

UNELE REZULTATE ÎN PROGRAMAREA MATEMATICĂ ȘI POSIBILE APLICAȚII (I)

Dr. Vincențiu Dumitru
Dr. Florica Luban

Academia de Studii Economice
București

Rezumat. În lucrare sunt trecute în revistă unele rezultate matematice obținute de autori și se sugerează posibile aplicații la rezolvarea unor probleme din tehnică sau economie.

Cuvinte cheie: identificarea sistemelor prin optimizare pe direcții conjugate, modele continue pentru probleme mixte, programare matematică în condiții de incertitudine, aplicații la programarea producției pe mașini și în investiții.

1. Asupra problemei identificării proceselor prin optimizare pe direcții conjugate

Să considerăm procesul

$$Ax = y \quad (1.1)$$

în care A este matrice $(n \times n)$ nesingulară și prin care fiecărui vector input $x \in R^n$ îi corespunde un vector output $y \in R^n$. Definim ca problemă a identificării sistemului, problema determinării matricei A . Așa cum se observă, problema este considerată determinist, cu alte cuvinte y se poate determina fără zgromot.

Dacă pentru x^1, \dots, x^n , vectori liniar independenți disponem de outputurile corespunzătoare y^1, \dots, y^n , atunci A este soluția ecuației matriceale

$$AX = Y \quad (1.2)$$

adică

$$A = YX^{-1} \quad (1.3)$$

unde matricele X și Y sunt formate cu vectorii coloană x , respectiv y .

Problema pe care o avem în vedere însă aici este aceea a determinării matricei A atunci cind nu disponem de outputurile y ci numai de valorile anumitor funcții de y , ca de exemplu:

$$f_1 = x^T \cdot y \quad (1.4)$$

sau

$$f_2 = y^T \cdot y \quad (1.5)$$

Pentru exemplificare să presupunem că A este o matrice simetrică și pozitiv definită și că putem determina valorile funcției (1.4). Atunci procesul (1.1) poate fi identificat cu ajutorul unui algoritm de optimizare

$$x^k = x^{k-1} + \lambda_k^* d^k \mid f_1(x^k) = \min_{\lambda_k} (x^{k-1} + \lambda_k d^k) \quad (1.6)$$

unde direcțiile d^k sunt direcții mutual conjugate cu A , adică

$$d^i A d^j = \gamma_i \delta_j^i \quad (1.7)$$

unde

$$\delta_j^i = \begin{cases} 0 & i \neq j \\ 1 & i = j \end{cases}$$

Într-adevăr, dacă în procesul de optimizare putem crea n direcții d^k , $k=1, \dots, n$, mutual ortogonale cu A , atunci este ușor de văzut [9], [10] că avem

$$A^{-1} = \tilde{D} \cdot \tilde{D}^T \quad (1.8)$$

unde \tilde{D} este o matrice $(n \times n)$ ai cărei vectori coloană sunt vectorii d^k normalizați cu factorul

$$\beta_k = \frac{1}{\sqrt{\gamma_k}} \quad (1.9)$$

adică

$$\tilde{d}^k := \beta_k d^k, k=1, \dots, n \quad (1.10)$$

Or, factorul de normalizare β_k se poate calcula numai cu ajutorul valorilor funcției f_1 și a lungimii pasului pe direcție, dat fiind că, dacă λ_k^* este determinat prin (1.6), atunci avem

$$\gamma_k = (f_1^{k-1} - f_1^k) / (\lambda_k^*) \quad (1.11)$$

Odată determinată A^{-1} prin (1.8), procesul (1.1) se identifică prin inversare.

Nu este greu de arătat că, dacă am cunoaște valorile outputului y într-un proces de optimizare (1.6) în care d^k sunt direcții conjugate cu A , putem obține direct pe A . Într-adevăr, dacă direcțiile d^k satisfac (1.7), atunci

$$v^k = Ad^k \quad (1.12)$$

satisfac

$$v^i A^{-1} v^j = d^i A A^{-1} A d^j = \gamma_i \cdot \delta_j^i \quad (1.13)$$

cu alte cuvinte, direcțiile v^k sunt mutual conjugate cu A^{-1} și au același factor de normalizare.

Rezultă că avem:

$$A = \tilde{V} \cdot \tilde{V}^T \quad (1.14)$$

unde matricea \tilde{V} are vectorii coloană $\perp \tilde{v}^j$ dați de:

$$\tilde{v}^j = \beta_j v^j \quad (1.15)$$

Tinând cont de (1.15) și de (1.12), rezultă

$$\tilde{v}^j = \frac{y^j - y^{j-1}}{[-(f^j - f^{j-1})]^{1/2}} = -\frac{y^{j-1} - y^j}{[x^{j-1} y^{j-1} - x^j y^j]^{1/2}} \quad (1.16)$$

Dacă în locul valorilor funcției $f_1(y)$ cunoaștem valorile unei funcții necunoscute $f(y) = \varphi(x)$ pe care o presupunem pseudoconvexă, atunci, în același mod, putem, într-un proces de optimizare pe direcții conjugate să determinăm hessiana funcției $\varphi(x)$ în jurul punctului de optim x^* și să identificăm funcția $\varphi(x)$ prin:

$$\phi(x) = \phi(x^*) + \frac{1}{2} (x - x^*) H^* (x - x^*) \quad (1.17)$$

Problema generării direcțiilor conjugate de d^k este discutată în [9], [17].

2. Unele restricții și funcții obiectiv specifice repartizării producției pe mașini. Modele de programare matematică continuă pentru probleme mixte

În problemele de programare a producției, în afară de restricțiile clasice relativ la satisfacerea cererii de produse și la capacitatea disponibilă a mașinilor se cer îndeplinite, dacă este posibil, și alte condiții ca de exemplu: minimizarea dispersiei procesului de producție prin minimizarea numărului de lansări a produselor pe mașini, realizarea unei continuități a prelucrării unui același produs pe o mașină, o încărcare eficientă a mașinilor etc. Realizarea acestor obiective conduce la respectarea termenelor de predare prescrise pentru unele produse, folosirea cât mai intensă și cât mai uniformă a parcoului de mașini etc.

