



METODA CELOR MAI MICI PĂTRATE TRUNCHIATE PENTRU O CLASĂ DE MODELE AUTOREGRESIVE

Cosmin Bătătorescu

Abstract

In the present paper we determine the parameters a_j and b_j of a Kremer type autoregressive model

$$X_{ij} = a_j + (b_j + r_{ij}) X_{i,j} + e_{ij}, \quad i = \overline{1, n}, \quad j = \overline{2, n},$$

using the truncated least squares method. We reduce the statistical problem to minimizing a concave function over a polytope, for which we present an iterative procedure for the determination of a local optimum. In the end, an adaptation of Tuy's cutting plane method is used for the construction of the global optimum of our problem.

1 Introducere

Lucrarea de față abordează o temă de actualitate în matematica actuarială, anume, rezerva pierderilor (loss reserving). Starea financiară a unei companii de asigurări nu poate fi evaluată în mod corespunzător fără o estimare corectă a rezervei pierderilor.

Problema rezervei pierderilor este rezumată astfel: date fiind informațiile din trecut, se pune problema estimării cuantumului plăților ce trebuie efectuate în viitor. Pentru aceasta, se consideră X_{ij} , $i = \overline{1, n}$, $j = \overline{1, n}$, un set de variabile aleatoare pe un câmp de probabilitate $\{\Omega, K, P\}$, unde X_{ij} reprezintă cuantumul total al cererilor de despăgubire a unei grupe de riscuri asigurate în anul j în raport cu anul i în care s-a produs accidentul. Observațiile se prezintă sub forma unui triunghi $X_\Delta = \{X_{ij} \mid i = \overline{1, n}, j = \overline{1, n - i + 1}\}$, ce reprezintă istoria cererilor de despăgubire.

În cadrul acestei lucrări vom prezenta un estimator cu un punct critic ridicat din punctul de vedere al programării matematice: regresia de cele mai

mici pătrate trunchiată (*regresie LTS*), cu scopul de a stabili un cadru în care acești estimatori pot fi obținuți exact.

Pentru modelul autoregresiv Kremer [4]

$$X_{ij} = a_j + (b_j + r_{ij}) X_{i,j-1} + e_{ij} \quad (1.1)$$

problema de regresie *LTS* se scrie

$$\min \sum_{i=1}^h \omega_{ij} e_{ij}^2 \quad (1.2)$$

unde am presupus următoarea ordonare a reziduurilor

$$(e_{1,j})^2 \leq (e_{2,j})^2 \leq \dots \leq (e_{n-j+1,j})^2 \quad (1.3)$$

iar h este numărul de observații netrunchiate din datele observate. Regresia *LTS* constă în determinarea valorilor \hat{a}_j, \hat{b}_j astfel încât suma pătratelor a celor mai mici h reziduuri să fie minimă.

În principiu (1.1) poate fi rezolvată dacă rezolvăm C_{n-j+1}^h probleme de regresie pentru toate submulțimile cu h elemente a lui $\{1, \dots, n-j+1\}$ și alegând apoi minimul absolut dintre acestea. Evident, din punctul de vedere al efortului de calcul, aceasta nu este o soluție acceptabilă, însă am arătat astfel că (1.1) are întotdeauna soluție.

2 Punctul critic

Pentru o valoare dată a lui j definim următoarele:

$$X_j = \begin{pmatrix} X_{1,j} \\ \vdots \\ X_{n-j+1,j} \end{pmatrix} \quad X_{j-1} = \begin{pmatrix} 1 & X_{1,j-1} \\ \vdots & \vdots \\ 1 & X_{n-j+1,j-1} \end{pmatrix},$$

x_{j-1} reprezintă a doua coloană a lui X_{j-1} , iar X_{j-1}^i reprezintă linia i a matricii X_{j-1} .

Notăm de asemenea cu $\beta_j = (a_j, b_j) \in \mathbb{R}^2$ vectorul parametrilor de regresie din modelul (1.1).

