmatrix} 3 \\ 6 \end{pmatrix} - \begin{pmatrix} -1 \\ 0 \end{pmatrix} 2 = \begin{pmatrix} 5 \\ 6 \end{pmatrix}$$

$$\tilde{z} = 18 - \sigma_3 (z_3 - c_3) \beta_3 = 18 - 3 \cdot 2 = 12.$$

Deoarece x_3 și-a atins marginea superioară, $\sigma_3 = -1$, iar tabloul simplex devine:

x_4	5	-1	0	1	1	-2
x_2	6	1	1	0	0	3
	12	2	0	3	0	-1
σ		-1	0	-1	0	1

De astă dată testul de optimalitate este satisfăcut ($\sigma_j (z_j - c_j) \leq 0$, $\forall j \in \mathcal{R}$) iar soluția de bază extinsă $x = (8, 6, 2, 5, 0)$ este optimă.

1.4. Dualitate în programarea liniară

De foarte multe ori, abordarea unei probleme reale poate fi făcută în mai multe moduri, fiecare dintre acestea având drept scop rezolvarea ei cât mai eficient cu putință. La o analiză mai atentă se constată că, deși sunt structural diferite, aceste abordări conțin legături profunde între ele. Dacă îndeplinesc anumite condiții, aceste probleme se numesc

duale una alteia. În optimizarea liniară, problemele duale se bucură de proprietăți foarte bune în ceea ce privește caracterizarea soluțiilor și a valorii optime.

Pentru exemplificare, vom enunța două probleme care sunt legate de același gen de activitate, cunoscute sub denumirea de probleme de transport.

Descrierea activității. Există două depozite, D_1 și D_2 , în care sunt depozitate 13, respectiv 17 tone de marfă ce trebuie transportată la trei beneficiari: B_1 , B_2 și B_3 . Fiecare beneficiar solicită să primească cel puțin 12, 8 și respectiv 10 tone de marfă. Costul unitar de transport de la fiecare depozit la fiecare beneficiar este dat în tabelul următor:

	B_1	B_2	B_3
D_1	5	2	3
D_2	3	4	2

Problema 1. Să se distribuie marfa din depozite la beneficiari, în așa fel încât, costul total de transport să fie minim.

Dacă notăm cu x_{ij} , $i = 1, 2$, $j = 1, 2, 3$, cantitatea ce se transportă de la depozitul D_i la beneficiarul B_j , problema se poate modela ca problemă de programare liniară astfel:

$$\begin{aligned} \min \{ & 5x_{11} + 2x_{12} + 3x_{13} + 3x_{21} + 4x_{22} + 2x_{23} \} \\ & -x_{11} - x_{12} - x_{13} \geq -13 \\ & -x_{21} - x_{22} - x_{23} \geq -17 \\ & x_{11} + x_{21} \geq 12 \\ & x_{12} + x_{22} \geq 8 \\ & x_{13} + x_{23} \geq 10 \\ & x_{ij} \geq 0, \quad i = 1, 2, \quad j = 1, 2, 3. \end{aligned}$$

Evident, primele două restricții (care au fost înmulțite cu -1) exprimă faptul că marfa ce pleacă din depozite nu poate depăși cantitatea existentă, iar următoarele trei, ca cerința beneficiarilor să fie satisfăcută.

Problema 2. Un întreprinzător cumpără marfa din depozitul D_i cu prețul unitar u_i , $i = 1, 2$, și apoi, o revinde beneficiarului B_j la prețul unitar v_j , $j = 1, 2, 3$. Condiția prin care este lăsat să facă această afacere este ca diferența dintre prețul de vânzare și cel de cumpărare

să nu depășească, în nici unul din cazuri, costul unitar de transport de la depozitul D_i la beneficiarul B_j . Evident, întreprinzătorul va fi interesat să stabilească prețurile u_i și v_j în așa fel încât să obțină un profit maxim. În cazul acesta, problema de programare liniară se poate formula astfel:

$$\begin{aligned} \max \{ & -13u_1 - 17u_2 + 12v_1 + 8v_2 + 10v_3 \} \\ & v_1 - u_1 \leq 5 \\ & v_2 - u_1 \leq 2 \\ & v_3 - u_1 \leq 3 \\ & v_1 - u_2 \leq 3 \\ & v_2 - u_2 \leq 4 \\ & v_3 - u_2 \leq 2 \\ & u_i \geq 0, \quad i = 1, 2, \quad v_j \geq 0, \quad j = 1, 2, 3. \end{aligned}$$

Problemele enunțate mai sus modelează de fapt aceeași activitate, dar abordează modul de rezolvare din două puncte de vedere diferite. Dacă pentru cazul prezentat aici, se aplică rezultatele pe care le vom studia în continuare, se constată că aceste probleme sunt duale una alteia și că soluțiile lor se află într-o anumită interdependență.

1.4.1. Reguli de asociere a problemelor duale

Să considerăm următoarea pereche de probleme de programare liniară în forma generală:

$$\left. \begin{array}{l} \text{în raport cu} \\ \inf \{ c_1^\top \cdot x_1 + c_2^\top \cdot x_2 + c_3^\top \cdot x_3 \} \\ A_{11} \cdot x_1 + A_{12} \cdot x_2 + A_{13} \cdot x_3 \geq b_1 \\ A_{21} \cdot x_1 + A_{22} \cdot x_2 + A_{23} \cdot x_3 = b_2 \\ A_{31} \cdot x_1 + A_{32} \cdot x_2 + A_{33} \cdot x_3 \leq b_3 \\ x_1 \geq \mathbf{0} \qquad x_3 \leq \mathbf{0} \end{array} \right\} \quad (P_g)$$

unde datele problemei sunt matricele $A_{ij} \in \mathbb{R}^{m_i \times n_j}$ și vectorii $b_i \in \mathbb{R}^{m_i}$,

$c_j \in \mathbb{R}^{n_j}$, $1 \leq i \leq 3$, $1 \leq j \leq 3$, și problema:

$$\left. \begin{array}{l} \text{în raport cu} \\ \sup \{ b_1^\top \cdot u_1 + b_2^\top \cdot u_2 + b_3^\top \cdot u_3 \} \\ A_{11}^\top \cdot u_1 + A_{21}^\top \cdot u_2 + A_{31}^\top \cdot u_3 \leq c_1 \\ A_{12}^\top \cdot u_1 + A_{22}^\top \cdot u_2 + A_{32}^\top \cdot u_3 = c_2 \\ A_{13}^\top \cdot u_1 + A_{23}^\top \cdot u_2 + A_{33}^\top \cdot u_3 \geq c_3 \\ u_1 \geq 0 \qquad u_3 \leq 0 \end{array} \right\} (D_g)$$

Definiția 1.4 *Perechea de probleme (P_g) și (D_g) se numesc probleme duale una alteia.*

Din cauza simetriei în care apar problemele (P_g) și (D_g), la prima vedere am fi tentați să credem că este vorba de două probleme obișnuite de programare liniară, construite cu aceleași date, dar puse în altă ordine. Felul în care sunt asociate aceste probleme, confirmă în parte această observație, dar legătura dintre ele este cu mult mai profundă. Vom descrie în continuare modul în care sunt asociate problemele duale.

Reguli de asociere.

- Unei probleme de minimizare îi corespunde o problemă de maximizare, și reciproc.
- Coeficienții din funcția obiectiv a unei probleme devin coeficienții termenului liber în cealaltă problemă, și reciproc.
- Matricea restricțiilor dintr-o problemă este matricea transpusă din cealaltă problemă, și reciproc.
- Fiecărei restricții dintr-o problemă îi corespunde o variabilă în cealaltă problemă, și reciproc. Relația de asociere este următoarea:
 - unei restricții concordante îi corespunde o variabilă nenegativă (≥ 0), și reciproc;
 - unei restricții de tip egalitate îi corespunde o variabilă oarecare (fără condiții de semn), și reciproc;
 - unei restricții neconcordante îi corespunde o variabilă nepozitivă (≤ 0), și reciproc.

De regulă, problema inițială de la care se pornește, se consideră a fi **problema primală**, iar cea care i se asociază, este **problema duală**. Se constată cu ușurință că aceste reguli de asociere au proprietatea că duala problemei duale este problema primală.

Dacă problema primală este într-una din formele particulare definite la pagina 11, atunci problema duală va fi următoarea:

$$\left\{ \begin{array}{l} \text{primala în formă standard: } \inf \{c^T \cdot x \mid A \cdot x = b, x \geq 0\} \\ \text{problema duală: } \sup \{b^T \cdot u \mid A^T \cdot u \leq c\} \end{array} \right.$$

$$\left\{ \begin{array}{l} \text{primala în formă canonică: } \inf \{c^T \cdot x \mid A \cdot x \geq b, x \geq 0\} \\ \text{problema duală: } \sup \{b^T \cdot u \mid A^T \cdot u \leq c, u \geq 0\} \end{array} \right.$$

$$\left\{ \begin{array}{l} \text{primala în formă mixtă: } \left\{ \begin{array}{l} \inf \{c^T \cdot x\} \\ \text{în raport cu:} \\ A_1 \cdot x \geq b_1 \\ A_2 \cdot x = b_2 \end{array} \right., x \geq 0 \\ \text{problema duală: } \left\{ \begin{array}{l} \sup \{b_1^T \cdot u_1 + b_2^T \cdot u_2\} \\ \text{în raport cu:} \\ A_1^T \cdot u_1 + A_2^T \cdot u_2 \leq c, \\ u_1 \geq 0 \end{array} \right. \end{array} \right.$$

În cazul problemelor canonice, asocierea prin dualitate păstrează ambele problemele în aceeași formă, adică, restricțiile rămân concordante și variabilele nenegative. Din cauza acestei simetrii, studiul proprietăților de dualitate le vom face pe acest tip de probleme. Deoarece formele problemelor de programare liniară sunt echivalente, toate rezultatele de dualitate se vor putea aplica fără dificultate în orice situație.

1.4.2. Teoreme de dualitate

Considerăm următoarea pereche de probleme duale:

$$\inf \{c^T \cdot x \mid x \in \mathcal{P}\} \quad (\text{P})$$

$$\sup \{b^T \cdot u \mid u \in \mathcal{D}\} \quad (\text{D})$$

unde, pentru $A \in \mathbb{R}^{m \times n}$, $b \in \mathbb{R}^m$ și $c \in \mathbb{R}^n$, domeniile de admisibilitate pentru fiecare problemă sunt definite astfel:

$$\mathcal{P} = \{x \in \mathbb{R}^n \mid A \cdot x \geq b, x \geq 0\}$$

$$\mathcal{D} = \{u \in \mathbb{R}^m \mid A^T \cdot u \leq c, u \geq 0\}$$

Propoziția 1.14 *Dacă domeniile de admisibilitate a problemelor (P) și (D) sunt nevide, $\mathcal{P} \neq \emptyset$ și $\mathcal{D} \neq \emptyset$, atunci, pentru orice $x \in \mathcal{P}$ și orice $u \in \mathcal{D}$ are loc relația: $c^T \cdot x \geq b^T \cdot u$.*

Demonstrație. Pentru orice $x \in \mathcal{P}$ și orice $u \in \mathcal{D}$, avem:

$$\left. \begin{array}{l} A \cdot x - b \geq 0 \\ u \geq 0 \end{array} \right\} \implies u^T \cdot A \cdot x \geq u^T \cdot b,$$

$$\left. \begin{array}{l} x \geq 0 \\ A^T \cdot u - c \leq 0 \end{array} \right\} \implies x^T \cdot A^T \cdot u \leq x^T \cdot c.$$

De aici rezultă evident: $c^T \cdot x \geq u^T \cdot A \cdot x \geq u^T \cdot b$. ■

Observația 1.9 *În condițiile Propoziției 1.14, pentru orice $x \in \mathcal{P}$, valoarea $c^T \cdot x$ este o margine superioară a tuturor valorilor funcției obiectiv a problemei (D) și prin urmare, aceasta are un optim finit. Totodată, deoarece pentru orice $u \in \mathcal{D}$ valoarea $b^T \cdot u$ este o margine inferioară a problemei (P), aceasta are de asemenea un optim finit.*

Propoziția 1.15 *Dacă $\mathcal{P} \neq \emptyset$, $\mathcal{D} \neq \emptyset$ și există $\bar{x} \in \mathcal{P}$, $\bar{u} \in \mathcal{D}$ astfel încât $c^T \cdot \bar{x} = b^T \cdot \bar{u}$, atunci, \bar{x} este o soluție optimă a problemei (P) și \bar{u} este o soluție optimă a problemei (D).*

Demonstrație. Să presupunem, spre exemplu, că \bar{x} nu este o soluție optimă a problemei (P). Atunci, există $x_0 \in \mathcal{P}$, astfel încât $c^T \cdot x_0 < c^T \cdot \bar{x}$. Dar, ținând seama de condiția din enunț, obținem $c^T \cdot x_0 < b^T \cdot \bar{u}$, ceea ce contrazică Propoziția 1.14. Prin urmare, \bar{x} este soluție optimă a problemei (P). Analog se demonstrează proprietatea și pentru \bar{u} . ■

Teorema 1.16 (Teorema fundamentală a dualității) *Fiind data perechea de probleme duale (P) și (D), doar una din următoarele situații se poate realiza:*

1. $\mathcal{P} \neq \emptyset$ și $\mathcal{D} \neq \emptyset$. În cazul acesta, există $\tilde{x} \in \mathcal{P}$ și $\tilde{u} \in \mathcal{D}$ soluții optime pentru (P), respectiv (D), astfel încât $c^T \cdot \tilde{x} = b^T \cdot \tilde{u}$.
2. $\mathcal{P} = \emptyset$ și $\mathcal{D} = \emptyset$.
3. $\mathcal{P} \neq \emptyset$ și $\mathcal{D} = \emptyset$ sau $\mathcal{P} = \emptyset$ și $\mathcal{D} \neq \emptyset$. În cazul acesta, problema care are soluții admisibile, are optimul infinit.

Demonstrație. Să considerăm următoarea matrice pătratică de ordinul $n + m + 1$:

$$S = \begin{pmatrix} \mathbf{0}_n & -A^\top & c \\ A & \mathbf{0}_m & -b \\ -c^\top & b^\top & 0 \end{pmatrix},$$

unde $\mathbf{0}_n$ și $\mathbf{0}_m$ sunt matrice pătratice nule de ordinul n , respectiv m . Avem evident $S = -S^\top$ și deci, putem aplica Teorema 1.2: există $\bar{z} \in \mathbb{R}^{n+m+1}$, $\bar{z} \geq \mathbf{0}$, astfel încât $S \cdot \bar{z} \geq \mathbf{0}$ și $S \cdot \bar{z} + \bar{z} > \mathbf{0}$. Dacă grupăm componentele lui \bar{z} și le notăm $\bar{z} = \begin{pmatrix} \bar{x} \\ \bar{u} \\ r \end{pmatrix}$, unde $\bar{x} \in \mathbb{R}^n$, $\bar{u} \in \mathbb{R}^m$ și

$r \in \mathbb{R}$, atunci avem:

$$\bar{x} \geq \mathbf{0}, \quad \bar{u} \geq \mathbf{0}, \quad r \geq 0, \quad (1.4.1)$$

$$-A^\top \cdot \bar{u} + cr \geq \mathbf{0}, \quad (1.4.2)$$

$$A \cdot \bar{x} - br \geq \mathbf{0}, \quad (1.4.3)$$

$$-c^\top \cdot \bar{x} + b^\top \cdot \bar{u} \geq 0, \quad (1.4.4)$$

$$\bar{x} - A^\top \cdot \bar{u} + cr > \mathbf{0}, \quad (1.4.5)$$

$$A \cdot \bar{x} + \bar{u} - br > \mathbf{0}, \quad (1.4.6)$$

$$-c^\top \cdot \bar{x} + b^\top \cdot \bar{u} + r > 0. \quad (1.4.7)$$

Deoarece $r \geq 0$, putem considera două cazuri: $r > 0$ și $r = 0$.

În cazul $r > 0$, puntem defini:

$$\tilde{x} = \frac{1}{r} \bar{x} \quad \text{și} \quad \tilde{u} = \frac{1}{r} \bar{u}. \quad (1.4.8)$$

Din (1.4.1) rezultă $\tilde{x} \geq \mathbf{0}$ și $\tilde{u} \geq \mathbf{0}$. Împărțind relațiile (1.4.2) și (1.4.3) prin r , obținem:

$$A \cdot \tilde{x} \geq b \quad \text{și} \quad A^\top \cdot \tilde{u} \leq c$$

și astfel, $\tilde{x} \in \mathcal{P}$ și $\tilde{u} \in \mathcal{D}$. Din Propoziția 1.14, avem:

$$c^\top \cdot \tilde{x} \geq b^\top \cdot \tilde{u}$$

și dacă împărțim relația (1.4.4) prin r , obținem

$$c^\top \cdot \tilde{x} \leq b^\top \cdot \tilde{u}.$$

Din ultimele două relații rezultă: $c^T \cdot \bar{x} = b^T \cdot \bar{u}$. Condițiile Propoziției 1.15 fiind îndeplinite, rezultă că \bar{x} este soluție optimă a problemei (P) și \bar{u} este soluție optimă a problemei (D). Prin urmare, în cazul acesta este realizată situația de la punctul 1.

În cazul $r = 0$, vom arăta mai întâi că nu putem avea $\mathcal{P} \neq \emptyset$ și $\mathcal{D} \neq \emptyset$. Presupunem prin absurd că există $x_0 \in \mathcal{P}$ și $u_0 \in \mathcal{D}$. Ținând seama de (1.4.1), avem:

$$\left. \begin{array}{l} A \cdot x_0 - b \geq \mathbf{0} \\ \bar{u} \geq \mathbf{0} \end{array} \right\} \implies \bar{u}^T \cdot b \leq \bar{u}^T \cdot A \cdot x_0 \leq 0, \quad (1.4.9)$$

deoarece, din (1.4.2) avem $A^T \cdot \bar{u} \leq \mathbf{0}$. Pe de altă parte,

$$\left. \begin{array}{l} \bar{x} \geq \mathbf{0} \\ A^T \cdot u_0 - c \leq \mathbf{0} \end{array} \right\} \implies \bar{x}^T \cdot c \geq \bar{x}^T \cdot A^T \cdot u_0 \geq 0,$$

deoarece, din (1.4.3) avem $A \cdot \bar{x} \geq \mathbf{0}$. Din relațiile de mai sus obținem:

$$\bar{x}^T \cdot c \geq 0 \geq \bar{u}^T \cdot b,$$

care este în contradicție cu (1.4.7).

Prin urmare, nu putem avea decât, fie $\mathcal{P} = \emptyset$ și $\mathcal{D} = \emptyset$, caz în care este realizată situația de la punctul 2., fie doar una dintre mulțimile \mathcal{P} sau \mathcal{D} este nevidă, caz în care este realizată situația de la punctul 3. Pentru cazul din urmă, vom arăta că problema care admite soluții are optim infinit. Dacă presupunem, spre exemplu, că există $x_0 \in \mathcal{P}$, atunci vom considera vectorul

$$x(\lambda) = x_0 + \lambda \bar{x},$$

definit pentru parametrul real $\lambda \geq 0$. Avem evident $x(\lambda) \geq \mathbf{0}$ și

$$A \cdot x(\lambda) = A \cdot x_0 + \lambda A \cdot \bar{x} \geq A \cdot x_0 \geq b.$$

Deci, pentru orice $\lambda \geq 0$, avem $x(\lambda) \in \mathcal{P}$.

Dacă ținem seama de relația (1.4.7) și de faptul că în acest caz are loc și (1.4.9), obținem:

$$c^T \cdot \bar{x} < b^T \cdot \bar{u} \leq \bar{u}^T \cdot A \cdot x_0 \leq 0.$$

Prin urmare, avem:

$$\lim_{\lambda \rightarrow \infty} c^T \cdot x(\lambda) = \lim_{\lambda \rightarrow \infty} (c^T \cdot x_0 + \lambda c^T \cdot \bar{x}) = -\infty,$$

adică, problema (P) are optim infinit. În mod analog se poate arăta că, dacă există $u_0 \in \mathcal{D}$, atunci problema (D) are optim infinit. ■

Teorema 1.17 (Teorema tare a ecarturilor complementare)
Dacă $\mathcal{P} \neq \emptyset$ și $\mathcal{D} \neq \emptyset$, atunci, pentru perechea de probleme (P) și (D), există soluțiile optime \tilde{x} , respectiv \tilde{u} , astfel încât:

$$\begin{aligned} (A \cdot \tilde{x} - b) + \tilde{u} &> \mathbf{0}, \\ (c - A^T \cdot \tilde{u}) + \tilde{x} &> \mathbf{0}. \end{aligned}$$

Demonstrație. În condițiile date, ne situăm în cazul 1. al Teoremei fundamentale a dualității. Din demonstrația acesteia, rezultă că putem construi soluțiile optime \tilde{x} și \tilde{u} , date de (1.4.8). Împărțind relațiile (1.4.5) și (1.4.6) prin $r > 0$, obținem condițiile din enunț. ■

Teorema 1.18 (Teorema slabă a ecarturilor complementare)

Fie $x \in \mathcal{P}$ și $u \in \mathcal{D}$. Vectorul x este o soluție optimă pentru (P) și u este o soluție optimă pentru (D), dacă și numai dacă, sunt satisfăcute relațiile:

$$\begin{aligned} u^T \cdot (A \cdot x - b) &= 0, \\ x^T \cdot (c - A^T \cdot u) &= 0. \end{aligned}$$

Demonstrație. Pentru a arăta ca are loc implicația directă, presupunem x și u soluții optime pentru (P), respectiv (D). Din Teorema fundamentală a dualității rezultă: $c^T \cdot x - b^T \cdot u = 0$. Dacă în membrul stâng adăugăm și scădem $u^T \cdot A \cdot x$, ($= x^T \cdot A^T \cdot u$), și regrupăm termenii, obținem:

$$u^T \cdot (A \cdot x - b) + x^T \cdot (c - A^T \cdot u) = 0.$$

Deoarece x și u sunt soluții admisibile pentru problemele respective, ambii termeni din suma de mai sus sunt nenegativi și deci, fiecare termen trebuie să fie egal cu zero.

Pentru a arăta implicația reciprocă, adunăm membru cu membru relațiile din enunț. Obținem $c^T \cdot x = b^T \cdot u$. Deoarece $x \in \mathcal{P}$ și $u \in \mathcal{D}$, condițiile Propoziției 1.15 sunt îndeplinite și rezultă că x și u sunt soluții optime pentru (P), respectiv (D). ■

Teoremele ecarturilor complementare pun în evidență legătura dintre o pereche de soluții optime și modul în care sunt satisfăcute restricțiile cuplului de probleme duale (P) și (D). Astfel, din Teorema tare a ecarturilor complementare rezultă că, dacă la optim o restricție este *activă* (adică este satisfăcută prin egalitate), atunci componenta corespunzătoare a soluției duale este pozitivă. De asemenea, dacă o componentă a soluției optime este zero, atunci restricția corespunzătoare prin dualitate este *pasivă* (sau neactivă, adică, ea este satisfăcută printr-o inegalitate strictă).

Reciproc, din Teorema slabă a ecarturilor complementare rezultă că la optim, unei componente pozitive a soluției îi corespunde prin dualitate o restricție activă, iar unei restricții pasive, o componentă nulă a soluției asociate prin dualitate.

1.5. Algoritm simplex dual

Să considerăm problema de programare liniară în forma standard și duala ei:

$$\inf \{c^T \cdot x \mid A \cdot x = b, x \geq \mathbf{0}\} \quad (\text{P})$$

$$\sup \{b^T \cdot u \mid A^T \cdot u \leq c\} \quad (\text{D})$$

și presupunem că dispunem de o bază optimă B a lui (P). În conformitate cu Teorema de optimalitate a algoritmului simplex sunt îndeplinite relațiile:

$$\begin{aligned} \bar{x} = B^{-1} \cdot b \geq \mathbf{0} & \quad (\text{primal-admisibilitatea lui } B) \\ c_B^T \cdot B^{-1} \cdot A \leq c^T & \quad (\text{condiția de optimalitate}) \end{aligned}$$

Din condiția de optimalitate, dacă notăm vectorul

$$\bar{u}^T = c_B^T \cdot B^{-1},$$

rezultă că \bar{u} este o soluție admisibilă a problemei duale (D). Pe de altă parte, valoarea optimă a problemei (P), corespunzătoare soluției de bază, este dată de:

$$\bar{z} = c_B^T \cdot \bar{x} = c_B^T \cdot B^{-1} \cdot b = \bar{u}^T \cdot b.$$

În baza Propoziției 1.15, deducem că \bar{u} este o soluție optimă a problemei (D).

Prin urmare, cu ajutorul unei baze optime B , putem descrie soluțiile de bază optime pentru ambele probleme (P) și (D).

Pentru o matrice de bază B , care partitionează coloanele lui $A = (B : R)$, definim următoarea noțiune:

Definiția 1.5 *Matricea de bază B se numește **dual admisibilă**, dacă are loc relația:*

$$c_B^T \cdot B^{-1} \cdot A \leq c^T$$

Cu ajutorul acestei noțiuni, teorema de optimalitate a algoritmului simplex poate fi enunțată într-o nouă formă.

Teorema 1.19 (de optimalitate) *Dacă baza B este primal și dual admisibilă, atunci ea este optimă pentru problemele (P) și (D).*

În raport cu noțiunile de primal și dual admisibilitate a unei baze B , putem observa că în algoritmul simplex, descris la pagina 23, se explorează un șir de baze primal admisibile până când se obține una, care este și dual admisibilă, sau se pune în evidență că problema are optim infinit. Din această cauză, procedeul acesta se numește algoritmul simplex "primal".

În cele ce urmează, vom expune un procedeu care va explora un șir de baze dual admisibile până când, fie se obține una care este și primal admisibilă (deci optimă), fie se pune în evidență că problema duală are optim infinit și atunci, în baza Teoremei fundamentale a dualității, problema (P) nu are soluții. Algoritmul care se obține prin acest procedeu se numește **algoritmul simplex dual**.

În continuare, vom folosi aceleași notații pe care le-am utilizat cu prilejul expunerii algoritmului simplex, descris la pagina 23.

Teorema 1.20 (a domeniului vid) *Fie B o bază dual admisibilă. Dacă există o componentă $\bar{x}_i < 0$, pentru care $y_{ij} \geq 0, \forall j = \overline{1, n}$, atunci problema (P) nu are soluții.*

Demonstrație. Fie vectorul $\bar{u}^\top = c_B^\top \cdot B^{-1}$ și notăm cu B_i^{-1} linia "i" a matricei B^{-1} . Definim vectorul:

$$u^\top(\lambda) = \bar{u}^\top - \lambda B_i^{-1}.$$

unde $\lambda \geq 0$ este un parametru real. Pentru orice $j = \overline{1, n}$, avem:

$$\begin{aligned} u^\top(\lambda) \cdot A^j &= \bar{u}^\top \cdot A^j - \lambda B_i^{-1} \cdot A^j = \\ &= z_j - \lambda y_{ij} \geq z_j \geq c_j \end{aligned}$$

deoarece B este dual admisibilă. De aici rezultă că pentru orice $\lambda \geq 0$, vectorul $u(\lambda)$ este o soluție admisibilă pentru (D).

Valoarea funcției obiectiv corespunzătoare este:

$$u^\top(\lambda) \cdot b = \bar{u}^\top \cdot b - \lambda B_i^{-1} \cdot b = \bar{z} - \lambda \bar{x}_i$$

și deoarece $\bar{x}_i < 0$, rezultă $\lim_{\lambda \rightarrow \infty} u^\top(\lambda) \cdot b = \infty$. Prin urmare, problema (D) are optim infinit și în baza Teoremei fundamentale a dualității, problema (P) nu are soluții. ■

Teorema 1.21 (de schimbare a bazei) *Fie B o bază dual admisibilă și componenta $\bar{x}_r < 0$, pentru care există $j \in \mathcal{R}$, astfel ca $y_{rj} < 0$. Dacă alegem indicele $k \in \mathcal{R}$, astfel încât :*

$$\frac{z_k - c_k}{y_{rk}} = \min_{j \in \mathcal{R}} \left\{ \frac{z_j - c_j}{y_{rj}} \mid y_{rj} < 0 \right\} \quad (1.5.1)$$

atunci, matricea \tilde{B} , obținută din B prin înlocuirea coloanei A^{s_r} cu A^k (unde indicele $s_r \in \mathcal{B}$, cu $\text{loc}(s_r) = r$), este o matrice de bază dual admisibilă, pentru care avem: $\bar{z} = c_{\tilde{B}}^\top \cdot \tilde{B}^{-1} \cdot b \geq c_B^\top \cdot B^{-1} \cdot b = \bar{z}$.

Demonstrație. Din relația (1.5.1) avem evident $y_{rk} < 0$. Din Lema substituției rezultă că \tilde{B} este o matrice nesingulară. Pentru a vedea că ea este o matrice de bază dual admisibilă, trebuie să verificăm că pentru orice j , $1 \leq j \leq n$, avem $\bar{z}_j - c_j = c_{\tilde{B}}^\top \cdot \tilde{B}^{-1} \cdot A^j - c_j \leq 0$. Aplicând formula (1.2.15), avem:

$$\bar{z}_j - c_j = (z_j - c_j) - \frac{(z_k - c_k) y_{rj}}{y_{rk}}.$$

Deoarece B este dual admisibilă, pentru orice $j = \overline{1, n}$, avem $z_j - c_j \leq 0$. Prin urmare, dacă $y_{rj} \geq 0$, din relația de mai sus rezultă

evident $\tilde{z}_j - c_j \leq 0$. Dacă $y_{rj} < 0$, ținând seama de (1.5.1), putem scrie:

$$\tilde{z}_j - c_j = y_{rj} \left(\frac{z_j - c_j}{y_{rj}} - \frac{z_k - c_k}{y_{rk}} \right) \leq 0.$$

În concluzie, \tilde{B} este bază dual admisibilă.

Ultima afirmație a teoremei rezultă din formula (1.2.14):

$$\tilde{z} = \bar{z} - \frac{(z_k - c_k)}{y_{rk}} \bar{x}_r \geq \bar{z}.$$

■

Observația 1.10 Prin schimbarea de bază, avem: $\tilde{\mathcal{B}} = \mathcal{B} \setminus \{s_r\} \cup \{k\}$ și $\text{loc}(k) = r$.

Algoritmul simplex dual.

Pasul 0. Se determină (dacă există) o bază dual admisibilă B și se calculează B^{-1} .

Pasul 1. Se calculează: $\bar{x} = B^{-1} \cdot b$, $\bar{z} = c_B^\top \cdot \bar{x}$, $Y = B^{-1} \cdot A$, $z^\top - c^\top = c_B^\top \cdot Y - c^\top$.

Pasul 2. (testul de optimalitate) Dacă $\bar{x} \geq 0$, atunci \bar{z} este valoarea optimă, iar $x_B = \bar{x}$ și $x_{\mathcal{R}} = 0$ este soluția de bază optimă a problemei (P). STOP.

Pasul 3. (testul de domeniu vid) Dacă există $\bar{x}_i < 0$ astfel încât $y_{ij} \geq 0$ pentru orice $j = \overline{1, n}$, atunci problema (P) nu are soluții. STOP.

Pasul 4. (schimbarea bazei) Se alege $\bar{x}_r < 0$ și din relația (1.5.1) se determină $k \in \mathcal{R}$. Se formează matricea \tilde{B} , care se obține din B prin înlocuirea coloanei A^{s_r} cu A^k (unde indicele $s_r \in \mathcal{B}$, iar $\text{loc}(s_r) = r$), se calculează \tilde{B}^{-1} cu formula (1.2.4), și cu această inversă a noii matrice de bază se revine la Pasul 1.

Există metode pentru determinarea bazelor dual admisibile (vezi, spre exemplu, [37, p. 44]), pe care însă nu le mai prezentăm aici. Un argument în sprijinul acestei decizii ar fi că, în practică, de cele mai multe ori, bazele dual admisibile se obțin în mod natural din cele

optime, după ce acestea își pierd primal admisibilitatea în urma unor schimbări ce intervin fie în datele problemei, fie în structura lor.

Se observă cu ușurință că algoritmul simplex dual lucrează cu aceleași elemente ca și cel primal. Din această cauză, organizarea calculelor pentru aplicarea lui la rezolvarea manuală a problemelor de programare liniară, se poate face folosind tabloul simplex standard sau cel revizuit.

Capitolul 2

Metode de descompunere

2.1. Introducere

Rezolvarea problemelor de programare liniară de dimensiuni mari prezintă numeroase dificultăți din cauza prelucrării anevoioase a datelor, pe de o parte, iar pe de altă parte, din cauza acumulării erorilor de rotunjire ce se fac inevitabil pe parcursul iterațiilor algoritmului simplex. Din fericire însă, majoritatea problemelor de acest fel au o structură specială a restricțiilor, matricea coeficienților având o formă "bloc-unghiulară", ce se poate reprezenta astfel:

$$\begin{pmatrix} A_1 & A_2 & & A_k \\ D_1 & & & \\ & D_2 & & \\ & & & \\ & & & D_k \end{pmatrix}$$

unde $A_i \in \mathbb{R}^{m_0 \times n_i}$ și $D_i \in \mathbb{R}^{m_i \times n_i}$, $1 \leq i \leq k$.

Dacă ar lipsi cele m_0 "restricții de cuplare" definite prin elementele matricelor A_i , $1 \leq i \leq k$, atunci problema de programare liniară s-ar descompune în k probleme independente, fiecare având matricea de restricții D_i , $1 \leq i \leq k$. Rezultă că în această situație, am putea opta între a rezolva o singură problemă mare, având matricea restricțiilor de dimensiune $\left(\sum_{i=1}^k m_i\right) \times \left(\sum_{i=1}^k n_i\right)$, sau de a rezolva k probleme mai mici, fiecare având matricea de restricții de dimensiune $m_i \times n_i$. Evident, cea de-a doua opțiune este mai convenabilă, deoarece se lucrează cu probleme care au un volum de date mai mic.

Plecând de la această idee, în perioada anilor '60-'70, s-au elaborat

o serie de metode care abordează problemele de dimensiuni mari, cu matricea restricțiilor în formă bloc-unghiulară, prin rezolvarea unei succesiuni de probleme liniare de dimensiuni cu mult mai mici.

2.2. Principiul de descompunere Dantzig-Wolfe

Dantzig și Wolfe [8] au fost primii care au publicat în 1960 un algoritm de descompunere pentru problemele de programare liniară. Procedeu devine eficient dacă este aplicat la probleme liniare cu restricțiile în formă bloc-unghiulară. Principiul de rezolvare constă în construirea unui "program principal" care este echivalent cu problema inițială și care are un număr de linii doar cu o unitate mai mare decât numărul restricțiilor de cuplare. Pe de altă parte însă, numărul de coloane devine foarte mare, dar acestea nu trebuie tabelate de la început, ci se "generează" în momentul în care ele sunt necesare în aplicarea algoritmului simplex. O iterație a algoritmului constă din două etape: în prima etapă, se rezolvă un număr de subprobleme independente; în a doua etapă, se rezolvă programul principal în care se introduc rezultatele obținute prin rezolvarea subproblemelor.

2.2.1. Rezultate preliminare

Justificarea algoritmului Dantzig-Wolfe se bazează pe unele noțiuni și rezultate din teoria generală a analizei convexe (vezi, spre exemplu, Rockafellar [32], Karlin [18]).

Fie $X \subset \mathbb{R}^n$ o mulțime convexă.

Definiția 2.1 Vom spune că $x \in X$ este un punct extrem al mulțimii X , dacă pentru orice $a \in X$ și $b \in X$, $a \neq b$, avem $x \neq \lambda a + (1 - \lambda)b$, oricare ar fi $\lambda \in (0, 1)$.

Mulțimea punctelor extreme ale lui X o vom nota cu $Ext(X)$.

Observația 2.1 Orice soluție de bază a unei probleme de programare liniară este un punct extrem al domeniului de admisibilitate.

Teorema 2.1 Dacă $y \notin X$ atunci există un hiperplan care separă punctul y de mulțimea X .

Definiția 2.2 Un "hiperplan de sprijin" a mulțimii convexe X are proprietatea că X se află de o parte a sa și cel puțin un punct al lui X este conținut în hiperplan.

Teorema 2.2 Dacă X este o mulțime convexă, atunci orice hiperplan de sprijin la X conține un punct extrem al lui X .

Definiția 2.3 Fie $M \subset \mathbb{R}^n$ o mulțime oarecare. Acoperirea convexă $Co(M)$ a lui M este cea mai mică mulțime convexă ce conține pe M .

Teorema 2.3 Fie $X \subset \mathbb{R}^n$ o mulțime convexă și compactă. Atunci $Co(Ext(X)) = X$.

Demonstrație. Vom arăta mai întâi că $Co(Ext(X)) \subseteq X$. Pentru orice $y \in Co(Ext(X))$, există puncte $x^i \in Ext(X)$ astfel încât

$$y = \sum_i \lambda_i x^i, \quad \text{cu } \lambda_i \geq 0 \text{ și } \sum_i \lambda_i = 1.$$

Deoarece $x^i \in X$ și mulțimea X este convexă, rezultă că $y \in X$.

Pentru a arăta că $Co(Ext(X)) \supseteq X$, vom presupune prin absurd că există $y \in X$, astfel ca $y \notin Co(Ext(X))$. Cu alte cuvinte, y nu poate fi descris ca o combinație convexă de puncte extreme ale lui X . În aceste condiții, conform Teoremei 2.1, există un hiperplan $a^\top \cdot x = b$ ($a \in \mathbb{R}^n$ și $b \in \mathbb{R}$) care separă punctul y de mulțimea $Co(Ext(X))$, adică,

$$a^\top \cdot y \geq b \quad \text{și} \quad (2.2.1)$$

$$a^\top \cdot x < b \quad \text{pentru orice } x \in Co(Ext(X)) \quad (2.2.2)$$

Deoarece X este compactă, există $b_0 = \max \{a^\top \cdot x \mid x \in X\}$. Prin urmare, $a^\top \cdot x \leq b_0$ pentru orice $x \in X$ și deci, $a^\top \cdot x = b_0$ este un hiperplan de sprijin a lui X . În baza Teoremei 2.2, rezultă că există un punct extrem $\bar{x} \in Ext(X)$, astfel încât $a^\top \cdot \bar{x} = b_0$. Dar această relație este în contradicție cu (2.2.2), deoarece, din alegerea lui b_0 și (2.2.1), avem $b_0 \geq b$. ■

Teorema 2.3 poate fi enunțată și într-o formă diferită, care este mai adecvată pentru aplicarea ei în elaborarea metodei de descompunere.

