

XXVIII. MAGYAR OPERÁCIÓKUTATÁSI KONFERENCIA, BALATONÓSZÖD, 2009. JÚN. 8-10.

# Kalibrálás és konvex programozás – egy határterület áttekintése

Mihályffy László, KSH

# Konvex programozási feladat

$$F(\mathbf{x}) = \min!$$

$$A\mathbf{x} = \mathbf{b}$$

$$\mathbf{x}^1 \leq \mathbf{x} \leq \mathbf{x}^2,$$

ahol  $\mathbf{x}, \mathbf{x}^1, \mathbf{x}^2 \in \mathbb{R}^n$ ,  $\mathbf{b} \in \mathbb{R}^m$ ,  $A$   $m \times n$ -es,

$F : \mathbb{R}^n \rightarrow \mathbb{R}^1$ , konvex, folytonosan differenciálható

# Kalibrálási feladat

$$F(w_1, \dots, w_n, w_1^0, \dots, w_n^0) \\ = \sum_{j=1}^n G(w_j / w_j^0) = \min!$$

$$\sum_{j=1}^n x_{ij} w_j = X_i, \quad i = 1, 2, \dots, m (< n)$$

$$(L \leq w_j / w_j^0 \leq U, \quad j = 1, 2, \dots, n)$$

$w_1^0, \dots, w_n^0$  „design” súlyok

$w_1, w_2, \dots, w_n$  kalibrált súlyok

$0 \leq L < 1, \quad 1 < U, \quad F$ : távolságfüggvény,

konvex, folyt. diffh.,  $F=0 \Leftrightarrow w_j \equiv w_j^0$

# Kalibrálási feladat

Mátrix-vektor írásmód:

$$\mathbf{X}\mathbf{w} = X, \text{ ahol}$$

$$\mathbf{X} \quad m \times n$$

$$\mathbf{w} = (w_1, w_2, \dots, w_n)^T$$

$$\text{és } X = (X_1, X_2, \dots, X_m)^T;$$

# Négy feladat-típus

*Távolsággüggvények:*

Kvadratikus:  $G(w, w^0) = \frac{1}{2}(w - w^0)^2 / w^0$

Információ-divergencia:

$$G(w, w^0) = w \log \frac{w}{w^0} - w + w^0$$

I. típus: kvadratikus, individuális korlát nincs

II. típus: inf. div., individuális korlát nincs

III. típus: kvadratikus + individuális korlát

IV. típus: inf. div. +individuális korlát

# I. típus

Lagrange-függvény:

$$\Psi = 1/2 \sum_{j=1}^n (w_j - w_j^0)^2 / w_j^0 - \lambda^T (\mathbf{X}\mathbf{w} - X)$$

$$\lambda = (\lambda_1, \dots, \lambda_m)^T$$

Kalibrált súlyok::

$$\mathbf{w} = \mathbf{w}^0 + \mathbf{\Omega}\mathbf{X}^T (\mathbf{X}\mathbf{\Omega}\mathbf{X}^T)^{-1} (X - \hat{X})$$

Célváltozó becsült értékösszege:

$$\hat{Y}^{\text{kal}} = \hat{Y} + \mathbf{y}^T \mathbf{\Omega}\mathbf{X}^T (\mathbf{X}\mathbf{\Omega}\mathbf{X}^T)^{-1} (X - \hat{X})$$

$$= \hat{Y} + \sum_{i=1}^m b_i (X_i - \hat{X}_i)$$

$$\mathbf{\Omega} = \text{diag}(w_1^0, \dots, w_n^0),$$

$$\hat{X} = (\hat{X}_1, \dots, \hat{X}_m)^T \leftarrow \text{segédvált. becsült ért. össz.}$$

# I. típus tulajdonságai

- explicit előállítás,
- kalibrált becslés = regressziós becslés
- kalibrált súlyok lehetnek negatívak v. túl nagyok

## II. típus: Iteratív arányos közelítések, „raking”

(Darroch-Ratcliff, 1972).