Notăm cu β^τ estimatorii β_j obținuți printr-o tehnică τ .

Dacă vom înlocui un număr $0 \leq m \leq n-j+1$ de observații din $(X_{i,j-1}, X_{i,j})$ din observațiile inițiale, pentru un anumit j fixat, cu o mulțime de observații $(\tilde{X}_{i,j-1}, \tilde{X}_{i,j})$, nouă, obținem un nou set de observații $(\tilde{X}_{j-1}, \tilde{X}_j)$. Aplicând aceeași tehnică τ asupra acestui nou set de observații vom obține estimatorii $\beta^\tau(\tilde{X}_{j-1}, \tilde{X}_j)$, care, în mod normal vor fi diferiți de cei originali.

Pentru măsurarea distanței $\left\| \beta^\tau \left(\tilde{X}_{j-1}, \tilde{X}_j \right) - \beta^\tau \right\|$ putem folosi orice normă din \mathbb{R}^2 . Considerând toate posibilitățile de a înlocui cel mult m elemente din cele $n - j + 1$ observate, pentru un j fixat, distanța de mai sus nu este întotdeauna finită.

Definiția 2.1 *Se numește deplasare maximă rezultată din înlocuirea a cel mult m observații din setul original de date prin altele noi, arbitrare, cantitatea*

$$b(m, \tau, X_{j-1}, X_j) = \sup_{\tilde{X}_{j-1}, \tilde{X}_j} \left\| \beta^\tau \left(\tilde{X}_{j-1}, \tilde{X}_j \right) - \beta^\tau \right\|.$$

Definiția 2.2 *Fiind date observațiile (X_{j-1}, X_j) , punctul critic pentru τ este definit ca*

$$\alpha(\tau, X_{j-1}, X_j) = \min_{0 \leq m < n-j+1} \left\{ \frac{m}{n-j+1} \mid b(m, \tau, X_{j-1}, X_j) \text{ este infinit} \right\}.$$

Observația 2.1 *În fond, punctul critic reprezintă numărul minim de observații din setul inițial (X_{j-1}, X_j) care, dacă sunt înlocuite cu alte observații aleatoare, fac tehnica de regresie τ să eșueze (breakdown).*

Definiția 2.3 *O tehnică de regresie τ se numește regresie echivariantă dacă pentru orice $v \in \mathbb{R}^2$ are loc:*

$$\beta^\tau(X_{j-1}, X_j + X_{j-1}v) = \beta^\tau(X_{j-1}, X_j) + v.$$

Observația 2.2 *Este evident faptul că regresile L_2 , L_1 și L_∞ sunt regresii echivariante și invariante la permutații.*

Teorema următoare definește marginea superioară a punctului critic pentru orice tehnică de regresie echivariantă τ .

Teorema 2.1 ([6], Teorema 4, pag. 125) *Fie τ o tehnică de regresie echivariantă și (X_{j-1}, X_j) datele observate astfel încât $X_{j-1}, X_j \in \mathbb{R}^{n-j+1}$ și $n - j + 1 \geq 3$. Atunci:*

$$\alpha(\tau, X_{j-1}, X_j) \leq \frac{\lfloor \frac{n-j+2}{2} \rfloor}{n-j+1}.$$

Corolarul 2.2 *Asimptotic, punctul critic al oricărei tehnici echivariante de regresie τ pentru orice set de date (X_{j-1}, X_j) este mărginit superior de 0.5, care este valoarea cea mai mare posibilă.*

În mod evident, cu cât punctul critic al unei tehnici de regresie este mai mare, cu atât acea tehnică este mai robustă. Cum ambele tehnici de regresie L_2 și L_∞ sunt regresii echivariante, rezultă imediat faptul că și regresia *LTS* este regresie echivariantă, și, prin prisma teoremei 2.1 rezultă că punctul critic pentru aceasta este mărginit superior de valoarea 0.5.