Corolarul 2.4 Fie mulțimea $X = \{x \in \mathbb{R}^n \mid A \cdot x = b, x \geq 0\}$ nevidă și mărginită, și fie $Ext(X) = \{x^i, 1 \leq i \leq r\}$. Atunci, orice element $x \in X$ poate fi scris sub forma:

$$x = \sum_{i=1}^r \lambda_i x^i, \text{ unde } \lambda_i \geq 0 \text{ și } \sum_{i=1}^r \lambda_i = 1.$$

Extinderea acestui rezultat la cazul în care X nu este mărginită este dată de următoarea teoremă.

Teorema 2.5 Fie mulțimea $X = \{x \in \mathbb{R}^n \mid A \cdot x = b, x \geq 0\} \neq \emptyset$. Atunci $x \in X$, dacă și numai dacă x poate fi scris ca o combinație convexă de puncte extreme ale lui X , plus o combinație liniară nenegativă de raze extreme (soluții nenule ale sistemului omogen) ale lui X , adică

$$x = \sum_i \lambda_i x^i \quad (2.2.3)$$

unde

$$\sum_i \delta_i \lambda_i = 1, \quad \lambda_i \geq 0 \quad (2.2.4)$$

și

$$\delta_i = \begin{Bmatrix} 1 \\ 0 \end{Bmatrix} \text{ după cum } x^i \text{ este } \begin{Bmatrix} \text{punct extrem} \\ \text{rază extremă} \end{Bmatrix} \text{ a lui } X. \quad (2.2.5)$$

2.2.2. Principiul de descompunere

Să considerăm pentru început o problemă de programare liniară în care restricțiile sunt grupate în două părți:

$$\inf c^T \cdot x$$

în raport cu

$$A \cdot x = b_0 \quad (m_0 \text{ restricții})$$

$$D \cdot x = b \quad (m \text{ restricții})$$

$$x \geq 0$$

unde $A \in \mathbb{R}^{m_0 \times n}$, $D \in \mathbb{R}^{m \times n}$, $c \in \mathbb{R}^n$, $b_0 \in \mathbb{R}^{m_0}$ și $b \in \mathbb{R}^m$. Este evident că orice problemă de programare liniară se poate scrie în această formă.

Vom presupune că poliedrul convex

$$S = \{x \in \mathbb{R}^n \mid D \cdot x = b, x \geq 0\}$$

este mărginit și mulțimea punctelor sale extreme este

$$\text{Ext}(S) = \{x^j, 1 \leq j \leq r\}.$$

În baza Corolarului 2.4, oricare ar fi $x \in S$, avem:

$$x = \sum_{j=1}^r \lambda_j x^j, \text{ unde } \lambda_j \geq 0 \text{ și } \sum_{j=1}^r \lambda_j = 1. \quad (2.2.6)$$

Problema inițială se poate formula astfel: să se determine $x \in S$ astfel încât să fie satisfăcute restricțiile $A \cdot x = b_0$ și să se realizeze minimumul lui $c^\top \cdot x$. Dacă ținem seama de (2.2.6) și notăm:

$$\begin{aligned} \gamma_i &= c^\top \cdot x^i \\ \alpha^i &= A \cdot x^i \end{aligned} \quad (2.2.7)$$

atunci, problema inițială se poate rescrie în funcție de variabilele λ_i astfel:

$$\left. \begin{aligned} &\inf \sum_{j=1}^r \gamma_j \lambda_j \\ &\text{în raport cu} \\ &\sum_{j=1}^r \alpha^j \lambda_j = b_0 \\ &\sum_{j=1}^r \lambda_j = 1 \\ &\lambda_j \geq 0, 1 \leq j \leq r \end{aligned} \right\} \quad (\text{PP})$$

Problema (PP) se numește "program principal" și este echivalent cu problema inițială. Remarcăm că programul principal are doar $m_0 + 1$ restricții, față de $m_0 + m$ cât are problema inițială, iar acest lucru reprezintă o restrângere a dimensiunii în cazul în care m este mare. În schimb, numărul de coloane este egal cu numărul punctelor extreme

a mulțimii S , care poate fi considerabil de mare. Acest lucru însă nu devine un impediment în rezolvarea programului principal deoarece, pentru aplicarea algoritmului simplex, nu trebuie să cunoaștem decât acele coloane care formează baza curentă și cel mult încă o coloană, care eventual urmează să fie introdusă în noua bază.

Pentru a determina o bază primal admisibilă a programului principal, se poate folosi o metodă de fază 1, după ce s-au determinat un număr $l \geq m_0 + 1$ de puncte extreme ale mulțimii S . La rândul lor, punctele extreme se pot obține printr-o procedură de fază 1 aplicată restricțiilor $\{D \cdot x = b, x \geq 0\}$, urmată de un număr de iterații de schimbare a bazei, cu respectarea criteriului din algoritmul simplex.

Fie B o bază primal admisibilă a programului principal, \mathcal{B} mulțimea indicilor de bază și $u^\top = \gamma_B^\top \cdot B^{-1}$, vectorul multiplicatorilor simplex corespunzători acestei baze. Pentru a vedea dacă această bază este optimă, trebuie să calculăm

$$u^\top \cdot \begin{pmatrix} \alpha^s \\ 1 \end{pmatrix} - \gamma_s = \max_j \left\{ u^\top \cdot \begin{pmatrix} \alpha^j \\ 1 \end{pmatrix} - \gamma_j \right\} \quad (2.2.8)$$

Dacă partiționăm vectorul $u^\top = (u_0^\top, u_1)$, cu $u_0 \in \mathbb{R}^{m_0}$ și $u_1 \in \mathbb{R}$, și ținem seama de notațiile (2.2.7), atunci avem:

$$u^\top \cdot \begin{pmatrix} \alpha^j \\ 1 \end{pmatrix} - \gamma_j = (u_0^\top, u_1) \cdot \begin{pmatrix} A \cdot x^j \\ 1 \end{pmatrix} - c^\top \cdot x^j = (u_0^\top \cdot A - c^\top) \cdot x^j + u_1$$

Prin urmare, determinarea maximului în relația (2.2.8) se poate scrie

$$\max_j \left\{ u^\top \cdot \begin{pmatrix} \alpha^j \\ 1 \end{pmatrix} - \gamma_j \right\} = \max_{x^j \in \text{Ext}(S)} \left\{ (u_0^\top \cdot A - c^\top) \cdot x^j \right\} + u_1 \quad (2.2.9)$$

Reamintim că x^j este un punct extrem al lui S și observăm că expresia de maximizat în (2.2.9) este liniară în x^j . Deoarece o soluție optimă a unei probleme liniare, cu domeniul de admisibilitate mărginit, este întotdeauna și un punct extrem al acestei mulțimi, maximizarea din (2.2.9) este echivalentă cu subproblema

$$\max_{x \in \mathbb{R}^n} \left\{ (u_0^\top \cdot A - c^\top) \cdot x \mid D \cdot x = b, x \geq 0 \right\} \quad (2.2.10)$$

Rezolvând această subproblemă, se obține o soluție x^s pentru care valoarea maximă din relația (2.2.8), pe care o vom nota cu Δ , este

$$\Delta = u^\top \cdot \begin{pmatrix} \alpha^s \\ 1 \end{pmatrix} - \gamma_s = (u_0^\top \cdot A - c^\top) \cdot x^s + u_1$$

Dacă $\Delta \leq 0$, atunci baza B este optimă pentru programul principal și $\bar{\lambda} = B^{-1} \cdot \begin{pmatrix} b_0 \\ 1 \end{pmatrix}$ este soluția optimă corespunzătoare. Soluția optimă pentru problema inițială se obține acum din relația (2.2.6):

$$\bar{x} = \sum_{i \in B} \bar{\lambda}_i x^i$$

Dacă $\Delta > 0$, atunci coloana care intră în bază este $\alpha^s = \begin{pmatrix} A \cdot x^s \\ 1 \end{pmatrix}$, cu coeficientul de cost $\gamma_s = c^\top \cdot x^s$. Efectuând acum o operație de schimbare a bazei în programul principal, obținem o nouă bază primal admisibilă și calculele se reiau cu testul de optimalitate a acesteia.

Acest procedeu de rezolvare devine deosebit de atractiv dacă este aplicat la probleme cu o structură bloc-unghiulară a restricțiilor, de forma următoare:

$$\left. \begin{array}{l} \inf \{ c_1^\top \cdot x_1 + c_2^\top \cdot x_2 + \cdots + c_k^\top \cdot x_k \} \\ \left. \begin{array}{l} A_1 \cdot x_1 + A_2 \cdot x_2 + \cdots + A_k \cdot x_k = b_0 \\ D_1 \cdot x_1 = b_1 \\ D_2 \cdot x_2 = b_2 \\ \vdots \\ D_k \cdot x_k = b_k \end{array} \right\} \right\} \quad (\text{PBU}) \\ x_i \geq 0, i = \overline{1, k}, k > 0. \end{array}$$

unde, pentru orice $i = \overline{1, k}$, avem $A_i \in \mathbb{R}^{m_0 \times n_i}$, $D_i \in \mathbb{R}^{m_i \times n_i}$, $c_i \in \mathbb{R}^{n_i}$, $b_i \in \mathbb{R}^{m_i}$ și $b_0 \in \mathbb{R}^{m_0}$.

Pentru problema bloc-unghiulară (PBU), subproblema (2.2.10) devine:

$$\max \left\{ \left(\sum_{i=1}^k u_0^\top \cdot A_i - c_i^\top \right) \cdot x_i \mid D_i \cdot x_i = b_i, x_i \geq 0, i = \overline{1, k} \right\} \quad (2.2.11)$$

Deoarece în (2.2.11) funcția obiectiv este aditiv separabilă în \mathbf{x}_i iar restricțiile sunt independente în raport cu \mathbf{x}_i , această problemă se reduce la rezolvarea a k subprobleme independente:

$$\max_{\mathbf{x}_i \in \mathbb{R}^{n_i}} \{ (u_0^\top \cdot A_i - c_i^\top) \cdot \mathbf{x}_i \mid D_i \cdot \mathbf{x}_i = b_i, \mathbf{x}_i \geq \mathbf{0} \}, \quad i = \overline{1, k}. \quad (2.2.12)$$

În baza principiului de descompunere Dantzig-Wolfe prezentat mai sus, putem enunța următorul algoritm pentru rezolvarea problemei bloc-unghiulare (PBU). Vom presupune că avem la dispoziție o bază primal admisibilă B a programului principal (PP) și multiplicatorii simplex $u^\top = (u_0^\top, u_1)$ corespunzători.

Algoritm de descompunere Dantzig-Wolfe.

Pasul 0: Se determină o bază primal admisibilă B pentru programul principal (PP) și multiplicatorii simplex $u^\top = (u_0^\top, u_1)$ corespunzători.

Pasul 1: Folosind multiplicatorii simplex u_0 , se rezolvă subproblemele (2.2.12), obținând soluțiile $\bar{\mathbf{x}}_i(u_0)$, $i = \overline{1, k}$.

Pasul 2: Se calculează

$$\Delta = \sum_{i=1}^k (u_0^\top \cdot A_i - c_i^\top) \cdot \bar{\mathbf{x}}_i(u_0) + u_1$$

Dacă $\Delta \leq 0$, atunci soluția optimă pentru (PBU) este

$$\bar{x} = \sum_{i \in B} \lambda_i x^i \quad (2.2.13)$$

unde x^i sunt punctele extreme ale mulțimii

$$S = \left\{ x \in \mathbb{R}^{\sum_{i=1}^k n_i} \mid \begin{pmatrix} D_1 & & \\ & \ddots & \\ & & D_k \end{pmatrix} \cdot x = \begin{pmatrix} b_1 \\ \vdots \\ b_k \end{pmatrix} \right\} \quad (2.2.14)$$

corespunzătoare soluțiilor de bază λ_i . STOP.

Pasul 3: Dacă $\Delta > 0$, se formează coloana

$$\begin{pmatrix} \alpha^s \\ 1 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^k A_i \mathbf{x}_i(u_0) \\ 1 \end{pmatrix}$$

care printr-o operație de schimbare a bazei din algoritmul simplex va fi introdusă într-o nouă bază primal admisibilă pentru (PP) și în mod corespunzător, se obține un nou vector al multiplicatorilor simplex. După aceasta, se revine la Pasul 1.

Observația 2.2 *Dacă programul principal are toate soluțiile de bază nedegenerate, atunci fiecare iterație va produce o descresștere strictă a funcției obiectiv. Deoarece există un număr finit de baze posibile și nici una nu se poate repeta, principiul de descompunere va determina soluția optimă într-un număr finit de iterații.*

Observația 2.3 *Trebuie subliniat faptul că soluția optimă \bar{x} a problemei (PBU) nu este neapărat una dintre cele obținute la rezolvarea subproblemelor (2.2.12). Din (2.2.13) rezultă că \bar{x} este o anumită combinație convexă a unui număr de astfel de soluții. Prin urmare, programul principal nu poate obține optimul global pur și simplu prin trimiterea "prețurilor" corespunzătoare lui u_0 către subprobleme; el trebuie să combine soluțiile subproblemelor într-un plan general. În acest sens, descompunerea lui Dantzig și Wolfe nu este o "descenralizare" completă a procesului de luare a deciziei. Din această cauză, Dantzig [7, capitolul 23] a denumit această descompunere "planificare centralizată fără informație completă la centru".*

Programul principal restrâns.

Principiul de descompunere Dantzig-Wolfe, în forma prezentată mai sus, rezolvă probleme de optimizare doar în prima etapă (subproblemele (2.2.12)), în timp ce în etapa a doua, se execută doar o singură operație de schimbare a bazei. Se poate da însă o formulare mai simetrică a acestei metode, astfel ca în ambele etape să se rezolve probleme de optimizare. Pentru aceasta, în locul programului principal (PP), vom considera un "program principal restrâns", format doar din coloanele care formează baza curentă în (PP) și coloana care urmează să fie introdusă în noua bază. Astfel, programul principal restrâns

este:

$$\left. \begin{array}{l} \text{în raport cu} \\ \inf \left\{ \sum_{i=1}^m \gamma_i \lambda_i + \gamma \lambda \right\} \\ \sum_{i=1}^m \alpha^i \lambda_i + \alpha \lambda = b_0 \\ \sum_{i=1}^m \lambda_i + \lambda = 1 \\ \lambda_i \geq 0, \quad i = \overline{1, m}, \quad \lambda \geq 0 \end{array} \right\} \quad (\text{PPR})$$

unde $m = m_0 + 1$, λ_i sunt variabilele de bază curente și λ este variabila care intră în noua bază, având coeficientul de cost redus

$$u_0^\top \cdot \alpha + u_1 - \gamma > 0.$$

Evident, rezolvarea acestei probleme este echivalentă cu iterația de schimbare a bazei prezentată în algoritmul de descompunere.

Utilitatea unui program principal restrâns va fi pusă în evidență în cele ce urmează.

Variante pentru descompunerea primală.

Există diferite moduri în care se poate descompune problema inițială, fiecare modalitate influențând forma programului principal și a programului principal restrâns.

Pentru orice $i = \overline{1, k}$, considerăm poliedrul convex

$$S_i = \{x \in \mathbb{R}^{n_i} \mid D_i \cdot x = b_i, x \geq \mathbf{0}\} \quad (2.2.15)$$

și notăm punctele sale extreme cu $x_i^j \in \text{Ext}(S_i)$. Astfel, orice punct $\mathbf{x}_i \in S_i$ poate fi scris sub forma unei combinații convexe de puncte extreme: $\mathbf{x}_i = \sum_j \lambda_j x_i^j$. Înlocuind în (PBU), obținem următorul program

principal:

$$\left. \begin{array}{l} \text{în raport cu} \\ \inf \sum_{i=1}^k \sum_j \gamma_{ij} \lambda_{ij} \\ \sum_{i=1}^k \sum_j \alpha_i^j \lambda_{ij} = b_0 \quad (\text{r-1}) \\ \sum_j \lambda_{ij} = 1, \quad i = \overline{1, k} \quad (\text{r-2}) \\ \lambda_{ij} \geq 0. \end{array} \right\} \quad (\text{PP+})$$

unde $\gamma_{ij} = c_i^\top \cdot x_i^j$ și $\alpha_i^j = A_i \cdot x_i^j$.

Această problemă diferă de (PP) prin aceea că are k linii de convexitate (r-2) în loc de una și fiecare subsistem $\{D_i \cdot \mathbf{x}_i = b_i, \mathbf{x}_i \geq \mathbf{0}\}$, este reprezentat separat printr-o mulțime de variabile λ_{ij} (anterior, toate subsistemele erau agregate împreună).

Pentru rezolvarea problemei (PP+), să considerăm o bază primal admisibilă B de dimensiune $(m_0 + k) \times (m_0 + k)$ și fie $u^\top = (u_0^\top, u_1^\top)$ multiplicatorii simplex corespunzători, unde $u_0 \in \mathbb{R}^{m_0}$ este asociat restricțiilor de cuplare (r-1), iar $u_1 = (u_{11}, \dots, u_{1k})^\top \in \mathbb{R}^k$ condițiilor de convexitate (r-2). Coeficientul de cost relativ corespunzător variabilei λ_{ij} este

$$\Delta_{ij} = (u_0^\top \cdot A_i - c_i^\top) \cdot x_i^j + u_{1i}$$

Pentru i fixat, problema găsirii valorii

$$\bar{z}_i = \max_j \Delta_{ij}$$

este echivalentă cu rezolvarea subproblemei

$$\bar{z}_i = \max_{x \in \mathbb{R}^{n_i}} \{ (u_0^\top \cdot A_i - c_i^\top) \cdot x \mid D_i \cdot x = b_i, x \geq \mathbf{0} \}$$

care este aceeași ca în (2.2.12). Dacă

$$\max_{1 \leq i \leq k} \max_j \Delta_{ij} = \max_{1 \leq i \leq k} \{ \bar{z}_i + u_{1i} \} \leq 0,$$

atunci soluția curentă este optimă. Dacă nu, coloana care intră în bază este aceea care realizează

$$\max_{1 \leq i \leq k} \{ \bar{z}_i + u_{1i} \} = \bar{z}_s + u_{1s} > 0$$

Dacă $\bar{x}_s(u_0)$ este soluția optimă a subproblemei s , atunci coloana care intră în bază va fi

$$\begin{pmatrix} A_s \cdot \bar{x}_s(u_0) \\ e^s \end{pmatrix} \quad (2.2.16)$$

unde $e^s \in \mathbb{R}^k$ este un vector unitar, având pe poziția s valoarea 1 și zero în rest.

Este posibil ca să existe și alți indici i , pentru care $\bar{z}_i + u_{1i} > 0$ și în plus, după ce s-a obținut noua bază ce conține coloana (2.2.16), aceste costuri reduse să rămână pozitive și în raport cu baza nouă. Această observație este o motivație puternică pentru a forma un nou program principal restrâns, în care să se adauge câte o coloană α_i^* pentru fiecare subsistem independent:

$$\left. \begin{array}{l} \inf \left\{ \sum_{i=1}^k \sum_{j \in \mathcal{B}} \gamma_{ij} \lambda_{ij} + \sum_{i=1}^k \gamma_i^* \lambda_i^* \right\} \\ \text{în raport cu} \\ \left. \begin{array}{l} \sum_{i=1}^k \sum_{j \in \mathcal{B}} \alpha_i^j \lambda_{ij} + \sum_{i=1}^k \alpha_i^* \lambda_i^* = b_0 \\ \sum_{j \in \mathcal{B}} \lambda_{ij} + \lambda_i^* = 1, \quad i = \overline{1, k} \\ \lambda_{ij} \geq 0, \quad \lambda_i^* \geq 0, \quad i = \overline{1, k}, j \in \mathcal{B} \end{array} \right\} \end{array} \right\} \text{(PPR+)}$$

Această problemă are k variabile λ_i^* , corespunzătoare restricțiilor de convexitate, și în comparație cu (PPR), dimensiunea bazei a crescut de la $m_0 + 1$ la $m_0 + k$. Acest inconvenient este însă compensat de perspectiva de a obține o descreștere mai mare a funcției obiectiv, în urma efectuării mai multor iterații simplex care se vor face la rezolvarea lui (PPR+).

Observația 2.4 Programul principal restrâns (PPR) are o singură linie de convexitate, grupând împreună toate blocurile diagonale, spre deosebire de (PPR+) care are k linii de convexitate, tratând fiecare bloc separat. Evident, alte grupări ale acestor blocuri conduc la programe principale care pot avea un număr de linii de convexitate cuprins între 1 și k . Considerarea unor astfel de cazuri intermediare este impus de cele mai multe ori de particularitățile problemei care urmează a fi rezolvată.

Observația 2.5 Dacă ipoteza de mărginire a poliedrelor convexe S_i (definite în (2.2.15)) nu este îndeplinită, atunci utilizarea Corolarului 2.4 trebuie înlocuită cu Teorma 2.5. Razele extreme care apar în descrierea unui punct $x \in S_i$ sunt soluții nenule ale sistemului omogen

$$D_i \cdot x = 0, \quad x \geq 0$$

și sunt în număr finit. Dacă o subproblemă are optim infinit, algoritmul simplex pune în evidență o rază extremă (vezi Observația 1.3 de la pagina 19). Principiul de descompunere se aplică și în acest caz, prin substituirea lui (2.2.3) în restricțiile de cuplare și funcția obiectiv a problemei (PBU). Singura diferență în programul principal (PP) este înlocuirea restricției de convexitate $\sum_{i=1}^r \lambda_i = 1$ cu (2.2.4) și (2.2.5), scrise relativ la mulțimea S , care este definită de (2.2.14).

2.2.3. Exemplu de aplicare a principiului de descompunere

Vom considera următoarea problemă:

$$\inf \{-x_1 - 3x_2 + 2x_3 + 3y_1 - 2y_2 - 4y_3\}$$

în raport cu

$$\begin{array}{rcccccc} x_1 & +2x_2 & -x_3 & -2y_1 & +3y_2 & -y_3 & = 10 \\ 4x_1 & -2x_2 & -x_3 & & & & = 2 \\ x_1 & +x_2 & +2x_3 & & & & = 5 \\ & & & y_1 & -y_2 & +3y_3 & = 0 \\ & & & y_1 & +y_2 & -y_3 & = 2 \end{array}$$

$$x_i \geq 0, \quad y_i \geq 0, \quad i = \overline{1, 3}.$$

Această problemă are o restricție de cuplare și două blocuri independente. Pentru a utiliza pe deplin programul principal restrâns, vom considera două restricții de convexitate. Notăm:

$$S_1 = \{x \in \mathbb{R}_+^3 \mid 4x_1 - 2x_2 - x_3 = 2, \quad x_1 + x_2 + 2x_3 = 5\}$$

$$S_2 = \{y \in \mathbb{R}_+^3 \mid y_1 - y_2 + 3y_3 = 0, \quad y_1 + y_2 - y_3 = 2\}$$

Fie $x \in S_1$ și $y \in S_2$. În baza Corolarului 2.4 putem scrie:

$$x = \sum_j x^j \lambda_j \quad \text{și} \quad y = \sum_j y^j \mu_j \quad (2.2.17)$$

unde $x^j \in \text{Ext}(S_1)$ și $y^j \in \text{Ext}(S_2)$, iar λ_j și μ_j sunt parametrii combinațiilor convexe respective.

Grupăm coeficienții funcției obiectiv și a restricției de cuplare în felul următor:

$$\begin{aligned} c_1^\top &= (-1, -3, 2), & c_2^\top &= (3, -2, -4) \\ A_1 &= (1, 2, -1), & A_2 &= (-2, 3, -1) \end{aligned}$$

Cu aceste notații, programul principal se poate scrie astfel:

$$\inf \left\{ \sum_j (c_1^\top \cdot x^j) \lambda_j + \sum_j (c_2^\top \cdot y^j) \mu_j \right\}$$

în raport cu

$$\begin{aligned} \sum_j (A_1 \cdot x^j) \lambda_j + \sum_j (A_2 \cdot y^j) \mu_j &= 10 \\ \sum_j \lambda_j &= 1 \\ \sum_j \mu_j &= 1 \end{aligned}$$

$$\lambda_j \geq 0, \quad \mu_j \geq 0, \quad \forall j.$$

Va trebui mai întâi să identificăm o bază primal admisibilă a programului principal. Pentru aceasta, avem nevoie de trei puncte extreme ale poliedrelor S_1 și S_2 , convenabil alese. Vom considera, spre exemplu, $x^1 \in \text{Ext}(S_1)$, $x^1 = (2, 3, 0)^\top$, obținut prin rezolvarea sistemului ce definește pe S_1 , luând pe x_1, x_2 variabile principale și variabila secundară $x_3 = 0$. Analog, determinăm pentru cel de al doilea bloc pe $y^1 \in \text{Ext}(S_2)$ și $y^2 \in \text{Ext}(S_2)$, $y^1 = (1, 1, 0)^\top$ și $y^2 = (0, 3, 2)^\top$.

Cu ajutorul acestor puncte extreme putem explicita trei coloane ale programului principal. Avem:

$$c_1^\top \cdot x^1 = (-1, -3, 2) \cdot \begin{pmatrix} 2 \\ 3 \\ 0 \end{pmatrix} = -11;$$

$$A_1 \cdot x^1 = (1, 2, -1) \cdot \begin{pmatrix} 2 \\ 3 \\ 0 \end{pmatrix} = 8;$$

$$c_2^\top \cdot y^1 = 1; \quad c_2^\top \cdot y^2 = -10;$$

$$A_2 \cdot y^1 = 1; \quad A_2 \cdot y^2 = 8.$$

Astfel, o explicitare incompletă a programului principal se poate scrie astfel:

$$\inf \left\{ -11\lambda_1 + \mu_1 - 10\mu_2 + \sum \dots \right\}$$

în raport cu

$$8\lambda_1 + \mu_1 + 8\mu_2 + \sum \dots = 10$$

$$\lambda_1 + \sum \dots = 1$$

$$\mu_1 + \mu_2 + \sum \dots = 1$$

$$\lambda_j \geq 0, \quad \mu_j \geq 0, \quad \forall j.$$

Matricea $B = \begin{pmatrix} 8 & 1 & 8 \\ 1 & 0 & 0 \\ 0 & 1 & 1 \end{pmatrix}$ se dovedește a fi o bază primal admi-

bilă pentru programul principal, iar tabloul simplex revizuit corespunzător acestei baze este:

λ_1	1	0	1	0	
μ_1	6/7	-1/7	8/7	8/7	
μ_2	1/7	1/7	-8/7	-1/7	
	-81/7	-11/7	11/7	18/7	

Multiplicatorii simplex se află pe ultima linie a tabloului și în notațiile noastre sunt:

$$u_0 = \frac{-11}{7}, \quad u_{11} = \frac{11}{7}, \quad u_{12} = \frac{18}{7}.$$

Iterația 1.

Pasul 1. Rezolvăm subproblemele (2.2.12):

$$\begin{aligned} \bar{z}_1 &= \max \{ (u_0^\top \cdot A_1 - c_1^\top) \cdot x \mid x \in S_1 \} = \\ &= \max \left\{ \frac{-4}{7}x_1 - \frac{1}{7}x_2 - \frac{3}{7}x_3 \mid x \in S_1 \right\} = \frac{-10}{7} \end{aligned}$$

cu soluția optimă $\bar{x}(u_0) = (1, 0, 2)^\top$.

$$\bar{z}_2 = \max \{ (u_0^\top \cdot A_2 - c_2^\top) \cdot y \mid y \in S_2 \} =$$

$$= \max \left\{ \frac{1}{7}y_1 - \frac{19}{7}y_2 + \frac{39}{7}y_3 \mid y \in S_2 \right\} = \frac{-18}{7}$$

cu o soluție optimă $\bar{y}(u_0) = (1, 1, 0)^T$.

Pasul 2. Determinăm

$$\max_{i=1,2} \{\bar{z}_i + u_{1i}\} = \max \left\{ \frac{-10}{7} + \frac{11}{7}, \frac{-18}{7} + \frac{18}{7} \right\} = \frac{1}{7}$$

Pasul 3. Coloana care va fi introdusă în bază este:

$$\begin{pmatrix} A_1 \cdot \bar{x}(u_0) \\ e^1 \end{pmatrix} = \begin{pmatrix} -1 \\ 1 \\ 0 \end{pmatrix}$$

iar tabloul simplex revizuit devine:

λ_1	1	0	1	0	1
μ_1	6/7	-1/7	8/7	8/7	9/7
μ_2	1/7	1/7	-8/7	-1/7	-9/7
	-81/7	-11/7	11/7	18/7	1/7

Efectuând operațiile de schimbare a bazei cu pivotul $\frac{9}{7}$, obținem:

λ_1	1/3	1/9	1/9	-8/9	
λ_2	2/3	-1/9	8/9	8/9	
μ_2	1	0	0	1	
	-35/3	-14/9	13/9	22/9	

Multiplicatorii simplex pentru baza curentă sunt:

$$u_0 = \frac{-14}{9}, u_{11} = \frac{13}{9}, u_{12} = \frac{22}{9}$$

Iterația 2.

Pasul 1. Rezolvăm subproblemele (2.2.12):

$$\begin{aligned} \bar{z}_1 &= \max \left\{ (u_0^T \cdot A_1 - c_1^T) \cdot x \mid x \in S_1 \right\} = \\ &= \max \left\{ \frac{-5}{9}x_1 - \frac{1}{9}x_2 - \frac{4}{9}x_3 \mid x \in S_1 \right\} = \frac{-13}{9} \end{aligned}$$

cu o soluție optimă $\bar{x}(u_0) = (2, 3, 0)^\top$.

$$\begin{aligned}\bar{z}_2 &= \max \{ (u_0^\top \cdot A_2 - c_2^\top) \cdot y \mid y \in S_2 \} = \\ &= \max \left\{ \frac{1}{9}y_1 - \frac{8}{3}y_2 + \frac{50}{9}y_3 \mid y \in S_2 \right\} = \frac{-22}{9}\end{aligned}$$

cu soluția optimă $\bar{y}(u_0) = (0, 3, 1)^\top$.

Pasul 2. Deoarece

$$\max_{i=1,2} \{ \bar{z}_i + u_{1i} \} = \max \left\{ \frac{-13}{9} + \frac{13}{9}, \frac{-22}{9} + \frac{22}{9} \right\} = 0$$

am obținut soluția optimă. Valoarea optimă a problemei inițiale este cea obținută în ultimul tablou simplex și este egală cu $\frac{-35}{3}$, iar soluția optimă se calculează cu formulele (2.2.17):

$$\tilde{x} = \begin{pmatrix} \tilde{x}_1 \\ \tilde{x}_2 \\ \tilde{x}_3 \end{pmatrix} = \lambda_1 x^1 + \lambda_2 x^2 = \frac{1}{3} \begin{pmatrix} 2 \\ 3 \\ 0 \end{pmatrix} + \frac{2}{3} \begin{pmatrix} 1 \\ 0 \\ 2 \end{pmatrix} = \begin{pmatrix} \frac{4}{3} \\ \frac{1}{3} \\ \frac{4}{3} \end{pmatrix}$$

$$\tilde{y} = \begin{pmatrix} \tilde{y}_1 \\ \tilde{y}_2 \\ \tilde{y}_3 \end{pmatrix} = \mu_1 y^1 + \mu_2 y^2 = \begin{pmatrix} 0 \\ 3 \\ 1 \end{pmatrix}$$

unde parametrii combinațiilor convexe sunt soluțiile optime ale programului principal.

2.3. Metode de partiționare și relaxare

În numeroase situații, problemele de dimensiuni mari se prezintă cu o structură bloc diagonală în care legătura dintre blocuri se realizează atât prin restricții de cuplare, cât și prin variabile de cuplare. Să considerăm problema următoare, care are blocurile cuplate în ambele moduri:

$$\inf \{ c_1^\top \cdot x^1 + c_2^\top \cdot x^2 + \dots + c_k^\top \cdot x^k + c_0^\top \cdot y \} \quad (2.3.1)$$

în raport cu:

$$A_1 \cdot x^1 + A_2 \cdot x^2 + \dots + A_k \cdot x^k + G_0 \cdot y = b_0 \quad (2.3.2)$$

$$\begin{array}{rcl} D_1 \cdot x^1 & +G_1 \cdot y & = b_1 \\ & D_2 \cdot x^1 & +G_2 \cdot y = b_2 \\ & & \vdots \quad \quad \quad \vdots \\ & & D_k \cdot x^k +G_k \cdot y = b_k \end{array} \quad (2.3.3)$$

$$x^i \geq 0, \quad i = \overline{1, k}, \quad y \geq 0 \quad (2.3.4)$$

Pentru rezolvarea acestei probleme se poate aplica principiul de descompunere Dantzig-Wolfe. Dacă problema are numai variabile de cuplare, atunci procedeul Dantzig-Wolfe poate fi aplicat dualei, care are numai restricții de cuplare. Dacă sunt prezente atât variabile cât și restricții de cuplare, atunci restricțiile se pot partiționa în (2.3.2) și (2.3.3). Restricțiile (2.3.2) vor fi folosite la programul principal, iar (2.3.3) pentru subproblemă. Deoarece subproblema are formă dual-unghiulară, ea poate fi rezolvată direct, sau prin aplicarea din nou a algoritmului Dantzig-Wolfe asupra dualei. În consecință, problema (2.3.1)-(2.3.4) poate fi rezolvată cu principiul de descompunere Dantzig-Wolfe, care se folosește într-un algoritm în care o iterație este structurată pe trei nivele: două nivele pentru rezolvarea subproblemei, și al treilea nivel, pentru rezolvarea programului principal. Deoarece o astfel de iterație este destul de complexă, pot apare unele dificultăți cauzate în special de faptul că metoda Dantzig-Wolfe converge deseori foarte lent.

Problema (2.3.1)-(2.3.4) poate fi abordată și într-un mod diferit, și anume, prin partiționarea variabilelor în două submulțimi, variabilele de cuplare y și variabilele bloc x^i . Variabilele x^i sunt din nou partiționate în mulțimi dependente și independente, în raport cu matricele de bază ale blocurilor D_i . Această partiționare permite ca restricțiile bloc și variabilele dependente să fie eliminate din program, obținându-se o problemă redusă, de dimensiuni mai mici. Astfel de metode se numesc "de partiționare și relaxare". Se folosește termenul de relaxare

deoarece, prin eliminarea variabilelor dependente, se pierde controlul asupra condițiilor de nenegativitate ale acestora.

Conceptul de relaxare a restricțiilor a fost plasat de Geoffrion [12] într-un cadru general, care permite o mai bună înțelegere a aplicării lui la aceste metode.

2.3.1. Principiul de relaxare

Să considerăm problema convexă:

$$\inf \{ f(x) \mid g_i(x) \leq 0, i = \overline{1, m}; x \in S \subseteq \mathbb{R}^n \} \quad (P)$$

unde f și g_i sunt funcții convexe definite pe mulțimea convexă S . Vom presupune că numărul de restricții este suficient de mare ca să producă dificultăți în rezolvarea problemei și că la optim, un număr relativ mic de restricții sunt active. În aceste condiții, o strategie rezonabilă de rezolvare constă în relaxarea (adică, eliminarea temporară) a unor restricții și considerarea unei probleme noi, formată doar cu restricțiile rămase. Dacă această problemă este neadmisibilă, la fel va fi și cea inițială. Dacă aceasta are o soluție optimă care satisface și restricțiile eliminate, atunci soluția va fi optimă și pentru problema inițială. Dacă o parte din restricțiile relaxate nu sunt satisfăcute, atunci un anumit număr dintre acestea vor fi luate în considerare pentru a defini o nouă problemă și procedeul se repetă.

Geoffrion [12] a formalizat această idee după cum urmează. Fie $\mathcal{M} = \{1, 2, \dots, m\}$; se notează cu \mathcal{R} o submulțime a lui \mathcal{M} , $\mathcal{R} \subset \mathcal{M}$, și considerăm problema redusă:

$$\inf \{ f(x) \mid g_i(x) \leq 0, i \in \mathcal{R}; x \in S \} \quad (P_R)$$

Presupunem că poate fi găsită o mulțime inițială \mathcal{R} astfel încât problema redusă (P_R) să aibe un infimum finit și că acesta este atins.

Algoritmul general de partiționare și relaxare:

Pasul 0: Se ia $\bar{f} = -\infty$ și se alege o mulțime inițială $\mathcal{R} \subset \mathcal{M}$ astfel încât f să fie inferior mărginită în raport cu restricțiile problemei reduse (P_R) .

Pasul 1: Se rezolvă problema (P_R) . Dacă aceasta nu admite soluții, atunci evident și problema (P) este neadmisibilă. STOP.

În caz contrar, se obține o soluție optimă \tilde{x}^R .

Pasul 2: Dacă $g_i(\tilde{x}^R) \leq 0$, pentru $i \in \mathcal{M} \setminus \mathcal{R}$, atunci soluția \tilde{x}^R este optimă și pentru problema inițială (P) . STOP.

Pasul 3: În caz contrar, fie

$$\mathcal{V} \subseteq \{i \in \mathcal{M} \setminus \mathcal{R} \mid g_i(\tilde{x}^R) > 0\}$$

o submulțime ce conține cel puțin un indice al unei restricții nesatisfăcute și fie

$$\mathcal{U} = \{i \in \mathcal{R} \mid g_i(\tilde{x}^R) < 0\}.$$

Pasul 4: Dacă $f(\tilde{x}^R) = \bar{f}$, atunci \mathcal{R} se înlocuiește prin $\mathcal{R}' = \mathcal{R} \cup \mathcal{V}$ și se revine la Pasul 1.