Kezdő érték:  $w_j^0$

Iteráció:

$$(1) \quad r_i \sum_{j=1}^n x_{ij} w_j = X_i \quad i = 1, 2, \dots, m$$

$$(2) \quad w'_j = w_j \prod_{i=1}^m r_i^{x_{ij}/x_{.j}}, \quad \text{ahol} \quad x_{.j} = \sum_{i=1}^m x_{ij}$$

Tulajdonságok konvergens, minimalizálja a távolságfüggvényt,  $w_j \geq 0$ , de lehet túl nagy

*(2)-ben számtani közép is használható*



## III-IV. típus: Newton módszer

Laagrange-függvény:

$$\Psi = \sum_{j=1}^n G(w_j, w_j^0) - \lambda^T (\mathbf{X}\mathbf{w} - X)$$

$$\Rightarrow \partial G / \partial w_j = \mathbf{X}_{\cdot j}^T \lambda, \quad \mathbf{X}_{\cdot j} \text{ az } \mathbf{X} \text{ } j\text{-edik oszlopa}$$

$$\Rightarrow w_j = h(\mathbf{X}_{\cdot j}^T \lambda), \quad h \text{ a } \partial G / \partial w_j \text{ inverze}$$

Módosítás az individuális korlátok miatt: ahol  $w_j$  kilépne a korlátok közül, a  $h$  függvényt a megfelelő alsó- v. felső korláttal tesszük egyenlővé

## III-IV. típus: Newton módszer

Megoldandó egyenlet:

$$X - \hat{X} - \phi(\lambda) = 0, \quad \phi(\lambda) = \sum_{j=1}^n h(\mathbf{X}_{.j}^T \lambda) \mathbf{X}_{.j} - \hat{X}$$

Módosított célfüggvény a IV. típusnál:

$$G(v) = \frac{1}{A} \left[ (v - L) \log \frac{v - L}{1 - L} + (U - v) \log \frac{U - v}{U - 1} \right],$$

$$A = (U - L) / ((1 - L)(U - 1)), \quad v = w_j / w_j^0$$

## III-IV. típus: „Raking” módosítása

A (2) lépésben

$$w'_j = w_j \prod_{i=1}^m r_i^{x_{ij} / x_{.j}}$$

lehatároljuk a változó értékét, amennyiben túllép a korláton

Akkor is lehetséges, ha számtani középpel dolgozunk

# Eljárások összehasonlítása

Négy eljárás:

- (1) iteratív arányos közelítések, mértani átlaggal,
  - (2) iteratív arányos közelítések számtani átlaggal (KSH)
  - (3) Newton módszer, információ div. távolságfüggvénnyel
  - (4) Newton módszer kvadratikus távolságfüggvénnyel
- plusz mindegyiket a konvex programozással  
(Wolfe redukált gradiens módszer)

# Összehasonlítási szempontok

- a konvex programozás minimumának megközelítése
- az eljárás hatása néhány célváltozóra
- gépidő-igény

Felhasznált szoftver:

(1)-(2) módszer: saját fejlesztés (SAS /Interactive Matrix Language)

(3)-(4) módszer: CALMAR SAS macro, O. Sautory, INSEE

Wolfe redukált gradiens módszere: saját fejlesztés (SAS IML)

# Adatállományok

KSH munkaerő-felmérés, 2006. febr. és 2009. jan  
(kb. 10000-10000 háztartás)

Megyéenkénti kalibrálás  $\Rightarrow$  összesen 40 feladat,  
egyenként 22 segédváltozóval (2x10  
korcsoportos létszám, háztartás-szám, megyei  
jogú városok lakossága)