Teorema 2.3 ([6], Teorema 6, pag. 132) Marginea superioară a punctului critic pentru tehnica de regresie *LTS* este atins pentru

$$h = \left\lfloor \frac{n-j+1}{2} \right\rfloor + 1.$$

3 Regresie *LTS* și optimizare globală

Utilizând variabile 0–1, problema de regresie *LTS* se poate rescrie sub forma următoarei probleme neliniare

$$\begin{cases} \min_{\beta, \delta} \sum_{i=1}^{n-j+1} \omega_{ij} (X_{ij} - a_j - b_j X_{i,j-1})^2 \delta_{ij} \\ h_l \leq \sum_{i=1}^{n-j+1} \delta_{ij} \leq h_u ; \delta_{ij} \in \{0, 1\} \quad \forall i \end{cases} \quad (3.4)$$

unde

$$\delta_{ij} = \begin{cases} 0, & \text{dacă observația } (X_{i,j-1}, X_{ij}) \text{ a fost exclusă} \\ 1, & \text{în rest} \end{cases}$$

iar h_l, h_u sunt numere întregi ce satisfac relația $1 \leq h_l \leq h_u \leq n-j+1$.

Pentru a obține punctul critic maxim (vezi teorema 2.3), din punct de vedere teoretic trebuie făcută alegerea $h_l = h_u = \left\lfloor \frac{n-j+1}{2} \right\rfloor + 1$.

Pentru a utiliza cât mai multe din datele observate, în general se lucrează cu valorile

$$h_l = \left\lfloor \frac{n-j+1}{2} \right\rfloor + 1 - a, \quad h_u = \left\lfloor \frac{n-j+1}{2} \right\rfloor + 1 + a$$

unde a este un număr întreg pozitiv ce satisface relația $0 \leq a \leq \left\lfloor \frac{n-j+1}{2} \right\rfloor$.

Propoziția 3.1 În contextul regresiei *LTS*, o soluție optimă (β^*, δ^*) pentru 3.4 satisface relația $e_{n-j+1}^\top \delta^* = h_l$.

În continuare vom considera totuși un set admisibil $\delta \in \mathbb{R}^{n-j+1}$, așa cum apare el în (3.4), pentru a da o generalitate teoriei ce urmează.

Pentru a scrie problema de regresie *LTS* în formă matriceală, notăm cu

$$D_j = \text{diag}(\delta_{1,j}, \delta_{2,j}, \dots, \delta_{n-j+1,j}), \quad \Omega_j = \text{diag}(\omega_{1,j}, \omega_{2,j}, \dots, \omega_{n-j+1,j}) \quad (3.5)$$

matricile de dimensiune $(n-j+1) \times (n-j+1)$ ce au pe diagonala principală valorile δ_{ij} respectiv ω_{ij} , iar în rest valoarea 0. De asemenea vom nota

$$\Delta_j = \left\{ \delta \in \mathbb{R}^{n-j+1} \mid h_l \leq e_{n-j+1}^\top \delta \leq h_u ; 0 \leq \delta_i \leq 1 \quad \forall i = \overline{1, n-j+1} \right\} \quad (3.6)$$

relaxarea liniară a constrângerii din (3.4).

Δ_j este un politop în \mathbb{R}_+^{n-j+1} iar problema (3.4) se rescrie

$$\min_{\beta, \delta} \left\{ (X_j - X_{j-1}\beta)^\top D_j \Omega_j (X_j - X_{j-1}\beta) \mid \delta \in \Delta_j ; \delta \text{ întreg} \right\}. \quad (3.7)$$

Pentru a rezolva această problemă, vom efectua mai întâi minimizarea în funcție de β , și apoi în funcție de δ . Astfel, $\forall \delta \in \Delta_j$, fie

$$Z(\delta) = \min_{\beta} (X_j - X_{j-1}\beta)^\top D_j \Omega_j (X_j - X_{j-1}\beta). \quad (3.8)$$