Pasul 5: Dacă $f(\tilde{x}^R) > \bar{f}$, atunci \mathcal{R} se înlocuiește prin $\mathcal{R}' = \mathcal{R} \cup \mathcal{V} \setminus \mathcal{U}$, \bar{f} se înlocuiește cu $f(\tilde{x}^R)$ și se revine la Pasul 1.

Acest algoritm adaugă una sau mai multe restricții încălcate și, dacă $f(\tilde{x}^R)$ crește, atunci elimină acele restricții din \mathcal{R} care nu sunt active în \tilde{x}^R . Faptul că nu elimină nici o restricție în cazul în care $f(\tilde{x}^R) = \bar{f}$, garantează, după cum vom arăta în continuare, că rezolvarea problemei (P) se termină într-un număr finit de iterații.

Propoziția 2.6 Fie \tilde{x}^R o soluție optimă a problemei reduse (P_R) . Dacă $g_i(\tilde{x}^R) \leq 0$ pentru orice $i \in \mathcal{M} \setminus \mathcal{R}$, atunci \tilde{x}^R este o soluție optimă și pentru problema (P) .

Demonstrație. Presupunem prin absurd că \tilde{x}^R nu este o soluție optimă a lui (P) . Fie deci $\bar{x} \in \mathbb{R}^n$ astfel încât $g_i(\bar{x}) \leq 0$ pentru orice $i \in \mathcal{M}$ și

$$f(\bar{x}) < f(\tilde{x}^R).$$

Definim

$$x(\lambda) = \lambda \tilde{x}^R + (1 - \lambda) \bar{x}, \quad \lambda \in [0, 1].$$

Pentru orice $i \in \mathcal{M}$ și $\lambda \in [0, 1)$ avem:

$$g_i(x(\lambda)) = g_i(\lambda \tilde{x}^R + (1 - \lambda) \bar{x}) \leq \lambda g_i(\tilde{x}^R) + (1 - \lambda) g_i(\bar{x}) \leq 0$$

și astfel $x(\lambda)$ este o soluție admisibilă a problemei (P_R) . În această situație, avem:

$$f(x(\lambda)) \leq \lambda f(\tilde{x}^R) + (1 - \lambda) f(\bar{x}) < f(\tilde{x}^R),$$

ceea ce contrazice optimalitatea lui \tilde{x}^R în problema (P_R) . ■

Propoziția 2.6 se poate demonstra și altfel: deoarece $\mathcal{R} \subseteq \mathcal{M}$, avem evident

$$\begin{aligned} f(\tilde{x}^R) &= \inf \{f(x) \mid g_i(x) \leq 0, i \in \mathcal{R}\} \leq \\ &\leq \inf \{f(x) \mid g_i(x) \leq 0, i \in \mathcal{M}\} \end{aligned}$$

Pe de altă parte, deoarece $g_i(\tilde{x}^R) \leq 0$ și pentru $i \in \mathcal{M} \setminus \mathcal{R}$, rezultă că \tilde{x}^R este soluție admisibilă pentru problema (P) . Prin urmare, avem

$$\inf \{f(x) \mid g_i(x) \leq 0, i \in \mathcal{M}\} \leq f(\tilde{x}^R)$$

și deci, din relația precedentă obținem:

$$\inf \{f(x) \mid g_i(x) \leq 0, i \in \mathcal{M}\} = f(\tilde{x}^R). \quad \bullet$$

Propoziția 2.7 *Dacă \tilde{x}^R este o soluție optimă a problemei reduse (P_R) și se elimină restricțiile din \mathcal{U} , atunci \tilde{x}^R este o soluție optimă și pentru problema $(P_{R \cup \mathcal{U}})$. În plus, dacă \tilde{x}^R este unica soluție optimă a lui (P_R) , atunci ea este unică și pentru $(P_{R \cup \mathcal{U}})$.*

Demonstrație. Presupunem prin absurd că există $x_0 \in S$ astfel încât $g_i(x_0) \leq 0$ pentru $i \in \mathcal{R} \setminus \mathcal{U}$ și

$$f(x_0) < f(\tilde{x}^R). \quad (2.3.5)$$

Considerăm punctele $x(\lambda)$ de pe segmentul de dreaptă cu extremitățile \tilde{x}^R și x_0 :

$$x(\lambda) = \lambda x_0 + (1 - \lambda) \tilde{x}^R, \quad 0 < \lambda < 1.$$

Deoarece S este convexă, $x(\lambda) \in S$ pentru orice $\lambda \in (0, 1)$.

Funcțiile g_i fiind convexe, avem:

$$g_i(x(\lambda)) \leq \lambda g_i(x_0) + (1 - \lambda) g_i(\tilde{x}^R) \quad (2.3.6)$$

Pentru $i \in \mathcal{R} \setminus \mathcal{U}$ rezultă evident $g_i(x(\lambda)) \leq 0$, pentru orice $\lambda \in (0, 1)$, deoarece $g_i(x_0) \leq 0$ și $g_i(\tilde{x}^R) = 0$.

Pentru $i \in \mathcal{U}$, avem $g_i(\tilde{x}^{\mathcal{R}}) < 0$. Prin urmare, dacă $g_i(x_0) \leq 0$, din (2.3.6) rezultă din nou $g_i(x(\lambda)) \leq 0$, pentru orice $\lambda \in (0, 1)$. Dacă însă $g_i(x_0) > 0$, putem alege λ_0 astfel încât:

$$0 < \lambda_0 \leq \min_{i \in \mathcal{U}} \left\{ \frac{-g_i(\tilde{x}^{\mathcal{R}})}{g_i(x_0) - g_i(\tilde{x}^{\mathcal{R}})} \mid g_i(x_0) > 0 \right\} < 1$$

și din (2.3.6) rezultă $g_i(x(\lambda_0)) \leq 0$. Astfel, $g_i(x(\lambda_0)) \leq 0$, pentru orice $i \in \mathcal{R}$.

În concluzie, $x(\lambda_0)$ este o soluție admisibilă pentru (P_R) . Din convexitatea funcției f și (2.3.5), rezultă:

$$f(x(\lambda_0)) \leq \lambda_0 f(x_0) + (1 - \lambda_0) f(\tilde{x}^{\mathcal{R}}) < f(\tilde{x}^{\mathcal{R}}).$$

Această relație contrazice însă optimalitatea lui $\tilde{x}^{\mathcal{R}}$ în problema (P_R) . Deci, $\tilde{x}^{\mathcal{R}}$ este o soluție optimă a problemei $(P_{R \cup U})$.

Pentru unicitate, dacă presupunem că mai există o soluție optimă x_0 a lui $(P_{R \cup U})$, adică $f(x_0) = f(\tilde{x}^{\mathcal{R}})$, dar $x_0 \neq \tilde{x}^{\mathcal{R}}$, atunci, repetând raționamentul de mai înainte, obținem că $x(\lambda_0) \neq \tilde{x}^{\mathcal{R}}$ este o soluție optimă a lui (P_R) . Însă acest fapt contrazice unicitatea lui $\tilde{x}^{\mathcal{R}}$. ■

Propoziția 2.8 *Dacă $\tilde{x}^{\mathcal{R}}$ și $\tilde{x}^{\mathcal{R}'}$ sunt soluțiile optime a două subprobleme obținute prin relaxare, unde \mathcal{R}' este determinat la Pasul 4 sau 5 al algoritmului, atunci*

$$f(\tilde{x}^{\mathcal{R}}) \leq f(\tilde{x}^{\mathcal{R}'}).$$

Demonstrație. Dacă $\mathcal{R}' = \mathcal{R} \cup \mathcal{V}$, atunci afirmația propoziției este evidentă. Pentru cazul $\mathcal{R}' = \mathcal{R} \cup \mathcal{V} \setminus \mathcal{U}$, folosind Propoziția 2.7, avem:

$$f(\tilde{x}^{\mathcal{R}}) = f(\tilde{x}^{\mathcal{R} \setminus \mathcal{U}}) \leq f(\tilde{x}^{(\mathcal{R} \setminus \mathcal{U}) \cup \mathcal{V}}),$$

ceea ce era de demonstrat. ■

Observația 2.6 *Convexitatea funcțiilor f și g_i , precum și cea a mulțimii S , permit eliminarea restricțiilor neactive. În absența convexității restricțiilor g_i , Propoziția 2.8 rămâne adevărată numai dacă restricțiile se adaugă (cazul $\mathcal{R}' = \mathcal{R} \cup \mathcal{V}$), fără ca vreuna să fie eliminată.*

Propoziția 2.9 *Algoritmul de partiționare și relaxare se termină într-un număr finit de iterații.*

Demonstrație. Deoarece mulțimea de indici \mathcal{M} este finită, ea are doar un număr finit de submulțimi distincte. Atâta timp cât valorile optime $f(\tilde{x}^{\mathcal{R}})$ ale subproblemelor $(P_{\mathcal{R}})$ cresc de la o iterație la alta, nici o submulțime de indici nu se poate repeta. Deoarece în cazul când $f(\tilde{x}^{\mathcal{R}}) = f(\tilde{x}^{\mathcal{R}'})$, nici o restricție nu se elimină și se adaugă cel puțin una, valoarea optimă a subproblemelor generate rămâne constantă numai pentru un număr finit de iterații. Astfel, algoritmul se termină într-un număr finit de iterații, fie la Pasul 1, fie la Pasul 2 (posibil ca $\mathcal{R} = \mathcal{M}$). ■

În cele ce urmează, vom aplica această metodă generală de partiționare și relaxare, la problemele liniare cu restricțiile bloc-unghiulare.

2.3.2. Algoritmul lui Ritter

Ritter [31] a elaborat un procedeu de partiționare pentru probleme liniare care au matricea restricțiilor în formă bloc-diagonală, blocurile fiind unite atât prin restricții de cuplare cât și prin variabile de cuplare. La fiecare iterație variabilele problemei se partiționează în două submulțimi: o mulțime S_1 în care condițiile de nenegativitate sunt relaxate și o mulțime S_2 în care acestea sunt impuse. În momentul în care variabilele din S_1 devin nenegative, soluția curentă este optimă. Procesul iterativ pornește de la o partiție inițială care se modifică până când se găsește o partiție optimă.

Problema pe care o vom studia în continuare se enunță astfel:

$$\inf \left\{ \sum_{i=1}^k c_i^{\top} \cdot x^i + c_0^{\top} \cdot y \right\} \quad (2.3.7)$$

în raport cu:

$$\sum_{i=1}^k A_i \cdot x^i + G_0 \cdot y = b_0 \quad (2.3.8)$$

$$D_i \cdot x^i + G_i \cdot y = b_i, \quad i = \overline{1, k} \quad (2.3.9)$$

$$x^i \geq 0, \quad i = \overline{1, k}, \quad y \geq 0. \quad (2.3.10)$$

Datele problemei au următoarele dimensiuni:

$$\begin{aligned} A_i &\in \mathbb{R}^{m_0 \times n_i}, & D_i &\in \mathbb{R}^{m_i \times n_i}, & i &= \overline{1, k}, \\ G_i &\in \mathbb{R}^{m_i \times n_0}, & c_i &\in \mathbb{R}^{n_i}, & b_i &\in \mathbb{R}^{m_i}, & i &= \overline{0, k}. \end{aligned}$$

Vom presupune că $\text{rang}(D_i) = m_i$, pentru orice $i = \overline{1, k}$. Această ipoteză nu restrânge generalitatea problemei deoarece, în cazul în care $\text{rang}(D_i) < m_i$, putem introduce variabile artificiale pentru a obține rangul dorit. Acestor variabile li se vor atribui în funcția obiectiv coeficienți de cost suficient de mari astfel încât, în cazul unei soluții optime, valoarea tuturor variabilelor artificiale să fie zero.

De asemenea, vom presupune cunoscut un vector inițial $y^0 \in \mathbb{R}^{n_0}$, $y^0 \geq 0$, astfel încât, pentru orice $i = \overline{1, k}$, sistemul

$$D_i \cdot x^i = b_i - G_i \cdot y^0$$

să fie compatibil. (Evident, dacă nu există un astfel de vector y^0 , atunci problema nu are soluții.)

În aceste condiții, pentru fiecare $i = \overline{1, k}$, vom considera subproblema

$$\inf \{ c_i^\top \cdot x^i \mid D_i \cdot x^i = b_i - G_i \cdot y^0, \quad x^i \geq 0 \}. \quad (2.3.11)$$

Prin rezolvarea acestei subprobleme se obține matricea de bază B_i (care poate fi cea optimă, sau o bază primal admisibilă care indică o direcție spre $-\infty$). Astfel, coloanele matricei D_i se pot partiționa în două: $D_i = \left(B_i \mid R_i \right)$ și folosind notațiile obișnuite, din (2.3.9) obținem:

$$x_{B_i} = B_i^{-1} \cdot b_i - B_i^{-1} \cdot R_i \cdot x_{R_i} - B_i^{-1} \cdot G_i \cdot y. \quad (2.3.12)$$

Funcția obiectiv (2.3.7) și restricțiile de cuplare (2.3.8) se pot rescrie și ele în raport cu partiționarea respectivă:

$$\sum_{i=1}^k (c_{B_i}^\top \cdot x_{B_i} + c_{R_i}^\top \cdot x_{R_i}) + c_0^\top \cdot y$$

$$\sum_{i=1}^k (A_{\mathcal{B}_i} \cdot x_{\mathcal{B}_i} + A_{\mathcal{R}_i} \cdot x_{\mathcal{R}_i}) + G_0 \cdot y = b_0$$

Dacă înlocuim pe $x_{\mathcal{B}_i}$ din (2.3.12) în relațiile de mai sus, obținem problema redusă:

$$\left. \begin{array}{l} \text{în raport cu} \\ \inf \left\{ \sum_{i=1}^k \gamma_i^\top \cdot x_{\mathcal{R}_i} + \gamma_0^\top \cdot y \right\} + \alpha \\ \sum_{i=1}^k M_i \cdot x_{\mathcal{R}_i} + M_0 \cdot y = \beta \\ x_{\mathcal{R}_i} \geq \mathbf{0}, \quad i = \overline{1, k}, \quad y \geq \mathbf{0} \end{array} \right\} \quad (P_R)$$

unde am folosit notațiile:

$$\gamma_i^\top = c_{\mathcal{R}_i}^\top - c_{\mathcal{B}_i}^\top \cdot B_i^{-1} \cdot R_i$$

$$\gamma_0^\top = c_0^\top - \sum_{i=1}^k c_{\mathcal{B}_i}^\top \cdot B_i^{-1} \cdot G_i$$

$$\alpha = \sum_{i=1}^k c_{\mathcal{B}_i}^\top \cdot B_i^{-1} \cdot b_i$$

$$M_i = A_{\mathcal{R}_i} - A_{\mathcal{B}_i} \cdot B_i^{-1} \cdot R_i$$

$$M_0 = G_0 - \sum_{i=1}^k A_{\mathcal{B}_i} \cdot B_i^{-1} \cdot G_i$$

$$\beta = b_0 - \sum_{i=1}^k A_{\mathcal{B}_i} \cdot B_i^{-1} \cdot b_i$$

Numărul restricțiilor din problema redusă (P_R) este m_0 , adică exact numărul restricțiilor de cuplare din problema inițială. Din felul în care a fost construit, sistemul de ecuații din problema redusă (P_R) împreună cu relațiile (2.3.12) sunt echivalente cu restricțiile (2.3.8) și (2.3.9). Cu toate acestea, în problema redusă (P_R) , variabilele $x_{\mathcal{B}_i}$, $i = \overline{1, k}$, nu mai sunt supuse condițiilor de nenegativitate și astfel, aceste condiții sunt relaxate. Prin urmare, mulțimea soluțiilor admisibile ale lui (P_R) include pe cea a problemei (2.3.7)-(2.3.10) și astfel, dacă

problema redusă nu are soluții, atunci nici cea inițială nu poate avea soluții. Se poate întâmpla însă ca (P_R) să aibe optim infinit, chiar dacă problema inițială are un optim finit. Pentru a preîntâmpina o astfel de situație, la problema redusă se adaugă restricția de mărginire

$$\sum_{i=1}^k \mathbf{e}_i^T \cdot \mathbf{x}_{\mathcal{R}_i} + \mathbf{e}_0^T \cdot \mathbf{y} \leq \mu$$

unde constanta $\mu > 0$ are o valoare foarte mare, iar vectorii \mathbf{e}_i au toate componentele egale cu 1 și sunt de dimensiuni în concordanță cu $\mathbf{x}_{\mathcal{R}_i}$. Dacă μ este suficient de mare și la terminarea algoritmului această restricție este activă, atunci problema inițială va avea optimul infinit.

Fie $(\tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{R}_k}, \tilde{\mathbf{y}})$ o soluție optimă a problemei reduse (P_R) . Din (2.3.12) obținem:

$$\tilde{\mathbf{x}}_{\mathcal{B}_i} = \mathbf{B}_i^{-1} \cdot (\mathbf{b}_i - \mathbf{R}_i \cdot \tilde{\mathbf{x}}_{\mathcal{R}_i} - \mathbf{G}_i \cdot \tilde{\mathbf{y}}), \quad i = \overline{1, k}. \quad (2.3.13)$$

Astfel, $(\tilde{\mathbf{x}}_{\mathcal{B}_1}, \tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{B}_k}, \tilde{\mathbf{x}}_{\mathcal{R}_k}, \tilde{\mathbf{y}})$ va fi o soluție optimă și pentru problema inițială "modificată", în care condițiile $\mathbf{x}_{\mathcal{B}_i} \geq \mathbf{0}$ au fost eliminate. În baza Propoziției 2.6 putem enunța următorul rezultat:

Teorema 2.10 (de optimalitate) *Dacă $(\tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{R}_k}, \tilde{\mathbf{y}})$ este o soluție optimă a problemei reduse (P_R) și $\tilde{\mathbf{x}}_{\mathcal{B}_i}$ se determină din (2.3.13), atunci $(\tilde{\mathbf{x}}_{\mathcal{B}_1}, \tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{B}_k}, \tilde{\mathbf{x}}_{\mathcal{R}_k}, \tilde{\mathbf{y}})$ este o soluție optimă pentru problema (2.3.7)-(2.3.10) dacă și numai dacă $\tilde{\mathbf{x}}_{\mathcal{B}_i} \geq \mathbf{0}$ pentru orice $i = \overline{1, k}$.*

Modificarea problemei reduse.

Dacă testul de optimalitate nu este îndeplinit, atunci vom putea aplica principiul de relaxare prezentat în paragraful anterior. Astfel, vom forma o problemă redusă nouă, în care se va impune condiția de nenegativitate pentru unele variabile din \mathcal{B}_i cu valori negative (și deci vor intra în (P_R)), în timp ce pentru anumite variabile din \mathcal{R}_i cu valori pozitive, această condiție va fi relaxată (adică, variabilele în cauză vor ieși din (P_R)).

Să presupunem, după o eventuală reordonare a variabilelor din blocul i , că primele $r \geq 1$ componente ale lui $\tilde{\mathbf{x}}_{\mathcal{B}_i}$ sunt negative:

$$(\tilde{\mathbf{x}}_{\mathcal{B}_i})_j < 0, \quad j = \overline{1, r},$$

iar primele $s \geq 0$ componente ale lui $\tilde{x}_{\mathcal{R}_i}$ sunt pozitive¹:

$$(\tilde{x}_{\mathcal{R}_i})_j > 0, \quad j = \overline{1, s}.$$

Legătura dintre $\tilde{x}_{\mathcal{B}_i}$ și $\tilde{x}_{\mathcal{R}_i}$ este dată de relația (2.3.12) care se poate rescrie astfel:

$$x_{\mathcal{B}_i} + B_i^{-1} \cdot R_i \cdot x_{\mathcal{R}_i} = B_i^{-1} \cdot (b_i - G_i \cdot y). \quad (2.3.14)$$

Două cazuri sunt posibile:

Cazul 1. Matricea formată din primele r linii și primele s coloane ale lui $B_i^{-1} \cdot R_i$ conține cel puțin un element diferit de zero.

Pentru a fixa ideile, vom considera că un astfel de element nenul se află în poziția (l, t) , unde $1 \leq l \leq r$ și $1 \leq t \leq s$. În această situație, în relația (2.3.14) se poate efectua o operație de schimbare a bazei (elementul (l, t) al matricei $B_i^{-1} \cdot R_i$ va fi pivotul) în care coloana D_i^l este înlocuită de coloana D_i^t . Cu alte cuvinte, variabila $(x_{\mathcal{R}_i})_t$ pentru care $(\tilde{x}_{\mathcal{R}_i})_t > 0$, este înlocuită de variabila $(x_{\mathcal{B}_i})_j$ pentru care $(\tilde{x}_{\mathcal{B}_i})_j < 0$. Operația de schimbare a bazei se poate efectua de mai multe ori în raport cu elementele nenule din primele r linii și s coloane ale lui $B_i^{-1} \cdot R_i$. Se obține astfel, pentru fiecare bloc i , o nouă matrice de bază \bar{B}_i . Cu ajutorul acestor matrice de bază, se va forma o nouă problemă redusă.

Cazul 2. Matricea formată din primele r linii și primele s coloane ale lui $B_i^{-1} \cdot R_i$ are toate elementele egale cu zero.

În acest caz nu se mai pot efectua operații de schimbare a bazei, în schimb, la problema redusă se va adăuga una sau mai multe restricții care să impună condiția de nenegativitate încălcată. Astfel, dacă $(\tilde{x}_{\mathcal{B}_i})_j < 0$, $1 \leq j \leq r$, pentru a impune condiția $(x_{\mathcal{B}_i})_j \geq 0$, la problema (P_R) se va adăuga restricția

$$(B_i^{-1})_j \cdot (b_i - R_i \cdot x_{\mathcal{R}_i} - G_i \cdot y) \geq 0 \quad (2.3.15)$$

care este de fapt linia j din relația (2.3.12). (Prin $(B_i^{-1})_j$ am notat linia j a matricei B_i^{-1} .)

Operațiile descrise în cazurile 1 sau 2 se pot efectua pentru fiecare bloc i , $1 \leq i \leq k$, pentru care $\tilde{x}_{\mathcal{B}_i}$ are componente negative. Folosind

¹Evident, dacă $s = 0$ înseamnă că $\tilde{x}_{\mathcal{R}_i} = 0$.

matricele de bază B_i rezultate din cazul 1 sau prin adăugarea restricțiilor din cazul 2, se obține o nouă problemă redusă.

Dacă nu suntem la prima iterație în care testul de optimalitate este încălcat, iar problema redusă conține restricții suplimentare de tipul (2.3.15), acestea vor trebui analizate separat, înainte de a se trece la tratarea cazurilor 1 sau 2.

Cazul 3. Dacă restricția (2.3.15) nu este activă pentru soluția optimă a problemei reduse, adică

$$(B_i^{-1})_j \cdot (b_i - R_i \cdot \tilde{x}_{\mathcal{R}_i} - G_i \cdot \tilde{y}) > 0,$$

atunci aceasta poate fi eliminată. Conform Propoziției 2.7, soluția optimă nu va fi afectată de această eliminare.

Cazul 4. Dacă restricția (2.3.15) este activă pentru soluția optimă a problemei reduse, adică

$$(B_i^{-1})_j \cdot (b_i - R_i \cdot \tilde{x}_{\mathcal{R}_i} - G_i \cdot \tilde{y}) = 0,$$

iar în vectorul linie $(B_i^{-1})_j \cdot R_i$ există un element nenul care permite efectuarea unei schimbări de bază astfel încât $(x_{B_i})_j$ să fie înlocuită de o variabilă $(x_{\mathcal{R}_i})_t$ pentru care $(\tilde{x}_{\mathcal{R}_i})_t > 0$, atunci, după efectuarea schimbării de bază, restricția va fi eliminată.

Soluția optimă va rămâne din nou neschimbată deoarece, prin schimbarea bazei, restricția în cauză este de fapt rescrisă într-o formă mai convenabilă, în raport cu o variabilă care este pozitivă, și astfel, condiția aceasta poate fi suprimată.

Cazul 5. Dacă restricția (2.3.15) este activă și toate elementele din vectorul linie $(B_i^{-1})_j \cdot R_i$ sunt nule, atunci aceasta va fi menținută în problema redusă.

Din cele prezentate mai sus, pentru rezolvarea problemei (2.3.7)-(2.3.10), putem enunța următorul algoritm:

Algoritmul lui Ritter

Pasul 0. Prin rezolvarea subproblemelor (2.3.11) se determină matricele de bază inițiale B_i pentru fiecare bloc $i = \overline{1, k}$, și se formează problema redusă (P_R) .

Pasul 1. Se rezolvă problema redusă; se obține soluția $(\tilde{x}_{\mathcal{R}_1}, \dots, \tilde{x}_{\mathcal{R}_k}, \tilde{y})$. Din relația (2.3.13) se calculează $\tilde{x}_{\mathcal{B}_i}$, $i = \overline{1, k}$. Dacă $\tilde{x}_{\mathcal{B}_i} \geq 0$, pentru orice $i = \overline{1, k}$, atunci $(\tilde{x}_{\mathcal{B}_1}, \tilde{x}_{\mathcal{R}_1}, \dots, \tilde{x}_{\mathcal{B}_k}, \tilde{x}_{\mathcal{R}_k}, \tilde{y})$ este o soluție optimă a problemei (2.3.7)-(2.3.10).

Pasul 2. Pentru fiecare bloc în care $\tilde{x}_{\mathcal{B}_i}$ are componente negative, dacă problema redusă conține restricții suplimentare de tipul (2.3.15), atunci acestea vor fi prelucrate conform Cazurilor 3-5.

Pasul 3. Pentru fiecare bloc în care $\tilde{x}_{\mathcal{B}_i}$ are componente negative, fie se efectuează operațiile de schimbare a bazei corespunzătoare Cazului 1, fie se adaugă restricții pentru impunerea unor condiții de nenegativitate din Cazul 2.

Pasul 4. Cu matricele de bază și restricțiile obținute din Pașii 2 și 3, se formează o nouă problemă redusă și se revine la Pasul 1.

Deoarece algoritmul lui Ritter este un procedeu de partiționare și relaxare, se pot aplica rezultatele generale cu privire la această metodă. Astfel, în baza Propoziției 2.8, valorile funcției obiectiv vor fi monoton crescătoare, iar Propoziția 2.9 asigură convergența într-un număr finit de iterații a algoritmului. În consecință, putem enunța următoarea teoremă:

Teorema 2.11 *Dacă eliminarea condițiilor de nenegativitate asupra variabilelor pozitive din $x_{\mathcal{R}_i}$ se face doar dacă valoarea funcției obiectiv este strict crescătoare, atunci algoritmul lui Ritter se termină într-un număr finit de iterații, fie cu o soluție optimă a problemei (2.3.7)-(2.3.10), fie se obține o problemă redusă care nu admite soluții.*

2.3.3. Algoritmul lui Rosen

Metoda de relaxare și partiționare a lui Rosen [33] este o variantă a algoritmului lui Ritter, care se aplică la problemele de optimizare liniară cu restricțiile bloc-unghiulare, adică, care au matricea restricțiilor în formă bloc-diagonală, iar blocurile sunt unite doar prin restricții de cuplare. Evident, pot fi considerate și probleme în care legătura dintre blocuri să fie realizată doar prin variabile de cuplare, deoarece acestora le corespund probleme duale ce au forma descrisă mai înainte.

Din cauza acestei forme a restricțiilor, algoritmul care se obține are anumite avantaje, cum ar fi, de exemplu, faptul că la problema redusă nu mai trebuie adăugate restricții suplimentare. Pe de alta parte, rezolvarea succesivă a problemelor reduse se poate face mai eficient, putându-se utiliza algoritmul simplex dual, deoarece baza optimă de la iterația i , este înlocuită cu ușurință în iterația $i + 1$ de una dual admisibilă.

Problema bloc-unghiulară se enunță astfel:

$$\inf \sum_{i=1}^k c_i^T \cdot x^i \quad (2.3.16)$$

în raport cu:

$$\sum_{i=1}^k A_i \cdot x^i = b_0 \quad (2.3.17)$$

$$D_i \cdot x^i = b_i, \quad i = \overline{1, k} \quad (2.3.18)$$

$$x^i \geq \mathbf{0}, \quad i = \overline{1, k}. \quad (2.3.19)$$

Datele problemei au următoarele dimensiuni:

$$A_i \in \mathbb{R}^{m_0 \times n_i}, \quad D_i \in \mathbb{R}^{m_i \times n_i}, \quad c_i \in \mathbb{R}^{n_i}, \quad i = \overline{1, k},$$

$$b_i \in \mathbb{R}^{m_i}, \quad i = \overline{0, k}.$$

Vom presupune, fără a influența generalitatea problemei, că matricea restricțiilor (2.3.17)-(2.3.18) are rangul egal cu $\sum_{i=0}^k m_i$. De aici rezultă că $\text{rang}(D_i) = m_i$ pentru orice $i = \overline{1, k}$. Pentru determinarea unor baze inițiale asociate fiecărui bloc, se rezolvă subproblemele

$$\inf \{c_i^T \cdot x^i \mid D_i \cdot x^i = b_i, \quad x^i \geq \mathbf{0}\}, \quad i = \overline{1, k} \quad (2.3.20)$$

Dacă una din aceste subprobleme nu are soluție, atunci nici problema (2.3.16)-(2.3.19) nu va avea soluție. În caz contrar, fie B_i bazele obținute prin rezolvarea subproblemelor (2.3.20), acestea putând fi cele optime sau cele care indică o direcție spre $-\infty$. Cu ajutorul acestor baze, partiționăm coloanele matricelor $D_i = \left(B_i \ ; \ R_i \right)$ și folosind

notațiile obișnuite, sistemele (2.3.18) se pot rescrie astfel:

$$x_{B_i} = B_i^{-1} \cdot b_i - B_i^{-1} \cdot R_i \cdot x_{R_i} \quad (2.3.21)$$

În mod similar, se partiționează și funcția obiectiv (2.3.16) și restricțiile de cuplare (2.3.17):

$$\inf \sum_{i=1}^k (c_{B_i}^\top \cdot x_{B_i} + c_{R_i}^\top \cdot x_{R_i})$$

$$\sum_{i=1}^k (A_{B_i} \cdot x_{B_i} + A_{R_i} \cdot x_{R_i}) = b_0$$

și înlocuind aici pe x_{B_i} din (2.3.21), obținem problema redusă:

$$\left. \begin{array}{l} \text{în raport cu} \\ \inf \sum_{i=1}^k \gamma_i^\top \cdot x_{R_i} + \alpha \\ \sum_{i=1}^k M_i \cdot x_{R_i} = \beta \\ x_{R_i} \geq \mathbf{0}, \quad i = \overline{1, k} \end{array} \right\} \quad (P_R)$$

unde am folosit notațiile:

$$\gamma_i^\top = c_{R_i}^\top - c_{B_i}^\top \cdot B_i^{-1} \cdot R_i$$

$$\alpha = \sum_{i=1}^k c_{B_i}^\top \cdot B_i^{-1} \cdot b_i$$

$$M_i = A_{R_i} - A_{B_i} \cdot B_i^{-1} \cdot R_i$$

$$\beta = b_0 - \sum_{i=1}^k A_{B_i} \cdot B_i^{-1} \cdot b_i$$

Problema redusă (P_R) are doar m_0 restricții. Deoarece restricțiile problemei reduse împreună cu (2.3.21) fac parte din restricțiile problemei inițiale, dacă (P_R) nu are soluții, atunci nici problema (2.3.16)-(2.3.19) nu va avea soluții. Există însă posibilitatea ca (P_R) să aibe optim infinit, în timp ce problema inițială să aibe optim finit. Pentru a preîntâmpina o astfel de situație, la problema redusă se adaugă

o restricție de mărginire de forma

$$\sum_{i=1}^k \mathbf{e}_i^T \cdot \mathbf{x}_{\mathcal{R}_i} \leq \mu$$

unde constanta $\mu > 0$ are o valoare foarte mare, iar vectorii \mathbf{e}_i au toate componentele egale cu 1 și sunt de dimensiuni în concordanță cu $\mathbf{x}_{\mathcal{R}_i}$. Dacă μ este suficient de mare și la terminarea algoritmului această restricție este activă, atunci optimul problemei inițiale va tinde spre $-\infty$.

Fie $(\tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{R}_k})$ o soluție optimă a problemei reduse (P_R) . Din (2.3.21) obținem:

$$\tilde{\mathbf{x}}_{\mathcal{B}_i} = B_i^{-1} \cdot b_i - B_i^{-1} \cdot R_i \cdot \tilde{\mathbf{x}}_{\mathcal{R}_i}, \quad i = \overline{1, k}. \quad (2.3.22)$$

Astfel, $(\tilde{\mathbf{x}}_{\mathcal{B}_1}, \tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{B}_k}, \tilde{\mathbf{x}}_{\mathcal{R}_k})$ va fi o soluție optimă și pentru problema inițială "modificată", în care condițiile $\mathbf{x}_{\mathcal{B}_i} \geq \mathbf{0}$ au fost relaxate. Ținând seama de rezultatele anterioare cu privire la metoda de relaxare, putem enunța următoarea teoremă.

Teorema 2.12 (de optimalitate) *Dacă $(\tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{R}_k})$ este o soluție optimă a problemei reduse (P_R) și $\tilde{\mathbf{x}}_{\mathcal{B}_i}$ se determină din (2.3.22), atunci $(\tilde{\mathbf{x}}_{\mathcal{B}_1}, \tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{B}_k}, \tilde{\mathbf{x}}_{\mathcal{R}_k})$ este o soluție optimă pentru problema (2.3.16)-(2.3.19) dacă și numai dacă $\tilde{\mathbf{x}}_{\mathcal{B}_i} \geq \mathbf{0}$ pentru orice $i = \overline{1, k}$.*

Dacă testul de optimalitate nu este îndeplinit, se poate forma o nouă problemă redusă, în care se va impune condiția de nenegativitate pentru cel puțin o variabilă din \mathcal{B}_i cu valori negative, în timp ce pentru o anumită variabilă din \mathcal{R}_i cu valori pozitive, această condiție va fi relaxată (adică, se va putea efectua cel puțin o operație de schimbare a bazei între coloanele din D_i). Deoarece problema (2.3.16)-(2.3.19) nu conține variabile de cuplare, la problema redusă nu mai trebuie să se adauge restricții suplimentare, așa cum a fost cazul la algoritmul lui Ritter.

Teorema 2.13 *Fie $(\tilde{\mathbf{x}}_{\mathcal{R}_1}, \dots, \tilde{\mathbf{x}}_{\mathcal{R}_k})$ o soluție optimă a problemei reduse (P_R) . Dacă pentru un anumit i , $1 \leq i \leq k$, vectorul $\tilde{\mathbf{x}}_{\mathcal{B}_i}$ determinat din (2.3.22), are componente negative, atunci în matricea D_i se poate*

efectua cel puțin o operație de schimbare a bazei de înlocuire a unei coloane D_i^r , pentru care $(\tilde{x}_{B_i})_r < 0$, cu o coloană D_i^s , pentru care $(\tilde{x}_{R_i})_s > 0$.

Demonstrație. Pentru a simplifica scrierea pe parcursul acestei demonstrații, vom renunța la folosirea indicelui i , care indentifică blocul în care condiția de optimalitate este încălcată. Astfel, vom considera partiționarea matricei $D = (B : R) \in \mathbb{R}^{m \times n}$, iar mulțimile de indici pentru coloanele corespunzătoare le notăm cu \mathcal{B} și \mathcal{R} .

Conform ipotezelor de lucru, baza B este primal admisibilă pentru subproblema (2.3.20) și deci, soluția de bază asociată are toate componentele nenegative: $\begin{pmatrix} \bar{x}_{\mathcal{B}} \\ \mathbf{0} \end{pmatrix} \geq \mathbf{0}$, unde $\bar{x}_{\mathcal{B}} = B^{-1} \cdot b$, fiind așadar o soluție admisibilă a sistemului

$$\begin{cases} B \cdot x_{\mathcal{B}} + R \cdot x_{\mathcal{R}} = b \\ x_{\mathcal{B}} \geq \mathbf{0}, \quad x_{\mathcal{R}} \geq \mathbf{0} \end{cases} \quad (2.3.23)$$

Pe de altă parte, vectorul $\begin{pmatrix} \tilde{x}_{\mathcal{B}} \\ \tilde{x}_{\mathcal{R}} \end{pmatrix}$ verifică doar sistemul de ecuații de mai sus, dar încalcă condiția $x_{\mathcal{B}} \geq \mathbf{0}$, deoarece în ipotezele teoremei, $\tilde{x}_{\mathcal{B}}$ conține elemente negative.

Pentru $\lambda \in [0, 1]$ definim vechoul $x(\lambda) \in \mathbb{R}^n$ astfel:

$$x(\lambda) = \begin{pmatrix} x_{\mathcal{B}}(\lambda) \\ x_{\mathcal{R}}(\lambda) \end{pmatrix} = (1 - \lambda) \begin{pmatrix} \bar{x}_{\mathcal{B}} \\ \mathbf{0} \end{pmatrix} + \lambda \begin{pmatrix} \tilde{x}_{\mathcal{B}} \\ \tilde{x}_{\mathcal{R}} \end{pmatrix}.$$

Avem evident $D \cdot x(\lambda) = b$, oricare ar fi $\lambda \in [0, 1]$. Deoarece $x_{\mathcal{R}}(\lambda) = \lambda \tilde{x}_{\mathcal{R}} \geq \mathbf{0}$, pentru ca $x(\lambda)$ să fie o soluție a sistemului (2.3.23), este suficient să impunem condiția

$$x_{\mathcal{B}}(\lambda) = (1 - \lambda) \bar{x}_{\mathcal{B}} + \lambda \tilde{x}_{\mathcal{B}} \geq \mathbf{0},$$

adică,

$$\lambda \leq \frac{(\bar{x}_{\mathcal{B}})_i}{(\bar{x}_{\mathcal{B}})_i - (\tilde{x}_{\mathcal{B}})_i}, \quad \text{pentru orice } i \in \mathcal{I},$$

unde $\mathcal{I} = \{i \mid (\tilde{x}_{\mathcal{B}})_i < 0\} \subseteq \{1, 2, \dots, m\}$. Prin urmare, luând

$$\lambda_0 = \min_{i \in \mathcal{I}} \left\{ \frac{(\bar{x}_{\mathcal{B}})_i}{(\bar{x}_{\mathcal{B}})_i - (\tilde{x}_{\mathcal{B}})_i} \right\} = \frac{(\bar{x}_{\mathcal{B}})_r}{(\bar{x}_{\mathcal{B}})_r - (\tilde{x}_{\mathcal{B}})_r}, \quad (2.3.24)$$

avem $x(\lambda_0) \geq \mathbf{0}$, și $x_r(\lambda_0) = 0$.