# Számítási eredmények (részlet)

## 1. Táblázat

Távolság- függvény	Távolság-fgv. értéke a minimum %-ában			
	1.	2.	3.	4.
55910	106.9	106.8	100.0	100.0
17143	108.1	108.3	100.3	102.6
9871	111.6	111.9	100.0	101.1
5160	106.2	106.2	100.0	100.5
9537	109.9	110.0	100.0	100.9
7613	115.3	115.3	100.0	102.3
6859	106.3	105.9	100.0	100.0
4914	110.3	110.9	100.0	100.0
3803	108.9	108.9	100.0	100.0
2735	110.2	109.9	100.0	100.1
4756	109.4	109.5	100.0	100.0
8034	108.5	108.5	100.0	100.1
7921	112.8	113.0	100.2	100.5

# Számítási eredmények (részlet)

# 2a Táblázat

M	Foglalkoztatott					Munkanélküli				
	Létszám	1.	2.	3.	4.	Létszám	1.	2.	3.	4.
01	755618	0.00	-0.21	-0.22	-0.33	32183	0.02	0.57	1.00	0.73
02	145528	-0.07	-0.81	-0.41	0.05	14335	-0.03	-1.90	-1.60	-1.37
03	189137	0.02	-0.33	-0.33	-0.44	16732	-0.15	0.04	0.01	0.99
04	128268	0.03	-0.61	-0.66	-0.52	14398	0.01	3.41	3.13	2.50
17	91181	-0.00	-0.17	-0.15	-0.11	8641	0.03	0.50	0.90	0.04
18	114347	-0.01	0.03	0.02	0.04	9903	0.14	-0.24	-0.54	-1.20
20	131226	0.01	0.42	0.45	0.36	10420	-0.06	-2.12	-1.21	1.09
T	3865062	0.00	0.01	-0.06	-0.05	331249	-0.04	-0.44	0.52	0.27



# Számítási eredmények (részlet)

# 2b Táblázat

M	Ráták, %						Rel. eltérések, %			
		1.	2.	3.	4.		1.	2.	3.	4.
01	4.09	4.09	4.12	4.13	4.13	.	0.02	0.75	1.17	1.02
09	9.16	9.15	9.26	9.29	9.23	.	-0.09	1.13	1.36	0.78
10	9.35	9.33	9.46	9.49	9.59	.	-0.25	1.14	1.47	2.48
11	10.81	10.81	10.40	10.41	10.34	.	0.06	-3.75	-3.64	-4.27
13	5.50	5.50	5.54	6.10	5.90	.	-0.01	0.86	10.88	7.27
14	9.43	9.40	9.42	9.41	9.52	.	-0.25	-0.13	-0.20	0.93
15	14.30	14.31	14.35	14.35	14.36	.	0.01	0.35	0.29	0.42
20	7.36	7.35	7.18	7.24	7.41	.	-0.07	-2.35	-1.54	0.67
T	7.89	7.89	7.86	7.94	7.92	.	-0.04	-0.42	0.53	0.30

# Konklúziók

Az (1)-(2) módszerek megoldásánál a táv. függvény átlagosan 8-9 %-kal marad el a konvex programozás optimumától, a két módszere eredménye közel van egymáshoz

A (3)-(4) módszerek gyakorlatilag az optimálissal megegyező megoldást adnak (max.eltérés 1-2 %).

A négy módszer gyakorlatilag azonos eredményt ad a foglalkoztatott és a munkanélküli létszámra, valamint a munkanélküliségi rátára. Az átlagos relatív eltérés 0,5%, ill. 2-3 % a létszámadatoknál, és 0,5 százalékpont alatt van a rátánál.

Az eltérések a mintavételi hiba határain belül vannak

# Konklúziók

Deville-Särndal (1992): a kalibrálási eljárások aszimptotikusa ekvivalensek

Műveleti sebesség: a CALMAR programmal a Newton módszer kb kétszer gyorsabb az iteratív arányos közelítésekénél. A konvex programozás lényegesen lassabb.

Végeredmény: mind a Newton módszernek, mind pedig az iteratív arányos közelítések módszerének indokolt a használata kalibrálási feladatok megoldására