Aceasta este o problemă ponderată de cele mai mici pătrate, și cum $\delta_{ij} \geq 0$, $\omega_{ij} \geq 0$ rezultă că există întotdeauna $\beta(\delta)$ soluție optimă pentru (3.8). Problema originală (3.7) devine astfel

$$\min \{ Z(\delta) \mid \delta \in \Delta_j ; \delta \text{ întreg} \}. \quad (3.9)$$

Teorema 3.2

i) $Z(\delta)$ este o funcție concavă $\forall \delta \in \mathbb{R}_+^{n-j+1}$.

ii) Orice vector $\delta \in \Delta_j$ care este un vector 0-1 va fi un punct de extrem pentru Δ_j .

iii) Toate punctele de extrem ale lui Δ_j sunt vectori 0-1.

iv) $\min \{ Z(\delta) \mid \delta \in \Delta_j \}$ se obține într-un punct de extrem al lui Δ_j .

Din teorema 3.2 rezultă că putem renunța la condiția ca δ să fie întreg în (3.7), deoarece din partea iv) a aceleiași teoreme avem

$$\begin{aligned} & \min_{\beta, \delta} \left\{ (X_j - X_{j-1}\beta)^\top D_j \Omega_j (X_j - X_{j-1}\beta) \mid \delta \in \Delta_j ; \delta \text{ întreg} \right\} \\ &= \min_{\beta, \delta} \left\{ (X_j - X_{j-1}\beta)^\top D_j \Omega_j (X_j - X_{j-1}\beta) \mid \delta \in \Delta_j \right\}. \end{aligned} \quad (3.10)$$

În consecință, regresia LTS este o problemă de minimizare în $n-j+3$ variabile reale, $\beta_1, \beta_2, \delta_1, \dots, \delta_{n-j+1}$. Funcția obiectiv din (3.10) este o funcție continuă și derivabilă, astfel încât putem utiliza condițiile Kuhn-Tucker pentru a caracteriza minimul local al (3.10).

Vom considera abordarea în două etape a rezolvării problemei (3.7) care, prin prisma punctului iv) al teoremei 3.2, presupune găsirea soluției problemei concave

$$\min \{ Z(\delta) \mid \delta \in \Delta_j \} \quad (3.11)$$

În cadrul teoremei următoare vom determina $Z(\delta)$ și vom aborda apoi rezolvarea problemei (3.11), spre exemplu, prin algoritmi generali prezentați în [2] și [3] pentru a găsi minimul global. Pentru a ușura scrierea în continuare, folosim următoarele notații

$$X_{j-1}(\delta) = X_{j-1}^\top D_j \Omega_j X_{j-1},$$

$$X_{j-1}X_j(\delta) = \begin{pmatrix} X_{j-1}(\delta) & X_{j-1}^\top D_j \Omega_j X_j \\ X_j^\top D_j \Omega_j X_{j-1} & X_j^\top D_j \Omega_j X_j \end{pmatrix}.$$

Teorema 3.3

i) Soluția optimă $\beta(\delta)$ pentru 3.8 este

$$\beta(\delta) = X_{j-1}(\delta)^{-1} X_{j-1}^\top D_j \Omega_j X_j \quad (3.12)$$

ii) Funcția $Z(\delta)$ din 3.8 este dată de

$$Z(\delta) = \frac{\det X_{j-1} X_j(\delta)}{\det X_{j-1}(\delta)}. \quad (3.13)$$

iii) Gradientul $\nabla Z(\delta)$ este dat de

$$\nabla Z(\delta) = (e_1^2(\delta), \dots, e_{n-j+1}^2(\delta))^\top \quad (3.14)$$

unde $e_i(\delta)$ este reziduul de ordin i evaluat în $\beta(\delta)$, adică

$$e_i(\delta) = X_{ij} - X_{j-1}^i \beta(\delta), \quad \forall i = \overline{1, n-j+1}. \quad (3.15)$$