Dacă x este vectorul necunoscutelor, problemele de mai sus conduc la problema minimizării cardinalului lui x , (MCRL): $\min |x|^+$, cu condițiile $Ax = b$, $x \geq 0$, unde cu $|x|^+$ se notează cardinalul lui x , adică numărul componentelor strict pozitive ale lui x . În cele ce urmează presupunem că domeniul de admisibilitate al problemei MCRL este mărginit și fie x_c^* soluția ei.

Pentru determinarea acestei soluții autorii au propus [13] rezolvarea unei probleme echivalente, P_{σ_1} în variabile continue. Între cele două probleme există următoarea legătură:

Teorema 2.1. Există un vector $\alpha^T = (\alpha_1, \dots, \alpha_n)$, $\alpha_i > 0$ astfel încât soluția problemei P_{σ_1} :

$$\min_{\sigma_1(x)} = \sum_{i=1}^n x_i / (\alpha_i + x_i), Ax = b, x \geq 0 \text{ este o soluție a problemei MCRL.}$$

Demonstrație. Fie $S = \{x \mid Ax = b, x \geq 0\}$. Pentru orice $x \in S$ avem $x = \sum_{i=1}^k \lambda_i \cdot x_v^i$, $\sum_{i=1}^k \lambda_i = 1$, $\lambda_i \geq 0$ unde x_v^i sunt vîrfurile poliedrului soluțiilor admisibile și deci, cum $x_v^i \geq 0$, avem:

$$|x|^+ = \left| \sum_{i=1}^k \lambda_i x_v^i \right|^+ \geq \max |x_v^i|^+,$$

adică soluția problemei MCRL nu este un punct interior al lui S . Pot exista mai multe soluții, toate vîrfuri sau chiar o infinitate de soluții în cazul cind avem mai multe muchii ale poliedrului soluțiilor. Oricum, o soluție a problemei MCRL este un vîrf.

Dacă notăm cu e_x vectorul cu $(e_x)_i = 1$ dacă $x_i > 0$ și $(e_x)_i = 0$ dacă $x_i = 0$, atunci avem:

$$|x|^+ > \sigma_1[x, \alpha] \quad |x \in \mathbb{R}^n, \alpha_1 \leq \alpha_0 \varepsilon_i, x_i \neq 0 \Rightarrow \\ \Rightarrow x_i \geq \alpha_0(1 - \varepsilon_i)] \geq |x|^+ \cdot (1 - \varepsilon^T e_x) \quad (2.1)$$

unde cu ε se notează vectorul de componente ε_i , $0 < \varepsilon_i < 1$. Fie $\sigma_{\sigma_1} = \min_{i,j} \{x_{ij}^j > 0, x_v^j\}$ și $x_{\sigma_1}^*$ soluția problemei P_{σ_1} pentru $\alpha_i = \sigma_{\sigma_1} \varepsilon_i$. Conform cu (2.1):

$$\sigma_{\sigma_1}(x_{\sigma_1}^*) \geq |x_{\sigma_1}^*|^+ \left(1 - \varepsilon^T e_{x_{\sigma_1}^*}\right) \quad (2.2)$$

Dacă $\sigma_{\sigma_1}(x_{\sigma_1}^*)^+ > |x_c^*|^+$ atunci, cum $|x_c^*|^+ > \sigma_1(x_c^*)$, luând ε suficient de mic, rezultă:

$$\sigma_{\sigma_1}(x_{\sigma_1}^*) > \sigma_1(x_c^*), \quad (2.3)$$

adică $x_{\sigma_1}^*$ nu este un punct de minim al problemei P_{σ_1} .

Dacă $|x_{\sigma_1}^*|^+ < |x_c^*|^+$, atunci x_c^* nu este o soluție a problemei MCRL.

Ca o consecință imediată a Teoremei 2.1., rezultă că orice soluție $x_{\sigma_1}^*$ a problemei P_{σ_1} este o soluție a

problemei: $\min |x|^+$, cu condițiile $Ax = b - \mu A e_{x_{\sigma_1}^*}$,

unde μ este valoarea celei mai mici componente a lui x_c^* diferită de zero, și $e_{x_{\sigma_1}^*}$ este un vector cu $(e_{x_{\sigma_1}^*})_i = 1$

dacă $x_i^* > 0$ și $(e_{x_{\sigma_1}^*})_i = 0$ dacă $x_i^* = 0$.

De asemenea, să facem observația că, dacă problema MCRL are o soluție unică, atunci cele două probleme sunt echivalente.

Teorema 2.2. O condiție suficientă ca soluția $x_{\sigma_1}^*$ a problemei P_{σ_1} , pentru un α dat, să fie o soluție x_c^* a problemei MCRL este ca:

$$|x_{\sigma_1}^*|^+ - \sigma_1(x_{\sigma_1}^*, \alpha) < 1 \quad (2.4)$$

Demonstrație. Fie x_c^* , o soluție a problemei MCRL. Avem următorul sir de inegalități:

$$|x_{\sigma_1}^*|^+ \geq |x_c^*|^+ > \sigma_1(x_c^*) \geq \sigma_1(x_{\sigma_1}^*) \quad (2.5)$$

Dacă $|x_{\sigma_1}^*|^+ - \sigma_1(x_{\sigma_1}^*, \alpha) < 1$ inegalitatele (2.5)

implică $|x_{\sigma_1}^*|^+ = |x_c^*|^+$

Nu rezultă însă neapărat că, dacă

$$\left| x_{\sigma_1}^* \right|^+ = \left| x_c^* \right|^+ \text{ atunci } \left| x_{\sigma_1}^* \right|^+ - \sigma_1(x_{\sigma_1}^*) < 1$$

sau, ceea ce este același lucru, că, dacă

$$\left| x_{\sigma_1}^* \right|^+ - \sigma_1(x_{\sigma_1}^*) > 1, \text{ atunci}$$

$$\left| x_{\sigma_1}^* \right|^+ \neq \left| x_c^* \right|^+.$$

Pe baza teoremelor 2.1 și 2.2 putem da următorul algoritm pentru rezolvarea problemei MCRL:

Fie la secvența k vectorul α^k și $x_{\sigma_s}^*$ un vîrf cu cel mai mic număr de componente pozitive cunoscut pînă acum.