Vom nota $\mathcal{J} = \{j \mid (\tilde{x}_{\mathcal{R}})_j > 0\} \subseteq \{1, 2, \dots, n - m\}$. Mulțimea \mathcal{J} este nevidă, deoarece în caz contrar, $\tilde{x}_{\mathcal{R}} = \mathbf{0}$ și atunci, din (2.3.22) rezultă $\tilde{x}_{\mathcal{B}} = B^{-1} \cdot b \geq \mathbf{0}$, ceea ce contrazice ipoteza că $\tilde{x}_{\mathcal{B}}$ are componente negative. Deoarece $x(\lambda_0)$ verifică sistemul $D \cdot x = b$, putem scrie

$$B \cdot (\tilde{x}_{\mathcal{B}} + \lambda_0 (\tilde{x}_{\mathcal{B}} - \tilde{x}_{\mathcal{B}})) + \lambda_0 \sum_{j \in \mathcal{J}} R^j (\tilde{x}_{\mathcal{R}})_j = b,$$

sau, înmulțind la stânga cu B^{-1} și ținând seama că $x_r(\lambda_0) = 0$, avem

$$\sum_{\substack{i=1 \\ i \neq r}}^m x_i(\lambda_0) e^i + \lambda_0 \sum_{j \in \mathcal{J}} B^{-1} \cdot R^j (\tilde{x}_{\mathcal{R}})_j = B^{-1} \cdot b, \quad (2.3.25)$$

unde $e^i \in \mathbb{R}^m$ este vectorul unitar cu 1 pe poziția i . Rangul matricei sistemului (2.3.25) este egal cu m și este același ca cel al matricei D . Deoarece vectorii e^i sunt linear independenți și sunt doar $m - 1$ la număr, rezultă că există un $s \in J$ astfel încât $(B^{-1} \cdot R^s)_r \neq 0$. Cu alte cuvinte, din (2.3.25) deducem că sistemul $D \cdot x = b$ admite o soluție nenegativă chiar și în absența coloanei B^r din matricea D . În baza Teoremei fundamentale a programării liniare, dacă $x(\lambda_0)$ este o soluție admisibilă pentru (2.3.23) în care coloana B^r lipsește, atunci există și o soluție admisibilă de bază. Matricea de bază astfel obținută nu va conține pe B^r , în schimb, va avea în componența ei cel puțin o coloană R^s , $s \in J$. Astfel, teorema este demonstrată. ■

Pentru a obține o nouă bază primal admisibilă \tilde{B}_i corespunzătoare unui bloc neoptimal i , adică pentru care vectorul $\tilde{x}_{\mathcal{B}_i}$, determinat din (2.3.22) are componente negative, este suficient să se rezolve o problemă de tipul

$$\left. \begin{array}{l} \min \{x_r\} \\ \text{în raport cu} \quad B \cdot x_{\mathcal{B}} + \sum_{j \in \mathcal{J}} R^j (x_{\mathcal{R}})_j = b \\ x_{\mathcal{B}} \geq \mathbf{0}, \quad (x_{\mathcal{R}})_j \geq 0, \quad j \in \mathcal{J} \end{array} \right\} \quad (2.3.26)$$

unde indicele r realizează minimumul din relația (2.3.24). O matrice inițială de bază este chiar matricea B , iar problema admite o soluție

optimă în care x_r este o variabilă secundară.

Prin rezolvarea problemelor de tipul (2.3.26) pentru fiecare bloc neoptimal, se obțin matricele de bază noi \tilde{B}_i cu ajutorul cărora se determină o nouă problemă redusă și procedeul se repetă.

Deoarece metoda descrisă aici folosește tot o tehnică de partiționare și relaxare, rezultatele generale se pot aplica și aici pentru a justifica faptul că problema se poate rezolva într-un număr finit de iterații.

Procedeul descris mai sus se poate rezuma în următorul algoritm:

Algoritmul lui Rosen

Pasul 0. Se determină pentru fiecare bloc $i = \overline{1, k}$, bazele inițiale B_i prin rezolvarea subproblemelor (2.3.20). Dacă una din subprobleme nu admite soluție, atunci nici problema (2.3.16)-(2.3.19) nu are soluție. STOP.

Altfel, cu ajutorul bazelor B_i , $i = \overline{1, k}$, se formează problema redusă (P_R).

Pasul 1. Se rezolvă problema redusă (P_R). Dacă (P_R) nu are soluție, atunci nici problema (2.3.16)-(2.3.19) nu are soluție. STOP.

Altfel, se obține o soluție optimă $(\tilde{x}_{\mathcal{R}_1}, \dots, \tilde{x}_{\mathcal{R}_k})$.

Pasul 2. Se calculează \tilde{x}_{B_i} , $i = \overline{1, k}$, din relația (2.3.22).

Pasul 3. Dacă $\tilde{x}_{B_i} \geq 0$, $i = \overline{1, k}$, atunci $(\tilde{x}_{B_1}, \tilde{x}_{\mathcal{R}_1}, \dots, \tilde{x}_{B_k}, \tilde{x}_{\mathcal{R}_k})$ este o soluție optimă a problemei (2.3.16)-(2.3.19). STOP.

În caz contrar, pentru fiecare bloc i în care \tilde{x}_{B_i} are componente negative, se determină indicele $r \in \mathcal{I}$ din formula (2.3.24) și se rezolvă problema (2.3.26) corespunzătoare, obținându-se o nouă bază primal admisibilă \tilde{B}_i .

Pasul 4. Cu ajutorul bazelor \tilde{B}_i obținute la pasul anterior, se formează o nouă problemă redusă și se revine la Pasul 1.

Observația 2.7 *Există diferite moduri în care se poate alege variabila asupra căreia să se impună condiția de nenegativitate încălcată. Deoarece această operație nu conduce la mărirea dimensiunii problemei reduse, devine atractivă ideea de a impune cât mai multe astfel de condiții în același timp. Acest lucru se poate realiza cu ușurință prin*

înlocuirea funcției obiectiv din problema (2.3.26) cu

$$\min \left\{ \sum_{i \in \mathcal{I}} x_i \right\}.$$

Considerarea unor astfel de probleme se poate face pentru fiecare bloc neoptimal.

Observația 2.8 Dacă testul de optimalitate nu este îndeplinit, în urma operațiilor care se efectuează asupra blocurilor neoptimale la Pașii 3 și 4 ai algoritmului, baza optimă a problemei reduse se transformă într-una dual admisibilă. Astfel, la iterația următoare, se poate folosi algoritmul simplex dual pentru rezolvarea problemei reduse.

Pentru a justifica observația de mai sus, să considerăm o problemă cu un singur bloc:

$$\inf \left\{ c^\top \cdot x \mid \begin{array}{l} A \cdot x = b_0 \\ D \cdot x = b \end{array} \cdot x \geq \mathbf{0} \right\}. \quad (2.3.27)$$

în care $A \in \mathbb{R}^{m_0 \times n}$, $D \in \mathbb{R}^{m \times n}$, iar $c \in \mathbb{R}^n$, $b_0 \in \mathbb{R}^{m_0}$ și $b \in \mathbb{R}^m$.

Deoarece orice problemă de programare liniară, care are cel puțin două restricții, poate fi considerată în forma de mai sus, rezultă că algoritmul lui Rosen are un caracter general. Pe de altă parte, într-o problemă cu mai multe blocuri, acestea sunt independente între ele, în sensul că orice schimbare de bază efectuată în cadrul unui bloc nu are efect asupra celorlalte blocuri, iar în ceea ce privește restricțiile de cuplare, schimbările care survin aici se aplică doar în zona care corespunde blocului respectiv. Din această cauză, analiza pe care o facem în continuare asupra problemei (2.3.27) se poate extinde fără nici o dificultate și la problemele cu mai multe blocuri.

Prin partiționarea coloanelor lui $D = \left(B \mid R \right)$ în raport cu o matrice nesingulară B , avem

$$x_B = B^{-1} \cdot b - B^{-1} \cdot R \cdot x_R \quad (2.3.28)$$

și substituind pe x_B în problema (2.3.27), obținem problema redusă

$$\left. \begin{array}{l} \text{în raport cu} \\ \inf \{ \gamma^\top \cdot x_{\mathcal{R}} \} + \alpha \\ M \cdot x_{\mathcal{R}} = \beta \\ x_{\mathcal{R}} \geq \mathbf{0} \end{array} \right\} \quad (2.3.29)$$

în care condiția $x_B \geq \mathbf{0}$ este relaxată și am introdus notațiile:

$$\begin{aligned} \gamma^\top &= c_{\mathcal{R}}^\top - c_B^\top \cdot B^{-1} \cdot R \\ \alpha &= c_B^\top \cdot B^{-1} \cdot b \\ M &= A_{\mathcal{R}} - A_B \cdot B^{-1} \cdot R \\ \beta &= b_0 - A_B \cdot B^{-1} \cdot b \end{aligned}$$

Rezolvarea problemei reduse conduce la partiționarea coloanelor matricei $M = \left(M_1 : M_2 \right)$, unde M_1 este matricea de bază optimă. Vom nota cu \mathcal{R}_1 și \mathcal{R}_2 , mulțimile de indici corespunzătoare coloanelor care intră în componența lui M_1 , respectiv M_2 .

Printr-o eventuală reordonare a coloanelor problemei (2.3.27), putem considera $\mathcal{B} = \{1, 2, \dots, m\}$, $\mathcal{R}_1 = \{m+1, m+2, \dots, m+m_0\}$ și $\mathcal{R}_2 = \{m+m_0+1, \dots, n\}$. Tabloul simplex corespunzător soluției optime a problemei (2.3.27), va avea următoarea structură:

		$x_{\mathcal{R}_1}$	$x_{\mathcal{R}_2}$
$x_{\mathcal{R}_1}$	$\bar{\beta}$	\mathbf{I}_{m_0}	$M_1^{-1} \cdot M_2$
v	$\mathbf{0}_{m_0}^\top$		w^\top

unde $\bar{\beta} = M_1^{-1} \cdot \beta$, v este valoarea optimă a problemei reduse, $\mathbf{0}_{m_0}$ este vectorul nul de dimensiune m_0 , \mathbf{I}_{m_0} este matricea unitate de ordinul m_0 , iar w^\top este vectorul linie constituit din costurile reduse. Deoarece M_1 este o bază optimă, avem $w \leq \mathbf{0}$. Putem extinde acest tablou prin

includerea în el și a restricțiilor (2.3.28):

		x_B	$x_{\mathcal{R}_1}$	$x_{\mathcal{R}_2}$
x_B	\bar{b}	I_m	$Y_{\mathcal{R}_1}$	$Y_{\mathcal{R}_2}$
$x_{\mathcal{R}_1}$	$\bar{\beta}$	$0_{m_0 \times m}$	I_{m_0}	$M_1^{-1} \cdot M_2$
v		0_m^\top	$0_{m_0}^\top$	w^\top

unde $\bar{b} = B^{-1} \cdot b$ și $Y = B^{-1} \cdot R$. De fapt, tabloul de mai sus reprezintă o rescriere a problemei (2.3.27) într-o formă echivalentă.

Dacă presupunem acum că vectorul $\bar{x}_B = \bar{b} - Y_{\mathcal{R}_1} \cdot \bar{\beta}$ are o componentă negativă, fie aceasta $(\bar{x}_B)_r < 0$, atunci, conform algoritmului lui Rosen, există o componentă $y_{rk} \neq 0$ a matricei $Y_{\mathcal{R}_1}$ pentru care $(\bar{x}_{\mathcal{R}_1})_k = \bar{\beta}_k > 0$. Schimbarea de bază, care se efectuează pentru înlocuirea variabilei $(x_{\mathcal{R}_1})_k = x_{m+r-k}$ cu $(x_B)_r = x_r$, se va realiza cu pivotul y_{rk} . Deoarece în tabloul considerat mai sus, ultimul element din coloana $k \in \mathcal{R}_1$ este zero, valorile lui v și w nu se vor modifica în urma schimbării de bază. Astfel, noua bază care se va obține pentru problema redusă va rămâne dual admisibilă. De asemenea, cele m_0 linii din tablou, corespunzătoare lui \mathcal{R}_1 , vor rămâne neschimbate, cu excepția liniei k , care va primi valorile după cum urmează:

	\dots	x_r	\dots	x_{m+1}	\dots	x_{m+k}	\dots	x_{m+m_0}	\dots
\vdots		0		1	\dots	0		0	
		\vdots		\vdots		\vdots		\vdots	
$\bar{\beta}_k - \frac{\bar{b}_r}{y_{rk}}$	\dots	0	$\frac{-1}{y_{rk}}$	0	\dots	$\frac{-y_{rk}}{y_{rk}}$	0	$\frac{-y_{r,m_0}}{y_{rk}}$	\dots
		\vdots		\vdots		\vdots		\vdots	
\vdots		0		0	\dots	0	\dots	1	

De aici se vede cu ușurință că, pentru noua problemă redusă, în care vom avea $\mathcal{R}_1^{nou} = \mathcal{R}_1 \setminus \{k\} \cup \{r\}$, inversa matricei de bază se obține din cea veche astfel:

$$(M_1^{nou})^{-1} = E_{rk} \cdot M_1^{-1}$$

unde E_{rk} este o matrice pătratică de ordinul m_0 , care diferă de matricea unitate doar prin linia k , care se înlocuiește cu linia r a matricei

$Y_{\mathcal{R}_1}$, luând toate elementele cu semnul schimbat

$$E_{rk} = \begin{pmatrix} 1 & & 0 & 0 & 0 & & 0 \\ \vdots & & \vdots & \vdots & \vdots & & \vdots \\ 0 & \cdots & 1 & 0 & 0 & & 0 \\ -y_{r1} & \cdots & -y_{rk-1} & -y_{rk} & -y_{rk+1} & \cdots & -y_{rm_0} \\ 0 & & 0 & 0 & 1 & & 0 \\ \vdots & & \vdots & \vdots & \vdots & & \vdots \\ 0 & & 0 & 0 & 0 & & 1 \end{pmatrix}$$

Indiferent de numărul de schimbări de variabilă care se face între componentele lui x_B și $x_{\mathcal{R}_1}$, valorile lor corespunzătoare nu se vor schimba, deoarece acestea reprezintă soluția unică a sistemului de ecuații

$$\begin{aligned} \mathbf{I}_m \cdot x_B + Y_{\mathcal{R}_1} \cdot x_{\mathcal{R}_1} &= \bar{b} \\ \mathbf{I}_{m_0} \cdot x_{\mathcal{R}_1} &= \bar{\beta} \end{aligned}$$

Prin urmare, noua bază M_1^{nou} , care se obține pentru problema redusă, va fi dual admisibilă, deoarece $w \leq 0$ rămâne neschimbat și soluția corespunzătoare conține componente negative.

2.3.4. Exemplu de aplicare a algoritmului lui Rosen

Să considerăm următoarea problemă:

$$\inf \{-x_1 - x_2 - 2x_5 - x_6 + x_8\}$$

în raport cu

$$\begin{array}{rcccccl} x_1 & +2x_2 & & +2x_5 & +x_6 & & = & 40 \\ x_1 & +x_2 & & +4x_5 & +2x_6 & & = & 50 \\ x_1 & +3x_2 & +x_3 & & & & = & 30 \\ 2x_1 & +x_2 & & +x_4 & & & = & 20 \\ & & & & x_5 & & +x_7 & = & 10 \\ & & & & & & x_6 & +x_8 & = & 10 \\ & & & & x_5 & +x_6 & & +x_9 & = & 15 \end{array}$$

$$x_i \geq 0, \quad i = \overline{1, 9}.$$

Pasul 0. Pentru determinarea bazelor primal admisibile inițiale, vom rezolva subproblemele:

$$\inf \left\{ -x_1 - x_2 \mid \begin{array}{l} x_1 + 3x_2 + x_3 = 30 \\ 2x_1 + x_2 + x_4 = 20 \\ x_i \geq 0, i = \overline{1,4} \end{array} \right\}$$

care are soluția optimă: $x_1 = 6, x_2 = 8, x_3 = x_4 = 0$, și

$$\inf \left\{ -2x_5 - x_6 + x_8 \mid \begin{array}{l} x_5 + x_7 = 10 \\ x_6 + x_8 = 10 \\ x_5 + x_6 + x_9 = 15 \\ x_i \geq 0, i = \overline{5,9} \end{array} \right\}$$

care are soluția optimă: $x_5 = 10, x_6 = x_8 = 5, x_7 = x_9 = 0$.

Bazele inițiale vor fi:

$$B_1 = \begin{pmatrix} 1 & 3 \\ 2 & 1 \end{pmatrix}, \quad \text{care are inversa } B_1^{-1} = \frac{1}{5} \begin{pmatrix} -1 & 3 \\ 2 & -1 \end{pmatrix} \text{ și}$$

$$B_2 = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 1 \\ 1 & 1 & 0 \end{pmatrix}, \quad \text{care are inversa } B_2^{-1} = \begin{pmatrix} 1 & 0 & 0 \\ -1 & 0 & 1 \\ 1 & 1 & -1 \end{pmatrix}$$

Cu ajutorul matricelor de bază B_1 și B_2 , se fac următoarele substituții în funcția obiectiv și în restricțiile de cuplare ale problemei inițiale:

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 6 \\ 8 \end{pmatrix} - \begin{pmatrix} -\frac{1}{5} & \frac{3}{5} \\ \frac{2}{5} & -\frac{1}{5} \end{pmatrix} \begin{pmatrix} x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} 6 + \frac{1}{5}x_3 - \frac{3}{5}x_4 \\ 8 - \frac{2}{5}x_3 + \frac{1}{5}x_4 \end{pmatrix}$$

$$\begin{pmatrix} x_5 \\ x_6 \\ x_8 \end{pmatrix} = \begin{pmatrix} 10 \\ 5 \\ 5 \end{pmatrix} - \begin{pmatrix} 1 & 0 \\ -1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} x_7 \\ x_9 \end{pmatrix} = \begin{pmatrix} 10 - x_7 \\ 5 + x_7 - x_9 \\ 5 - x_7 + x_9 \end{pmatrix}$$

Se obține astfel problema redusă:

$$\inf \left\{ -29 + \frac{1}{5}x_3 + \frac{2}{5}x_4 - x_7 + 3x_9 \mid \begin{array}{l} \frac{3}{5}x_3 + \frac{1}{5}x_4 + x_7 + x_9 = 7 \\ \frac{1}{5}x_3 + \frac{2}{5}x_4 + 2x_7 + 2x_9 = 14 \\ x_i \geq 0, i \in \{3, 4, 7, 9\} \end{array} \right\}$$

Iterația 1.

Pasul 1. Se rezolvă problema redusă, care are soluția optimă:

$$x_7 = 7, x_3 = x_4 = x_9 = 0, \text{ iar valorarea optimă este:} \\ -29 - 7 = -36.$$

Tabloul simplex corespunzător soluției optime este:

	x_3	x_4	x_7	x_9
x_3	0	1	0	0
x_7	7	0	1/5	1
	-7	0	-3/5	-4

Pasul 2. Cu soluția problemei reduse, determinăm valorile variabilelor substituie:

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 6 \\ 8 \end{pmatrix} - \begin{pmatrix} -\frac{1}{5} & \frac{3}{5} \\ \frac{2}{5} & -\frac{1}{5} \end{pmatrix} \begin{pmatrix} 0 \\ 0 \end{pmatrix} = \begin{pmatrix} 6 \\ 8 \end{pmatrix}$$

$$\begin{pmatrix} x_5 \\ x_6 \\ x_8 \end{pmatrix} = \begin{pmatrix} 10 \\ 5 \\ 5 \end{pmatrix} - \begin{pmatrix} 1 & 0 \\ -1 & 1 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} 7 \\ 0 \end{pmatrix} = \begin{pmatrix} 3 \\ 12 \\ -2 \end{pmatrix}$$

Pasul 3. Deoarece $x_8 = -2$, soluția nu este optimă. Va trebui deci să efectuăm o schimbare de bază în blocul al doilea, înlocuindu-l pe x_7 , care este singura variabilă care are o valoare pozitivă, cu x_8 , care are o valoare negativă. Noua bază va corespunde variabilelor x_5 , x_6 și x_7 , deci

$$B_2^{nou} = \begin{pmatrix} 1 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 1 & 0 \end{pmatrix}, \quad (B_2^{nou})^{-1} = \begin{pmatrix} 0 & -1 & 1 \\ 0 & 1 & 0 \\ 1 & 1 & -1 \end{pmatrix}$$

Pasul 4. Se formează o nouă problemă redusă corespunzătoare lui B_2^{nou} , efectuând în problema inițială substituțiile:

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 6 \\ 8 \end{pmatrix} - \begin{pmatrix} -\frac{1}{5} & \frac{3}{5} \\ \frac{2}{5} & -\frac{1}{5} \end{pmatrix} \begin{pmatrix} x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} 6 + \frac{1}{5}x_3 - \frac{3}{5}x_4 \\ 8 - \frac{2}{5}x_3 + \frac{1}{5}x_4 \end{pmatrix}$$

$$\begin{pmatrix} x_5 \\ x_6 \\ x_7 \end{pmatrix} = \begin{pmatrix} 5 \\ 10 \\ 5 \end{pmatrix} - \begin{pmatrix} -1 & 1 \\ 1 & 0 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} x_8 \\ x_9 \end{pmatrix} = \begin{pmatrix} 5 + x_8 - x_9 \\ 10 - x_8 \\ 5 - x_8 + x_9 \end{pmatrix}$$

Problema care se obține este:

$$\inf \left\{ \begin{array}{l} -34 + \frac{1}{5}x_3 + \frac{2}{5}x_4 - x_8 + 2x_9 \\ \frac{3}{5}x_3 + \frac{1}{5}x_4 - x_8 + 2x_9 = 2 \\ \frac{1}{5}x_3 + \frac{2}{5}x_4 - 2x_8 + 4x_9 = 4 \\ x_i \geq 0, i \in \{3, 4, 8, 9\} \end{array} \right\}$$

Iterația 2.

Pasul 1. Pentru rezolvarea problemei reduse, vom scrie tabloul simplex în raport cu baza corespunzătoare lui x_3 și x_8 , care știm că este dual admisibilă:

	x_3	x_4	x_8	x_9	
x_3	0	1	0	0	
x_8	-2	0	-1/5	1	-2
	2	0	-1/5	0	0

Aplicând algoritmul simplex dual, x_8 va fi înlocuit în bază de x_9 :

	x_3	x_4	x_8	x_9	
x_3	0	1	0	0	
x_9	1	0	-1/10	1/2	1
	2	0	-1/5	0	0

Acest tablou este optim, soluția fiind: $x_9 = 1$, $x_3 = x_4 = x_8 = 0$, iar valoarea optimă a problemei reduse va fi egală cu $-34 + 2 = -32$.

Pasul 2. Calculăm valorile variabilelor substituie:

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 6 \\ 8 \end{pmatrix} - \begin{pmatrix} -\frac{1}{5} \\ \frac{2}{5} \end{pmatrix} \begin{pmatrix} \frac{3}{5} \\ -\frac{1}{5} \end{pmatrix} \begin{pmatrix} 0 \\ 0 \end{pmatrix} = \begin{pmatrix} 6 \\ 8 \end{pmatrix}$$

$$\begin{pmatrix} x_5 \\ x_6 \\ x_7 \end{pmatrix} = \begin{pmatrix} 5 \\ 10 \\ 5 \end{pmatrix} - \begin{pmatrix} -1 & 1 \\ 1 & 0 \\ 1 & -1 \end{pmatrix} \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 4 \\ 10 \\ 6 \end{pmatrix}$$

Deoarece acestea sunt toate nenegative, soluția obținută în această iterație este optimă pentru problema bloc-unghiulară: $x_1 = 6$, $x_2 = 8$, $x_3 = x_4 = 0$, $x_5 = 5$, $x_6 = 10$, $x_7 = 5$, $x_8 = 0$, $x_9 = 1$, cu valoarea optimă: -32 .

Capitolul 3

Metode cu șiruri recurente

3.1. Introducere

Algoritmul simplex se bazează pe următoarea strategie: pornește dintr-un punct de extrem al domeniului de admisibilitate (dacă acesta există), alege de-a lungul unei muchii un vârf adiacent cu cel anterior, astfel încât valoarea funcției obiectiv să-și îmbunătățească valoarea; procedul se repetă până când, fie se ajunge într-un vârf optimal, fie valoarea funcției obiectiv devine nemărginită de-a lungul unei raze extreme ale domeniului. Cu alte cuvinte, căutarea soluției optime se face **pe frontiera** domeniului de admisibilitate, direcțiile folosite fiind de-a lungul muchiilor domeniului. Această strategie s-a dovedit însă neadecvată pentru problemele liniare de dimensiuni mari, timpul de rezolvare devenind prohibitiv din cauza numărului mare de iterații care crește exponențial în raport cu dimensiunea problemei.

Murty și Fathi [26] au prezentat variante ale algoritmului simplex care constau în alegerea succesiunii de vârfuri după direcții ce trec prin interiorul domeniului de admisibilitate sau al unei fețe de dimensiune cel puțin doi. Se poate demonstra că, în ipoteze puțin restrictive, acești algoritmi sunt finiți, iar implementarea lor se face folosind inversa bazei curente, întocmai ca la algoritmul simplex. Experimentele de calcul au pus în evidență faptul că timpul de rezolvare a problemelor liniare este îmbunătățit pe această cale față de varianta clasică, dar fenomenul creșterii exponențiale a iterațiilor odată cu creșterea dimensiunii nu este eliminat.

Fenomenul acesta s-a putut constata chiar și la metodele de descompunere sau partiționare, folosite în rezolvarea unor probleme reale.

O alternativă la aceste metode a fost elaborarea unor algoritmi care să construiască un șir de puncte convergent către soluția optimă, fie din interiorul domniului de admisibilitate (metode de punct interior), fie din exteriorul acestuia (metode de punct exterior). Inspirația pentru o astfel de abordare provine din optimizarea neliniară. Ceea ce se urmărește în mod deosebit la aceste metode este ca efortul de calcul să nu mai aibe o creștere exponențială în raport cu dimensiunea problemei, ci să fie "în timp polinomial" - noțiune pe care o vom explica în paragraful următor.

Prin publicarea în 1979 a algoritmului elipsoidal, Hacıan [16] a fost primul care a pus în evidență posibilitatea obținerii unor metode care sunt mai eficiente în rezolvarea problemelor de dimensiuni mari decât cele bazate pe algoritmul simplex. Fiind o metodă de punct exterior, această inovație în ceea ce privește abordarea problemelor liniare, a fost primită pentru început cu destulă rețineră, deoarece viteza sa de convergență nu a fost suficient de convingătoare. Abia după publicarea în 1984 a algoritmului lui Karmarkar [20], interesul pentru astfel de metode alternative a cunoscut o dezvoltare remarcabilă.

Algoritmul lui Karmarkar este o metodă de punct interior pentru rezolvarea problemelor de programare liniară. El necesită cunoașterea unui "punct inițial" din interiorul domeniului de admisibilitate, pentru ca începând cu acesta, să se genereze un șir de puncte din interiorul domeniului de admisibilitate, cu proprietatea că costurile lor să converge către costul optimal.

Există două tipuri de astfel de algoritmi:

- **algoritmul proiectiv**, care folosește transformări proiective pentru generarea șirului de puncte. Karmarkar a demonstrat că algoritmul este convergent și rezolvă problema în timp polinomial;
- **algoritmul afin**, care folosește transformări affine pentru generarea punctelor. Pentru acesta nu s-a demonstrat că poate să convergă în timp polinomial, în schimb, el prezintă evidente avantaje pentru implementarea lui practică și de altfel, majoritatea consemnărilor cu privire la performanțele obținute de algoritmi de punct interior, sunt făcute pentru cazul afin.

Pentru ambele variante există un câmp vectorial al soluțiilor admisibile, care poate fi descris de ecuații diferențiale din care se obțin traiectorii ale soluțiilor admisibile în interiorul domeniului, iar toate aceste traiectorii ajung la o soluție optimă. De regulă, cele două tipuri de algoritmi generează puncte de-a lungul unor traiectorii diferite, dar ele au totuși în comun o traiectorie, numită "traiectoria centrală".

3.2. Algoritmul elipsoidal

Primul algoritm în timp polinomial a fost elaborat de matematicianul sovietic L.G. Hacıan [16] și este o metodă de punct exterior. Acest algoritm nu rezolvă direct o problemă de programare liniară, ci un sistem de inegalități echivalent cu aceasta. Deoarece conceptul principal pe care se bazează este cel de "elipsoid", metoda mai este cunoscută și sub denumirea de "algoritm elipsoidal".

Calculatorul virtual.

Pentru a putea evalua cu mai multă ușurință efortul de calcul în aplicarea algoritmului, vom considera că avem la dispoziție un **calculator virtual**, care are următoarele caracteristici:

- toate operațiile aritmetice (+, -, *, /) sunt efectuate într-o unitate de timp, indiferent de mărimea operanzilor, iar rezultatul este obținut exact (fără trunchiere). De asemenea, rădăcina pătrată se poate extrage exact și tot într-o unitate de timp;
- se pot efectua comparații;
- nu există limitări pentru reprezentarea numerelor.

Evident, calculatoarele reale nu se bucură de toate aceste proprietăți. Rezultatele operațiilor aritmetice sunt de cele mai multe ori trunchiate, ca de altfel și extragerea rădăcinii pătrate, care în plus, se obține în urma unui proces iterativ ce implică foarte multe operații aritmetice.

Mărimea unei probleme.

Fiind dată o problemă de programare liniară, vom numi **mărimea**

problemei numărul de biți necesari pentru reprezentarea binară a tuturor coeficienților nenuli. Acest număr îl vom nota cu L și valoarea sa este estimată prin formula:

$$L = mn + \lceil \log_2 |P| \rceil + n \lceil \log_2 n \rceil \quad (3.2.1)$$

unde m și n sunt dimensiunile problemei, iar P este produsul tuturor coeficienților nenuli din problemă. Notăția $\lceil x \rceil$ reprezintă cel mai mic număr natural care este mai mare sau egal cu x .

Rezolvarea în timp polinomial.

Vom spune că o problemă se poate rezolva **în timp polinomial**, dacă există un polinom p și o metodă de calcul prin care se obține soluția optimă într-un număr de operații ce este mărginit de valoarea $p(L)$, unde L este mărimea problemei.

Bine-nțeles, acest concept este legat de existența calculatorului virtual. Chiar dacă un astfel de calculator nu există în mod real, valoarea $p(L)$ pune în evidență efortul de calcul necesar pentru rezolvarea problemei. Astfel, timpul de rezolvare a unei probleme va avea o creștere "polinomială în timp" în raport cu mărimea L , și nu una "exponențială" în raport cu dimensiunea ei.

3.2.1. Probleme liniare echivalente

Vom considera următoarea problemă de programare liniară:

$$\inf \{ c^T \cdot x \mid A \cdot x = b, x \geq 0 \} \quad (\text{PL})$$

unde $A \in \mathbb{Z}^{m \times n}$, $b \in \mathbb{Z}^m$, $c \in \mathbb{Z}^n$ și $\text{rang}(A) = m$. Cerința ca toate datele problemei să fie numere întregi nu constituie o restrângere a generalității, deoarece, din punct de vedere practic, se lucrează oricum numai cu numere raționale și amplificarea acestora cu numitorul lor comun, conduce la o problemă în forma de mai sus.

Dacă considerăm problema duală a lui (PL):

$$\sup \{ b^T \cdot u \mid A^T \cdot u \leq c \} \quad (\text{DL})$$

atunci rezolvarea problemelor (PL) și (DL) este echivalentă cu găsirea unei soluții a sistemului liniar:

$$\left. \begin{array}{rcl} A \cdot x & = & b \\ x & \geq & \mathbf{0} \\ & A^T \cdot u & \leq c \\ c^T \cdot x - b^T \cdot u & \leq & 0 \end{array} \right\} \quad (\text{SL})$$

Din teoria dualității știm că inegalitatea strictă $c^T \cdot x - b^T \cdot u < 0$ nu are loc niciodată, pentru orice x și u care verifică primele trei condiții din (SL). Prin urmare, o soluție \bar{x} , \bar{u} a lui (SL) trebuie să verifice $c^T \cdot \bar{x} - b^T \cdot \bar{u} = 0$, de unde rezultă că \bar{x} va fi o soluție optimă a lui (PL), iar \bar{u} o soluție optimă a problemei duale (DL).

Sistemul liniar (SL) se poate rescrie cu ușurință sub forma unui sistem liniar de inegalități (orice egalitate este echivalentă cu o pereche de inegalități):

$$S \cdot y \leq \beta$$

unde $y = (x, u)^T \in \mathbb{R}^{n+m}$, iar

$$S = \begin{pmatrix} A & \mathbf{0}_{m \times m} \\ -A & \mathbf{0}_{m \times m} \\ -\mathbf{I}_n & \mathbf{0}_{n \times m} \\ \mathbf{0}_{n \times n} & A^T \\ c^T & -b^T \end{pmatrix} \quad \text{și} \quad \beta = \begin{pmatrix} b \\ -b \\ \mathbf{0}_n \\ c \\ 0 \end{pmatrix}$$

Deoarece în continuare ne vom ocupa de găsirea unei soluții a sistemului de inegalități, vom nota matricea S tot cu A , iar termenul liber β cu b , fără a face confuzie cu notațiile de până acum:

$$A \cdot x \leq b \quad (\text{SI})$$

unde $A \in \mathbb{Z}^{m \times n}$ și $b \in \mathbb{Z}^m$.

Dacă L este mărimea problemei (PL), calculată conform relației (3.2.1), atunci mărimea lui (SI) va fi aproximativ $3L$. Concluzia care se desprinde de aici este următoarea:

Observația 3.1 *Dacă există un algoritm polinomial în timp care să rezolve sistemul de inegalități (SI), atunci și problema de programare liniară (PL) este rezolvată în timp polinomial.*

Următoarele leme oferă unele rezultate tehnice pe care le vom folosi în justificarea algoritmului elipsoidal.

Lema 3.1 *Dacă $v \in \mathbb{R}^n$ este o soluție de bază a sistemului de ecuații $A \cdot x = b$, iar L este mărimea acestuia, atunci există numerele întregi $d \neq 0$ și d_1, d_2, \dots, d_n , astfel încât $v_i = \frac{d_i}{d}$, $i = \overline{1, n}$, iar $|d| < 2^L$ și $|v_i| < 2^L$.*

Demonstrație. Deoarece v este o soluție de bază, există o matrice $B = (A^{i_1} \cdots A^{i_m}) \in \mathbb{Z}^{m \times m}$, formată din coloane liniar independente ale lui A , astfel încât $\det(B) \neq 0$. Vom lua $d = \det(B)$. Elementele lui A fiind numere întregi, rezultă $d \in \mathbb{Z}$. Pe de altă parte, avem:

$$\begin{aligned} |d| &\leq \sum_{\sigma \in S_m} |a_{i_1, \sigma(i_1)} a_{i_2, \sigma(i_2)} \cdots a_{i_m, \sigma(i_m)}| \leq m! |P| \leq \\ &\leq n! |P| \leq n^n |P| = 2^{n \log_2 n + \log_2 |P|} < 2^L. \end{aligned}$$

unde S_m este mulțimea permutărilor de m elemente, iar P produsul tuturor elementelor nenule din A și b .

Deoarece v este o soluție de bază, componentele v_i , care nu corespund coloanelor din B , vor fi egale cu zero și deci putem considera: $v_i = \frac{0}{d}$. Celelalte componente se pot obține din regula lui Cramer, rezolvând sistemul $B \cdot x = b$. Astfel, putem scrie: $v_i = \frac{d_i}{d}$, unde d_i este determinantul obținut din d , în care o anumită coloană este înlocuită cu b . La fel ca mai sus, $|d_i| < 2^L$, și deoarece $d \neq 0$, rezultă $|d| \geq 1$. Prin urmare, $|v_i| < 2^L$. ■

Lema 3.2 *Dacă v și w sunt soluții de bază ale sistemului de ecuații $A \cdot x = b$ și $|c^T \cdot v - c^T \cdot w| \leq 2^{-2L}$, atunci $c^T \cdot v = c^T \cdot w$.*

Demonstrație. Prin reducere la absurd, presupunem $c^T \cdot v \neq c^T \cdot w$. Deoarece componentele soluțiilor de bază v și w sunt numere raționale cu numitorii mai mici ca 2^L , putem scrie: $c^T \cdot v = \frac{N_1}{d_1}$ și $c^T \cdot w = \frac{N_2}{d_2}$, unde $|d_1| < 2^L$ și $|d_2| < 2^L$. Avem:

$$|c^T \cdot v - c^T \cdot w| = \left| \frac{N_1}{d_1} - \frac{N_2}{d_2} \right| = \left| \frac{d_2 N_1 - d_1 N_2}{d_1 d_2} \right|$$

Deoarece $d_2 N_1 - d_1 N_2 \neq 0$, rezultă $|d_2 N_1 - d_1 N_2| \geq 1$, și astfel,

$$|c^\top \cdot v - c^\top \cdot w| \geq \frac{1}{|d_1 d_2|} > 2^{-2L},$$

ceea ce este în contradicție cu ipoteza din enunț. ■

Reamintim că prin A_i notăm linia "i" a matricei A . Pentru orice $v \in \mathbb{R}^n$, vom nota

$$\theta_i(v) = A_i \cdot v - b_i$$

Astfel, dacă v satisface inegalitatea a "i"-a, avem $\theta_i(v) \leq 0$.