iv) Gradientul $\nabla \beta(\delta)$ al lui $\beta(\delta)$ este dat de: $\nabla \beta(\delta) =$

$$\left(e_1(\delta) X_{j-1}(\delta)^{-1} (X_{j-1}^1)^\top, \dots, e_{n-j+1}(\delta) X_{j-1}(\delta)^{-1} (X_{j-1}^{n-j+1})^\top \right)^\top. \quad (3.16)$$

v) Matricea Hessiană a derivatelor de ordinul 2 a lui $Z(\delta)$ este dată de

$$\frac{\partial^2 Z}{\partial \delta_i \partial \delta_k} = -2e_i(\delta) e_k(\delta) X_{j-1}^i X_{j-1}(\delta)^{-1} (X_{j-1}^k)^\top. \quad (3.17)$$

4 Optimizare locală în regresia LTS

Structura particulară a mulțimii de constrângeri din problema de regresie LTS sugerează următoarea abordare euristică de determinare a soluției problemei (3.4). Fie $\delta^0 \in \Delta_j$ un punct de extrem al polipoului Δ_j cu j fixat. Dat fiind δ^0 , rezolvăm problema (3.8) prin metoda celor mai mici pătrate pentru a determina $Z(\delta^0)$.

Fie $\delta^1, \dots, \delta^{r_0}$ mulțimea vecinilor lui δ^0 .

Definiția 4.1 δ^0 se numește un optim local pentru $Z(\delta)$ dacă $Z(\delta^0) \leq Z(\delta^i)$, $\forall i = \overline{1, r_0}$, unde $Z(\delta)$ este cel definit în (3.8).

Pentru a implementa algoritmul de căutare locală, ne trebuie în primul rând o caracterizare completă a "vecinilor" ce trebuie parcursi.

Teorema 4.1 *Fie $\delta^0 \in \Delta_j$ un punct de extrem al lui Δ_j . Definim $H_0 = \{k \in \mathbb{N} \mid \delta_k^0 = 1\}$, $\delta^{ik} = \delta^0 - u_i + u_j$, $\delta^{i+} = \delta^0 + u_i$, $\delta^{i-} = \delta^0 - u_i$ unde $u_k \in \mathbb{R}^{n-j+1}$ este vectorul unitar.*

i) Dacă $e_{n-j+1}^\top \delta^0 = h_u$, atunci $\delta \in \mathbb{R}^{n-j+1}$ este un vecin al lui δ^0 pe Δ_j dacă și numai dacă $\delta = \delta^{ik}$ pentru $i \in H_0$ și $k \in \mathbb{N} \setminus H_0$, sau dacă $h_l < h_u$ și $\delta = \delta^{i-}$ pentru $i \in H_0$.

ii) Dacă $h_l < e_{n-j+1}^\top \delta^0 < h_u$, atunci $\delta \in \mathbb{R}^{n-j+1}$ este un vecin al lui δ^0 pe Δ_j dacă și numai dacă $\delta = \delta^{i+}$ pentru un $i \in \mathbb{N} \setminus H_0$ sau $\delta = \delta^{i-}$ pentru $i \in H_0$.

iii) $e_{n-j+1}^\top \delta^0 = h_l$, atunci $\delta \in \mathbb{R}^{n-j+1}$ este un vecin al lui δ^0 pe Δ_j dacă și numai dacă $\delta = \delta^{ik}$ pentru $i \in H_0$ și $k \in \mathbb{N} \setminus H_0$, sau dacă $h_l < h_u$ și $\delta = \delta^{i+}$ pentru $i \in \mathbb{N} \setminus H_0$.

Dacă $h_l = h_u$ obținem din teorema 4.1 că orice punct de extrem $\delta^0 \in \Delta_j$ are exact $h(n-j+i-h)$ vecini, unde $h = |H_0|$, iar dacă $h_l < h_u$, atunci δ^0 are exact $h(n-j+i-h+1)$ vecini.