Pasul 1. Determină

$$\left| x_{\sigma_{\alpha^k}}^* \right|^+ : \sigma_1(x_{\sigma_{\alpha^k}}^*) = \min \sigma(x, \alpha^k),$$

$$x \in S = \{x \mid Ax = b, x \geq 0\}.$$

Pasul 2. Test de optimalitate. Dacă

$$\left| x_{\sigma_{\alpha^k}}^* \right|^+ - \sigma_1(x_{\sigma_{\alpha^k}}^*) < 1,$$

atunci $x_{\sigma_{\alpha^k}}^*$ este o soluție a problemei MCRL,

STOP, altfel se trece la pasul 3.

Pasul 3. Dacă

$$\left| x_{\sigma_{\alpha^k}}^* \right|^+ \leq \left| x_{\sigma_s}^* \right|^+, \text{ atunci}$$

$$x_{\sigma_s}^* := x_{\sigma_{\alpha^k}}^*.$$

Punctul $x_{\sigma_s}^*$ este soluția problemei MCRL μ :

$$\min |x|^+, Ax = b - \mu_{\sigma_s} A e_{\sigma_s}.$$

Dacă problema MCRL μ aproximează suficient problema MCRL, STOP, altfel se trece la pasul 4.

Pasul 4.

$$\alpha^k := p \alpha^k, 0 < p < 1; k := k + 1.$$

Teorema 2.3. Algoritmul de soluționare a problemei MCRL este finit. Într-adevăr, dat fiind un punct $x_{\sigma_s}^*$,

acesta, fie că este optimul pentru problema MCRL și după un număr de iterații va satisface criteriul de optimalitate ținînd cont de faptul că

$\lim_{\alpha \rightarrow 0} \sigma_1(x^0, \alpha) = |x^0|^+$, fie că va fi înlocuit cu un punct optimal deoarece α^k va satisface condițiile teoremei 2.1.

Funcția concavă $d(x) = x / (\alpha + x)$, definită pe $R^{\alpha} \setminus \{\alpha\}$ a fost introdusă în [13] ca o funcție de interes general în rezolvarea problemelor de programare întreagă sau mixtă, ca urmare a proprietății ei de a avea aproape peste tot, în R_+ , în sens generalizat, valori aproape egale cu 1.

Spunem că o proprietate are loc aproape peste tot în sens generalizat dacă raportul dintre măsura mulțimii punctelor care nu posedă proprietatea și măsura mulțimii tuturor punctelor pe care se studiază această proprietate poate fi făcută mai mică decât un ϵ arbitrar de mic.

În [11], [16], funcția $d(x)$ este studiată ca o funcție de apartenență în sensul teoriei mulțimilor vagi. Tot aici se studiază proprietățile funcției de apartenență complementare:

$$s(x) = 1 - d(x) = \alpha / (\alpha + x), \alpha > 0$$

care este o funcție convexă pe R_+ .

În mod analog cu demonstrația teoremelor 2.1 și 2.2, se pot demonstra teoremele:

Teorema 2.4. Există un vector $\alpha^T = (\alpha_1, \dots, \alpha_n)$ astfel ca soluția $x_{\sigma_2}^*$ a problemei P_{σ_2} :

$$\max \sigma_2(x, \alpha) = \sum_{i=1}^n \alpha_i / (\alpha_i + x_i)$$

cu condițiile $Ax = b, x \geq 0$, să fie o soluție x_c^* a problemei MCRL.

Teorema 2.5. O condiție suficientă ca soluția $x_{\sigma_2}^*$ a problemei P_{σ_2} să fie o soluție a problemei MCRL este ca să aibă loc inegalitatea:

$$\sigma_2(x_{\sigma_2}^*) + \left| x_{\sigma_2}^* \right|^+ - n < 1$$

Rezultatele obținute pot fi incluse într-un domeniu mai larg, abordat de V. Cabot [4] în 1975, pentru rezolvarea în real a problemei de determinare a unei soluții admisibile pentru problema de programare lineară pe o latice, PLL:

$$\min z = \sum_{j=1}^n c_j x_j, x \in S, S = \{x \mid Ax = b, x \geq 0\}$$

cu condiția suplimentară $|x|^+ \leq r$ unde K este o mulțime de indici.

În legătură cu această problemă, tot în [11] am dat o condiție pentru caracterizarea unei soluții cu cardinal minim a problemei PLL, dacă problema are o soluție admisibilă.

Probleme privind afectarea produselor pe mașini

Presupunem un proces de producție cu variabile continue - o condiție de integritate asupra variabilelor nu ar schimba forma modelului, dar ar complica și mai

mult rezolvarea lui - în care notăm cu x_{ik} cantitatea din produsul i care se realizează pe mașina k .

Principalele restricții ale problemei de afectare sunt:

- restricții privind acoperirea cererii pe sortimente:

$$\sum_{k \in K} x_{ik} \geq D_i, \quad i \in I \quad (2.6)$$

- restricții privind capacitatea disponibilă a fiecărei mașini

$$\sum_{i \in I} t_{ik} x_{ik} \leq T_k, \quad k \in K \quad (2.7)$$

unde am notat cu I mulțimea produselor, cu K mulțimea mașinilor, cu D_i cererea pentru produsul i , cu T_k timpul total de funcționare al mașinii k în perioada respectivă de planificare și cu t_{ik} timpul necesar mașinii k pentru a realiza o unitate de produs i .

