

Karakterizacija rješenja LAD problema

1 LAD problem

Neka su $\mathbf{X} \in \mathbb{R}^{m \times n}$ te $\mathbf{y} \in \mathbb{R}^m$. Označimo s $\mathbf{r}(\mathbf{a}) = \mathbf{X}\mathbf{a} - \mathbf{y} \in \mathbb{R}^m$. Treba odrediti vektor $\mathbf{a} \in \mathbb{R}^n$ takav da je

$$\|\mathbf{r}(\mathbf{a})\|_1 \rightarrow \min_{\mathbf{a} \in \mathbb{R}^n}. \quad (1)$$

Problem (1) zovemo LAD (least absolute deviation) problem.

Primjer 1 Zadani su podaci (x_i, y_i) , $i = 1, \dots, m$ $x_i \neq x_j$, $i \neq j$, za koje treba odrediti pravac oblika $y = ax + b$ tako da vrijedi

$$\sum_{i=1}^m |ax_i + b - y_i| \rightarrow \min_{(a,b) \in \mathbb{R}^2}.$$

Pravac sa tim svojstvom zovemo LAD pravac. Problem određivanja LAD pravca specijalni je slučaj LAD

problema (1) uz oznake $\mathbf{X} = \begin{pmatrix} x_1 & 1 \\ x_2 & 1 \\ \vdots & \vdots \\ x_m & 1 \end{pmatrix}$, $\mathbf{y} = (y_1, \dots, y_m)^T$ te $\mathbf{a} = (a, b)^T$.

2 Svođenje LAD problema na problem linearnog programiranja

Neka je

$$\|\mathbf{X}\mathbf{a} - \mathbf{y}\|_1 = \|\mathbf{r}(\mathbf{a})\|_1 = \sum_{i=1}^m |r_i|, \quad r_i := r_i(\mathbf{a}).$$

Uvedimo nove varijable $u_i, v_i \geq 0$ tako da je $r_i = u_i - v_i$, $i = 1, \dots, m$ te $c_j, d_j \geq 0$ sa svojstvom $a_j = c_j - d_j$, $j = 1, \dots, n$. Označimo s $\mathbf{e} = (1, \dots, 1)^T \in \mathbb{R}^m$. Promatrajmo sljedeći problem linearnog programiranja:

$$\begin{aligned} \sum_{i=1}^m (u_i + v_i) = \mathbf{e}^T \mathbf{u} + \mathbf{e}^T \mathbf{v} + \mathbf{0}^T \mathbf{c} + \mathbf{0}^T \mathbf{d} &\rightarrow \min_{\mathbf{u}, \mathbf{v}, \mathbf{c}, \mathbf{d}} \\ -\mathbf{u} + \mathbf{v} + \mathbf{X}(\mathbf{c} - \mathbf{d}) &= \mathbf{y} \\ \mathbf{u}, \mathbf{v}, \mathbf{c}, \mathbf{d} &\geq \mathbf{0}, \end{aligned}$$

odnosno u matičnom obliku

$$\begin{aligned} (\mathbf{e}^T, \mathbf{e}^T, \mathbf{0}^T, \mathbf{0}^T) \begin{pmatrix} \mathbf{u} \\ \mathbf{v} \\ \mathbf{c} \\ \mathbf{d} \end{pmatrix} &\rightarrow \min_{\mathbf{u}, \mathbf{v}, \mathbf{c}, \mathbf{d}} \\ (-\mathbf{I} \quad \mathbf{I} \quad \mathbf{X} \quad -\mathbf{X}) \begin{pmatrix} \mathbf{u} \\ \mathbf{v} \\ \mathbf{c} \\ \mathbf{d} \end{pmatrix} &= \mathbf{y} \\ \mathbf{u}, \mathbf{v}, \mathbf{c}, \mathbf{d} &\geq \mathbf{0}. \end{aligned} \quad (2)$$

Uočimo da za svaki $i \in \{1, \dots, m\}$ varijable u_i i v_i u sustavu uvjeta (2) stoje uz dva linearno zavisna stupca matrice $(-\mathbf{I} \quad \mathbf{I} \quad \mathbf{X} \quad -\mathbf{X})$ pa oba ne mogu biti ispodvremeno bazične dopustive varijable odnosno mora vrijediti $u_i v_i = 0$, $i = 1, \dots, m$. Prema tome $|u_i - v_i| = u_i + v_i$, $i = 1, \dots, m$, što znači da je problem linearnog programiranja (2) ekvivalentan LAD problemu (1).

3 Karakterizacijski teorem

LAD problem (1) specijalni je slučaj općenitijeg problema aproksimacije, koji glasi:

Za zadanu matricu $\mathbf{X} \in \mathbb{R}^{m \times n}$ te vektor $\mathbf{y} \in \mathbb{R}^m$ treba odrediti vektor $\mathbf{a} \in \mathbb{R}^n$ takav da je

$$\|\mathbf{r}(\mathbf{a})\| = \|\mathbf{X}\mathbf{a} - \mathbf{y}\| \rightarrow \min_{\mathbf{a} \in \mathbb{R}^n}, \quad (3)$$

pri čemu je $\|\cdot\| : \mathbb{R}^m \rightarrow \mathbb{R}$ bilo koja norma.