Dat fiind un punct de extrem $\delta^0 \in \Delta_j$, notăm cu x_{j-1}^0 subvectorul lui x_{j-1} corespunzător lui $H_0 = \{k \in \mathbb{N} \mid \delta_k^0 = 1\}$ și respectiv X_j^0 subvectorul lui X_j . Pentru a simplifica notația, presupunem că $H_0 = \{1, \dots, h\}$ unde $h = |H_0|$, adică după o eventuală reindexare, liniile active din (x_{j-1}, X_j) corespunzătoare lui δ^0 să fie primele h linii.

Conform teoremei 4.1, mutarea într-un vecin δ^1 al lui δ^0 pe Δ_j presupune transformarea lui H_0 într-o mulțime H_1 în unul din următoarele trei moduri:

1. $H_1 = H_0 \setminus \{i\}$ pentru $i \in H_0$, sau
2. $H_1 = H_0 + \{i\}$ pentru $k \in \mathbb{N} \setminus H_0$, sau
3. $H_1 = H_0 \setminus \{i\} + \{k\}$ pentru $i \in H_0$, $k \in \mathbb{N} \setminus H_0$.

În mod corespunzător, matricea (x_{j-1}^0, X_j^0) se transformă în (x_{j-1}^1, X_j^1) astfel

$$x_{j-1}^1 = x_{j-1}^0 - x_{i,j-1} u_i \quad X_j^1 = X_j^0 - X_{ij} u_i \quad (4.18)$$

$$x_{j-1}^1 = \begin{pmatrix} x_{j-1}^0 \\ 0 \end{pmatrix} + x_{k,j-1} u_{h+1} \quad X_j^1 = \begin{pmatrix} X_j^0 \\ 0 \end{pmatrix} + X_{kj} u_{h+1} \quad (4.19)$$

$$x_{j-1}^1 = x_{j-1}^0 + (x_{kj} - x_{ij}) \quad X_j^1 = X_j^0 + (X_{kj} - X_{ij}) u_i \quad (4.20)$$

unde u_i este vectorul unitar din \mathbb{R}^h respectiv \mathbb{R}^{h+1} .

Corespunzător celor trei cazuri din (4.18), (4.19) și (4.20) avem:

$$\begin{aligned} (x_{j-1}^1)^\top x_{j-1}^1 &= (x_{j-1}^0)^\top x_{j-1}^0 - (x_{i,j-1})^2, \\ (x_{j-1}^1)^\top X_j^1 &= (x_{j-1}^0)^\top X_j^0 - x_{i,j-1} X_{ij} \end{aligned} \quad (4.21)$$

$$\begin{aligned} (x_{j-1}^1)^\top x_{j-1}^1 &= (x_{j-1}^0)^\top x_{j-1}^0 + (x_{k,j-1})^2, \\ (x_{j-1}^1)^\top X_j^1 &= (x_{j-1}^0)^\top X_j^0 + x_{k,j-1} X_{kj} \end{aligned} \quad (4.22)$$

$$\begin{aligned} (x_{j-1}^1)^\top x_{j-1}^1 &= (x_{j-1}^0)^\top x_{j-1}^0 - (x_{i,j-1})^2 + (x_{k,j-1})^2 \\ (x_{j-1}^1)^\top X_j^1 &= (x_{j-1}^0)^\top X_j^0 - x_{i,j-1} X_{ij} + x_{k,j-1} X_{kj} \end{aligned} \quad (4.23)$$

Trebuie să obținem formulele iterative pentru a calcula valoarea lui $Z^1 = \left[(x_{j-1}^1)^\top x_{j-1}^1 \right]^{-1}$ pornind de la $Z^0 = \left[(x_{j-1}^0)^\top x_{j-1}^0 \right]^{-1}$.