Lema 3.3 Pentru orice $v \in \mathbb{R}^n$, există $y \in \mathbb{R}^n$, astfel încât:

- i) $\theta_i(y) \leq \max\{0, \theta_i(v)\}$, pentru orice $i = \overline{1, m}$. Cu alte cuvinte, toate inegalitățile satisfăcute de v nu sunt încălcate de y .
- ii) mulțimea vectorială $\{A_i \mid \text{pentru care } \theta_i(y) \geq 0\}$ este un sistem de generatori pentru liniile matricei A .

Demonstrație. Este suficient să arătăm că, dacă v nu satisface condiția ii), atunci există un vector v' care satisface i) și

$$\{i \mid \theta_i(v') \geq 0\} \supsetneq \{i \mid \theta_i(v) \geq 0\}$$

Reluând un astfel de procedeu de cel mult m ori, obținem vectorul y cu proprietățile cerute de lemă.

Vom presupune, după o eventuală reordonare a liniilor lui A , că

$$\begin{aligned} \theta_i(v) &\geq 0 && \text{pentru } i = \overline{1, k}, \\ \theta_i(v) &< 0 && \text{pentru } i = \overline{k+1, m}. \end{aligned}$$

Deoarece $\{A_1, \dots, A_k\}$ nu este un sistem de generatori pentru liniile matricei A , există $l \in \{k+1, \dots, m\}$ astfel încât liniile A_1, \dots, A_k, A_l să fie liniar independente. Atunci sistemul de ecuații

$$\begin{aligned} A_i \cdot x &= 0, && i = \overline{1, k}, \\ A_l \cdot x &= 1 \end{aligned}$$

este compatibil și are o soluție $u \in \mathbb{R}^n$. Pentru $\lambda \in \mathbb{R}$, definim vectorul

$$v' = v + \lambda u$$

Deoarece $A_l \cdot u = 1$, putem lua

$$\lambda = \min \left\{ \frac{-\theta_i(u)}{A_i \cdot u} \mid A_i \cdot u > 0, k+1 \leq i \leq m \right\}$$

Se observă cu ușurință că $0 < \lambda \leq -\theta_l(u)$ și există un indice $i_* \in \{k+1, \dots, m\}$ pentru care

$$\theta_{i_*}(v) + \lambda A_{i_*} \cdot u = 0$$

Pe de altă parte, avem:

$$\theta_i(v') = A_i \cdot (v + \lambda u) - b = \theta_i(v) + \lambda A_i \cdot u$$

Din alegerea lui λ , rezultă că pentru orice $i = \overline{1, m}$, avem $\theta_i(v') \leq 0$ și în plus, există un indice $i_* \in \{k+1, \dots, m\}$ pentru care avem $\theta_{i_*}(v') = 0$. Astfel, lema este demonstrată. ■

Deoarece algoritmul elipsoidal caută de fapt o soluție a sistemului de inegalități stricte

$$A \cdot x < b' \quad (\text{SIs})$$

unde $b'_i = b_i + \varepsilon$, iar $\varepsilon = 2^{-2L}$ (L fiind mărimea problemei (SI)), teorema care urmează stabilește o anumită echivalență între sistemele (SI) și (SIs).

Teorema 3.4 *Sistemul de inegalități (SI) are o soluție, dacă și numai dacă (SIs) are o soluție. În plus, există un algoritm polinomial în timp care transformă o soluție a lui (SIs) într-o soluție pentru (SI).*

Demonstrație. Evident, orice soluție a lui (SI) este și o soluție pentru (SIs).

Reciproc, fie $v \in \mathbb{R}^n$ o soluție a lui (SIs):

$$A_i \cdot v < b_i + \varepsilon, \quad i = \overline{1, m}.$$

Fie $y \in \mathbb{R}^n$ vectorul obținut prin Lema 3.3. Dacă $A_i \cdot v < b_i$, atunci ,

$$A_i \cdot y - b_i = \theta_i(y) \leq \max \{0, \theta_i(v)\} = 0.$$

Dacă $b_i \leq A_i \cdot v < b_i + \varepsilon$, atunci,

$$A_i \cdot y - b_i = \theta_i(y) \leq \max \{0, \theta_i(v)\} < \varepsilon.$$

Din cele de mai sus rezultă că

$$A_i \cdot y < b_i + \varepsilon, \quad \text{pentru orice } i = \overline{1, m}. \quad (3.2.2)$$

Vom reordona inegalitățile astfel încât

$$A_i \cdot y \geq b_i, \quad 1 \leq i \leq p, \quad (3.2.3)$$

$$A_i \cdot y < b_i, \quad p < i \leq m$$

și deoarece $\{A_1, \dots, A_p\}$ este un sistem de generatori al liniilor matricii A , fie $r \leq p$, numărul de linii liniar independente, adică,

$$\{A_1, \dots, A_r\} \text{ este o bază pentru liniile lui } A. \quad (3.2.4)$$

Fie $z \in \mathbb{R}^n$ o soluție a sistemului de ecuații

$$A_i \cdot z = b_i, \quad 1 \leq i \leq r.$$

Vom arăta că $A \cdot z \leq b$.

Dacă ținem seama de (3.2.4), pentru orice $k = \overline{1, m}$, putem scrie

$$A_k = \sum_{i=1}^r \lambda_i A_i \quad (3.2.5)$$

unde coeficienții $\lambda_i = \frac{d_i}{d}$ se pot obține aplicând regula lui Cramer. Din Lema 3.1 avem $|d| < 2^L$ și pentru orice $i = \overline{1, m}$, $|d_i| < 2^L$. Fără a pierde generalitatea, vom presupune că $d > 0$ (schimbând eventual două linii între ele). Avem:

$$A_k \cdot z - b_k = \sum_{i=1}^r \frac{d_i}{d} A_i \cdot z$$

de unde, prin amplificarea cu d , obținem:

$$d(A_k \cdot z - b_k) = \sum_{i=1}^r d_i b_i - db_k \in \mathbb{Z}. \quad (3.2.6)$$

Pe de altă parte, ținând seama de (3.2.5) și (3.2.2), putem scrie:

$$d(A_k \cdot z - b_k) = \sum_{i=1}^r d_i b_i + d \left(A_k - \sum_{i=1}^r \lambda_i A_i \right) \cdot y - db_k =$$

$$\begin{aligned}
&= -\sum_{i=1}^r d_i (A_i \cdot y - b_i) + d (A_k - b_k) < \\
&< \sum_{i=1}^r |d_i| \varepsilon + d \varepsilon < (r+1) 2^L \varepsilon < \frac{r+1}{2^L} < 1
\end{aligned}$$

Această inegalitate, împreună cu (3.2.6) implică: $d(A_k \cdot z - b_k) \leq 0$.
Deoarece $d > 0$, rezultă

$$A_k \cdot z - b_k \leq 0, \quad \text{pentru orice } k = \overline{1, m}$$

și astfel teorema este demonstrată. ■

3.2.2. Transformări afine și elipsoizi

Definiția 3.1 *Aplicația $T : \mathbb{R}^n \rightarrow \mathbb{R}^n$ este o transformare afină, dacă există $t \in \mathbb{R}^n$ și matricea nesingulară $Q \in \mathbb{R}^{n \times n}$ astfel încât:*

$$T(x) = t + Q \cdot x.$$

Orice transformare afină este inversabilă. Dacă notăm $y = T(x)$, transformarea inversă este:

$$T^{-1}(y) = Q^{-1} \cdot (y - t).$$

De asemenea, se poate demonstra cu ușurință că pentru orice mulțimi $A, B \subseteq \mathbb{R}^n$, avem:

$$T(A \cap B) = T(A) \cap T(B),$$

$$A \subseteq B \implies T(A) \subseteq T(B).$$

Pentru vectorii $x \in \mathbb{R}^n$ vom considera norma euclidiană

$$\|x\| = \sqrt{x^T \cdot x}.$$

Definiția 3.2 *Sfera de centru $c \in \mathbb{R}^n$ și rază $r > 0$ este mulțimea*

$$S(c, r) = \{x \in \mathbb{R}^n \mid \|x - c\| \leq r\}.$$

Definiția 3.3 *Imaginea sferei unitate $S(0, 1)$ printr-o transformare afină $T(x) = t + Q \cdot x$ este un elipsoid:*

$$T(S(0, 1)) = \{t + Q \cdot x \mid x^T \cdot x \leq 1\}.$$

Dacă notăm $y = t + Q \cdot x$, atunci $x = Q^{-1} \cdot (y - t)$, și prin urmare,

$$\begin{aligned} T(S(\mathbf{0}, 1)) &= \{t + Q \cdot x \mid x^\top \cdot x \leq 1\} = \\ &= \left\{y \mid (y - t)^\top \cdot (Q^{-1})^\top \cdot Q^{-1} \cdot (y - t) \leq 1\right\} = \\ &= \left\{y \mid (y - t)^\top \cdot B^{-1} \cdot (y - t) \leq 1\right\}, \end{aligned}$$

unde am notat $B = Q \cdot Q^\top$.

Deoarece Q este nesingulară, matricea B este simetrică și pozitiv definită. Reciproc, pentru orice matrice B , simetrică și pozitiv definită, există o matrice nesingulară Q astfel încât $B = Q \cdot Q^\top$.

Din cele prezentate mai sus rezultă că orice elipsoid E_t este descris de o formă pătratică:

$$E_t = \left\{y \in \mathbb{R}^n \mid (y - t)^\top \cdot B^{-1} \cdot (y - t) \leq 1\right\},$$

unde $t \in \mathbb{R}^n$ este centrul elipsoidului, iar B este o matrice simetrică și pozitiv definită.

Pentru a înțelege mai bine fenomenul care se petrece prin aplicarea unei transformări afine, să considerăm elipsoidul centrat în originea spațiului \mathbb{R}^n :

$$E_0 = \left\{y \in \mathbb{R}^n \mid y^\top \cdot B^{-1} \cdot y \leq 1\right\}.$$

Fie matricea diagonală $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_n)$, unde $\lambda_i, i = \overline{1, n}$, sunt valorile proprii ale matricii B și U matricea ortonormală ($U^{-1} = U^\top$), cu liniile formate din vectorii proprii normalizați, corespunzători valorilor proprii. Din teoria spectrală se știe că:

$$B = U^\top \cdot \Lambda \cdot U$$

și prin urmare avem

$$B^{-1} = U^\top \cdot \Lambda^{-1} \cdot U = \left(\sqrt{\Lambda^{-1}} \cdot U\right)^\top \cdot \left(\sqrt{\Lambda^{-1}} \cdot U\right),$$

unde $\sqrt{\Lambda^{-1}} = \text{diag}\left(\frac{1}{\sqrt{\lambda_1}}, \dots, \frac{1}{\sqrt{\lambda_n}}\right)$. Ținând cont de aceste lucruri, putem scrie:

$$\begin{aligned} E_0 &= \left\{y \in \mathbb{R}^n \mid y^\top \cdot \left(\sqrt{\Lambda^{-1}} \cdot U\right)^\top \cdot \left(\sqrt{\Lambda^{-1}} \cdot U\right) \cdot y \leq 1\right\} = \\ &= \left\{y \in \mathbb{R}^n \mid \left(\sqrt{\Lambda^{-1}} \cdot U \cdot y\right)^\top \cdot \left(\sqrt{\Lambda^{-1}} \cdot U \cdot y\right) \leq 1\right\}. \end{aligned}$$

Dacă notăm $x = \sqrt{\Lambda^{-1}} \cdot U \cdot y$, atunci $y = U^T \cdot \sqrt{\Lambda} \cdot x$, de unde rezultă

$$E_0 = \left\{ U^T \cdot \sqrt{\Lambda} \cdot x \mid x^T \cdot x \leq 1 \right\}.$$

Interpretând expresia de mai sus, coordonatele unui punct $x \in S(0, 1)$ sunt scalate fiecare cu factorul $\sqrt{\lambda_i}$, $1 \leq i \leq n$, iar după aceea U^T efectuează o rotație asupra lor.

Exemplul 3.1

Să considerăm matricea $B = \begin{pmatrix} 5 & 2 \\ 2 & 8 \end{pmatrix}$, a cărei inversă este $B^{-1} = \begin{pmatrix} \frac{2}{9} & -\frac{1}{18} \\ -\frac{1}{18} & \frac{5}{36} \end{pmatrix}$. Elipsa cu centrul în sistemul axelor de coordonate, definită de această matrice, este:

$$\begin{aligned} E_0 &= \{y \in \mathbb{R}^2 \mid y^T \cdot B^{-1} \cdot y \leq 1\} = \\ &= \left\{ y \in \mathbb{R}^2 \mid \frac{2}{9}y_1^2 - \frac{1}{9}y_1y_2 + \frac{5}{36}y_2^2 - 1 \leq 1 \right\}. \end{aligned}$$

Valorile proprii și vectorii proprii normalizați ai matricei B sunt:

$$4 \leftrightarrow \begin{pmatrix} \frac{2}{\sqrt{5}} \\ -\frac{1}{\sqrt{5}} \end{pmatrix} \quad \text{și} \quad 9 \leftrightarrow \begin{pmatrix} \frac{1}{\sqrt{5}} \\ \frac{2}{\sqrt{5}} \end{pmatrix}.$$

Prin urmare, avem:


$$\begin{aligned} B &= \begin{pmatrix} \frac{2}{\sqrt{5}} & \frac{1}{\sqrt{5}} \\ -\frac{1}{\sqrt{5}} & \frac{2}{\sqrt{5}} \end{pmatrix} \begin{pmatrix} 4 & 0 \\ 0 & 9 \end{pmatrix} \begin{pmatrix} \frac{2}{\sqrt{5}} & -\frac{1}{\sqrt{5}} \\ \frac{1}{\sqrt{5}} & \frac{2}{\sqrt{5}} \end{pmatrix} = \\ &= \begin{pmatrix} \frac{2}{\sqrt{5}} & \frac{1}{\sqrt{5}} \\ -\frac{1}{\sqrt{5}} & \frac{2}{\sqrt{5}} \end{pmatrix} \begin{pmatrix} 2 & 0 \\ 0 & 3 \end{pmatrix} \begin{pmatrix} 2 & 0 \\ 0 & 3 \end{pmatrix} \begin{pmatrix} \frac{2}{\sqrt{5}} & -\frac{1}{\sqrt{5}} \\ \frac{1}{\sqrt{5}} & \frac{2}{\sqrt{5}} \end{pmatrix}. \end{aligned}$$

și deci, elipsa se poate descrie astfel:

$$E_0 = \left\{ \begin{pmatrix} \frac{2}{\sqrt{5}} & \frac{1}{\sqrt{5}} \\ -\frac{1}{\sqrt{5}} & \frac{2}{\sqrt{5}} \end{pmatrix} \begin{pmatrix} 2x_1 \\ 3x_2 \end{pmatrix} \mid x_1^2 + x_2^2 \leq 1 \right\},$$

adică, punctele din sfera unitate sunt scalate cu factorul 2 în prima componentă, cu 3 în cea de-a doua componentă, iar apoi se efectuează rotația dată de matricea $\frac{1}{\sqrt{5}} \begin{pmatrix} 2 & 1 \\ -1 & 2 \end{pmatrix}$. De exemplu, punctul

$x = \begin{pmatrix} 0 \\ 1 \end{pmatrix}$ de pe sfera unitate, devine $y = \frac{3}{\sqrt{5}} \begin{pmatrix} 1 \\ 2 \end{pmatrix}$, și reprezintă vârful elipsei din cadranul întâi. În figura alăturată sunt reprezentate cercul unitate și elipsa E_0 .



Următoarele rezultate, cunoscute din geometrie și algebra liniară, vor fi utilizate în demonstrațiile teoremelor care justifică algoritmul elipsoidal.

Propoziția 3.5 [34, p. 54] *Fiind dată transformarea afină $T(x) = t + Q \cdot x$ și mulțimea $E \subset \mathbb{R}^n$, de volum $\text{vol}(E)$, avem*

$$\text{vol}(T(E)) = |\det(Q)| \text{vol}(E).$$

Propoziția 3.6 (Gram-Schmidt) *Pentru orice vector $v \in \mathbb{R}^n$, există o matrice ortogonală U astfel încât: $U \cdot v = (\|v\|, 0, \dots, 0)^T$.*

Pentru $v_0, v_1, \dots, v_n \in \mathbb{R}^n$, vom nota $Co(v_0, v_1, \dots, v_n)$ acoperirea convexă a mulțimii $\{v_0, v_1, \dots, v_n\}$.

Propoziția 3.7 *Dacă mulțimea $P = \{x \in \mathbb{R}^n \mid A \cdot x \leq b\}$ are interiorul nevid, atunci există $n + 1$ puncte extreme v_0, v_1, \dots, v_n ale lui P pentru care $\text{vol}(Co(v_0, v_1, \dots, v_n)) > 0$.*

Propoziția 3.8 *Pentru orice puncte $v_0, v_1, \dots, v_n \in \mathbb{R}^n$, avem:*

$$\text{vol}(Co(v_0, v_1, \dots, v_n)) \geq \frac{1}{n!} \left| \det \begin{pmatrix} 1 & 1 & 1 & \dots & 1 \\ | & | & | & & | \\ v_0 & v_1 & v_2 & \dots & v_n \\ | & | & | & & | \end{pmatrix} \right|$$

3.2.3. Algoritmul elipsoidal

Algoritmul elipsoidal al lui Hacıan determină o soluție a sistemului de inegalități stricte (SIs) în timp polinomial. Ideea de rezolvare este următoarea: la fiecare iterație se construiește un elipsoid E , care include mulțimea $P = \{x \in \mathbb{R}^n \mid A \cdot x < b\}$. Dacă centrul t al lui E aparține lui P , atunci t conține soluția optimă a problemei de programare liniară și algoritmul se oprește. În caz contrar, există o restricție "i" pentru care $A_i \cdot t \geq b_i$. Această inegalitate definește un semispațiu care trece prin t și nu-l conține pe P . Prin urmare,

$$P \subset E \cap \{x \in \mathbb{R}^n \mid A_i \cdot (x - t) \leq 0\}.$$

Algoritmul construiește un nou elipsoid E' care va include mulțimea P (mai exact, $E' \supset E \cap \{x \in \mathbb{R}^n \mid A_i \cdot (x - t) \leq 0\}$), și va avea volumul strict mai mic decât cel al lui E : $\text{vol}(E') < \text{vol}(E)$.

În acest mod, algoritmul lui Hacıan generează un șir de elipsoizi, care conțin mulțimea P și al căror volum este descrescător, până când centrul unuia aparține lui P .

În cazul în care mulțimea P este vidă, criteriul de oprire a procedurii descris mai sus se va baza pe faptul că, pentru toate mulțimile de forma lui P , există o margine inferioară $\mu > 0$ a volumelor lor (reamintim că A și b au componentele numere întregi). Astfel, dacă volumul unui elipsoid devine mai mic decât μ , atunci răspunsul algoritmului va fi: $P = \emptyset$.

În continuare, vom considera că L este mărimea problemei (SIs) și că la iterația k , elipsoidul cu centrul în punctul t_k este definit de matricea pozitiv definită B_k :

$$E_k = \left\{ x \in \mathbb{R}^n \mid (x - t_k)^\top \cdot B_k^{-1} \cdot (x - t_k) \leq 1 \right\} \quad (3.2.7)$$

Elipsoidul inițial va fi sfera de rază $n2^L$, astfel că $S(\mathbf{0}, n2^L) \supseteq P$.

Algoritm elipsoidal.

Pasul 0. Luăm $K = 16n(n+1)L$, $t_0 = \mathbf{0}$, și $B_0 = n^2 2^{2L} \mathbf{I}_n$.

Pentru $k = \overline{0, K}$, se efectuează operațiile următoare:

Pasul k.

- Dacă $A \cdot t_k < b$, scrie "soluția problemei este t_k ". STOP.
- Dacă există un indice i pentru care $A_i \cdot t_k \geq b_i$, notăm $a = A_i^\top$ și calculăm:

$$t_{k+1} = t_k - \frac{1}{n+1} \frac{B_k \cdot a}{\sqrt{a^\top \cdot B_k \cdot a}} \quad (3.2.8)$$

$$B_{k+1} = \frac{n^2}{n^2 - 1} \left[B_k - \frac{2}{n+1} \frac{(B_k \cdot a) \cdot (B_k \cdot a)^\top}{a^\top \cdot B_k \cdot a} \right] \quad (3.2.9)$$

Se trece la pasul următor.

Pasul K+1. Scrie " $P = \emptyset$ ". (Elipsoidul a devenit prea mic ca problema (SIs) să admită soluții.

Exemplul 3.2


Să presupunem că $B_k = \begin{pmatrix} 5 & 2 \\ 2 & 8 \end{pmatrix}$, $t_k = \begin{pmatrix} 0 \\ 0 \end{pmatrix}$ definesc elipsa E_k , iar restricția încălcată a sistemului de inegalități este $x_1 - x_2 < -1$. În această situație, avem:

$$B_k \cdot a = \begin{pmatrix} 5 & 2 \\ 2 & 8 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ -1 \end{pmatrix} = \begin{pmatrix} 3 \\ -6 \end{pmatrix}$$

și $a^\top \cdot B_k \cdot a = 9$. Efectuând calculele conform relațiilor (3.2.8) și (3.2.9), obținem:

$$t_{k+1} = \frac{1}{3} \begin{pmatrix} -1 \\ 2 \end{pmatrix}, \quad B_{k+1} = \frac{1}{9} \begin{pmatrix} 52 & 40 \\ 40 & 64 \end{pmatrix}$$

Ar fi suficient ca noua elipsă să includă doar regiunea mărginită de elipsa centrată în origine și semiplanul deasupra dreptei $x_1 - x_2 = -1$. Deoarece formulele corespunzătoare unei astfel de condiții ar fi mult prea complicate în cazul general, se preferă ca noua elipsă să includă semielipsa obținută prin intersecția dreptei $x_1 - x_2 = 0$, care este paralelă cu restricția încălcată. Figura alăturată ilustrează situația din cazul nostru.



Înainte de a justifica corectitudinea algoritmului descris mai sus, vom demonstra două propoziții ajutătoare.

Propoziția 3.9 Fie $n \geq 2$ și considerăm mulțimea

$$E = \left\{ x \in \mathbb{R}^n \mid (x - t)^\top \cdot B^{-1} \cdot (x - t) \leq 1 \right\},$$

unde $t = \left(\frac{-1}{n+1}, 0, \dots, 0 \right)^\top \in \mathbb{R}^n$ și

$$B = \begin{pmatrix} \frac{n^2}{(n+1)^2} & 0 & 0 \\ 0 & \frac{n^2}{n^2-1} & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & \frac{n^2}{n^2-1} \end{pmatrix}$$

Au loc următoarele:

- (a) matricea B este pozitiv definită (deci, E este un elipsoid);
- (b) semisfera $HS \stackrel{\text{def}}{=} \{x \in \mathbb{R}^n \mid x^\top \cdot x \leq 1, x_1 \leq 0\} \subseteq E$;
- (c) $\frac{\text{vol}(E)}{\text{vol}(S(0,1))} < 2^{2\binom{-1}{n+1}}$.

Demonstrație. (a) Avem evident $B = Q \cdot Q^\top$, unde $Q = \sqrt{B}$ este următoarea matrice nesară:

$$Q = \begin{pmatrix} \frac{n}{n+1} & 0 & 0 \\ 0 & \frac{n}{\sqrt{n^2-1}} & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & \frac{n}{\sqrt{n^2-1}} \end{pmatrix}$$

(b) Fie $x \in HS$. Deoarece $x^\top \cdot x \leq 1$, rezultă $|x_i| \leq 1$, pentru orice $i = \overline{1, n}$. În particular, pentru $x_1 \leq 0$, vom avea: $x_1^2 + x_1 \leq 0$. Prin urmare, avem:

$$\begin{aligned} (x-t)^\top \cdot B^{-1} \cdot (x-t) &= \frac{(n+1)^2}{n^2} \left(x_1 + \frac{1}{n+1} \right)^2 + \sum_{i=2}^n x_i^2 = \\ &= \frac{n^2-1}{n^2} x^\top \cdot x + \frac{2n+2}{n^2} (x_1^2 + x_1) + \frac{1}{n^2} \leq \\ &\leq \frac{n^2-1}{n^2} + \frac{1}{n^2} = 1, \end{aligned}$$

deci, $HS \subseteq E$.

(c) Dacă considerăm transformarea afină $T(x) = t + Q \cdot x$, atunci $E = T(S(\mathbf{0}, 1))$. Folosind Propoziția 3.5, avem:

$$\begin{aligned} \frac{\text{vol}(E)}{\text{vol}(S(\mathbf{0}, 1))} &= |\det Q| = \frac{n}{n+1} \left(\frac{n^2}{n^2-1} \right)^{\frac{n-1}{2}} = \\ &= \left(1 - \frac{1}{n+1} \right) \left(1 + \frac{1}{n^2-1} \right)^{\frac{n-1}{2}} \end{aligned}$$

Dacă ținem seama de inegalitatea: $1 + y \leq \exp(y)$, $\forall y \in \mathbb{R}$, atunci,

$$\begin{aligned} |\det Q| &\leq \exp \left(-\frac{1}{n+1} + \frac{n-1}{2(n^2-1)} \right) = \\ &= \exp \left(\frac{-1}{2(n+1)} \right) < 2^{\frac{-1}{2(n+1)}}. \end{aligned}$$

■

Propoziția 3.10 Fie B_k o matrice pozitiv definită și $t_k \in \mathbb{R}^n$. Fie $a \in \mathbb{R}^n$, $a \neq \mathbf{0}$, iar t_{k+1} și B_{k+1} sunt date de (3.2.8), respectiv de (3.2.9). Notăm

$$HE_k(a) = E_k \cap \{x \in \mathbb{R}^n \mid a^\top \cdot (x - t_k) \leq 0\}$$

unde E_k este elipsoidul definit prin (3.2.7); analog se definește și E_{k+1} . Dacă E și HS sunt cele din Propoziția 3.9, atunci există o transformare afină $T(\cdot)$ astfel încât:

(a) $T(S(\mathbf{0}, 1)) = E_k$;

$$(b) T(E) = E_{k+1};$$

$$(c) T(HS) = HE_k(a).$$

Demonstrație. Deoarece matricea B_k este pozitiv definită, există Q_k nesingulară, astfel încât $B_k = Q_k \cdot Q_k^\top$. În baza Propoziției 3.6, există matricea ortogonală U^\top (reamintim $U \cdot U^\top = I$) astfel încât

$$U^\top \cdot Q_k^\top \cdot a = (\|Q_k^\top \cdot a\|, 0, \dots, 0)^\top.$$

Definim transformarea afină $T(\cdot)$ astfel:

$$T(x) = t_k + (Q_k \cdot U) \cdot x \quad (3.2.10)$$

(a) Imaginea sferei unitate prin transformarea definită mai sus, este:

$$\begin{aligned} T(S(0, 1)) &= \{T(x) \mid x^\top \cdot x \leq 1\} = \\ &= \{y \mid (T^{-1}(y))^\top \cdot (T^{-1}(y)) \leq 1\} = \\ &= \{y \mid (y - t_k)^\top \cdot (Q_k^{-1})^\top \cdot U \cdot U^\top \cdot Q_k^{-1} \cdot (y - t_k) \leq 1\} \\ &= \{y \mid (y - t_k)^\top \cdot B_k^{-1} \cdot (y - t_k) \leq 1\} = E_k \end{aligned}$$

(b) Pentru a arăta că are loc cea de-a doua egalitate, vom exprima mai întâi matricea B_{k+1} și vectorul $x - t_{k+1}$ într-o formă echivalentă, ținând seama că putem scrie $B_k = Q_k \cdot U \cdot U^\top \cdot Q_k^\top$.

$$\begin{aligned} B_{k+1} &= \frac{n^2}{n^2-1} \left[B_k - \frac{2}{n+1} \frac{(B_k \cdot a) \cdot (B_k \cdot a)^\top}{a^\top \cdot B_k \cdot a} \right] = \\ &= \frac{n^2}{n^2-1} \left[Q_k \cdot U \cdot U^\top \cdot Q_k^\top - \frac{2}{n+1} \frac{(Q_k \cdot U \cdot U^\top \cdot Q_k^\top \cdot a) \cdot (Q_k \cdot U \cdot U^\top \cdot Q_k^\top \cdot a)^\top}{a^\top \cdot Q_k \cdot U \cdot U^\top \cdot Q_k^\top \cdot a} \right] = \\ &= Q_k \cdot U \cdot \left[\frac{n^2}{n^2-1} I - \frac{2n^2}{(n^2-1)(n+1)} \frac{(U^\top \cdot Q_k^\top \cdot a)(U^\top \cdot Q_k^\top \cdot a)^\top}{\|Q_k^\top \cdot a\|^2} \right] \cdot U^\top \cdot Q_k^\top \end{aligned}$$

Deoarece avem

$$(U^\top \cdot Q_k^\top \cdot a) (U^\top \cdot Q_k^\top \cdot a)^\top = \begin{pmatrix} \|Q_k^\top \cdot a\|^2 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 0 \end{pmatrix}$$

rezultă

$$\begin{aligned}
 B_{k+1} &= Q_k \cdot U \cdot \begin{pmatrix} \frac{n^2}{(n+1)^2} & 0 & 0 \\ 0 & \frac{n^2}{n^2-1} & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & \frac{n^2}{n^2-1} \end{pmatrix} \cdot U^\top \cdot Q_k^\top = \\
 &= Q_k \cdot U \cdot B \cdot U^\top \cdot Q_k^\top
 \end{aligned} \tag{3.2.11}$$

unde B este matricea definită în Propoziția 3.9.

În continuare, avem:

$$\begin{aligned}
 x - t_{k+1} &= x - t_k + \frac{1}{n+1} \frac{Q_k \cdot U \cdot U^\top \cdot Q_k^\top \cdot a}{\|Q_k^\top \cdot a\|} = \\
 &= x - t_k - Q_k \cdot U \cdot t
 \end{aligned}$$

unde $t = (\frac{-1}{n+1}, 0, \dots, 0)^\top$ este centrul elipsoidului E . Ținând seama de (3.2.10), putem scrie: $x - t_k = Q_k \cdot U \cdot T^{-1}(x)$, și prin urmare.

$$x - t_{k+1} = Q_k \cdot U \cdot (T^{-1}(x) - t) \tag{3.2.12}$$

Folosind acum relațiile (3.2.11) și (3.2.12), rezultă următoarele:

$$\begin{aligned}
 T(E) &= \left\{ T(x) \mid (x - t)^\top \cdot B^{-1} \cdot (x - t) \leq 1 \right\} = \\
 &= \left\{ x \mid (T^{-1}(x) - t)^\top \cdot B^{-1} \cdot (T^{-1}(x) - t) \leq 1 \right\} = \\
 &= \left\{ x \mid (x - t_{k+1})^\top \cdot (Q_k^{-1}) \cdot U \cdot B^{-1} \cdot U^\top \cdot Q_k^{-1} \cdot (x - t_{k+1}) \leq 1 \right\} = \\
 &= \left\{ x \mid (x - t_{k+1})^\top \cdot B_{k+1}^{-1} \cdot (x - t_{k+1}) \leq 1 \right\} = E_{k+1}.
 \end{aligned}$$

(c) Pentru orice vector $x \in \mathbb{R}^n$ au loc următoarele echivalențe evidente:

$$x_1 \leq 0 \iff \|Q_k^\top \cdot a\| x_1 \leq 0 \iff x^\top \cdot U^\top \cdot Q_k^{-1} \cdot a \leq 0.$$

De aici rezultă

$$\begin{aligned}
 T(\{x \in \mathbb{R}^n \mid x_1 \leq 0\}) &= \{T(x) \mid x^\top \cdot U^\top \cdot Q_k^\top \cdot a \leq 0\} = \\
 &= \{y \mid (T^{-1}(y))^\top \cdot U^\top \cdot Q_k^\top \cdot a \leq 0\} = \\
 &= \{y \mid (y - t_k)^\top \cdot (Q_k^{-1})^\top \cdot U \cdot U^\top \cdot Q_k^\top \cdot a \leq 0\} = \\
 &= \{y \mid (y - t_k)^\top \cdot a \leq 0\}.
 \end{aligned}$$

Prin urmare, vom avea:

$$\begin{aligned} T(HS) &= T(S(\mathbf{0}, 1) \cap \{x \in \mathbb{R}^n \mid x_1 \leq 0\}) = \\ &= T(S(\mathbf{0}, 1)) \cap T(\{x \in \mathbb{R}^n \mid x_1 \leq 0\}) = \\ &= E_k \cap \{y \mid a^\top \cdot (y - t_k) \leq 0\} = HE_k(a). \end{aligned}$$

■

Teorema 3.11 Fie B_k o matrice pozitiv definită și $t_k \in \mathbb{R}^n$. Dacă $a \in \mathbb{R}^n$, $a \neq \mathbf{0}$, iar t_{k+1} și B_{k+1} sunt date de (3.2.8), respectiv de (3.2.9), atunci,

(a) matricea B_{k+1} este pozitiv definită (deci, E_{k+1} este un elipsoid);

(b) semielipsoidul $HE_k(a) \subseteq E_{k+1}$;

(c) $\frac{\text{vol}(E_{k+1})}{\text{vol}(E_k)} < 2^{\frac{-1}{2(n+1)}}$.

Demonstrație. (a) Din Propoziția 3.10, relația (3.2.11), deducem

$$\begin{aligned} B_{k+1} &= Q_k \cdot U \cdot B \cdot U^\top \cdot Q_k^\top = \\ &= \left(Q_k \cdot U \cdot \sqrt{B}\right) \cdot \left(Q_k \cdot U \cdot \sqrt{B}\right)^\top \end{aligned}$$

și deoarece evident matricea $Q_k \cdot U \cdot \sqrt{B}$ este nesingulară, rezultă că B_{k+1} este pozitiv definită. În consecință, E_{k+1} este un elipsoid.

(b) Din Propoziția 3.10, punctul (c), avem $HE_k(a) = T(HS)$. Pe de altă parte, din Propoziția 3.9, punctul (b), $HS \subseteq E$. Deci,

$$HE_k(a) = T(HS) \subseteq T(E) = E_{k+1}.$$

(c) Folosind Propozițiile 3.5 și 3.9, punctul (c), avem:

$$\frac{\text{vol}(E_{k+1})}{\text{vol}(E_k)} = \frac{\text{vol}(T(E))}{\text{vol}(T(S(\mathbf{0}, 1)))} = \frac{|\det(QU)| \text{vol}(E)}{|\det(QU)| \text{vol}(S(\mathbf{0}, 1))} < 2^{\frac{-1}{2(n+1)}}.$$

■

În continuare vom analiza faptul că, dacă un elipsoid are volumul mai mic decât $2^{-(n+2)L}$, sistemul (SIs) nu admite soluții.

Propoziția 3.12 Mulțimea soluțiilor sistemului (SIs), de mărime L , are volumul mai mare decât $2^{-(n+2)L}$.

Demonstrație. Din Teorema 3.4 știm că, dacă sistemul $A \cdot x < b$ are soluții, atunci și $A \cdot x \leq b$ va avea soluții. Dar ultimul sistem de

inegalități este echivalent cu $A \cdot x + \mathbf{I} \cdot y = b$, $y \geq \mathbf{0}$. Folosind acum Lema 3.1 rezultă că, pentru orice soluție $z \in \mathbb{R}^n$, avem: $|z_i| < 2^L$ și $|z_i| > 2^{-L}$, $\forall i = \overline{1, n}$. Prin urmare, mulțimea

$$P = \{x \in \mathbb{R}^n \mid A \cdot x \leq b, |x_i| \leq 2^L, |x_i| \geq 2^{-L}, \forall i = \overline{1, n}\}$$

are interiorul nevid. Din Propoziția 3.7 rezultă că există $n + 1$ puncte extreme v_0, v_1, \dots, v_n ale lui P , astfel încât $\text{vol}(Co(v_0, v_1, \dots, v_n)) > 0$.

Din Propoziția 3.8 avem

$$\text{vol}(Co(v_0, v_1, \dots, v_n)) \geq \frac{1}{n!} \left| \det \begin{pmatrix} 1 & 1 & 1 \\ | & | & | \\ v_0 & v_1 & v_n \\ | & | & | \end{pmatrix} \right| > 0$$

Vectorii v_j fiind puncte extreme ale lui P , din Lema 3.1 rezultă că aceștia pot fi scriși sub forma $v_j = \frac{1}{d_j} u_j$, unde $d_j \in \mathbb{Z}$ și $u_j \in \mathbb{Z}^n$.

Rezultă

$$\left| \det \begin{pmatrix} 1 & 1 & 1 \\ | & | & | \\ v_0 & v_1 & v_n \\ | & | & | \end{pmatrix} \right| = \frac{1}{|d_0 d_1 \cdots d_n|} \left| \det \begin{pmatrix} d_0 & d_1 & d_n \\ | & | & | \\ u_0 & u_1 & u_n \\ | & | & | \end{pmatrix} \right|$$

Deoarece valoarea determinantului din membrul drept este un număr întreg nenul, rezultă

$$\text{vol}(Co(v_0, v_1, \dots, v_n)) \geq \frac{1}{n!} \frac{1}{|d_0 d_1 \cdots d_n|}$$

Ținând cont de faptul că pentru orice j avem $|d_j| < 2^L$ și că $n! < 2^L$ (datorită termenului $n \lceil \log_2 n \rceil$ din definiția lui L), avem:

$$\text{vol}(P) \geq \text{vol}(Co(v_0, v_1, \dots, v_n)) \geq 2^{-(n+2)L}.$$

■

Observația 3.2 Folosind un raționament similar cu cel de la începutul demonstrației de mai sus, din Lema 3.1 se poate deduce cu ușurință că, orice soluție a sistemului (SIs) aparține sferei $S(\mathbf{0}, n2^L) = E_0$, deoarece fiecare componentă a soluției este mărginită în modul de 2^L .