Pentru a realiza vectorul de producție $x = (x_{ik} | x_{ik} \geq 0, i \in I, k \in K)$ cu o împrăștiere minimă și/sau cu o anumită preferință pentru afectarea produselor pe mașini, în [33] propunem ca funcție obiectiv:

$$\min \sigma_1(x, \alpha) = \sum_{i \in I} \sum_{k \in K} p_{ik} x_{ik} / (\alpha_{ik} + x_{ik}), \\ p_{ik} \geq 0, \alpha_{ik} > 0, x_{ik} \geq 0 \quad (2.8)$$

Dacă toți p_{ik} sunt egali, minimizând (2.8) supusă la restricțiile liniare, (2.6), (2.7) rezultă conform teoremelor 2.1 și 2.2 că am minimizat $|x|$. Dacă p_{ik} sunt coeficienții de penalizare diferenți, numărul componentelor strict pozitive poate crește, dar putem să obținem o afectare preferențială a produselor pe mașini.

În [33] am arătat că în locul funcției obiectiv (2.8) se poate utiliza echivalent funcția:

$$\max \sigma_2(x, \alpha) = \sum_{i \in I} \sum_{k \in K} p_{ik} \alpha_{ik} / (\alpha_{ik} + x_{ik}), \quad (2.9)$$

$$p_{ik} \geq 0, \alpha_{ik} > 0, x_{ik} \geq 0.$$

Funcția obiectiv (2.8) sau (2.9), dacă este normalizată corespunzător, o putem interpreta ca o funcție de apartenență [11] pentru realizarea produsului i pe mașina k , în sensul teoriei mulțimilor vagi.

Deci, minimizarea împrăștierii produsului i_0 pe mulțimea K a mașinilor poate fi privită ca minimizarea funcției de apartenență a produsului i_0 la mulțimea K a mașinilor, adică:

$$\min \sigma_1(x, \alpha) = \frac{x}{|K|} + \sum_{k \in K} x_{i_0 k} / (\alpha_{i_0 k} + x_{i_0 k}) \quad (2.10)$$

$$\alpha_{i_0 k} > 0$$

sau maximizarea funcției complementare de apartenență la nivel zero:

$$\min \sigma_2(x, \alpha) = \frac{x}{|K|} + \sum_{k \in K} \alpha_{i_0 k} / (\alpha_{i_0 k} + x_{i_0 k}) \quad (2.11) \\ \alpha_{i_0 k} > 0$$

Să presupunem acum că se dorește ca la realizarea cererii D_i din produsul i , să nu participe decât cel mult m_i dintr-o anume submulțime $V_k \subset K_i$, unde K_i este mulțimea mașinilor care pot realiza produsul i . Această condiție poate fi impusă de o restricție de forma:

$$\sum_{k \in V_i} x_{ik} / (\alpha_{ik} + x_{ik}) \leq m_i \quad (2.12)$$

În același mod se poate scrie o restricție care să impună ca pe o anumită mașină k să nu se facă decât cel mult n_k produse dintr-o anumită submulțime de produse $V_i \subset I_k$, unde I_k este mulțimea produselor care se pot realiza pe mașina k . Avem:

$$\sum_{i \in V_i} x_{ik} / (\alpha_{ik} + x_{ik}) \leq n_k \quad (2.13)$$

Restricțiile de formă (2.12) sau (2.13) sunt restricții neconvexe, cu variabile reale, echivalente cu aşa numitele restricții de cardinalitate [41] sau probleme de programare matematică generalizată pe o latice [30].

Din aceeași clasă a restricțiilor neconvexe, putem identifica condițiile de încărcare eficientă a mașinilor.

Astfel, pentru anumite procese de producție se poate cere încărcarea unei mașini cu un anumit produs la nivelul capacitatii ei sau la nivel zero, astfel încât mașina să rămână liberă pentru realizarea altor produse. O astfel de condiție poate fi scrisă sub formă:

$$x_{ik} \geq \beta \cdot q_{ik} [x_{ik} / (\alpha_{ik} + x_{ik})] \quad (2.14)$$

unde q_{ik} este producția maximă, care poate fi obținută din produsul i pe mașina k în perioada de programare, și β este un procent dat.

Pentru modelele de programare a producției, foarte adesea determinarea unei soluții admisibile în raport cu restricțiile de cerere și capacitate este o problemă dificilă. Ca urmare, problemele de programare matematică cu restricții inexacte sunt intens studiate.

În cazul restricțiilor liniare (2.6), (2.7), se poate încerca parametrizarea vectorului termenului liber, astfel încât să avem:

$$(A) \left\{ \begin{array}{l} \sum_{k \in K} x_{ik} \geq D_i - q_i, \quad i \in I \\ \sum_{i \in I} t_{ik} x_{ik} \leq T_k + \tau_k, \quad k \in K \end{array} \right. \quad (2.15)$$

$$(B) \left\{ \begin{array}{l} 0 \leq q_i \leq \bar{q}_i, \quad i \in I \\ 0 \leq \tau_k \leq \bar{\tau}_k, \quad k \in K \end{array} \right. \quad (2.16)$$

unde q_i este cantitatea din produsul i cu care nu va fi realizată cererea, τ_k este timpul suplimentar necesar mașinii k pentru realizarea programului de producție, iar \bar{q}_i și $\bar{\tau}_k$ sunt limitele prevăzute pentru q_i și respectiv τ_k .

Pentru a minimiza abaterile față de cerere și capacitatele de producție disponibile, putem utiliza ca funcții obiectiv:

$$\min f_1(q, \tau) = \sum_{i \in I} p_i q_i + \sum_{k \in K} p_k \tau_k, \quad p_i \geq 0, p_k \geq 0 \quad (2.19)$$

$$\min f_2(q, \tau) = \sum_{i \in I} p_i q_i^2 + \sum_{k \in K} p_k \tau_k^2, \quad p_i \geq 0, p_k \geq 0 \quad (2.20)$$

Pentru a găsi un vector de producție, $z = (x, q, \tau) \in S = A \cap B$ și care în plus să minimizeze numărul abaterilor de la programul de producție și/sau numărul de suplimentări de capacitate, propunem [33], [35] minimizarea funcției obiectiv:

$$\begin{aligned} \min \sigma_1(q, \tau, \alpha) = & \frac{1}{|I| + |K|} \left[\sum_{i \in I} q_i / (\alpha_i + q_i) + \right. \\ & \left. + \sum_{k \in K} \tau_k / (\alpha_k + \tau_k) \right] \end{aligned} \quad (2.21)$$

Utilizarea funcției (2.21) este motivată, de asemenea, de teorema 2.1 și 2.2.