Pentru a simplifica scrierea, facem următoarele notații:

$$\begin{aligned} \alpha_i &= 1 - \frac{(x_{i,j-1})^2}{Z^0}, & \alpha_k &= 1 + \frac{(x_{k,j-1})^2}{Z^0}, \\ \beta_{ik} &= \frac{x_{i,j-1} x_{k,j-1}}{Z^0}, & \alpha_{ik} &= \alpha_i \alpha_k + \beta_{ik}^2 \end{aligned}$$

Prin calcul direct, pornind de la formulele (4.18)-(4.20) pentru X_j^1 , se obțin următoarele formule iterative, corespunzătoare celor trei cazuri:

$$\begin{aligned} \beta(\delta^1) &= \beta(\delta^0) - \frac{e_i^0 Z^0 x_{i,j-1}}{\alpha_i} \\ \beta(\delta^1) &= \beta(\delta^0) + \frac{e_k^0 Z^0 x_{k,j-1}}{\alpha_k} \\ \beta(\delta^1) &= \beta(\delta^0) + \left(\frac{\beta_{ik}}{\alpha_{ik}} e_k^0 - \frac{\alpha_k}{\alpha_{ik}} e_i^0 \right) Z^0 x_{i,j-1} + \left(\frac{\alpha_i}{\alpha_{ik}} e_k^0 + \frac{\beta_{ik}}{\alpha_{ik}} e_i^0 \right) Z^0 x_{k,j-1} \end{aligned}$$

unde

$$e_i^0 = X_{ij} - X_{j-1}^i \beta(\delta^0), \quad e_k^0 = X_{kj} - X_{j-1}^k \beta(\delta^0).$$

Suntem acum în măsura de a calcula îmbunătățirea ce se obține pentru funcția obiectiv $Z(\delta)$ din (3.8) prin trecerea de la $\delta^0 \in \Delta_j$ la un vecin $\delta^1 \in \Delta_j$.

Să notăm cu ΔZ_i , ΔZ^k și ΔZ_i^k cantitatea $Z(\delta^1) - Z(\delta^0)$ respectiv în cazul (4.18)-(4.20). Se obține:

$$\Delta Z_i = -\frac{(e_i^0)^2}{\alpha_i}, \quad \Delta Z^k = \frac{(e_k^0)^2}{\alpha_k}, \quad \Delta Z_i^k = \frac{\alpha_i (e_k^0)^2 + 2\beta_{ik} e_i^0 e_k^0 - \alpha_k (e_i^0)^2}{\alpha_{ik}}$$

Din cele de mai sus, putem deduce algoritmul local de determinare a parametrilor regresiei LTS.

Algoritmul 4.1

Date de intrare: $n - j + 1, h, x_{j-1}, X_j$.

Pas 0. Se determină o mulțime acceptabilă $H_0 \subseteq \mathbb{N}$ cu $|H_0| = h$, și fie $\delta^0 \in \mathbb{R}^{n-j+1}$ cu

$$\delta_k^0 = \begin{cases} 1 & \text{dacă } k \in H_0 \\ 0 & \text{dacă } k \in \mathbb{N} \setminus H_0 \end{cases} .$$

Pas 1. Calculăm $Z^0, \beta(\delta^0)$ și $e^0 = X_j - X_{j-1}\beta(\delta^0)$.

Calculăm $\Delta Z_{\min} = \min \{ \Delta Z_i^k \mid i \in H_0, k \in \mathbb{N} \setminus H_0 \}$.

Pas 2. Dacă $\Delta Z_{\min} \geq 0$, stop: δ^0 este optim local pentru problema (3.4). Altfel, înlocuim H_0 cu $H_1 = H_0 \setminus \{i\} + \{k\}$, unde $i \in H_0, k \in \mathbb{N} \setminus H_0$ astfel încât ΔZ_{\min} să fie atins, și apoi se repetă pasul 1.