Propoziția 3.13 *La iterația $K = 16n(n+1)L$ a algoritmului, elipsoidul E_K are volumul $\text{vol}(E_K) < 2^{-(n+2)L}$.*

Demonstrație. Avem:

$$\text{vol}(E_K) < \text{vol}(E_{K-1}) 2^{\frac{-1}{2(n+1)}} < \dots < \text{vol}(E_0) 2^{\frac{-K}{2(n+1)}} = \text{vol}(E_0) 2^{-8nL}$$

Deoarece $E_0 \subseteq \{x \in \mathbb{R}^n \mid |x_i| \leq n2^L, i = \overline{1, n}\}$, rezultă $\text{vol}(E_0) \leq (2n2^L)^n$, și în continuare

$$\text{vol}(E_K) < (2n2^L)^n 2^{-8nL} < 2^{2nL} 2^{-8nL} = 2^{-6nL} < 2^{-(n+2)L}.$$

Observația 3.3 *Mulțimea soluțiilor sistemului de inegalități (SIs), $P = \{x \in \mathbb{R}^n \mid A \cdot x < b\}$, este inclusă în orice elipsoid E_k generat de algoritm. Deoarece $\text{vol}(P) \geq 2^{-(n+2)L}$ (Propoziția 3.12), iar $\text{vol}(E_K) < 2^{-(n+2)L}$ (Propoziția 3.13), rezultă că, dacă nici unul din centrele elipsoizilor generați în cele K iterații a algoritmului nu aparține lui P , atunci $P = \emptyset$.*

În încheierea acestei prezentări, trebuie subliniat din nou faptul că toate raționamentele făcute aici se bazează pe utilizarea unui calculator "ideal", cu aritmetică exactă. Demonstrația că proprietățile acestui algoritm se extind și pentru calculatoarele "reale" este destul de anevoioasă, însă posibilă. Implementarea algoritmului lui Hacıan și folosirea sa la rezolvarea unor probleme reale, au pus în evidență viabilitatea lui. Cu toate acestea, viteza sa de convergență s-a dovedit a fi mai mică în comparație cu cea a altor algoritmi, cum ar fi, spre exemplu, cel de punct interior al lui Karmarkar.

3.3. Algoritmul proiectiv

În 1984 Karmarkar [20] a propus un algoritm extrem de inovant pentru rezolvarea problemelor de programare liniară. Acesta a fost primul algoritm de programare liniară în timp polinomial care să concureze în mod viabil cu algoritmul simplex în rezolvarea problemelor de dimensiuni mari, provenite din lumea reală. Spre deosebire de algoritmul simplex, care generează puncte extreme pe frontiera domeniului

de admisibilitate, algoritmul lui Karmarkar este o metodă de punct interior. Folosind o tehnică de transformări proiective, el generează în interiorul domeniului de admisibilitate un șir de puncte al căror costuri converg către costul optimal. În final, în urma unui criteriu de oprire, se obține un punct suboptimal, care prin intermediul unor transformări elementare este adus într-un punct optimal de pe frontiera domeniului de admisibilitate. Prezentarea algoritmului proiectiv a lui Karmarkar, pe care o facem în continuare, se bazează pe articolul lui inițial [20] și pe expunerea din [19].

3.3.1. Problema în forma standard Karmarkar

Algoritmul lui Karmarkar rezolvă probleme de programare liniară care au o formă specială, numită *forma standard Karmarkar*. Datele problemei sunt reprezentate de o matrice $A \in \mathbb{Z}^{m \times n}$ (matricea coeficienților restricțiilor) și de un vector $c \in \mathbb{Z}^n$ (vectorul coeficienților funcției obiectiv), unde \mathbb{Z} este mulțimea numerelor întregi.

Vom nota prin $\mathbf{e} \in \mathbb{R}^n$ vectorul care are toate componentele egale cu 1.

Definiția 3.4 *Simplexul standard $(n-1)$ -dimensional este mulțimea:*

$$\Delta = \left\{ x \in \mathbb{R}^n \mid x \geq \mathbf{0}, \mathbf{e}^\top \cdot x = \sum_{j=1}^n x_j = 1 \right\}$$

Vectorul $a_0 = \frac{1}{n}\mathbf{e}$ se numește centrul simplexului.

Dacă notăm spațiul liniar:

$$\Omega = \{ x \in \mathbb{R}^n \mid A \cdot x = 0 \}$$

atunci domeniul de admisibilitate Π a problemei în formă standard Karmarkar este:

$$\Pi = \Omega \cap \Delta$$

Fără a restrânge generalitatea, putem presupune că toate cele $m+1$ restricții care definesc domeniul Π sunt liniar independente.

În plus, forma standard Karmarkar presupune că:

- centrul simplexului este un punct admisibil: $a_0 = \frac{1}{n} \mathbf{e} \in \Pi$;
- costul $c^\top \cdot x$ este nenegativ pentru orice $x \in \Pi$:

$$\forall x \in \Pi \Rightarrow c^\top \cdot x \geq 0.$$

Cu notațiile și ipotezele de mai sus, problema de programare liniară în *forma standard Karmakar* se scrie astfel:

$$\inf \{ c^\top \cdot x \mid x \in \Omega \cap \Delta \}$$

3.3.2. Minimizarea pe sferă

Fie $z \in \mathbb{R}^n$ și $r \in \mathbb{R}$, $r > 0$. Sfera cu centrul z și rază r este mulțimea:

$$S(z, r) = \{ x \in \mathbb{R}^n \mid \|x - z\| \leq r \}$$

Intersecția unui spațiu afin de dimensiune nenulă cu o sferă a cărui centru aparține acestui spațiu, este o sferă de aceeași rază dar de dimensiune mai mică cu o unitate. De exemplu în \mathbb{R}^3 , intersecția unui plan ce trece prin centrul unei sfere tridimensionale este un disc, adică o sferă bidimensională.

Să considerăm $z \in \mathbb{R}^n$ cu proprietatea: $A \cdot z = b$ și

$$S' = \{ x \in \mathbb{R}^n \mid A \cdot x = b \} \cap S(z, r),$$

adică S' este intersecția unui spațiu afin cu o sferă având centrul în acel spațiu.


Minimizarea funcției liniare $c^\top \cdot x$ peste S' se realizează în felul următor: dacă notăm cu c_p proiecția lui c pe spațiul afin $\{ x \in \mathbb{R}^n \mid A \cdot x = b \}$ atunci $-c_p$ este direcția din acest spațiu, de-a lungul căreia funcția obiectiv descrește cel mai rapid. Prin urmare, plecând din centrul z al sferei și deplasându-ne în direcția $-c_p$ cu un pas de lungimea razei r , determinăm un punct de pe suprafața sferei $S(z, r)$ care este punctul de cost minim căutat.

Exemplul 3.3

Să considerăm problema:

$$\min \left\{ 3x_1 + 4x_2 \mid \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \in \mathbb{R}^2, (x_1 - 2)^2 + (x_2 - 5)^2 \leq 16 \right\}$$

Plecând din centrul $\begin{pmatrix} 2 \\ 5 \end{pmatrix}$ al sferei în direcția $\begin{pmatrix} -3 \\ -4 \end{pmatrix}$ cu un pas de lungime 4, se obține punctul de pe sferă $\frac{1}{5} \begin{pmatrix} -2 \\ 9 \end{pmatrix}$ care optimizează problema.



Din cele prezentate rezultă că, dacă problemele de programare liniară ar consta din minimizarea unei funcții liniare peste intersecția unui spațiu afin cu o sferă centrată în acest spațiu, atunci rezolvarea lor ar fi foarte simplă. Vom folosi în continuare această idee pentru a determina un procedeu de rezolvare a problemelor de programare liniară.

3.3.3. Evaluări de regularitate a domeniului de admisibilitate

Să presupunem că dispunem de un punct admisibil z a problemei:

$$\inf \{c^T x \mid A \cdot x = b\}$$

Dacă este atât de ușor să minimizăm $c^T \cdot x$ peste o sferă de dimensiune mai mică, obținută ca intersecție dintre un spațiu afin și o sferă centrată în el, de ce nu am încerca să înscriem în interiorul regiunii admisibile o sferă de dimensiune mai mică S centrată în z și să minimizăm $c^T \cdot x$ peste S ? Ar fi de dorit ca sfera S să fie cât mai mare cu putință, dar să rămână inclusă în interiorul regiunii admisibile. Dacă S nu este cu mult mai mică decât regiunea admisibilă, minimumul peste

S ar putea să nu fie cu mult mai mare decât minimul problemei de la care am plecat. Dacă w este un punct de cost minim în S , atunci costul lui w ar putea fi semnificativ mai mic decât costul punctului inițial z . Acest proces poate fi repetat, considerând pe w ca punct de plecare.

Se pune următoarea problemă: cât de bună poate fi o astfel de aproximare a soluției optime? Din punct de vedere intuitiv, dacă regiunea admisibilă este "rotundă" iar punctul z este "centrul" ei, atunci sfera S centrată în z ar putea conține "aproape" toate punctele admisibile. În aceste condiții este de presupus că minimul peste sfera înscrisă S ar putea fi o bună aproximare a optimului. Dacă însă regiunea admisibilă este "lungă și strâmtă", ca de exemplu un triunghi cu lungimea laturilor de 1, 1000 și 1000, sfera înscrisă ar putea fi prea mică și deci optimul peste S să nu aibe nici o relevanță față de optimul problemei.

O măsură naturală a aspectului de *regularitate* ("sfericitate") a domeniului de admisibilitate ar fi raportul dintre raza sferei circumscrise și raza sferei înscrise a acestuia. Astfel, pentru un domeniu reprezentat de o sferă obținem un raport egal cu 1, cel mai bun raport posibil; pentru un triunghi isoscel "lung și strâmt" putem obține un raport foarte mare, ceea ce sugerează că aproximarea optimului prin procedeul descris mai sus nu este adecvată.

Să formalizăm acum aceste argumente într-un cadru puțin mai general. Fie $P \subseteq \mathbb{R}^n$ un poliedru și $z \in P$. Fie $E \subseteq P$ o mulțime convexă închisă cu $z \in E$. (Ne putem imagina E ca fiind o sferă cu centrul z , inclusă în P .) Dorim să evaluăm "cât de bună" este soluția pe care o vom obține dacă minimizăm funcția liniară $c^T \cdot x$ peste E , în loc să o minimizăm peste mulțimea mai mare și mai complicată P .

Pentru a obține o evaluare a aproximării soluției optime, vom scala mulțimea E printr-un factor ν suficient de mare, având centrul scalării în z , astfel încât noua mulțime E' să conțină mulțimea P :

$$\begin{aligned} E' &= \{z + \nu(x - z) \mid x \in E\} \\ E &\subseteq P \subseteq E' \end{aligned}$$

Evident, E' are aceeași formă ca E . Fiecărui punct $x \in E$ îi corespunde

un punct $x' = z + \nu(x - z) \in E'$, și reciproc.

Fie $c^\top \cdot x_E$ valoarea minimă a lui $c^\top \cdot x$ peste E . Deoarece funcția $c^\top \cdot x$ este liniară, luând $x_{E'} = z + \nu(x_E - z)$, valoarea minimă a lui $c^\top \cdot x$ peste E' va fi $c^\top \cdot x_{E'}$. În continuare avem:

$$z - x_{E'} = \nu(z - x_E)$$

de unde obținem:

$$c^\top \cdot (z - x_{E'}) = \nu [c^\top \cdot (z - x_E)]$$

Valoarea care ne interesează este $c^\top \cdot x_P$, minimumul lui $c^\top \cdot x$ peste poliedrul P . Deoarece $P \subseteq E'$ avem $c^\top \cdot x_P \geq c^\top \cdot x_{E'}$ și deci:

$$c^\top \cdot (z - x_P) \leq c^\top \cdot (z - x_{E'}) = \nu [c^\top \cdot (z - x_E)]$$

Prin urmare, putem scrie:

$$\begin{aligned} (\nu - 1)(c^\top \cdot z) - \nu(c^\top \cdot x_E) &\geq -(c^\top \cdot x_P) \\ (\nu - 1)(c^\top \cdot z) - (\nu - 1)(c^\top \cdot x_P) &\geq \nu(c^\top \cdot x_E) - \nu(c^\top \cdot x_P) \\ (\nu - 1)[(c^\top \cdot z) - (c^\top \cdot x_P)] &\geq \nu[(c^\top \cdot x_E) - (c^\top \cdot x_P)] \end{aligned}$$

Deoarece $c^\top \cdot z > c^\top \cdot x_P$ (optimumul nu se atinge în interiorul domeniului), avem:

$$\frac{c^\top \cdot (x_E - x_P)}{c^\top \cdot (z - x_P)} \leq 1 - \frac{1}{\nu} \quad (3.3.1)$$

Diferența $c^\top \cdot z - c^\top \cdot x_P$ (exesul de cost) este o măsură care exprimă "cât de nesatisfăcător" este z , adică cu cât este mai mare costul său față de costul optimal $c^\top \cdot x_P$. Punctul x_E este mai bun decât z deoarece excesul său de cost este majorat de cel al lui z înmulțit cu factorul $1 - \frac{1}{\nu}$. Prin urmare, cu cât este mai mic ν , cu atât mai mare este progresul realizat în funcția obiectiv prin trecerea de la z la x_E . Cu cât P va avea o formă mai apropiată de cea a unei sfere centrate în z , cu atât ν va avea o valoare mai mică și astfel, el poate fi folosit pentru a exprima *regularitatea* poliedrului.

Subliniăm faptul că în forma standard Karmarkar, domeniul de admisibilitate a problemei este intersecția unui spațiu afin cu un simplex, și prin urmare, vom beneficia de proprietatea că simplexul este un poliedru regulat.

Algoritmul lui Karmarkar are drept punct de plecare pe $z = a_0$ și generează o succesiune de puncte admisibile a căror costuri converg către 0 (presupunând că costul optimal este 0). Procedeu poate fi descris în felul următor: să considerăm că am determinat un punct curent $a \in \Pi$ pentru care $c^\top \cdot a > 0$ și vrem să generăm următorul punct b . Pentru aceasta va trebui să înscriem în Π o sferă S centrată în a și să minimizăm $c^\top \cdot x$ peste S . Este însă puțin probabil ca minimum lui $c^\top \cdot x$ peste S să aproximeze bine adevăratul minim al lui $c^\top \cdot x$ peste Π , deoarece în general Π nu are o formă sferică cu centrul în a . Pentru a înlătura acest inconvenient, Karmarkar a avut o idee strălucită - care de altfel este esența întregului algoritm - anume, de a transforma problema dată printr-o aplicație T_a astfel încât să se obțină o nouă problemă în care imaginea punctului curent a prin T_a să fie a_0 , centrul simplexului Δ . Regiunea admisibilă Π' a noii probleme va fi dată la rândul ei tot de intersecția simplexului Δ cu un spațiu afin, întocmai ca și Π , iar mulțimea Δ este regulată și are drept centru pe a_0 . Aceasta înseamnă că dacă în noua problemă minimizăm peste o sferă înscrisă în Π' , vom obține un punct b' al cărui cost va fi semnificativ mai mic decât cel al lui a_0 . Dacă aplicăm lui b' transformarea inversă T_a^{-1} , se obține un nou punct b din Π . Deoarece costul lui b' în problema transformată este mult mai mic decât cel al lui a_0 , în problema originală costul lui b va fi și el mai mic decât cel al lui a . Prin aplicarea repetată a acestui procedeu se obține un șir de puncte ale căror costuri vor converge către 0. Evident, această descriere este un pic simplificată și omite intenționat unele dificultăți care apar pe parcurs.

Vom nota cu $S(a_0, r)$ cea mai mare sferă $(n - 1)$ -dimensională, centrată în a_0 , care este inclusă în Δ (sfera înscrisă), și cu $S(a_0, R)$ cea mai mică sferă $(n - 1)$ -dimensională, centrată în a_0 , care îl conține pe Δ (sfera circumscrisă).

Lema 3.14 *Razele sferelor $S(a_0, r)$ și $S(a_0, R)$ sunt date de următoarele formule:*

$$r = \frac{1}{\sqrt{n(n-1)}} \quad \text{și} \quad R = \sqrt{\frac{n-1}{n}}.$$

Demonstrație. *Sfera înscrisă.*

Pentru început vom demonstra următoarea afirmație: dacă $y \in \mathbb{R}^n$ satisface condițiile: $y_i \geq \frac{1}{n}$ pentru $i < n$, $y_n = 0$ și $y_1 + y_2 + \dots + y_n \geq 1$, atunci

$$\|y - a_0\|^2 \geq r^2 = \frac{1}{n(n-1)}.$$

Fie $z_i = y_i - \frac{1}{n}$ pentru $i = 1, 2, \dots, n-1$. Atunci

$$\|y - a_0\|^2 = \sum_{i=1}^{n-1} \left(y_i - \frac{1}{n}\right)^2 + \frac{1}{n^2} = \sum_{i=1}^{n-1} z_i^2 + \frac{1}{n^2}.$$

Avem evident $z_i \geq 0$ pentru orice i , iar

$$\sum_{i=1}^{n-1} z_i \geq 1 - \frac{n-1}{n} = \frac{1}{n}.$$

Deoarece $z_i \geq 0$ și $\sum_{i=1}^{n-1} z_i \geq \frac{1}{n}$, minimul expresiei $\sum_{i=1}^{n-1} z_i^2 + \frac{1}{n^2}$ este obținut

dacă $\sum_{i=1}^{n-1} z_i = \frac{1}{n}$ și toți z_i sunt identici, adică, $z_i = \frac{1}{n(n-1)}$ pentru $i = 1, 2, \dots, n-1$. În acest caz:

$$\sum_{i=1}^{n-1} z_i^2 + \frac{1}{n^2} = \frac{1}{n^2(n-1)} + \frac{1}{n^2} = \frac{1}{n(n-1)} = r^2.$$

și afirmația noastră este demonstrată.

Distanța de la a_0 la punctul $(0, \frac{1}{n-1}, \frac{1}{n-1}, \dots, \frac{1}{n-1})^\top$ de pe frontiera lui Δ este :

$$\sqrt{\frac{1}{n^2} + (n-1) \left(\frac{1}{n-1} - \frac{1}{n}\right)^2} = \sqrt{\frac{1}{n^2} + \frac{1}{(n-1)n^2}} = r$$

astfel încât raza oricărei sfere $(n-1)$ -dimensionale incluse în Δ nu poate fi mai mare decât r .

Să demonstrăm acum că orice punct $x \in \mathbb{R}^n$ aparține lui Δ , dacă satisface condițiile $e^\top \cdot x = 1$ și $\|x - a_0\| \leq r$. Presupunem prin absurd că x satisface condițiile cerute, dar că există o anumită componentă

a sa, să zicem ultima, care este negativă. Definim vectorul $y \in \mathbb{R}^n$ astfel:

$$y_i = \begin{cases} x_i & \text{dacă } i < n \text{ și } x_i \geq \frac{1}{n} \\ \frac{2}{n} - x_i & \text{dacă } i < n \text{ și } x_i < \frac{1}{n} \\ 0 & \text{dacă } i = n \end{cases}$$

Este ușor de verificat că $y_i \geq \frac{1}{n}$ pentru $i < n$, $y_n = 0$, $e^\top \cdot y \geq 1$ și $\|y - a_0\| \leq \|x - a_0\| \leq r$. Dar aceasta contrazice afirmația demonstrată mai înainte și deci prima formulă este demonstrată.

Sfera circumscrisă.

Distanța de la a_0 la orice punct extremal (vârf) al lui Δ , de exemplu la punctul $(1, 0, \dots, 0)^\top$, este:

$$\sqrt{\left(1 - \frac{1}{n}\right)^2 + \frac{n-1}{n^2}} = \sqrt{(n-1)n} = R.$$

Astfel, orice sferă $(n-1)$ -dimensională care include pe Δ trebuie să aibe raza cel puțin R . Pentru a completa demonstrația arătăm că distanța de la orice punct din Δ la a_0 este cel mult R .

Dacă α și β sunt numere reale nenegative, este ușor de verificat că

$$\left(\alpha - \frac{1}{n}\right)^2 + \left(\beta - \frac{1}{n}\right)^2 \leq \left[\left(\alpha + \beta\right) - \frac{1}{n}\right]^2 + \left(0 - \frac{1}{n}\right)^2$$

Fie $x \in \Delta$. Pentru $i = 2, 3, \dots, n$, putem înlocui succesiv componentele x_1 și x_i ale lui x prin $x_1 + x_i$ și 0, respectiv. Procedând în acest mod și ținând seama de relația de mai sus, obținem puncte din Δ a căror distanță față de a_0 este cel puțin egală sau mai mare decât cea a punctului anterior. În cele din urmă se va obține punctul $(1, 0, \dots, 0)^\top$. Deoarece distanța acestuia față de a_0 este R , nici un punct din Δ nu se va afla față de a_0 la o distanță mai mare decât R . Lema este astfel demonstrată. ■

Observația 3.4 Dacă considerăm mulțimea $P = \Delta$ și luăm $z = a_0$, $E = S(a_0, r)$ și $E' = S(a_0, R)$, atunci regularitatea simplexului $(n-1)$ -dimensional este dată de factorul de scalare $\nu = \frac{R}{r} = n-1$.

3.3.4. Transformări proiective

Așa cum am amintit în paragraful precedent, va trebui să construim o aplicație T_a care transformă problema dată într-una nouă, astfel încât imaginea punctului curent a să fie a_0 , centrul simplexului Δ . În plus, imaginea lui Δ prin T_a să fie tot Δ , adică, dacă $x \in \Delta$, suma coordonatelor lui $T_a(x)$ să fie egală cu 1. Dacă considerăm vectorul $a \in \mathbb{R}^n$, cu $a_i > 0$, $i = \overline{1, n}$, o transformare cu proprietățile cerute poate fi definită în mod natural astfel:

$$T_a(x) = x' \quad \text{unde} \quad x'_j = \frac{\frac{x_j}{a_j}}{\sum_{i=1}^n \frac{x_i}{a_i}}, \quad \text{pentru } j = \overline{1, n}.$$

Pentru a rescrie această expresie într-o formă matriceală echivalentă, vom nota matricea diagonală:

$$D = \text{diag}(a) = \begin{pmatrix} a_1 & 0 & 0 \\ 0 & a_2 & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & a_n \end{pmatrix}$$

pentru care evident

$$D^{-1} = \begin{pmatrix} \frac{1}{a_1} & 0 & 0 \\ 0 & \frac{1}{a_2} & 0 \\ \vdots & \vdots & \vdots \\ 0 & 0 & \frac{1}{a_n} \end{pmatrix}$$

Cu aceste notații, transformarea $T_a(x)$ se definește astfel:

$$T_a(x) = \frac{D^{-1} \cdot x}{e^T \cdot D^{-1} \cdot x}.$$

Vom arăta în continuare că T_a este de fapt o formă specială de transformare proiectivă.

Definiția 3.5 Fie matricea $E \in \mathbb{R}^{n \times n}$, vectorii $d, f \in \mathbb{R}^n$ și $g \in \mathbb{R}$. Dacă matricea $\begin{pmatrix} E & d \\ f^\top & g \end{pmatrix} \in \mathbb{R}^{(n+1) \times (n+1)}$ este nesingulară, aplicația definită pe \mathbb{R}^n pentru care $f^\top \cdot x + g \neq 0$ și $x \mapsto \frac{E \cdot x + d}{f^\top \cdot x + g}$, se numește transformare proiectivă.

Fie $E \in \mathbb{R}^{n \times n}$ o matrice nesingulară arbitrară și luăm $d = 0$, $g = 1$ și $f^\top = e^\top \cdot (E - I_n)$. Atunci, deoarece E este nesingulară, $d = 0$ și $g \neq 0$, aplicația $x \mapsto \frac{E \cdot x}{f^\top \cdot x + 1} = \frac{E \cdot x + d}{f^\top \cdot x + g}$ este o transformare proiectivă. Fie $\Sigma = \{x \in \mathbb{R}^n \mid e^\top \cdot x = 1\}$. Pentru $x \in \Sigma$ avem:

$$\frac{E \cdot x + d}{f^\top \cdot x + g} = \frac{E \cdot x}{e^\top \cdot E \cdot x - e^\top \cdot x + 1} = \frac{E \cdot x}{e^\top \cdot E \cdot x}$$

Cu alte cuvinte, pentru $x \in \Sigma$ și orice matrice E nesingulară, aplicația $x \mapsto \frac{E \cdot x}{e^\top \cdot E \cdot x}$ este o transformare proiectivă pe Σ . În cazul nostru, deoarece $a > 0$, D^{-1} este o matrice diagonală, cu diagonala pozitivă și astfel este evident nesingulară. Prin urmare, aplicația $T_a(x)$ definită mai sus este o transformare proiectivă.

Imaginea simplexului Δ prin transformarea T_a este chiar Δ . Într-adevăr, dacă $x \in \Delta$, atunci $x \geq 0$ și de aici, $T_a(x) \geq 0$. De asemenea, suma componentelor lui $T_a(x)$ este: $e^\top \cdot T_a(x) = \frac{e^\top \cdot D^{-1} \cdot x}{e^\top \cdot D^{-1} \cdot x} = 1$. Pe de altă parte, T_a este bijectivă deoarece aplicația $x' \mapsto \frac{D \cdot x'}{e^\top \cdot D \cdot x'}$ definită pe Δ este inversa lui T_a . Prin urmare, dacă $x \in \Delta$ și $T_a(x) = x'$, atunci:

$$T_a^{-1}(x') = \frac{D \cdot x'}{e^\top \cdot D \cdot x'}$$

adică,

$$T_a^{-1}(x') = x \quad \text{unde} \quad x_j = \frac{a_j x'_j}{\sum_{i=1}^n a_i x'_i} \quad \text{pentru } j = \overline{1, n}.$$

Dacă notăm cu A^j coloana j a matricei A , putem scrie:

$$\sum_{j=1}^n A^j x_j = \mathbf{0} \Leftrightarrow \sum_{j=1}^n A^j \frac{a_j x'_j}{\sum_{i=1}^n a_i x'_i} = \mathbf{0} \Leftrightarrow \sum_{j=1}^n (A^j a_j) x'_j = \mathbf{0}$$

Deoarece $A \cdot D$ este o matrice de dimensiune $(m \times n)$, cu coloanele de forma $A^j a_j$, avem $A \cdot x = 0$ dacă și numai dacă $A \cdot D \cdot x' = 0$. Reamintim că $\Omega = \{x \in \mathbb{R}^n \mid A \cdot x = 0\}$. Prin urmare, dacă notăm

$$\Omega' = \{x' \in \mathbb{R}^n \mid A \cdot D \cdot x' = 0\}$$

deducem că $T_a(\Omega) = \Omega'$. În plus, pentru orice $a \in \Omega$ avem

$$T_a(a) = a_0 \in \Omega'.$$

Deoarece $T_a(\Delta) = \Delta$ și $T_a(\Omega) = \Omega'$ iar T_a este inversabilă, avem:

$$T_a(\Delta \cap \Omega) = \Delta \cap \Omega'$$

Aceasta înseamnă că imaginea domeniului de admisibilitate Π a problemei originale prin transformarea proiectivă T_a este $\Delta \cap \Omega'$. Vom nota $\Pi' = T_a(\Pi) = \Delta \cap \Omega'$.

Din felul în care au fost definite cele două sfere $S(a_0, r)$ și $S(a_0, R)$ rezultă că:

$$S(a_0, r) \subseteq \Delta \subseteq S(a_0, R)$$

și deci, dacă intersectăm aceste mulțimi cu Ω , imaginea prin T_a va fi:

$$S(a_0, r) \cap \Omega' \subseteq \Delta \cap \Omega' \subseteq S(a_0, R) \cap \Omega'$$

Deoarece Ω' este un spațiu afin care îl conține pe a_0 , sferile $S(a_0, r) \cap \Omega'$ și $S(a_0, R) \cap \Omega'$ au dimensiunea cel mult $n-1$ și sunt de raze r respectiv R . Vom nota:

$$\begin{aligned} S'(a_0, r) &= S(a_0, r) \cap \Omega' \\ S'(a_0, R) &= S(a_0, R) \cap \Omega' \end{aligned}$$

Prin urmare avem:

$$S'(a_0, r) \subseteq \Pi' \subseteq S'(a_0, R)$$

iar $\nu = \frac{R}{r} = n - 1$. Deci Π' este un domeniu mărginit, fapt pentru care vom putea aproxima minimizarea unei funcții liniare peste Π' prin minimizarea acesteia peste sfera $S(a_0, r)$ înscrisă în Π' , excesul de cost având factorul egal cu $1 - \frac{1}{\nu} = 1 - \frac{1}{n-1}$.

Prin aplicarea unei astfel de transformări proiective apare totuși o problemă, anume, că funcția obiectiv, care este liniară în problema inițială, devine neliniară prin transformarea T_a . Scopul nostru este să minimizăm $c^\top \cdot x$ pentru $x \in \Pi$. Deoarece

$$c^\top \cdot x = c^\top \cdot T_a^{-1}(x') = \frac{\sum_{j=1}^n (c_j a_j) x'_j}{\sum_{i=1}^n a_i x'_i},$$

minimizarea lui $c^\top \cdot x$ pentru $x \in \Pi$ este echivalentă cu minimizarea lui $\frac{\sum_{j=1}^n (c_j a_j) x'_j}{\sum_{i=1}^n a_i x'_i}$ pentru $x' \in \Pi'$. Dar expresia din urmă este o funcție neliniară în x' , astfel că în descrierea simplistă a algoritmului lui Karmarkar făcută mai înainte, ar trebui de fapt să minimizăm o funcție rațională peste un poliedru. Vom arăta în continuare că este totuși suficient dacă aproximăm funcția rațională doar cu numărătorul său $\sum_{j=1}^n (c_j a_j) x'_j$, care este liniar în x' .

3.3.5. O funcție potențial aproape invariantă

În acest paragraf vom arăta că, prin minimizarea succesivă a funcțiilor de tipul $\sum_{j=1}^n (c_j a_j) x'_j$, se poate găsi un minim global al problemei inițiale. Trebuie precizat că, chiar dacă costurile punctelor generate vor converge către 0, ele nu vor avea neapărat o descreștere monotonă. Prin intermediul unei funcții potențial vom demonstra că, după un număr suficient de mare de iterații, costul $c^\top \cdot x$ a problemei va descrește substanțial, chiar dacă pentru anumiți pași valoarea acestuia ar putea fi crescătoare.

Dacă $c^\top \cdot x$ este funcția obiectiv inițială, pentru $x \in \Pi$, $c^\top \cdot x > 0$

și $x > 0$, definim funcția potențial:

$$f(x) = \ln \left[\frac{(c^\top \cdot x)^n}{x_1 x_2 \cdots x_n} \right]$$

Deoarece produsul componentelor $x_1 x_2 \cdots x_n < 1$, avem evident:

$$(c^\top x)^n \leq \frac{(c^\top \cdot x)^n}{x_1 x_2 \cdots x_n} = e^{f(x)}$$

și deci $c^\top \cdot x \leq e^{\frac{f(x)}{n}}$. Prin urmare, dacă $f(x)$ descrește către $-\infty$, atunci $c^\top \cdot x$ va converge către 0. În acest mod funcția f poate fi folosită pentru a evalua progresul realizat de-a lungul iterațiilor.

Vom arăta că este suficient să "minimizăm aproximativ" o funcție liniară pentru ca $f(x) \rightarrow -\infty$ și că este suficient să determinăm la fiecare iterație un punct nou b pentru care $f(b) \leq f(a) - \delta$ (unde $\delta > 0$ este o constantă) pentru a garanta convergența în timp polinomial a algoritmului.

Pentru calculul valorilor funcției f , va trebui să extindem operațiile elementare ale calculatorului virtual și pentru determinarea valorii logaritmului natural. Practic, există rutine performante care aproximează orice valoare a acestuia doar prin operații cu numere raționale. Din această cauză vom considera calculul logaritmului natural ca fiind făcut și el într-o unitate de timp.

Notăm:

$$c' = D \cdot c = \begin{pmatrix} a_1 c_1 \\ a_2 c_2 \\ \vdots \\ a_n c_n \end{pmatrix}$$

și definim:

$$f'(y) = \ln \left[\frac{(c'^\top \cdot y)^n}{y_1 y_2 \cdots y_n} \right]$$

pentru $y \in \Pi'$, $c'^\top \cdot y > 0$ și $y > 0$. Așa cum s-a arătat mai înainte, minimizarea lui $c^\top \cdot x$ peste Π revine la minimizarea lui $\frac{\sum (c_j a_j) y_j}{\sum a_i y_i}$ pentru $y \in \Pi'$. Deci, f' ar putea fi funcția potențial în problema transformată, dacă funcția obiectiv a acesteia ar fi doar $c'^\top \cdot y$.

Următoarea lemă arată că funcția potențial este aproape invariantă în raport cu T_a , adică diferența $f'(T_a(x)) - f(x)$ nu depinde de x .

Lema 3.15 Pentru orice $x \in \Pi$, dacă $c^\top \cdot x > 0$ și $x > 0$ atunci

$$f'(T_a(x)) = f(x) + \ln(a_1 a_2 \cdots a_n).$$

Demonstrație. Dacă $c^\top \cdot x > 0$ și $x > 0$ atunci ambele valori $f'(T_a(x))$ și $f(x)$ există. Folosind relațiile de definiție ale lui T_a și f' , obținem:

$$f'(T_a(x)) = \ln \frac{\left[c^\top \cdot D^\top \cdot \left(\frac{D^{-1}x}{e^\top D^{-1}x} \right) \right]^n}{\frac{\frac{x_1}{a_1} \frac{x_2}{a_2} \cdots \frac{x_n}{a_n}}{(e^\top \cdot D^{-1}x)^n}} = f(x) + \ln(a_1 a_2 \cdots a_n).$$

■

Pentru a determina un nou punct din secvența descrisă la pagina 126, vom proceda astfel: fiind cunoscut punctul curent $a \in \Pi$, vom folosi transformarea proiectivă T_a pentru a duce pe a în centrul a_0 a simplexului Δ . Folosind tehnica de optimizare pe sfera înscrisă în Δ , determinăm un punct $b' \in \Pi'$ pentru care $f'(b') \leq f'(a_0) - \delta$. Apoi aplicăm lui b' transformarea inversă T_a^{-1} și obținem punctul $b \in \Pi$. Deoarece f este "aproape invariantă" deducem $f(b) \leq f(a) - \delta$:

$$\begin{aligned} f(b) &= f'(b') - \ln(a_1 a_2 \cdots a_n) \leq \\ &\leq (f'(a_0) - \delta) - \ln(a_1 a_2 \cdots a_n) = \\ &= f(a) - \delta. \end{aligned}$$

Acesta este "progresul" ce se face la o iterație. De-a lungul iterațiilor, valoarea lui f va tinde către $-\infty$, deoarece la fiecare iterație valoarea lui f descrește cu δ .

3.3.6. Algoritmul lui Karmarkar

Vom nota cu L mărimea problemei de programare liniară în formă standard Karmarkar, care este numărul

$$L = (m + 1)n + \lceil \log_2 |P| \rceil + n \lceil \log_2 n \rceil$$

unde m, n sunt dimensiunile matricei A , iar P este produsul tuturor coeficienților nenuli din problemă.

Fie $\alpha \in (0, \frac{1}{2})$ un număr real oarecare și fie

$$\delta = \alpha - \frac{\alpha^2}{1 - \alpha} > 0.$$

Vom arăta în continuare că algoritmul lui Karmarkar rezolvă în timp polinomial orice problemă în formă standard.

Pentru a descrie mai ușor algoritmul, vom face apel la o funcție Φ , care generează șirul de puncte din interiorul domeniului Π , adică $x^{(k+1)} = \Phi(x^{(k)})$. Vom considera că Φ are următoarele proprietăți:

- dacă $a \in \Pi$, $a > \mathbf{0}$ și $c^\top \cdot a > 0$, atunci $\Phi(a) \in \Pi$, și $\Phi(a) > \mathbf{0}$;
- dacă problema are costul optim egal cu 0, atunci ori $c^\top \cdot \Phi(a) = 0$, ori $f(\Phi(a)) \leq f(a) - \delta$.

Definirea funcției Φ și demonstrarea proprietăților sale o vom face imediat după expunerea și justificarea algoritmului.

Algoritmul lui Karmarkar.

Iterația 0. Se consideră $x^{(0)} = a_0 = \frac{1}{n}e$ și fie $K = \lceil \frac{2nL}{\epsilon} \rceil$ (numărul maxim de iterații).

Dacă $c^\top \cdot a_0 = 0$, atunci o soluție optimă este a_0 . STOP.

Dacă $c^\top \cdot a_0 > 0$, atunci se efectuează iterațiile următoare, pentru $k = \overline{1, K}$:

Iterația k.

- Cu ajutorul funcției Φ se generează $x^{(k)} = \Phi(x^{(k-1)})$.
- Dacă $c^\top \cdot x^{(k)} = 0$, atunci o soluție optimă este $x^{(k)}$. STOP.
- Dacă $f(x^{(k)}) > f(x^{(k-1)}) - \delta$, atunci problema are costul optim pozitiv. STOP.

Iterația K+1. Găsește un punct extremal $v \in \Pi$ al cărui cost nu este mai mare decât $c^\top \cdot x^{(K)}$. În acest caz, v este o soluție de bază optimă, adică: $c^\top \cdot v = 0$.

Teorema 3.16 Presupunem că:

- pentru orice $a \in \Pi$, $a > \mathbf{0}$ și $c^\top \cdot a > 0$, avem $\Phi(a) \in \Pi$, și $\Phi(a) > \mathbf{0}$;

–dacă costul minim al problemei este 0, atunci ori $c^T \cdot \Phi(a) = 0$, ori $f(\Phi(a)) \leq f(a) - \delta$.