Aproximații lineare

Rezolvarea problemelor de programare matematică neconvexă este dificilă. Un algoritm pentru obținerea unei soluții optimale pentru modele cu funcții obiectiv neconvexe separabile și restricții liniare este propus de Falk și Soland în [27]. Algoritmul utilizează o procedură de "branch and bound", care se efectuează printr-o succesiune de optimizări cu funcții obiectiv date de anvelopa convexă a funcției neconvexe pe anumite domenii.

Cum pentru funcții separabile concave anvelopa convexă este lineară, rezultă că pentru toate modelele neconvexe de mai sus, în cazul problemelor de dimensiuni mari, ne putem mărgini la o soluție suboptimală, obținută în cadrul unor anumite limite de calcul date. Pentru exemplificarea procedurii pe un exemplu numeric se poate consulta [11].

Fie:

$$\varphi_{1j}(x_j, \alpha_j) = \frac{x_j}{\alpha_j + x_j} \quad (2.22)$$

$$\varphi_{2j}(x_j, \alpha_j) = \frac{\alpha_j}{\alpha_j + x_j} \quad (2.23)$$

Anvelopa convexă în intervalul $[l_j, L_j]$ a funcției φ_{1j} este:

$$\begin{aligned} \psi_{1j}(x_j, \alpha_j) = & \left[\alpha_j / ((\alpha_j + l_j)(\alpha_j + L_j)) \right] \cdot x_j + \\ & + l_j L_j / ((\alpha_j + l_j) \cdot (\alpha_j + L_j)) \end{aligned} \quad (2.24)$$

iar a funcției $-\varphi_{2j}$ pe același interval este:

$$\begin{aligned} \psi_{2j}(x_j, \alpha_j) = & \left[\alpha_j / ((\alpha_j + l_j)(\alpha_j + L_j)) \right] \cdot x_j + \\ & + \left[1 - l_j L_j / ((\alpha_j + l_j) \cdot (\alpha_j + L_j)) \right] \end{aligned} \quad (2.25)$$

a) Să considerăm funcția obiectiv neconvexă (2.8) în care toți $p_{ik} = 1$. Considerând în mod natural că fiecare $x_{ik} \in [0, c_{ik}]$, unde c_{ik} este cantitatea din produsul i pe care mașina k o poate tehnica realiză, anvelopa convexă a funcției (2.8) înținând seama de (2.24) cu $l_j = 0$, $L_j = c_{ik}$ avem:

$$\psi_3(x, \alpha) = \sum_{i \in I} \sum_{k \in K} \left[1 / (\alpha_{ik} + c_{ik}) \right] x_{ik}, \quad \alpha_{ik} > 0 \quad (2.26)$$

și pentru $\alpha_{ik} < c_{ik}$ putem enunța următoarea teoremă de primă aproximare:

Teorema 2.6. Funcția obiectiv a unui proces de producție care minimizează numărul de componente strict pozitive ale vectorului de producție și prin aceasta dispersia prelucrării pe mașini este, într-o primă aproximare, o funcție lineară, cu coeficienți invers proporționali cu capacitatea mașinilor, relativă la fiecare componentă a vectorului de produse.

b) În cazul funcției (2.21), pentru $q_i \in [0, \bar{q}_i]$, $\tau_k \in [0, \bar{\tau}_k]$, anvelopa convexă este:

$$\begin{aligned} \psi_4(x, \alpha) = & \frac{1}{|I| + |K|} \left[\sum_{i \in I} \frac{1}{\alpha_i + \bar{q}_i} q_i + \right. \\ & \left. + \sum_{k \in K} \frac{1}{\alpha_k + \bar{\tau}_k} \tau_k \right] \end{aligned} \quad (2.27)$$

de unde pentru $\alpha_i < \bar{q}_i$ și $\alpha_k < \bar{\tau}_k$ putem enunța teoremele:

Teorema 2.7. Funcția obiectiv a unui proces de producție, care minimizează numărul de poziții neîndeplinite din planul de producție este, într-o primă aproximare, o funcție lineară, cu coeficienții invers proporționali cu nivelul permis de nerrealizare a cererii.

Teorema 2.8. Funcția obiectiv a unui proces de producție, care minimizează numărul de suplimentări de capacitate de producție este, într-o primă aproximare, o funcție lineară, cu coeficienți invers proporționali cu nivelul permis de suplimentare a capacitatii de producție.

O altă justificare a acestor aproximări lineare ar putea fi și aceea a unor penalizări invers proporționale cu mărimea disponibilității vectorului resursă neparametrizat, ceea ce corespunde ideii intuitive că, o resursă cu disponibil mare permite un interval de variație mai mare decât o resursă cu disponibil mai mic.

Unele din funcțiile obiectiv prezentate mai sus au fost testate numeric, astăzi prin rezolvarea unor probleme test, cît și a unor probleme concrete de programare a producției la o secție de electrozi de sudură [36].

Experimentele au condus la obținerea unor programe de producție cu un număr de schimbări de matrițe la presare, de depășiri de capacitate și de nerrealizări ale pozițiilor de plan mai mic decât în cazul utilizării altor funcții de eficiență.

3. Asupra unor modele de programare matematică în investiții

Dat fiind un model, problema formulării unor criterii de determinare a unei soluții, în condiții de incertitudine asupra coeficienților și apoi a rezolvării modelului de optimizare în raport cu acest criteriu, a făcut obiectul a numeroase cercetări care s-au constituit deja în discipline de studiu, cum ar fi programarea stocastică, în care se presupune că se cunosc funcțiile de distribuție a vectorilor coeficienților sau a erorilor cu care aceștia sunt cunoscuți. Pentru probleme reale, determinarea acestor distribuții poate fi ea însăși o problemă grea, astfel încât prezintă un real interes studiul modelelor în care despre unii coeficienți se cunoaște numai că ei variază în anumite intervale sau domenii. Diferite aspecte nestocastice ale inexactității au făcut obiectul unor cercetări, devenite de acum clasice, cum sunt cercetările lui Dantzig [8] sau mai recent [1], [5], [14], [39], [42].