Algoritmul 4.1 poate fi modificat în baza unei idei adaptate a lui Tuy [7] a metodei planului de secțiune: mai întâi rulăm algoritmul 4.1 pentru a obține un optim local δ^{L_1} . Fie $H_1 = \{k \in \mathbb{N} \mid \delta_k^{L_1} = 1\}$ și reținem valorile δ^{L_1} precum și valoarea funcției obiectiv $Z(\delta^{L_1})$ ca fiind cele mai bune până în momentul curent. Pentru a defini iterația, înlocuim politopul Δ_j prin $\Delta_j^1 = \Delta_j \cap \left\{ \delta \in \mathbb{R}^{n-j+1} \mid \sum_{k \in \mathbb{N} \setminus H_1} \delta_k \geq 2 \right\}$. Utilizând, de exemplu, algoritmul aditiv al lui Balas [1], determinăm un vector $0-1$ $\delta \in \Delta_j^1$ pentru care aplicăm din nou algoritmul 4.1 având ca punct de pornire δ .

Astfel se va obține un nou optim local, δ^{L_2} , care, dacă va fi nevoie, îl marcăm ca fiind cea mai bună soluție până la momentul curent. Notând $H_2 = \{k \in \mathbb{N} \mid \delta_k^{L_2} = 1\}$ înlocuim Δ_j^1 prin $\Delta_j^2 = \Delta_j^1 \cap \left\{ \delta \in \mathbb{R}^{n-j+1} \mid \sum_{k \in \mathbb{N} \setminus H_2} \delta_k \geq 2 \right\}$ și astfel continuăm iterația.

Numărul de puncte de extrem ale lui Δ_j ce trebuie comparate poate fi redus la C_{n-j+1}^h .

$$\text{Fie } \Delta_s = \left\{ \delta \in \mathbb{R}^{n-j+1} \mid 2 < \sum_{i=1}^{n-j+1} \delta_i = s < h; 0 \leq \delta_i \leq 1; s \text{ întreg} \right\} .$$

Definiția 4.2 Se numesc extensii ale punctului de extrem $\xi \in \Delta_s$ pe Δ_j toate punctele de extrem $\delta \in \Delta_j$ ce satisfac relația $\delta \geq \xi$.

Arătăm în cele ce urmează că pentru un punct de extrem $\delta^0 \in \Delta_j$ dat și valoarea corespunzătoare a funcției obiectiv $Z(\delta^0)$, orice punct de extrem $\delta \in \Delta_j$ care este extensia unui $\xi \in \Delta_s$ cu $Z(\xi) \geq Z(\delta^0)$ poate să fie exclus din calcule.

Teorema 4.2 Pentru un set de observații (x_{j-1}, X_j) , dacă există $\xi \in \Delta_s$ și $\delta^0 \in \Delta_j$ punct de extrem cu $Z(\xi) \geq Z(\delta^0)$ atunci orice extensie $\delta \in \Delta_j$ a lui ξ pe Δ_j are proprietatea că $Z(\delta) \geq Z(\xi)$.

Bibliografie

1. Balas, E., *An additive algorithm for solving linear programs with 0-1 variables*, Operations Research, 13, 517-546, 1965.
2. Falk, J.E., Hoffmann, K.L., *A successive underestimating method for concave minimization problems*, Mathematics of Operations Research, 1, 251-259, 1976.
3. Hoffmann, K.L., *A method for globally minimizing concave functions over convex sets*, Mathematical Programming, 20, 22-32, 1981.
4. Kremer, E., *Random Coefficient Autoregressive Loss Reserving*, Blätter der Deutschen Gesellschaft für Versicherungsmathematik, Vol XXI, p. 237-240, 1993.
5. Padberg, M., *Linear Optimization and Extensions*, Springer-Verlag, Berlin, 1995.
6. Rousseeuw, P.J., Leroy, A.M., *Robust Regression and Outlier Detection*, Wiley, New York, 1987.
7. Tuy, H., *Concave programming under linear constraints*, Soviet Math. Doklady, 4, 1437-1440, 1964.

High Quality Software
Str. Ion Nedeleanu, nr.13, bl.V22, sc.2, ap.51, 051722, București
E-mail: cosmin@hqs.ro