În aceste condiții algoritmul lui Karmarkar rezolvă corect problemele de programare liniară în forma standard Karmarkar.

Demonstrație. Singura situație în care algoritmul poate semnala un cost optim pozitiv este la iterația k , dacă costul $c^T \cdot x^{(k)} > 0$ și $f(x^{(k)}) > f(x^{(k-1)}) - \delta$. În acest caz, datorită ipotezei făcute asupra lui Φ , știm că problema are un cost optim pozitiv.

Dacă condiția $c^T \cdot x^{(k)} = 0$ este verificată, atunci evident $x^{(k)}$ este o soluție optimă a problemei.

Să presupunem acum că pentru orice $k = 1, 2, \dots, K$, avem $f(x^{(k)}) \leq f(x^{(k-1)}) - \delta$. Atunci

$$f(x^{(K)}) \leq f(x^{(0)}) - \left(\frac{2nL}{\delta}\right) \delta = f(x^{(k)}) \leq f(x^{(0)}) - 2nL$$

și

$$c^T x^{(K)} \leq e^{\frac{f(x^{(K)})}{n}} \leq e^{\frac{f(x^{(0)}) - 2nL}{n}}.$$

Deoarece $x^{(0)} = a_0$ deducem că:

$$f(x^{(0)}) = \ln \left[\frac{(c^T \cdot a_0)^n}{\left(\frac{1}{n}\right)^n} \right] = n \ln(nc^T \cdot a_0) = n \ln(c_1 + c_2 + \dots + c_n)$$

Dar, se poate arăta cu ușurință că $\ln(c_1 + c_2 + \dots + c_n) \leq L$, astfel încât avem $f(x^{(0)}) \leq nL$. Rezultă $\frac{f(x^{(0)}) - 2nL}{n} \leq -L$. Prin urmare,

$$c^T \cdot x^{(K)} \leq e^{-L} < 2^{-L}.$$

În acest caz, fie $v \in \Pi$ punctul extremal obținut la iterația $K + 1$ (soluția de bază v se poate determina cu ajutorul Teoremei fundamentale a programării liniare). Conform Lemei 3.1, soluția de bază v este un vector cu toate componentele raționale, având numitorul comun pozitiv și mai mic ca 2^L . Prin urmare, dacă $c^T \cdot v > 0$, atunci $c^T \cdot v > 2^{-L}$. Însă, pe de altă parte, avem: $0 \leq c^T \cdot v \leq c^T \cdot x^{(K)} < 2^{-L}$, ceea ce implică $c^T \cdot v = 0$.

În concluzie, algoritmul lui Karmarkar determină un punct de cost 0, dacă există unul, sau semnalează că un astfel de punct nu există. ■

Ne vom ocupa în continuare de construcția unei funcții Φ cu proprietățile cerute de algoritm.

Caracteristica principală a lui Φ este de a duce printr-o transformare proiectivă, un punct a din interiorul lui Π în centrul $a_0 \in \Pi'$ a simplexului Δ , apoi, de a găsi un punct $b' \in \Pi'$ astfel încât $f'(b') \leq f'(a_0) - \delta$ și în final, prin aplicarea transformării inverse, de a determina punctul $b \in \Pi$.

Domeniul transformat Π' are, așa cum am arătat mai înainte, o formă bună de regularitate cu centrul în a_0 . Acest lucru justifică alegerea lui b' ca soluție optimă în minimizarea lui $c'^T \cdot y$ pe sfera $S'(a_0, r) \subseteq \Pi'$. Problema care poate să apară aici este următoarea: aflându-se pe frontiera sferei, anumite componente ale lui b' pot fi zero și în acest caz, evaluarea progresului nu mai este posibilă prin intermediul funcției potențial f' , care este definită pentru vectori cu toate componentele strict pozitive.

Pentru a evita acest inconvenient, va trebui să ne asigurăm că b' rămâne strict în interiorul domeniului Π' , astfel că vom efectua minimizarea pe sfera $S'\left(a_0, \frac{\alpha}{n}\right)$, pentru care raza este

$$\frac{\alpha}{n} < \frac{\alpha}{\sqrt{n(n-1)}} < \alpha r < \frac{r}{2}.$$

Cu această alegere a lui b' vom putea demonstra că $f'(b') \leq f'(a_0) - \delta$.

Introducem următoarele notații:

$$\begin{aligned} \Sigma &= \{x \in \mathbb{R}^n \mid \mathbf{e}^T \cdot x = 1\}, \\ \bar{\Omega} &= \Omega' \cap \Sigma, \\ B &= \begin{pmatrix} A \cdot D \\ \mathbf{e}^T \end{pmatrix}. \end{aligned}$$

Evident, $a_0 \in \bar{\Omega}$, iar B este o matrice de dimensiune $(m+1) \times n$, obținută prin adăugarea unei linii la cele ale lui $A \cdot D$. De asemenea, putem scrie

$$\bar{\Omega} = \{x \in \mathbb{R}^n \mid B \cdot x = e^{(m+1)}\}$$

unde $e^{(m+1)}$ este vectorul unitar, de dimensiune $m+1$, care are 1 pe ultima poziție.

Modul în care funcția Φ asociază punctului $a \in \Pi$, vectorul $b = \Phi(a) \in \Pi$, este următorul:

Funcția Φ .

1. Fie $a \in \Pi$, $a > 0$, și matricea diagonală $D = \text{diag}(a)$.

Se determină vectorul $c' = D \cdot c$ și matricea $B = \begin{pmatrix} A \cdot D \\ e^\top \end{pmatrix}$.

2. Se calculează vectorul c_p , proiecția lui c' pe spațiul nul al lui B :

$$c_p = c' - B^\top \cdot (B \cdot B^\top)^{-1} \cdot B \cdot c'.$$

și se determină vectorul

$$\hat{c}_p = \begin{cases} \frac{c_p}{\|c_p\|} & \text{dacă } c_p \neq 0 \\ 0 & \text{dacă } c_p = 0 \end{cases}$$

3. Se calculează vectorul

$$b' = a_0 - \frac{\alpha}{n} \hat{c}_p$$

care se obține plecând din a_0 cu un pas de lungime $\frac{\alpha}{n}$ în direcția $-c_p$ (optimizarea pe sferă).

4. Se calculează

$$b = T_a^{-1}(b') = \frac{D \cdot b'}{e^\top \cdot D \cdot b'}$$

În continuare vom demonstra că funcția Φ astfel definită are proprietățile cerute de algoritmul lui Karmarkar.

Propoziția 3.17 *Proiecția vectorului $c' = D \cdot c$ pe spațiul nul al lui B este*

$$c_p = c' - B^\top \cdot (B \cdot B^\top)^{-1} \cdot B \cdot c'.$$

Demonstrație. Matricea diagonală D fiind evident inversabilă, avem $\text{rang}(A \cdot D) = \text{rang}(A) = m$. Ultima linie a matricei B este e^\top și aceasta nu poate fi dependentă de celelate, pentru că altfel, $(A \cdot D) \cdot a_0 = 0$ ar implica $e^\top \cdot a_0 = 0$, ceea ce este evident fals. Prin urmare, $\text{rang}(B) = m + 1$.

Pentru ca $(B \cdot B^T)^{-1}$ să existe, este suficient să arătăm că matricea $B \cdot B^T$, de dimensiune $(m+1) \times (m+1)$, are coloanele linear independente. Prin absurd, să presupunem că există $y \in \mathbb{R}^{m+1}$, $y \neq \mathbf{0}$, astfel încât $(B \cdot B^T) \cdot y = \mathbf{0}$. Atunci $y^T \cdot (B \cdot B^T) \cdot y = 0$, adică, $(B^T \cdot y)^T \cdot (B^T \cdot y) = \|B^T \cdot y\|^2 = 0$ și de aici rezultă $B^T \cdot y = \mathbf{0}$. o combinație lineară netrivială a liniilor lui B egală cu zero, ceea ce contrazice faptul că $\text{rang}(B) = m+1$.

Evident, c_p este în spațiul nul al lui B , deoarece

$$B \cdot c_p = B \cdot (c' - B^T \cdot (B \cdot B^T)^{-1} \cdot B \cdot c') = B \cdot c' - B \cdot c' = \mathbf{0}$$

Dacă notăm vectorul $v = (B \cdot B^T)^{-1} \cdot B \cdot c'$, atunci $c' - c_p = B^T \cdot v$, adică, $c' - c_p$ este situat în spațiul generat de liniile lui B .

Deoarece c' poate fi scris ca suma dintre vectorul c_p din spațiul nul al lui B și a vectorului $(c' - c_p)$ din spațiul generat de liniile lui B , rezultă că c_p este proiecția lui c' pe spațiul nul al lui B . ■

Propoziția 3.18 Vectorul $b' = a_0 - \frac{\alpha}{n} \hat{c}_p$ minimizează $c'^T \cdot x$ peste mulțimea $S(a_0, \frac{\alpha}{n}) \cap \bar{\Omega}$.

Demonstrație. Deoarece $a \in \Pi$ și $B \cdot \hat{c}_p = \mathbf{0}$, avem

$$\begin{aligned} B \cdot b' &= B \cdot a_0 - \frac{\alpha}{n} B \cdot \hat{c}_p = \begin{pmatrix} A \cdot D \cdot a_0 \\ \mathbf{e}^T \cdot a_0 \end{pmatrix} = \\ &= \begin{pmatrix} \frac{1}{n} A \cdot a \\ 1 \end{pmatrix} = \begin{pmatrix} \mathbf{0} \\ 1 \end{pmatrix} = e^{(m+1)}, \end{aligned}$$

deci, $b' \in \bar{\Omega}$. Pentru orice $x \in S(a_0, \frac{\alpha}{n}) \cap \bar{\Omega}$, avem, $B \cdot x = e^{(m+1)}$, și prin urmare, $B \cdot (b' - x) = \mathbf{0}$.

Doarece c_p este proiecția lui c' pe spațiul nul al lui B , $c' - c_p$ este ortogonal pe orice vector din spațiul nul al lui B , în particular și pe $b' - x$. Astfel $(c' - c_p)^T \cdot (b' - x) = 0$, de unde rezultă:

$$\begin{aligned} c'^T \cdot (b' - x) &= c_p^T \cdot (b' - x) = \|c_p\| \hat{c}_p^T \cdot \left[a_0 - \frac{\alpha}{n} \hat{c}_p - x \right] = \\ &= \|c_p\| \left[\hat{c}_p^T \cdot (a_0 - x) - \frac{\alpha}{n} \right]. \end{aligned}$$

Folosind inegalitatea lui Cauchy-Schwartz și ținând cont de faptul că $\|c_p\|$ este 0 sau 1, iar $x \in S(a_0, \frac{\alpha}{n})$, avem

$$\hat{c}_p^\top \cdot (a_0 - x) \leq \|c_p\| \|a_0 - x\| \leq \frac{\alpha}{n}$$

Prin urmare, $c'^\top \cdot (b' - x) \leq 0$, adică, $c'^\top \cdot b' \leq c'^\top \cdot x$ pentru orice $x \in S(a_0, \frac{\alpha}{n}) \cap \bar{\Omega}$. ■

Propoziția 3.19 Fie b' un punct care minimizează $c'^\top \cdot x$ peste $\bar{\Omega} \cap S(a_0, \frac{\alpha}{n}) = \Pi' \cap S(a_0, \frac{\alpha}{n})$. Presupunem că în problema inițială avem costul minim egal cu 0, și că $c'^\top \cdot a_0 > 0$. Atunci

$$\frac{c'^\top \cdot b'}{c'^\top \cdot a_0} \leq 1 - \frac{\alpha}{nR} \quad \text{și} \quad \left(\frac{c'^\top \cdot b'}{c'^\top \cdot a_0} \right)^n \leq \exp\left(-\frac{\alpha}{R}\right)$$

(unde $R = \sqrt{\frac{n-1}{n}}$ este raza sferei circumscrise lui Δ).

Demonstrație. Deoarece $\bar{\Omega}$ este un spațiu afin, avem

$$S(a_0, \frac{\alpha}{n}) \cap \bar{\Omega} \subseteq \Pi' \subseteq S(a_0, R) \cap \bar{\Omega},$$

iar $a_0 \in \bar{\Omega}$. Putem astfel evalua regularitatea mulțimii $P = \Pi'$ cu ajutorul mulțimilor $E = S(a_0, \frac{\alpha}{n}) \cap \bar{\Omega}$ și $E' = S(a_0, R) \cap \bar{\Omega}$, pentru care factorul de scalare este $\nu = \frac{R}{\alpha/n}$. Din ipoteză, costul minim

în problema inițială este 0 și deci, valoarea minimă a lui $c'^\top \cdot x$ peste mulțimea Π' este de asemenea 0. În aceste condiții, din formula (3.3.1) obținem

$$\frac{c'^\top \cdot b' - 0}{c'^\top \cdot a_0 - 0} \leq 1 - \frac{1}{\nu} = 1 - \frac{\alpha}{nR}.$$

Din faptul că $1 + t \leq \exp(t)$, pentru orice $t \in \mathbb{R}$, deducem că

$$\frac{c'^\top \cdot b'}{c'^\top \cdot a_0} \leq 1 - \frac{\alpha}{nR} \leq \exp\left(-\frac{\alpha}{nR}\right)$$

și de aici rezultă

$$\left(\frac{c'^\top \cdot b'}{c'^\top \cdot a_0} \right)^n \leq \exp\left(-\frac{\alpha}{R}\right).$$

■

Propoziția 3.20 Fie $b' = a_0 - \frac{\alpha}{n}\hat{c}_p$, cu $\alpha \in (0, \frac{1}{2})$ și $\|\hat{c}_p\| = 1$. Dacă notăm

$$\rho = \frac{b'_1 \cdots b'_n}{(\frac{1}{n})^n} = \prod_{j=1}^n (nb'_j)$$

atunci, are loc relația:

$$\ln \frac{1}{\rho} \leq \frac{\alpha^2}{1 - \alpha}.$$

Demonstrație. Fie vectorul $u = na_0 - nb' = e - nb'$; atunci, pentru orice j , componenta $u_j = 1 - nb'_j$. Astfel, putem scrie

$$\rho = \prod_{j=1}^n (1 - u_j). \quad (3.3.2)$$

Deoarece $b' \in \Sigma$, avem

$$\sum_{j=1}^n u_j = 0.$$

Pe de altă parte, din ipoteză rezultă $\|a_0 - b'\| = \frac{\alpha}{n}$. Din $\|u\| = n\|a_0 - b'\| = \alpha$ deducem că $\|u\|^2 = \sum_{j=1}^n u_j^2 = \alpha^2$ și deci, $|u_j| < \alpha$ pentru toți j .

Folosind inegalitatea mediilor (media geometrică este mai mică sau egală cu media aritmetică), din (3.3.2) rezultă

$$\left(\frac{1}{\rho}\right)^{\frac{1}{n}} = \left(\prod_{j=1}^n \frac{1}{1 - u_j}\right)^{\frac{1}{n}} \leq \frac{1}{n} \sum_{j=1}^n \frac{1}{1 - u_j},$$

de unde obținem

$$\frac{1}{\rho} \leq \left(\frac{1}{n} \sum_{j=1}^n \frac{1}{1 - u_j}\right)^n$$

Deoarece $|u_j| \leq \alpha$, suma puterilor, pentru $k \geq 2$, se poate evalua în modul următor:

$$\sum_{j=1}^n |u_j^k| \leq \sum_{j=1}^n \alpha^{k-2} u_j^2 = \alpha^k \quad (3.3.3)$$

(Aceasta este o evaluare mai fină decât cea evidentă $\sum_{j=1}^n |u_j^k| \leq n\alpha^k$).

Avem:

$$\sum_{j=1}^n \frac{1}{1-u_j} = \sum_{j=1}^n \sum_{k=0}^{\infty} u_j^k = \sum_{j=1}^n \left[1 + u_j + \sum_{k=2}^{\infty} u_j^k \right] = n + 0 + \sum_{j=1}^n \sum_{k=2}^{\infty} u_j^k$$

Dar

$$\sum_{j=1}^n \sum_{k=2}^{\infty} u_j^k \leq \sum_{j=1}^n \sum_{k=2}^{\infty} |u_j^k| = \sum_{k=2}^{\infty} \sum_{j=1}^n |u_j^k|,$$

și deoarece din (3.3.3) avem $\sum_{j=1}^n |u_j^k| \leq \alpha^k$, rezultă

$$\sum_{j=1}^n \sum_{k=2}^{\infty} u_j^k \leq \sum_{k=2}^{\infty} \alpha^k = \frac{\alpha^2}{1-\alpha}.$$

Prin urmare, avem:

$$\sum_{j=1}^n \frac{1}{1-u_j} \leq n + \frac{\alpha^2}{1-\alpha}$$

și deci,

$$\frac{1}{\rho} \leq \left(\frac{1}{n} \left(n + \frac{\alpha^2}{1-\alpha} \right) \right)^n = \left(1 + \frac{\alpha^2}{n(1-\alpha)} \right)^n$$

Deoarece $1 + \frac{\alpha^2}{n(1-\alpha)} \leq \exp\left(\frac{\alpha^2}{n(1-\alpha)}\right)$, rezultă $\frac{1}{\rho} \leq \exp\left(\frac{\alpha^2}{1-\alpha}\right)$ și deci,

$$\ln \frac{1}{\rho} \leq \frac{\alpha^2}{1-\alpha}.$$

■

Teorema 3.21 Fie vectorul $b = T_a^{-1}(b')$, obținut prin intermediul funcției Φ . Dacă există $w \in \Pi$ astfel încât $c^\top \cdot w = 0$, atunci ori $c^\top \cdot b = 0$, ori $f(b) \leq f(a) - \delta$.

Demonstrație. Demonstrăm mai întâi că dacă $c^\top \cdot w = 0$, atunci $c_p \neq 0$.

Vom presupune prin absurd că $c_p = 0$. Deoarece $c^\top \cdot w = 0$, rezultă că $c'^\top \cdot w' = 0$, unde $w' = T_a(w)$. Deoarece $c_p = 0$, c' este în spațiul

generat de liniile lui B și este ortogonal pe orice vector din spațiul nul al lui B , în particular pe $w' - a_0$. Astfel, $c'^T \cdot w' = c'^T \cdot a_0$. Dar, $c'^T \cdot a_0 > 0$, pentru că altfel, $c^T \cdot a = 0$, și algoritmul s-ar fi oprit înainte de a-l determina pe b . Prin urmare, $c'^T \cdot w' = c'^T \cdot a_0 > 0$, și am obținut o contradicție.

Astfel, $c_p \neq 0$ și $\|\hat{c}_p\| = 1$.

Fie $b' = a_0 - \frac{\alpha}{n}\hat{c}_p$, vectorul calculat la punctul 3 din descrierea lui Φ . Dacă $c'^T \cdot b' = 0$ atunci $c^T \cdot b = 0$. În caz contrar, avem:

$$\begin{aligned} f'(b') - f'(a_0) &= \ln \frac{(c'^T \cdot b')^n}{b'_1 \dots b'_n} - \ln \left(\frac{c'^T \cdot a_0}{\frac{1}{n}} \right)^n = \\ &= \ln \left(\frac{c'^T \cdot b'}{c'^T \cdot a_0} \right)^n - \ln \frac{b'_1 \dots b'_n}{\left(\frac{1}{n}\right)^n} \end{aligned}$$

În baza Propoziției 3.19 și a faptului că $R < 1$, avem

$$\ln \left(\frac{c'^T \cdot b'}{c'^T \cdot a_0} \right) \leq -\frac{\alpha}{R} < -\alpha.$$

Condițiile Propoziției 3.20 fiind îndeplinite, avem:

$$-\ln \frac{b'_1 \dots b'_n}{\left(\frac{1}{n}\right)^n} \leq \frac{\alpha^2}{1 - \alpha}$$

și prin urmare,

$$f'(b') - f'(a_0) = \ln \frac{(c'^T b')^n}{b'_1 \dots b'_n} - \ln \frac{b'_1 \dots b'_n}{\left(\frac{1}{n}\right)^n} \leq -\alpha + \frac{\alpha^2}{1 - \alpha} = -\delta.$$

Deoarece în baza Lemei 3.15 avem: $f(b) - f(a) = f'(b') - f'(a')$, rezultă:

$$f(b) \leq f(a) - \delta$$

și astfel, teorema este demonstrată. ■

Observația 3.5 Complexitatea calculelor din cadrul algoritmului lui Karmarkar este următoarea: fiecare iterație necesită un număr de ordinul $O(n^3)$ operații aritmetice pentru eliminările Gaussiene, iar numărul iterațiilor este de $O(nL)$. Prin urmare, numărul total de operații aritmetice este de ordinul $O(n^4L)$ și astfel, algoritmul rezolvă problema într-un timp polinomial.

Trebuie precizat faptul că cercetările făcute ulterior de diverși autori (de exemplu [30], [24], [38], [14]) au condus la variante ale algoritmului care au îmbunătățit ordinul de complexitate.

3.3.7. Conversia la forma standard Karmarkar

Vom arăta în continuare că forma standard Karmarkar este echivalentă cu orice problemă de programare liniară. Pentru aceasta, să considerăm problema liniară în formă standard:

$$\inf \{c^\top \cdot x \mid A \cdot x = b, x \geq 0\} \quad (3.3.4)$$

Rezolvarea acesteia este echivalentă cu găsirea unei soluții a sistemului liniar de inegalități:

$$\begin{cases} A \cdot x & = b \\ x & \geq 0 \\ A^\top \cdot u & \leq c \\ c^\top \cdot x - b^\top \cdot u & = 0 \end{cases} \quad (3.3.5)$$

Dacă înlocuim variabilele arbitrare $u_j = u_j^+ - u_j^-$, unde $u_j^+ \geq 0$, $u_j^- \geq 0$, introducem variabila vectorială ecart $s \geq 0$ și facem notațiile:

$$\bar{A} = \begin{pmatrix} A & & & \\ & A^\top & -A^\top & \mathbf{I} \\ c^\top & -b^\top & b^\top & \end{pmatrix}, \quad \bar{b} = \begin{pmatrix} b \\ c \\ 0 \end{pmatrix}$$

$$y^\top = (x^\top, (u^+)^\top, (u^-)^\top, s^\top)$$

sistemul de inegalități (3.3.5) se rescrie astfel:

$$\begin{cases} \bar{A} \cdot y = \bar{b} \\ y \geq 0 \end{cases} \quad (3.3.6)$$

Vom considera matricea \bar{A} de dimensiune $m \times n$ și fie L mărimea problemei date de (3.3.6).

Conform Lemei 3.1, componentele oricărei soluții de bază a sistemului (3.3.6) sunt mărginite în modul de 2^L . Prin urmare, dacă notăm numărul $\mu = n2^L$, putem adăuga la sistemul (3.3.6) și restricția:

$$y_1 + y_2 + \cdots + y_n \leq \mu,$$

fără ca soluțiile acestuia să fie afectate. Vom introduce aici variabila ecart $y_{n+1} \geq 0$, și considerăm acum variabila vectorială $y \in \mathbb{R}^{n+1}$. Dacă mai extindem și matricea \bar{A} cu o coloană nulă și notăm $\bar{A}' = (\bar{A} \mathbf{0})$, sistemul (3.3.6) devine echivalent cu:

$$\begin{cases} \bar{A}' \cdot y = \bar{b} \\ \mathbf{e}^\top \cdot y = \mu \\ y \geq \mathbf{0}. \end{cases}$$

Dacă scalăm variabila y și notăm $x' = \frac{1}{\mu}y$, atunci

$$\begin{cases} \bar{A}' \cdot y = \bar{b} \\ \mathbf{e}^\top \cdot y = \mu \\ y \geq \mathbf{0} \end{cases} \iff \begin{cases} \mu \bar{A}' \cdot x' = \bar{b} \\ \mathbf{e}^\top \cdot x' = 1 \\ x' \geq \mathbf{0}. \end{cases} \quad (3.3.7)$$

Din fiecare ecuație i , $1 \leq i \leq m$, a sistemului $\mu \bar{A}' \cdot x' = \bar{b}$, vom scade din ambii membri \bar{b}_i ($\mathbf{e}^\top \cdot x'$) = \bar{b}_i ; obținem sistemul echivalent: $(\mu \bar{A}' - \bar{b}^\top \cdot \mathbf{E}) \cdot x' = \mathbf{0}$, unde E este matricea cu toate elementele egale cu 1. Astfel, dacă notăm

$$A' = (\mu \bar{A}' - \bar{b}^\top \cdot \mathbf{E}),$$

sistemele din (3.3.7) devin echivalente cu:

$$\begin{cases} A' \cdot x' = \mathbf{0} \\ \mathbf{e}^\top \cdot x' = 1 \\ x' \geq \mathbf{0}. \end{cases} \quad (3.3.8)$$

Prin urmare, problema (3.3.4) este echivalentă cu sistemul (3.3.8), care reprezintă intersecția unui spațiu liniar cu un simplex. Pentru a ajunge la o problemă în forma standard Karmarkar, vom adăuga aici o nouă variabilă $x'_{n+2} \geq 0$, astfel încât vectorul $a_0 = \frac{1}{n+2}\mathbf{e} \in \mathbb{R}^{n+2}$ să fie o soluție inițială admisibilă. Obținem astfel următorul sistem, echivalent cu cel anterior:

$$\begin{cases} A' \cdot x' - (A' \cdot \mathbf{e}) x'_{n+2} = \mathbf{0} \\ \mathbf{e}^\top \cdot x' + x'_{n+2} = 1 \\ x' \geq \mathbf{0}, \quad x'_{n+2} \geq 0. \end{cases} \quad (3.3.9)$$

Dacă notăm acum $\hat{A} = A' - (A' \cdot \mathbf{e}) \in \mathbb{R}^{m \times (n+2)}$ și considerăm variabila vectorială $\hat{x} \in \mathbb{R}^{n+2}$, problema (3.3.4) este echivalentă cu

următoarea problemă în formă standard Karmarkar:

$$\min \left\{ \hat{x}_{n+2} \mid \hat{A} \cdot \hat{x} = \mathbf{0}, \mathbf{e}^T \cdot \hat{x} = 1, \hat{x} \geq \mathbf{0} \right\}.$$

Costul acestei probleme este întotdeauna $\hat{x}_{n+2} \geq 0$ și este evident faptul că această problemă are optimul 0, dacă și numai dacă sistemul (3.3.9) este compatibil, adică, dacă problema (3.3.4) are o soluție optimă finită.

Observația 3.6 *Este ușor de văzut că aceste operații de transformare a unei probleme de programare liniară într-o problemă standard Karmarkar necesită doar un număr polinomial de operații aritmetice, iar mărimea problemei rezultate este la rândul ei mărginită polinomial de mărimea problemei inițiale. Astfel, pe un calculator virtual ce execută toate operațiile aritmetice în mod exact, algoritmul proiectiv al lui Karmarkar rezolvă orice problemă de programare liniară într-un timp polinomial.*

Modul de a transforma o problemă de programare liniară în forma standard Karmarkar nu este unic. Există și alte scheme pentru transformările de acest fel, care pot conduce eventual la probleme de dimensiuni mai mici.

Proprietatea acestui algoritm de a rezolva problemele în timp polinomial se extinde și la calculatoarele tradiționale, cu care se lucrează în mod obișnuit, și care efectuează operațiile aritmetice în simplă sau dublă precizie.

3.4. Algoritmul afin

De la publicarea algoritmului proiectiv a lui Karmarkar în 1984, s-au întreprins numeroase cercetări în direcția adaptării metodelor de punct interior, specifice optimizărilor neliniare, la problemele de programare liniară. În prezent, aceste metode se pot împărți în două clase: cele care folosesc transformări proiective, și cele care folosesc transformări affine. O caracterizare foarte generală care se poate face acestor două clase de algoritmi este următoarea. Algoritmii proiectivi au o descriere mai greoaie, în schimb, sunt mai ușor de analizat.

Aceasta înseamnă că pentru descrierea lor este necesară utilizarea unor funcții barieră logaritmice (sau funcții potențial), a condiției ca funcția obiectiv să aibe optimul zero, etc., în schimb, cu ajutorul acestui apanaj tehnic, se poate demonstra că algoritmul converge în timp polinomial. Algoritmii afini se pot descrie mai ușor, dar sunt greu de analizat. Cu alte cuvinte, ei au o descriere geometric-intuitivă foarte simplă, dar demonstrarea convergenței lor este o problemă matematică interesantă și dificilă. Primele demonstrații de convergență cunoscute pentru acest caz sunt cele care presupun ca problemele liniare să fie atât primal, cât și dual nedegenerate (deși, din punct de vedere intuitiv, astfel de ipoteze n-ar fi necesare).

Ar fi greșit să se considere că algoritmi proiectivi ar fi mai buni decât cei afini, numai datorită faptului că pentru ei convergența poate fi dovedită mai ușor. De fapt, cele mai multe experimentări s-au făcut cu algoritmi afini (a se vedea [1], [23]), din cauză că aceștia au evidente avantaje față de algoritmi proiectivi. De exemplu, algoritmi afini se aplică direct problemelor liniare în formă standard și în afară de aceasta, implementarea lor se poate face mult mai eficient. Ca o ironie a soartei, putem afirma că "ce este teoretic mai bun (în cazurile defavorabile), nu este și practic mai eficient (în cazurile obișnuite)".

Deși studiul metodelor de punct interior pentru programarea liniară au luat un avânt abia după anul 1984, prima publicație a unui algoritm afin a fost făcută cu mult mai înainte și aparține matematicianului sovietic I.I. Dikin [9]. Vom expune în continuare acest algoritm, urmând modul de prezentare din lucrarea lui Vanderbei și Lagarias [39].

3.4.1. Prezentarea algoritmului

Fiind dată matricea A de dimensiune $m \times n$ și vectorii $c \in \mathbb{R}^n$, $b \in \mathbb{R}^m$, considerăm următoarea problemă primală de programare liniară:

$$\min \{c^T \cdot x \mid A \cdot x = b, x \geq \mathbf{0}\}. \quad (P)$$

Problema duală asociată este

$$\max \{b^T \cdot u \mid A^T \cdot u \leq c\}. \quad (D)$$

Vom introduce următoarele notații. Fie

$$\mathcal{P} = \{x \in \mathbb{R}^n \mid A \cdot x = b, x \geq \mathbf{0}\}$$

mulțimea soluțiilor admisibile pentru problema (P);

$$\mathcal{P}^0 = \{x \in \mathbb{R}^n \mid A \cdot x = b, x > \mathbf{0}\}$$

interiorul relativ al lui \mathcal{P} ; $\partial\mathcal{P} = \mathcal{P} - \mathcal{P}^0$ frontiera lui \mathcal{P} . Fiind dat un vector $x \in \mathbb{R}^n$, vom nota cu $D_x = \text{diag}(x)$ matricea diagonală.

Descrierea algoritmului se face prin intermediul a trei funcții. Prima funcție, $w : \mathcal{P}^0 \rightarrow \mathbb{R}^m$, asociază fiecărui $x \in \mathcal{P}^0$ un vector dual:

$$w(x) = (A \cdot D_x^2 \cdot A^\top) \cdot A \cdot D_x^2 \cdot c.$$

Cea de a doua funcție, $r : \mathcal{P}^0 \rightarrow \mathbb{R}^n$, exprimă diferența dintre membrii restricțiilor din problema duală:

$$r(x) = c - A^\top \cdot w(x).$$

Se observă cu ușurință că $w(x)$ este dual admisibil dacă și numai dacă $r(x) \geq 0$. Cea de a treia funcție, $y : \mathcal{P}^0 \rightarrow \mathcal{P}$, este definită astfel:

$$y(x) = x - \frac{D_x^2 \cdot r(x)}{\|D_x \cdot r(x)\|}. \quad (3.4.1)$$

Algoritmul afin.

Punctele generate sunt definite prin următoarea relație de recurență:

$$x^{(k+1)} = \begin{cases} y(x^{(k)}) & \text{dacă } x^{(k)} \in \mathcal{P}^0 \\ x^{(k)} & \text{dacă } x^{(k)} \in \partial\mathcal{P}. \end{cases}$$

De asemenea, se generează și vectorii duali:

$$w^{(k)} = \begin{cases} w(x^{(k)}) & \text{dacă } x^{(k)} \in \mathcal{P}^0 \\ w^{(k-1)} & \text{dacă } x^{(k)} \in \partial\mathcal{P}. \end{cases}$$

precum și vectorii costurilor reduce:

$$r^{(k)} = c - A^\top \cdot w^{(k)}.$$

Pentru simplificarea scrierii, vom nota $D_k = D_{x^{(k)}}$.

Se observă că, de prima dată când $x^{(k)}$ ajunge pe frontiera domeniului de admisibilitate, șirul care se generează în continuare, rămâne fixat pe acest vector. Prin comparație, șirul vectorilor duali rămân fixați pe valoarea corespunzătoare ultimului punct din interiorul domeniului, înainte de a se atinge frontiera $\partial \mathcal{P}$.

Algoritmul descris aici diferă cu puțin de cel prezentat de Barnes în [4] și de Vanderbei cu Lagarias în [40]. Deosebirea constă în felul în care se alege lungimea pasului. În cazul nostru, lungimea pasului este astfel încât de fiecare dată se ajunge pe suprafața elipsoidului înscris (a se vedea [4] pentru definiția elipsoidului în cauză), în timp ce Barnes, alege lungimea pasului cu o fracțiune α din distanța până la elipsoid. Astfel, dacă în cazul nostru algoritmul se poate opri după un număr finit de pași, în varianta lui Barnes are loc o apropiere asimptotică de soluția optimă. În lucrarea lui Vanderbei și Lagarias, lungimea pasului este și ea luată cu o anumită fracțiune din distanța până la cea mai apropiată față a domeniului de admisibilitate. Acest lucru ar însemna, ca în cazul nostru să schimbăm definiția funcției $y(x)$ dată de (3.4.1), astfel:

$$y(x) = x - \frac{\alpha D_x^2 \cdot r(x)}{\gamma(x)}$$

unde $\alpha \in (0, 1)$ și $\gamma(x) = \max_j \{x_j r_j(x)\}$. Se poate vedea cu ușurință că

$$\gamma(x) \leq \|D_x \cdot r(x)\|_\infty \leq \|D_x \cdot r(x)\|$$

(ipoteza 1. de mai jos implică $\gamma(x) > 0$). Deci, lungimea pasului aleasă de Vanderbei și Lagarias este cea mai mare, urmată de cea care folosește norma L^∞ , și în cele din urmă, de cea în normă L^2 pe care o vom folosi în prezentarea noastră. Majoritatea implementărilor folosesc lungimea cea mai mare a pasului, dar demonstrațiile pe care le vom da aici pot fi ușor adaptate la cazul normei L^∞ , împreună cu introducerea factorului de contracție $\alpha < 1$.

3.4.2. Teorema de convergență

Vom face următoarele ipoteze:

Ipoteza 1. $-\infty < \min_{\mathcal{P}} \{c^\top \cdot x\} < \max_{\mathcal{P}} \{c^\top \cdot x\}$.

Ipoteza 2. \mathcal{P}^0 este nevidă; $x^{(0)} \in \mathcal{P}^0$ este dat.

Ipoteza 3. Matricea A are liniile liniar independente.

Ipoteza 4. Matricea $A \cdot D_x^2 \cdot A^\top$ este inversabilă pentru orice $x \in \mathcal{P}$.

(Această condiție se mai numește și *nedegenerare primală*.)

Se observă cu ușurință că ipoteza 3 implică inversabilitatea lui $A \cdot D_x^2 \cdot A^\top$ pentru orice $x \in \mathcal{P}^0$, ceea ce înseamnă că ipoteza 4 este de fapt o condiție pentru nedegenerarea primală pe frontiera lui \mathcal{P} . În plus, nedegenerarea primală implică faptul că domeniul de definiție a funcției w poate fi extins pe întregul domeniu \mathcal{P} . De asemenea, ipoteza 1 implică $\|D_x \cdot r(x)\| \neq 0$ pentru orice $x \in \mathcal{P}^0$, și prin urmare, funcția $y(x)$ este bine definită.

Teorema 3.22 *Punctele $x^{(k)}$ generate de algoritm converg către un punct primal admisibil $\bar{x} \in \mathcal{P}$, iar șirul $w^{(k)}$ converge către un punct dual admisibil \bar{w} . În plus, punctul primal admisibil \bar{x} și costul redus $\bar{r} = c - A^\top \cdot \bar{w}$ satisfac condițiile ecarturilor complementare:*

$$\bar{x}_j = 0 \quad \text{dacă și numai dacă} \quad \bar{r}_j > 0. \quad (3.4.2)$$

Demonstrație. Vom considera separat cazurile în care \mathcal{P} este mărginită sau nemărginită și vom structura demonstrația în mai mulți pași în care demonstrăm anumite afirmații.

Cazul 1: mulțimea \mathcal{P} este mărginită.

Pasul 1. Admisibilitatea primală este conservată. Într-adevăr, se verifică cu ușurință că $A \cdot D_x^2 \cdot r(x) = 0$, și prin urmare, deoarece $A \cdot x = b$, avem:

$$A \cdot y(x) = A \cdot x - \frac{A \cdot D_x^2 \cdot r(x)}{\|D_x \cdot r(x)\|} = b.$$

Din definiția lui $y(x)$ dată de (3.4.1), componenta j se scrie:

$$y_j(x) = x_j \left(1 - \frac{x_j r_j(x)}{\|D_x \cdot r(x)\|} \right) \quad (3.4.3)$$

și deoarece evident $-1 \leq \frac{x_j r_j(x)}{\|D_x \cdot r(x)\|} \leq 1$, avem:

$$0 \leq y_j(x) \leq 2x_j \quad (3.4.4)$$

Pasul 2. Dacă se atinge frontiera, avem optimalitate. Să presupunem că $x^{(k)} \in \mathcal{P}^0$ și că $x_j^{(k+1)} = 0$. Atunci, din (3.4.3) avem $x_j^{(k)} r_j^{(k)}(x) = \|D_k \cdot r^{(k)}\|$. Din faptul că $x_i^{(k)} > 0$ pentru toți i , deducem că $r_j^{(k)} > 0$ și $r_i^{(k)} = 0$ pentru toți $i \neq j$. Deoarece $\bar{x} = x^{(k+1)}$ și $\bar{w} = w^{(k)}$, rezultă că (3.4.2) este adevărată. Prin urmare, vom presupune că $x^{(k)} \in \mathcal{P}^0$ pentru orice k .