Una dintre problemele relativ mai simple este aceea în care se presupune că vectorul termenilor liberi ai resurselor sau vectorul coeficienților funcției obiectiv variază într-un domeniu poliedral convex și mărginit.

În [1] se studiază această problemă în cazul unor modele lineare de programare matematică în care se presupune că vectorul coeficienților funcției obiectiv este un punct arbitrar al unui poliedru convex și mărginit. Pentru rezolvarea problemei, criteriul linear de alegere a soluției este înlocuit printr-unul din următoarele criterii: criteriul de minimax al lui Wald, criteriul lui Laplace de minimizare a mediei aritmetice a pierderilor, criteriul lui Hurwitz de minimizare a unei combinații lineare dintre maximul și minimul pierderii sau prin criteriul lui Savage-Niehans de regret minimax. Soluția optimală a modelului se definește în acest caz astfel ca, oricare va fi valoarea coeficienților în domeniul de variație, să ne asigurăm o soluție optimă în raport cu una din funcțiile scop menționate mai sus. În [1] se arată că pornind de la probleme lineare, cu coeficienții funcției obiectiv variind într-un domeniu poliedral convex și mărginit, se ajunge la rezolvarea uneia sau mai multor probleme lineare, în funcție de criteriul ales, pe domenii extinse.

În [14], extindem rezultatele din [1] la cazul în care funcția obiectiv este convexă în vectorul variabilelor x și convexă sau concavă în v (vectorul coeficienților funcției obiectiv), iar domeniul de admisibilitate X este o mulțime convexă arbitrară, nu neapărat un poliedru convex, vectorul v rămânând să fie un punct arbitrar într-un poliedru convex și mărginit V .

Aceste rezultate pot fi utilizate pentru a pune în evidență posibilitatea rezolvării unor modele nelineare de investiții, în condiții de incertitudine asupra valorii nete a proiectelor. Problema alocării fondurilor la diferite proiecte de investiții a reprezentat una dintre primele

aplicații ale programării matematice în economie. Încă din 1955, Lorie și Savage [32] definesc problema PLS astfel: dată fiind valoarea netă prezentă a unui set de alternative de investiții independente și date fiind cheltuielile pentru aceste proiecte în fiecare din cele T perioade de timp, pe orizontul căruia se studiază problema, să se găsească subsetul de proiecte care maximizează valoarea totală netă actuală a proiectelor acceptate și care satisfacă în același timp restricțiile asupra cheltuielilor în fiecare din cele T perioade.

Problema poate fi modelată ca o problemă de programare lineară întreagă.

$$\max \sum_{j=1}^n v_j x_j \quad (3.1)$$

cu condițiile

$$\sum_{j=1}^n c_{tj} x_j \leq C_t, \quad t=1, \dots, T \quad (3.2)$$

$$x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.3)$$

unde:

v_j - valoarea netă prezentă a proiectului j , cînd se ia în considerație procentul actual al dobînzii;

c_{tj} - cheltuielile necesare proiectului j în perioada t ;

C_t - cheltuielile maxime permise în perioada t .

Ulterior, acest model a fost extins de Weingartner [43] la cazul în care proiectele sunt interdependente. Si în acest caz, problema ce se propune a fi rezolvată este o problemă de programare lineară cu variabile zero-unu:

$$\max f(v, x) = v^T x \quad (3.4)$$

$$x \in X \quad (3.5)$$

$$x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.6)$$

unde $f(v, x)$ este o funcție lineară în x , cu coeficienți v , iar X este un poliedru convex.

Este evident că pentru problema alegării proiectelor de investiții, atât faptul că X este un poliedru convex, cel puțin în cazul proiectelor interdependente, cât și faptul că coeficienții v sunt cunoscuți cu exactitate, sunt ipoteze destul de restrictive, astfel încât este justificat următorul model de alegere a proiectelor de investiții, MWDL, model care maximizează valoarea netă actuală, în condițiile celei mai proaste stări a vectorului v în V :

$$\max_{x \in X} \min_{v \in V} f(v, x) \quad (3.7)$$

$$x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.8)$$

unde $f(v, x)$ este o funcție concavă în x pentru v fixat, și linear în v pentru x fixat, X o mulțime convexă, iar V un poliedru convex și mărginit.

Avem Teorema 3.1. Problema (3.7) este o problemă convexă. Demonstrația este imediată ținînd seama de faptul că, pentru x fixat, funcția $\varphi(x) = \min_{v \in V} f(v, x)$ este o funcție concavă.

Rezolvarea însă a unei probleme booleene de max min (3.7) - (3.8) nu ar fi o problemă simplă chiar dacă

problema este convexă. Reducerea ei la cazul unei probleme lineare zero-unu reprezintă desigur un avantaj evident, ținând seama că pentru dimensiunile relativ mici ale unor asemenea probleme, rezolvarea ei nu mai prezintă astăzi dificultăți.

Teorema 3.2. Soluția problemei MWDLE:

$$\max x_{n+1} \quad (3.9)$$

$$[x, x_{n+1}] \in X_e \quad (3.10)$$

$$x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.11)$$

unde:

$$X_e = \left\{ [x, x_{n+1}] \mid x \in X, x_{n+1} \geq z^k - f(v^k, x), v^k \in \hat{V} \right\} \quad (3.12)$$

iar, \hat{V} notează mulțimea vîrfurilor poliedrului convex și mărginit V , este o soluție a problemei MWDL.

Demonstrația este imediată dacă observăm că în condițiile în care pentru x fixat funcția $f(v, x)$ fiind lineară în v își va atinge minimul într-un vîrf al lui V și deci avem

$$\max_{x \in X} \min_{v \in V} f(v, x) = \max_{x \in X} \min_{v^k \in \hat{V}} f(v^k, x) \quad (3.13)$$

$$x_j \in \{0,1\}, \quad j = 1, \dots, n, \quad x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.14)$$

Odată obținută relația (3.13), teorema este demonstrată deoarece pe X_e , $\max x_{n+1}$ nu poate depăși $\min_{v \in V} f(v, x)$ conform condițiilor puse în (3.12).