Pasul 3. Valoarea funcției obiectiv descrește. Avem:

$$c^\top \cdot x - c^\top \cdot y(x) = \frac{c^\top \cdot D_x^2 \cdot r(x)}{\|D_x \cdot r(x)\|}$$

Pe de altă parte, $D_x \cdot r(x) = P_x \cdot D_x \cdot c$, unde prin

$P_x = \mathbf{I} - D_x \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x$ am notat operatorul de proiecție pe spațiul nul al lui $A \cdot D_x$. Deci,

$$c^\top \cdot x - c^\top \cdot y(x) = \frac{c^\top \cdot D_x \cdot P_x \cdot D_x \cdot c}{\|D_x \cdot r(x)\|}$$

și deoarece P_x este matricea de proiecție, ca este idempotentă și simetrică, astfel încât

$$c^\top \cdot x - c^\top \cdot y(x) = \|P_x \cdot D_x \cdot c\| = \|D_x \cdot r(x)\|$$

Rezultă deci,

$$c^\top \cdot x^{(k)} - c^\top \cdot x^{(k+1)} = \|D_k \cdot r^k\| \geq 0.$$

Pasul 4. Condiția ecarturilor complementare se păstrează la limită. În baza ipotezei 1 și a pasului anterior, șirul $c^\top \cdot x^{(k)}$ este mărginit inferior și descrescător, deci convergent. Astfel, din ultima relație rezultă că

$$\lim_{k \rightarrow \infty} \|D_k \cdot r^k\| = 0.$$

Pasul 5. Variabilele duale sunt mărginite. Din ipoteza 4 rezultă că $w(x)$ este o funcție continuă pe mulțimea compactă \mathcal{P} ; deci $w(x)$ este mărginită.

În cele ce urmează, vom adopta următoarele notații. Fie \bar{w} un punct de acumulare a șirului $w^{(k)}$, și $w^{(k_p)}$ un subșir convergent la \bar{w} , deci $\lim_{p \rightarrow \infty} w^{(k_p)} = \bar{w}$. Vom nota cu $\bar{r} = c - A^\top \cdot \bar{w}$. Definim următoarele mulțimi de indici:

$$\mathcal{B} = \{j \mid \bar{r}_j = 0\}, \quad \mathcal{R} = \{j \mid \bar{r}_j \neq 0\}.$$

Evident, \mathcal{B} este constituită din mulțimea indicilor de bază iar \mathcal{R} din cea a indicilor nebazici. În concordanță cu aceste mulțimi, coloanele matricei A se pot partiționa în două submatrici: $A = \begin{pmatrix} B \\ R \end{pmatrix}$, iar componentele vectorului $x \in \mathbb{R}^n$ în $x = \begin{pmatrix} x_{\mathcal{B}} \\ x_{\mathcal{R}} \end{pmatrix}$, unde, $x_{\mathcal{B}}$ reprezintă componentele de bază, iar $x_{\mathcal{R}}$ cele nebazice.

Pasul 6. Avem $\lim_{x_{\mathcal{R}} \rightarrow 0} r(x) = \bar{r}$. Din definiția lui $r(x)$ rezultă:

$$\begin{aligned} r(x) &= \left[\mathbf{I} - A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x^2 \right] \cdot c = \\ &= \left[\mathbf{I} - A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x^2 \right] \cdot \bar{r} \end{aligned}$$

unde cea de a doua egalitate rezultă din definiția lui \bar{r} și din faptul că matricea din parantezele drepte anulează pe A^\top . Ținând seama de faptul că componentele de bază a lui \bar{r} sunt zero, din ultima ecuație obținem:

$$\bar{r} - r(x) = A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot R \cdot D_{x_{\mathcal{R}}}^2 \cdot \bar{r}_{\mathcal{R}}$$

Deoarece matricea $(A \cdot D_x^2 \cdot A^\top)^{-1}$ există și este continuă pe tot domeniul compact \mathcal{P} , rezultă că ea este mărginită. Prin urmare, dacă $x_{\mathcal{R}} \rightarrow 0$, matricea diagonală $D_{x_{\mathcal{R}}}^2$ devine nulă și din ultima relație rezultă că afirmația este adevărată.

Pasul 7. Componentele nebazice ale lui x converg la zero. Fie $j \in \mathcal{R}$ fixat. Din pasul 4 rezultă $\lim_{k \rightarrow \infty} x_j^{(k)} r_j^{(k)} = 0$. În baza notațiilor făcute mai sus, $\lim_{p \rightarrow \infty} r_j^{(k_p)} = \bar{r}_j$, care este un număr diferit de zero. Deci, pentru subșirul $x_j^{(k_p)}$ avem: $\lim_{p \rightarrow \infty} x_j^{(k_p)} = 0$, pentru

orice $j \in \mathcal{R}$, adică,

$$\lim_{p \rightarrow \infty} x_{\mathcal{R}}^{(k_p)} = \mathbf{0}.$$

Să presupunem acum, prin absurd, că șirul $x_{\mathcal{R}}^{(k)}$ nu converge la zero în raport cu toate elementele sale, adică, există un $\delta > 0$ astfel încât $x_{\mathcal{R}}^{(k)} \in \overline{C}_\delta$ pentru un număr infinit de valori ale lui k , unde \overline{C}_δ este complementara mulțimii

$$C_\delta = \{x_{\mathcal{R}} \mid 0 \leq x_i < \delta, \text{ pentru orice } i \in \mathcal{R}\}.$$

Evident, pentru orice altă valoare mai mică decât δ , această proprietate se păstrează. Fie deci δ suficient de mic, astfel încât \overline{C}_δ să conțină o infinitate de elemente a șirului și

$$\left\| r_j^{(k'_p)} \right\| \geq \frac{1}{2} \|\bar{r}_j\| \quad (3.4.5)$$

pentru toți indicii j și toate punctele x pentru care $x_{\mathcal{R}} \in C_\delta$. Acest lucru este posibil datorită afirmației din pasul 6. În ipotezele presupuse de noi aici, mulțimea de indici

$$\mathcal{K} = \left\{ k \mid x_{\mathcal{R}}^{(k)} \in C_\delta \text{ și } x_{\mathcal{R}}^{(k+1)} \in \overline{C}_\delta \right\}$$

este infinită. Dacă notăm $\mathcal{K}_j = \left\{ k \in \mathcal{K} \mid x_j^{(k+1)} \geq \delta \right\}$, atunci $\mathcal{K} = \bigcup_{j \in \mathcal{R}} \mathcal{K}_j$. Deoarece \mathcal{R} este finită, există un indice j pentru care \mathcal{K}_j este infinită. Pentru orice $k'_p \in \mathcal{K}_j$ avem

$$x_{\mathcal{R}}^{(k'_p)} < \delta \quad \text{și} \quad x_j^{(k'_p+1)} \geq \delta.$$

Folosind formula (3.4.4), cea de a doua afirmație de mai sus implică $x_j^{(k'_p)} \geq \frac{\delta}{2}$. Din (3.4.5) observăm că pentru orice p , avem

$$\left\| x_j^{(k'_p)} r_j^{(k'_p)} \right\| \geq \frac{1}{4} \delta \|\bar{r}_j\| > 0.$$

Dar această relație contrazice afirmația din pasul 4 și astfel ajungem la concluzia că $x_{\mathcal{R}}^{(k)}$ converge la zero.

Pasul 8. Variabilele duale converg la \bar{w} . Similar ca la pasul 6, efectuăm mai întâi următoarele calcule:

$$\begin{aligned} w^k - \bar{w} &= (A \cdot D_k^2 \cdot A^\top)^{-1} \cdot A \cdot D_k^2 \cdot (c - A^\top \cdot \bar{w}) = \\ &= (A \cdot D_k^2 \cdot A^\top)^{-1} \cdot A \cdot D_k^2 \cdot \bar{r} = \\ &= (A \cdot D_k^2 \cdot A^\top)^{-1} \cdot R \cdot D_{x_{\mathcal{R}}}^{(k)} \cdot \bar{r}_{\mathcal{R}}. \end{aligned}$$

Deoarece $(A \cdot D_k^2 \cdot A^\top)^{-1}$ este mărginită și $x_{\mathcal{R}}^{(k)}$ converge la zero, rezultă că diferența de mai sus converge la zero.

Pasul 9. Pentru orice $j \in \mathcal{R}$, avem $\bar{r}_j \geq 0$. Presupunem prin absurd că există $j \in \mathcal{R}$ astfel încât $\bar{r}_j < 0$. Deoarece $w^k \rightarrow \bar{w}$, există un K astfel încât $r_j^{(k)} < 0$ pentru toți $k \geq K$. De aici, se observă că

$$x_j^{(k+1)} = x_j^{(k)} \left(1 - \frac{x_j^{(k)} r_j^{(k)}}{\|D_k \cdot r^{(k)}\|} \right) > x_j^{(k)} \quad \text{pentru orice } k \geq K.$$

ceea ce contrazice afirmația din pasul 7.

Pasul 10. Șirul componentelor de bază $x_{\mathcal{B}}^{(k)}$ este convergent (către $\bar{x}_{\mathcal{B}}$). Din felul în care algoritmul construiește punctele $x^{(k)}$, avem

$$x_j^{(k+1)} - x_j^{(k)} = - \frac{\left(x_j^{(k)}\right)^2 r_j^{(k)}}{\|D_k \cdot r^{(k)}\|} \quad (3.4.6)$$

Prin urmare, $x_j^{(k)}$ este convergent dacă

$$\sum_{k=0}^{\infty} \frac{\left(x_j^{(k)}\right)^2 |r_j^{(k)}|}{\|D_k \cdot r^{(k)}\|} < \infty.$$

Pentru $j \in \mathcal{B}$, avem

$$r_j(x) = r_j(x) - \bar{r}_j = (e^j)^\top \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot R \cdot D_{x_{\mathcal{R}}}^2 \cdot \bar{r}_{\mathcal{R}}$$

Deci,

$$x_j^2 r_j = \sum_{l \in \mathcal{R}} \sigma_{jl}(x) x_l^2 \bar{r}_l$$

unde

$$\sigma_{jl}(x) = (e^j)^\top \cdot D_x^2 \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot R \cdot e^l$$

Continuitatea funcției $\sigma_{jl}(x)$ și mărginirea domeniului \mathcal{P} implică existența constantelor de mărginire $\bar{\sigma}_{jl}$ astfel încât $|\sigma_{jl}(x)| \leq \bar{\sigma}_{jl}$ pentru orice $x \in \mathcal{P}$. Prin urmare,

$$\sum_{k=0}^{\infty} \frac{\left(x_j^{(k)}\right)^2 \left|r_j^{(k)}\right|}{\|D_k \cdot r^{(k)}\|} \leq \sum_{l \in \mathcal{R}} \bar{\sigma}_{jl} \sum_{k=0}^{\infty} \frac{\left(x_l^{(k)}\right)^2 \bar{r}_l}{\|D_k \cdot r^{(k)}\|} \quad (3.4.7)$$

Afirmația din pasul 7 și ecuația (3.4.6) implică că, pentru orice $l \in \mathcal{R}$, seria

$$\sum_{k=0}^{\infty} \frac{\left(x_l^{(k)}\right)^2 \bar{r}_l}{\|D_k \cdot r^{(k)}\|}$$

este convergentă. Deoarece $r_l^{(k)} \rightarrow \bar{r}_l$, rezultă că membrul drept din (3.4.7) este finit.

Pasul 11. Condiția ecarturilor complementare este îndeplinită.

Este suficient să arătăm că $\bar{x}_B > 0$. Fie $j \in \mathcal{B}$ fixat. Pentru a arăta că $\bar{x}_j > 0$, este suficient ca seria

$$\sum_{k=0}^{\infty} \frac{\log \left(x_j^{(k+1)}\right)}{x_j^{(k)}}$$

să fie absolut convergentă, ceea ce are loc, dacă și numai dacă seria

$$\sum_{k=0}^{\infty} \frac{x_j^{(k+1)} - x_j^{(k)}}{x_j^{(k)}}$$

este absolut convergentă. Din relația (3.4.3), obținem

$$\sum_{k=0}^{\infty} \frac{x_j^{(k+1)} - x_j^{(k)}}{x_j^{(k)}} = \sum_{k=0}^{\infty} \frac{x_j^{(k)} r_j^{(k)}}{\|D_k \cdot r^{(k)}\|}.$$

Pentru a arăta că seria din membrul drept este absolut convergentă, vom folosi același argument ca în pasul precedent, cu excepția faptului că σ_{jl} se va înlocui cu o funcție similară:

$$\rho_{jl}(x) = (e^j)^\top \cdot D_x \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot R \cdot e^l$$

Spre deosebire de situația din pasul precedent, unde funcția $\sigma_{jl}(x)$ era mărginită pe tot domeniul \mathcal{P} , în cazul de față este suficient ca

$\rho_{jl}(x)$ să fie mărginită doar pentru elementele șirului $x^{(k)}$. Acest lucru rezultă din faptul că $x^{(k)}$ este convergent și $(A \cdot D_x^2 \cdot A^\top)^{-1}$ este mărginită.

Cu aceasta, teorema este demonstrată pentru cazul când domeniul \mathcal{P} este mărginit.

Cazul 2: mulțimea \mathcal{P} este nemărginită.

Ipoteza de mărginire a domeniului de admisibilitate \mathcal{P} , împreună cu condiția de nedegenerare primală, a fost utilizată în următoarele situații:

1. La pasul 5, pentru a se arăta că funcția variabilelor duale $w(x)$ este mărginită.
2. La pasul 6, 8 și 11, pentru a se arăta că $(A \cdot D_x^2 \cdot A^\top)^{-1}$ este mărginită.
3. La pasul 10, pentru a se arăta că funcția $\sigma_{jl}(x)$ este mărginită.

Vom arăta în continuare că ipoteza de mărginire nu este necesară pentru nici una din situațiile de mai sus, adică, $(A \cdot D_x^2 \cdot A^\top)^{-1}$ este mărginită, chiar dacă mulțimea \mathcal{P} este nemărginită. Dacă notăm cu $\widehat{\mathcal{P}}$ mulțimea compactă formată din acoperirea convexă a punctelor extreme ale lui \mathcal{P} , atunci, orice punct $x \in \mathcal{P}$ se poate scrie sub forma $x = \hat{x} + \hat{t}$, unde $\hat{x} \in \widehat{\mathcal{P}}$ și $\hat{t} \geq 0$, $A \cdot \hat{t} = 0$. Se verifică cu ușurință că $A \cdot D_x^2 \cdot A^\top - A \cdot D_{\hat{x}}^2 \cdot A^\top$ este semipozitiv definită, de unde rezultă că $\lambda_1(x) \geq \lambda_1(\hat{x})$, unde $\lambda_1(x)$ reprezintă cea mai mică valoare proprie a lui $A \cdot D_x^2 \cdot A^\top$. Din condiția de nedegenerare primală și din faptul că $\widehat{\mathcal{P}}$ este compactă, rezultă că $\lambda_1(\hat{x}) \geq \bar{\lambda}_1 > 0$ pentru orice $\hat{x} \in \widehat{\mathcal{P}}$. Deoarece norma din L^2 a lui $(A \cdot D_x^2 \cdot A^\top)^{-1}$ este chiar $\frac{1}{\lambda_1(x)}$, avem

$$\left\| (A \cdot D_x^2 \cdot A^\top)^{-1} \right\| = \frac{1}{\lambda_1(x)} \leq \frac{1}{\lambda_1(\hat{x})} \leq \frac{1}{\bar{\lambda}_1} < \infty.$$

Trebuie subliniat faptul că condiția de nedegenerare primală este esențială pentru mărginirea lui $(A \cdot D_x^2 \cdot A^\top)^{-1}$, așa cum se poate vedea din următorul exemplu:

$$\min \{x_1 \mid x_1 - x_2 = 0, x_1 \geq 0, x_2 \geq 0\}.$$

Evident, $(x_1, x_2) = (0, 0)$ este un punct admisibil pentru care

$(A \cdot D_x^2 \cdot A^\top)^{-1} = \frac{1}{x_1^2 + x_2^2}$ devine nemărginită.

Vom arăta acum că, condiția de nedegenerare primală poate să lipsească din prima și a treia situație descrisă mai sus. Pentru aceasta, este suficient să demonstrăm că, pentru orice vector $v \in \mathbb{R}^n$, funcția

$$w^v(x) = (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x^2 \cdot v$$

este mărginită.

Introducem următoarele convenții de scriere:

- Dacă A_i este linia i din matricea A , atunci vom nota cu $A_i(v)$ matricea care se obține din A prin încocuirea liniei A_i cu vectorul v .
- $\det_{j_1, \dots, j_m}(A)$ este determinantul matricei pătratice $m \times m$, care este formată din coloanele A^{j_1}, \dots, A^{j_m} ale matricei A .

Pentru a scrie componenta $w_i^v(x)$, se folosește regula lui Cramer și teorema lui Cauchy-Binet:

$$w_i^v(x) = \frac{\sum_{1 \leq j_1 < \dots < j_m \leq n} (x_{j_1} \cdots x_{j_m})^2 \det_{j_1, \dots, j_m}(A) \det_{j_1, \dots, j_m}(A_i(v))}{\sum_{1 \leq j_1 < \dots < j_m \leq n} (x_{j_1} \cdots x_{j_m})^2 \left[\det_{j_1, \dots, j_m}(A) \right]^2} \quad (3.4.8)$$

Pentru a majora această expresie, vom folosi inegalitatea

$$\frac{\left| \sum_{i=1}^N r_i \right|}{\sum_{i=1}^N s_i} \leq \max_{1 \leq i \leq N} \frac{|r_i|}{s_i}$$

care este adevărată pentru orice șir de perechi de valori reale (r_i, s_i) , $1 \leq i \leq N$, pentru care $s_i > 0$. Deoarece anumiți termeni din suma de la numărătorul relației (3.4.8) se pot anula, concomitent cu cei corespunzători din suma de la numitor, putem folosi inegalitatea de

mai sus pentru a obține următoarea majorare:

$$|w_i^v(x)| \leq \max_{\substack{1 \leq j_1 < \dots < j_m \leq n \\ \det_{j_1, \dots, j_m}(A) \neq 0}} \left| \frac{\det_{j_1, \dots, j_m}(A_i(v))}{\det_{j_1, \dots, j_m}(A)} \right|.$$

Membrul drept al acestei inegalități este independent de x și astfel, reprezintă o margine superioară. ■

3.5. Traectorii continue

Să considerăm din nou problema de programare liniară:

$$\min \{ c^T \cdot x \mid A \cdot x = b, x \geq 0 \} \quad (3.5.1)$$

în care liniile matricei A sunt liniar independente și presupunem că există un vector w , având toate componentele pozitive și pentru care $A \cdot w = b$.

Algoritmii de tip Karmarkar folosesc un proces iterativ care constă în determinarea unui șir de puncte din interiorul domeniului de admisibilitate, puncte ce se obțin prin deplasarea cu un pas anume de-a lungul unor direcții, calculate la fiecare iterație. Dacă lungimea pasului devine infinitesimală și transformările pentru determinarea direcțiilor noi se recalculază de fiecare dată, obținem varianta "continuă" a algoritmilor respectivi. Varianta discretă a algoritmilor se poate prezenta astfel:

$$x^{(k+1)} = x^{(k)} + \alpha v^{(k)} + O(\alpha^2).$$

unde, la iterația k , notăm cu $v^{(k)}$ direcția de deplasare iar cu α , lungimea pasului. Luând pe $\alpha \rightarrow 0$, obținem varianta infinitesimală a procesului de determinare a punctelor, pentru care traiectoria lor continuă este dată de ecuația diferențială:

$$\frac{dx}{d\alpha} = v$$

unde v , ca funcție de x , definește un câmp vectorial.

Pentru algoritmul proiectiv, ecuația diferențială este:

$$\frac{dx}{dt} = - [D_x - x \cdot x^\top] \cdot P_{A \cdot D_x} \cdot D_x \cdot c$$

unde $D_x = \text{diag}(x)$ și

$$P_{A \cdot D_x} = \mathbf{I} - D_x \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x$$

iar pentru algoritmul afin, ecuația diferențială este:

$$\frac{dx}{dt} = -D_x \cdot P_{A \cdot D_x} \cdot D_x \cdot c \quad (3.5.2)$$

Numeroși autori (vezi spre exemplu [5], [6], [22], [35]) au studiat aceste traiectorii din diverse perspective, punându-se în evidență unele caracteristici foarte interesante ale acestora.

În continuare vom prezenta unele proprietăți care decurg direct din studiul ecuațiilor diferențiale prezentate mai sus. Pentru a fixa ideile, ne vom concentra doar asupra ecuației (3.5.2). De asemenea, pentru a simplifica expunerea, vom nota

$$\gamma(x) = P_{A \cdot D_x} \cdot D_x \cdot c$$

iar sistemul de ecuații diferențiale devine

$$\frac{dx}{dt} = -D_x \cdot \gamma(x)$$

Propoziția 3.23 *Dacă coordonatele condiției inițiale $x(0)$ sunt strict pozitive, atunci, pentru orice $t \geq 0$, avem $x(t) > 0$.*

Demonstrație. Sistemul se poate rescrie pe componente în forma $\frac{d}{dt}x_i = -x_i\gamma_i(x)$; astfel, pentru orice soluție avem:

$$\frac{d}{dt}x_i(t) + x_i(t)\gamma_i(x(t)) = 0$$

$$\exp\left(\int_0^t \gamma_i(x(s)) ds\right) \frac{d}{dt}x_i(t) + x_i(t) \frac{d}{dt} \exp\left(\int_0^t \gamma_i(x(s)) ds\right) = 0$$

$$\frac{d}{dt} \left[x_i(t) \exp \left(\int_0^t \gamma_i(x(s)) ds \right) \right] = 0$$

de unde obținem:

$$x_i(t) \exp \left(\int_0^t \gamma_i(x(s)) ds \right) = x_i(0)$$

$$x_i(t) = x_i(0) \exp \left(- \int_0^t \gamma_i(x(s)) ds \right)$$

și deci, pentru $x_i(0) > 0$ rezultă $x_i(t) > 0$ pentru orice t . ■

Propoziția 3.24 Funcția $t \mapsto A \cdot x(t)$ este constantă pentru orice soluție x a sistemului (3.5.2).

Demonstrație. Vom nota

$$F(x) = -D_x \cdot [\mathbf{I} - D_x \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x] \cdot D_x \cdot c \quad (3.5.3)$$

și observăm că:

$$\begin{aligned} A \cdot F(x) &= -A \cdot D_x \cdot [\mathbf{I} - D_x \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x] \cdot D_x \cdot c \\ &= -[A \cdot D_x - A \cdot D_x^2 \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x] \cdot D_x \cdot c = 0 \end{aligned} \quad (3.5.4)$$

De aici rezultă că

$$\frac{d}{dt} A \cdot x(t) = A \cdot \frac{d}{dt} x(t) = A \cdot F(x(t)) = 0$$

și deci funcția $t \mapsto A \cdot x(t)$ este constantă. ■

Din Propozițiile 3.23 și 3.24 rezultă că, dacă $x(0)$ are componentele $x_i(0) > 0$ pentru orice i și $A \cdot x(0) = b$, atunci, pentru orice t pentru care soluția $x(t)$ este definită, avem $A \cdot x(t) = b$ și $x_i(t) > 0$ pentru orice i .

Cu alte cuvinte, dacă dispunem de o soluție admisibilă $x(0) > \mathbf{0}$ a problemei (3.5.1), atunci sistemul de ecuații diferențiale (3.5.2) ne oferă o soluție admisibilă $x(t) > \mathbf{0}$ pentru orice t .

Propoziția 3.25 Pentru orice soluție $x(t) > \mathbf{0}$ a sistemului (3.5.2) avem: $\frac{d}{dt}c^\top \cdot x(t) \leq 0$.

Demonstrație. Într-adevăr, avem:

$$\begin{aligned} \frac{d}{dt}c^\top \cdot x(t) &= c^\top \cdot \frac{d}{dt}x(t) = \\ &= -c^\top \cdot D_x \cdot [\mathbf{I} - D_x \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x] \cdot D_x \cdot c \leq 0 \end{aligned}$$

deoarece, în condițiile noastre, matricea $\mathbf{I} - D_x \cdot A^\top \cdot (A \cdot D_x^2 \cdot A^\top)^{-1} \cdot A \cdot D_x$ este semipozitiv definită. Pentru a demonstra această afirmație, să notăm matricea $B = A \cdot D_x$.

Orice matrice simetrică M are valori proprii reale [17].

Norma matriceală se poate defini astfel:

$$|M| = \sup_{\|x\|=1} \|M \cdot x\|.$$

De aici rezultă că, dacă $\{\lambda_1, \lambda_2, \dots, \lambda_p\}$ sunt valorile proprii ale lui M , atunci,

$$|M| = \max_{1 \leq i \leq p} \{|\lambda_i|\}$$

Să considerăm acum matricea simetrică

$$M = B^\top \cdot (B \cdot B^\top)^{-1} \cdot B.$$

Trebuie să arătăm că, pentru orice vector v , avem:

$$v^\top \cdot (\mathbf{I} - M) \cdot v = v^\top \cdot v - v^\top \cdot M \cdot v \geq 0,$$

adică, $v^\top \cdot M \cdot v \leq \|v\|^2$. Deoarece $v^\top \cdot M \cdot v \leq |M| \|v\|^2$, este suficient să arătăm că

$$|M| \leq 1. \quad (3.5.5)$$

Fie λ o valoare proprie a lui M și $x_\lambda \neq \mathbf{0}$ vectorul propriu corespunzător. Avem: $M \cdot x_\lambda = \lambda x_\lambda$, adică,

$$B^\top \cdot (B \cdot B^\top)^{-1} \cdot B \cdot x_\lambda = \lambda x_\lambda \quad (3.5.6)$$

Dacă $B \cdot x_\lambda = \mathbf{0}$, rezultă că $\lambda x_\lambda = \mathbf{0}$ și deci, $\lambda = 0$.

Dacă $B \cdot x_\lambda \neq \mathbf{0}$, înmulțind (3.5.6) la stânga cu B , obținem:

$$B \cdot x_\lambda = \lambda B \cdot x_\lambda.$$

de unde rezultă $\lambda = 1$. Prin urmare, valorile proprii ale lui M pot lua doar valorile 0 sau 1 și astfel, relația (3.5.5) este adevărată. ■

Observația 3.7 *Ca fapt divers putem preciza că matricea M , definită mai sus, este idempotentă:*

$$M^2 = B^\top \cdot (B \cdot B^\top)^{-1} \cdot B \cdot B^\top \cdot (B \cdot B^\top)^{-1} \cdot B = M$$

și este la rândul ei semipozitiv definită:

$$v^\top \cdot M \cdot v = v^\top \cdot M^2 \cdot v = (M \cdot v)^\top \cdot (M \cdot v) \geq 0.$$

Din Propoziția 3.25 rezultă că, de-a lungul soluțiilor sistemului diferențial, costul problemei (3.5.1) este descrescător pentru $t \geq 0$.

În baza considerațiilor făcute mai sus, putem formula următoarea procedură iterativă pentru rezolvarea problemelor de programare liniară:

1. Presupunem cunoscut vectorul w , cu componentele $w_i > 0$ pentru orice i și care satisface $A \cdot w = b$.
2. Luăm $x^{(0)} = w$ și definim prin recurență șirul $x^{(k)}$:

$$x^{(k+1)} = x^{(k)} - \tau_k F(x^{(k)})$$

unde F este definit de relația (3.5.3).

Pe componente, relația de recurență devine:

$$x_i^{(k+1)} = x_i^{(k)} - \tau_k x_i^{(k)} \gamma_i(x^{(k)}),$$

adică:

$$x_i^{(k+1)} = [1 - \tau_k \gamma_i(x^{(k)})] x_i^{(k)}.$$

De aici este evident că, dacă luăm $\tau_k < \frac{1}{\gamma_i(x^{(k)})}$, atunci $x_i^{(k)} > 0$ implică $x_i^{(k+1)} > 0$.

În plus, din (3.5.4) avem

$$A \cdot x^{(k+1)} = A \cdot x^{(k)} - \tau_k A \cdot F(x^{(k)}) = A \cdot x^{(k)}$$

deci, $A \cdot x^{(k)} = b$ implică $A \cdot x^{(k+1)} = b$, ceea ce înseamnă că, dacă se pornește cu un punct admisibil, procesul iterativ construiește puncte admisibile.

De asemenea, din Propoziția 3.25 rezultă $c^\top \cdot x^{(k+1)} \leq c^\top \cdot x^{(k)}$ și prin urmare, la fiecare iterație valoarea funcției obiectiv se îmbunătățește.

Recunoaștem așadar cu ușurință că aceste idei stau la baza algoritmilor lui Karmarkar prezentați în paragrafele anterioare. Denumirea lor de a fi algoritmi "de punct interior" este foarte bine pusă în evidență de concluziile care decurg din propozițiile prezentate mai sus, adică, prin acest procedeu se construiește un șir minimizant de puncte din interiorul domeniului de admisibilitate.

Bibliografie

- [1] I. Adler, N.K. Karmarkar, M.G. Resende, *An implementation of Karmarkar's algorithm for linear programming*, Math. Programming **44** (1989), 297-335.
- [2] N. Andrei, *Programare matematică: metode de punct interior*, Editura Tehnică, București, 1999.
- [3] B. Aspvall, R.E. Stone, *Khachiyan's linear programming algorithm*, Journal of Algorithms **1** (1980), 1-13.
- [4] E.R. Barnes, *A variation on Karmarkar's algorithm for solving linear programming problems*, Math. Programming **36** (1986), 174-182.
- [5] D.A. Bayer, J.C. Lagarias, *The nonlinear geometry of linear programming. I, Affine and projective scaling trajectories*, Trans. Amer. Math. Soc. **314** (1989), 499-526.
- [6] D.A. Bayer, J.C. Lagarias, *The nonlinear geometry of linear programming. II, Legendre transform coordinates and central trajectories*, Trans. Amer. Math. Soc. **314** (1989), 527-581.
- [7] G.B. Dantzig, *Linear programming and extensions*. Princeton University Press, Princeton, 1963.
- [8] G.B. Dantzig, P. Wolfe, *The decomposition algorithm for linear programming*, Econometrica, **9**(4) (1961).
- [9] I.I. Dikin, *Iterative solution of problems of linear and quadratic programming*, Soviet Math. Dokl. **8** (1967), 674-675.
- [10] S.I. Gass, *Linear programming, methods and applications*, McGraw-Hill, Inc., New York, 1964.
- [11] P. Gács, L. Lovász, *Khachiyan's algorithm for linear programming*, Mathematical Programming Study, **14** (1981), 61-68.

- [12] A.M. Geoffrion, *Relaxation and the dual method in mathematical programming*, Working Paper 135, (1968), Western Management Science Institute, University of California at Los Angeles.
- [13] A.M. Geoffrion, *Reducing concave programs with some linear constraints*, SIAM J. Appl. Math., **15** (1967), 653-664.
- [14] C.C. Gonzaga, *An algorithm for solving linear programming problems in $O(n^3L)$ operations*, in *Progress in Mathematical Programming: Interior-Point and Related Methods*, N. Megiddo ed., Springer Verlag, New York, 1989, 1-28.
- [15] M.D. Grigoriadis, W.F. Walker, *A treatment of transportation problems by primal partition programming*, Management Sci., **14**(9) (1968), 565-599.
- [16] L.G. Hacıan, *Un algoritm polinomial pentru programarea liniară* (în limba rusă), Doklady Akademiia Nauk, **244** (1979), 1093-1096.
- [17] R.A. Horn, C.R. Johnson, *Analiză matriceală*, Editura Theta, București, 2001.
- [18] S. Karlin, *Mathematical methods and theory in games, programming and economics*, Vol. 1, Addison-Wesley Publishing Company, Inc., 1961.
- [19] H. Karloff, *Linear programming*, Progress in Theoretical Computer Science. Birkäuser, 1991.
- [20] N. Karmarkar, *A new polynomial-time algorithm for linear programming*, Combinatorica **4** (1984), 373-395.
- [21] L.S. Lasdon, *Teoria optimizării sistemelor mari*, Editura Tehnică, București, 1975.
- [22] N. Megiddo, *Pathways to the optimal set in linear programming*, Progress in Mathematical Programming, Interior-Point and Related Methods (N. Megiddo, ed.), Springer Verlag, New York, 1989, pp. 131-158.

- [23] C.L. Monma, A.J. Morton, *Computational experiments with a dual affine variant of Karmarkar's method for linear programming*, *Oper. Res. Lett.* **6** (1987), 261-267.
- [24] R.D.C. Monteiro, I. Adler, *Interior path following primal-dual algorithms. Part I: Linear programming*, *Mathematical Programming*, **44** (1989), 27-41.
- [25] K.G. Murty, *Linear complementarity, linear and nonlinear programming*, Helderman Verlag, 1988.
- [26] K.G. Murty, Y. Fathi, *A feasible direction method for linear programming*, *Operations Research Letters*, **3**(3) (1984), 121-127.
- [27] C.H. Papadimitriou, K. Steiglitz, *Combinatorial optimization: Algorithms and complexity*, Prentice Hall, Englewood Cliffs, NJ, 1982.
- [28] R.G. Parker, R.L. Rardin, *Discrete optimization*, Academic Press Inc., 1988.
- [29] A. Ravindran, D.T. Phillips, J.J. Solberg, *Operations research. Principles and practice*, John Wiley & Sons, New York, 1987.
- [30] J. Renegar, *A polynomial-time algorithm, based on Newton's method, for linear programming*, *Mathematical Programming*, **40** (1988), 50-94.
- [31] K. Ritter, *A decomposition method for linear programming problems with coupling constraints and variables*, Mathematics Research Center, University of Wisconsin, Report 739 (1967).
- [32] R.T. Rockafellar, *Convex Analysis*, Princeton University Press, Princeton, 1970.
- [33] J.B. Rosen, *Primal partition programming for block diagonal matrices*, *Numerische Mathematik*, **6** (1964), 250-260.

- [34] W. Rudin, *Real and Complex Analysis*, McGraw-Hill, New York, 1987.
- [35] G. Sonnevand, *An "analytic center" for polyhedrons and new classes of global algorithms for linear (smooth, convex) programming*, Proc. 12th IFIP Conf. System Modelling, Budapest, 1985, Lectures Notes in Computer Science, 1986.
- [36] A. Ștefănescu, *Curs de cercetări operaționale*, Tipografia Universității București, 1989.
- [37] A. Ștefănescu, C. Zidăroiu, *Cercetări operaționale*, Editura Didactică și Pedagogică, București. 1981.
- [38] P.M. Vaidya, *An algorithm for linear programming which requires $O(((m+n)n^2 + (m+n)^{1.5}n)L)$ arithmetic operations*, *Mathematical Programming* **47** (1990), 175-201.
- [39] R.J. Vanderbei, J.C. Lagarias, *Dikin's convergence result for the affinescaling algorithm*, *Contemporary Mathematics*, Mathematical developments arising from linear programming. (J.C. Lagarias and M.J. Todd, eds.), **114** (1990), 109-119.
- [40] R.J. Vanderbei, M.S. Meketon, B.A. Freedman, *A modification of Karmarkar's linear programming algorithm*, *Algorithmica* **1** (1986), 395-307.
- [41] H.P. Williams, *Model building in mathematical programming* (Third Edition), John Wiley & Sons Ltd., Chichester - West Sussex, England, 1991.
- [42] C. Zidăroiu, *Programare liniară*, Editura Tehnică, București, 1983.

Index

- Algoritmul
afin, 148, 159
Dantzig-Wolfe, 64
de partiționare și relaxare, 75
elipsoidal, 112
lui Karmarkar, 135
lui Ritter, 84
lui Rosen, 91
proiectiv, 159
simplex dual, 52, 54
simplex primal, 23, 52
simplex revizuit, 33
- Calculator virtual, 101, 133
Cost redus, 27
- Ecuatii
principale, 4
secundare, 4
- Elipsoid, 108
- Lema
Farkas-Minkowski, 6
substituției, 19
- Mărimea problemei, 101
- Matrice de bază, 4
dual admisibilă, 52
primal admisibilă, 17
- Multiplicator simplex, 27
- Norma euclidiană, 108
- Pivot, 31
- Probleme duale, 45
- Punct extrem, 58, 99
- Rază extremă, 19, 60, 69, 99
- Regula dreptunghiului, 31
- Restricție
activă, 51, 75, 84
concordantă, 11
neconcordantă, 11
- Soluție
de bază, 5
de bază extinsă, 35
- Tabloul simplex
revizuit, 32
standard, 30
- Teorema
de optim infinit, 18
de optimalitate, 18, 35, 40, 82, 88
de schimbare a bazei, 21, 53
domeniului vid, 52
ecarturilor complementare, 50
fundamentală a dualității, 47
fundamentală a programării liniare, 13
- Timp polinomial, 102
- Transformare
afină, 108
proiectivă, 121, 130
- Variabile
de bază, 5
ecart, 12
principale, 4
secundare, 4



**Tiparul s-a executat sub c-da nr. 1010/2002 la
Tipografia Editurii Universității din București**

DATA RESTITUIRII

06 IAN. 2004	19. MAR. 2005	
23. IAN. 2004	19. APR. 2004	
23. IAN. 2004	1. MAI. 2004	
13. FEB. 2004	7 IAN. 2005	
17 FEB.	28 APR. 2015	
17 FEB. 2004		
17 FEB. 2004		
05 MAR. 2004		
13 MAR. 2004		
8 FEB. 2004		
05 IUN. 2005		

ISBN 973-575-720-6

Lei 132000