Observație. Problema MWDLE este o problemă zero-unu convexă. Dacă X este o mulțime convexă definită de relații lineare atunci problema MWDLE este o problemă lineară zero-unu.

În locul criteriului (3.7), de minimax a lui Wald, am putea considera un criteriu Savage-Niehans de minimax al regrețului și ca urmare să rezolvăm o problemă MSNDL:

$$\min_{x \in X} \max_{v \in V} \left[\max_{x \in X} f(v, x) - f(v, x) \right] \quad (3.15)$$

$$x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.16)$$

Teorema 3.3. Dacă $f(x, v)$ este o funcție lineară în v și V este un poliedru convex și mărginit, iar \hat{V} este mulțimea vîrfurilor poliedrului V , atunci avem:

$$\begin{aligned} \min_{x \in X} \max_{v \in V} \left[\max_{x \in X} f(v, x) - f(v, x) \right] &= \\ &= \min_{x \in X} \max_{v \in \hat{V}} \left[\max_{x \in X} f(v, x) - f(v, x) \right] \end{aligned} \quad (3.17)$$

Demonstrația rezultă din faptul că, pentru v fixat, funcția $\phi(v) = \max_{x \in X} f(v, x) - f(v, x)$ este o funcție convexă în v dacă $f(v, x)$ este lineară în v .

Teorema 3.4. În condițiile teoremei 3.3, o soluție a problemei MSNDL

$$\min_{[x, x_{n+1}] \in X_e} x_{n+1} \quad (3.18)$$

$$x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.19)$$

unde:

$$X_e = \left\{ [x, x_{n+1}] \mid x \in X, x_{n+1} \geq z^k - f(v^k, x), v^k \in \hat{V} \right\}, \quad (3.20)$$

$$z^k := \min_{x \in X} f(v^k, x), \quad k = 1, \dots, |\hat{V}| \quad (3.21)$$

este o soluție a problemei MSNDL.

Demonstrația este imediată ținând cont de teorema 3.3. **Observație.** Dacă $f(v, x)$, pentru v fixat, este o funcție convexă în x și X este o mulțime convexă, atunci problema MSNDL este o problemă zero-unu convexă. Dacă $f(v, x)$ este lineară în v și x , iar X este un poliedru convex, atunci problema este o problemă zero-unu lineară.

Criteriul lui Laplace de maximizare a mediei aritmetice a cîștigurilor în vîrfurile extreme ale lui V

$$\max \frac{1}{|\hat{V}|} \sum_{k=1}^{|\hat{V}|} f(v^k, x), \quad x \in X, \quad x_j \in \{0,1\}, \quad j = 1, \dots, n \quad (3.22)$$

conduce, de asemenea, la o problemă zero-unu convexă dacă $f(v^k, x)$ sunt funcții concave în x , și X este o mulțime convexă.

Bibliografie

- AVENHAUS, R., BEEDGEN, R., CHERNAVSKY, S.Y., s.a.: Handling Uncertainties. In: Linear Programming Models, W.P. - 80 - 170, IASA, Laxenburg, Austria, 1980.
- BELLMAN, R.E., ZADEH, L.A.: Decision-making in a Fuzzy Environment, Management Sci. (Appl. Ser), 1970, pp. 141-164.
- BURKARD, R.E., KEIDING, H., KRARUP, J., PRUZAN, P.M.: Relationship between Optimality and Efficiency in Multicriteria 0-1, Math. Institut Universitat zu Köln, Report 80-10, Aug. 1980.
- CABOT, V.: On the Generalized Lattice Point Problem and Nonlinear Programming, Operations Research vol.23, nr.3, 1975, pp. 565-571.
- CHERNAVSKY, S.Y.: Decision Making under Uncertainty (O priniatii reshenii v usloviyah neopredelennosti) In: Factor neopredelennosti pri priniatii optimalnih reshenii v bolshih systemah energetiki. Irkutsk, 1974, pp. 35-46.
- CIOBANU, G.I., STOICA, M.: Production Scheduling in Fuzzy Conditions, LCCE Preprint CO-13-1979, A.S.E. București, 1979.
- COLLATZ, L.: Functional Analysis and Numerical Mathematics, Academic Press, New York, 1966.
- DANTZIG, G.B.: Linear Programming and Extensions, Princeton University Press, 1963.
- DUMITRU, V., LUBAN, FL., MOGA, S., SERBAN, R.: Nonlinear Programming, Algorithms, Programms, Numerical Results. Appendix P with Fl. Luban, S. Moga, R. Serban. (Programare nelineară, algoritmi, programe, rezultate numerice. Appendix în

- colaborare cu Fl. Luban, S.Moga, R.Serban), Bucureşti, Editura Academiei Române, 1975, p. 208.
10. DUMITRU, V.: Conjugate Direction Method, Hessian Approximation and a New Class of Mixed Type Algorithms for Optimization, *Econ. Comput. Econ. Cybern. Stud. Res.* 1975, No.2, pp. 39-53.
 11. DUMITRU, V., LUBAN, FL.: Funcții de apartenență și unele modele de programare matematică cu aplicații în programarea producției, LCCE Preprint CO-15-79, A.S.E., Bucureşti, 1979.
 12. DUMITRU, V., LUBAN, FL.: Asupra unor modele neconvexe de programare matematică. LCCE Preprint, CO-28-79, A.S.E.
 13. DUMITRU, V., LUBAN, FL.: Modele de programare cu variabile reale pentru probleme discrete sau mixte. În: *Studii și Cercetări de Calcul Economic și Cibernetică Economică*, Nr.2, 1980, pp 57-67.
 14. DUMITRU, V., LUBAN, FL.: Asupra unor modele de programare matematică cu funcții obiectiv nelineare și coeficienții inexacți, LCCE Preprint MMM - 5 - 81.
 15. DUMITRU, V., LUBAN, FL.: Mathematical Programming Real Variable Models for Integer and Mixed-Integer Problems and Some Applications to Production Scheduling. In: *Mathematica*, Cluj-Napoca, 1981, vol.23, nr.46, pp. 11-23.
 16. DUMITRU, V., LUBAN, FL.: Membership Functions, Some Mathematical Programming Models and Production Scheduling. In: *Fuzzy Sets and Systems* No.8, 1982, pp. 19-33.
 17. DUMITRU, V., LUBAN, FL.: A Nongradient Algorithm with Final Newton Moves. In: *Methods of Operations Research*, nr.49, 1985, pp. 17- 27.
 18. DUMITRU, V., LUBAN, FL.: Approximation and Optimization Using only Functions Values. In: *Proceedings of the Colloquium on Approximation and Optimization*, Cluj-Napoca, October 25-27, 1984, pp. 229-239.
 19. DUMITRU, V., LUBAN, FL.: On the Fuzzy and Multicriteria Mathematical Programming. Methods of Operations Research No. 53, 1986, pp. 57-66.
 20. DUMITRU, V., LUBAN, FL.: On Some Optimization Problems under Uncertainty. In: *Fuzzy Sets and Systems*, No. 18, 1986, pp. 237-272.
 21. DUMITRU, V., LUBAN, FL.: On the Monotone Functionals in Multicriteria Optimization. In: *Econ. Comput. Econ. Cybern. Stud. Res.* 1987, No. 1, pp. 77-83.
 22. DUMITRU, V., LUBAN, FL.: On the Pareto Invariance of Some Decision Functionals. Methods of Operations Research, No. 57, 1987, pp. 3-10.
 23. DUMITRU, V., LUBAN, FL.: Monotone Operators and Pareto Invariance in Multicriteria Optimization. In: *Proceedings of the XIIIth. Symposium on Operations Research*, Paderbon 1988, in *Methods of Operations Research* No. 60, Verlag Anton Hain, Frankfurt am Main 1990.
 24. DUMITRU, V., LUBAN, FL.: On the Invariance of the Pareto Optimal Set. In: *Computer Science Journal of Moldova*, vol.1, No.3, 1993, pp 51-61.
 25. EVERETT, N.: Generalized Lagrange Multiplier Method for Solving Problem of Optimum Allocation of Resources. In: *Operations Research*, No. 11, 1963, pp. 399-417.
 26. ESOGBUE, A.O., BELLMAN, R.E.: Fuzzy Dynamic Programming and its Extensions. In: *TIMS/Studies in the Management Sciences*, No. 20, 1984, pp. 147-167.
 27. FALK, J.E., SOLAND, R.M.: An Algorithm for Separable non-Convex Programming Problems, *Management Science*, No. 15, 1969, pp. 550- 569.
 28. FALK, J.E.: Exact Solutions of Inexact Linear Programms. In: *Operations Research*, Vol. 24, No. 4, July-Aug, 1976, pp. 783-787.
 29. FIACCO, A.V., McCORMICK, G.P.: *Nonlinear Programming Sequential Unconstrained Minimization Techniques*, John Wiley, 1968.
 30. GLOVER, P., KLINGMAN, D.: The Generalized Lattice - Point Problems. In: *Operations Research*, Vol. 21, No.1, 1973, pp. 141-155.
 31. KARLIN, S.: *Mathematical Methods and Theory in Games Programming and Economics*, Addison-Wesley, Reading U.S.A. 1959.
 32. LORIE, J.H., SAVAGE, L.T.: Three Problems in Rationing Capital, *J. Business*, 1955, pp.229-239.
 33. LUBAN, FL., DUMITRU, V.: Asupra repartizării producției pe mașini prin programare matematică. În: *Studii și Cercetări de Calcul Economic și Cibernetică Economică*, Nr. 4, 1979, pp 43-50.
 34. LUBAN, FL.: Programarea producției la o secție de electrozi de sudură, prin programare matematică. În: *Studii și Cercetări de Calcul Economic și Cibernetică Economică*, nr. 1, 1980, pp 47-56.
 35. LUBAN, FL., DUMITRU V.:Theorems for Linear Approximation of Some Nonconvex Production Programming Models. In: *Proceedings of the fifth European Meeting on Cybernetics and Systems Research*, Vienna, 8-11 April, 1980, Hemisphere Publishing Corporation, Washington DC, 1982, pp. 361-365.
 36. LUBAN, FL.: Modele de optimizare a activităților economice din metalurgie. Teza de doctorat, ASE, Bucureşti, 1980.
 37. MARUSCIAC, I.: Metode de rezolvare a problemelor de programare nelineară, Editura Dacia, Cluj, 1973.
 38. NEGOITĂ, C.V., SULARIA, M.: On Fuzzy Mathematical Programming and Tolerance in Planning. In: *Economic Cybernetics and Economic Computation. Studies and Research*, No.1, 1976, pp. 3-15.
 39. SOYSTER, A.L.: Convex Programming with Set-Inclusive Constraints and Applications to Inexact Linear Programming, *Operations Research*, Vol.21, No. 5, 1973.
 40. STANCU-MINASIAN, I.M.: Programarea stocastică cu mai multe funcții obiectiv. Editura Academiei României, Bucureşti, 1980.

41. TANAHASKI, K., LUENBERGER, D.: Cardinality - Constrained Linear Programming, Stanford University, 1971.
42. WIRTZER, A.D., CHERNAVSKY, S.Y.: On Search for Optimal Strategies for Economic System Development under Uncertainty. (In: Systemnii analiz i perspektivnoe planirovanie), Moscow, Computer Centre of the Academy of Sciences of USSR, 1973, pp. 209-217.
43. WEINGARTNER, H., MARTIN, H.: Capital Budgeting of Interrelated Projects: Survey and Synthesis, in Managerial Economics, G.P.E. Clarkson Ed., Penguin Books, Baltimore SUA, 1968.
44. ZIMMERMANN, M.J.: Fuzzy Programming and Linear Programming with Several Objective Functions. In: Fuzzy Sets and Systems, No.1, 1978, pp. 44-45.