U ovoj točki navest ćemo teorem koji daje karakterizaciju rješenja problema (3). U tu svrhu trebat će nam nekoliko pomoćnih pojmova.

a) Dualna norma

Neka je $r \in \mathbb{R}^m$ te $\|\cdot\| : \mathbb{R}^m \rightarrow \mathbb{R}$ norma na \mathbb{R}^m . Definiramo

$$\|\mathbf{r}\|^D := \max_{\|\mathbf{v}\|=1} \mathbf{r}^T \mathbf{v}.$$

Može se pokazati da je funkcija $\|\cdot\|^D : \mathbb{R}^m \rightarrow \mathbb{R}$ također norma na \mathbb{R}^m te je zovemo dualna norma norme $\|\cdot\|$. Također vrijede sljedeće tvrdnje:

- i) $\|\mathbf{r}\|_1^D = \|\mathbf{r}\|_\infty$, $\|\mathbf{r}\|_\infty^D = \|\mathbf{r}\|_1$
- ii) $(\|\mathbf{r}\|^D)^D = \|\mathbf{r}\|$
- iii) $\|\mathbf{r}\|_p^D = \|\mathbf{r}\|_q$, $\frac{1}{p} + \frac{1}{q} = 1$, $p > 1$.
- iv) $|\mathbf{r}^T \mathbf{v}| \leq \|\mathbf{r}\|^D \|\mathbf{v}\|$, $|\mathbf{r}^T \mathbf{v}| \leq \|\mathbf{r}\| \|\mathbf{v}\|^D$

b) Karakterizacijski skup

Vektoru $\mathbf{r} \in \mathbb{R}^m$ i normi $\|\cdot\|$ pridružimo skup

$$V_{\|\cdot\|}(\mathbf{r}) = \{\mathbf{v} \in \mathbb{R}^m : \|\mathbf{r}\| = \mathbf{r}^T \mathbf{v}, \|\mathbf{v}\|^D = 1\}.$$

Skup $V_{\|\cdot\|}(\mathbf{r})$ zovemo karakterizacijski skup pridružen vektoru \mathbf{r} i normi $\|\cdot\|$. Vrijede sljedeće tvrdnje

- i) $V_{\|\cdot\|_1}(\mathbf{r}) = \left\{ \mathbf{v} \in \mathbb{R}^m : v_i = \begin{cases} \text{sign}(r_i), & \text{ako je } r_i \neq 0 \\ \text{bilo koji broj iz intervala } [-1, 1], & \text{inače} \end{cases} \right\}$.
- ii) $V_{\|\cdot\|_2}(\mathbf{r}) = \frac{\mathbf{r}}{\|\mathbf{r}\|_2}$, $\mathbf{r} \neq \mathbf{0}$ te $V_{\|\cdot\|_2}(\mathbf{0}) = \{\mathbf{v} \in \mathbb{R}^m : v_1^2 + \dots + v_m^2 = 1\}$
- iii) $V_{\|\cdot\|_\infty}(\mathbf{r}) = \text{conv}\{\text{sign}(r_i)\mathbf{e}_i : |r_i| = \|\mathbf{r}\|_\infty\}$, pri čemu je \mathbf{e}_i i -ti koordinatni vektor.

Vrijedi sljedeći karakterizacijski teorem

Teorem 1 ([1]) Vektor $\mathbf{a} \in \mathbb{R}^n$ rješenje je problema (3) onda i samo onda ako postoji vektor $\mathbf{v} \in V_{\|\cdot\|}(\mathbf{r}(\mathbf{a}))$ takav da je $\mathbf{X}^T \mathbf{v} = \mathbf{0}$.

4 Primjene Teorema 1 na LAD problem

Promatrajmo LAD problem (1). Neka su $I = \{1, \dots, m\}$ te $Z(\mathbf{a}) = \{i \in I : r_i(\mathbf{a}) = 0\}$. Vrijedi sljedeći teorem.

Teorem 2 Ako je $\text{rang}(\mathbf{X}) = r$, onda postoji rješenje LAD problema (1) sa svojstvom da $Z(\mathbf{a})$ sadrži barem r indeksa.

Primjedba 1 Primijenimo li Teorem 2 na Primjer 1 dobivamo poznatu tvrdnu da uvijek postoji najbolji LAD pravac $y = a^*x + b^*$ koji prolazi kroz barem dvije točke podataka (x_μ, y_μ) i (x_ν, y_ν) , $\mu, \nu \in I$, $I = \{1, \dots, m\}$, $\mu \neq \nu$.

Nadalje vrijedi sljedeća karakterizacija:

Teorem 3 Neka su (x_i, y_i) , $i = 1, \dots, m$ takvi da je $x_i \neq x_j$ za $i \neq j$. Pravac $y = a^*x + b^*$ koji prolazi točno dvijema točkama podataka (x_μ, y_μ) i (x_ν, y_ν) , $\mu, \nu \in I$, $I = \{1, \dots, m\}$, $\mu \neq \nu$ je najbolji LAD pravac onda i samo onda ako vrijedi

$$\left| \sum_{i \in \{\mu, \nu\}} \text{sign}(a^*x_i + b^* - y_i) \frac{x_i - x_\mu}{x_\mu - x_\nu} \right| \leq 1 \quad \text{i} \quad \left| \sum_{i \in \{\mu, \nu\}} \text{sign}(a^*x_i + b^* - y_i) \frac{x_i - x_\nu}{x_\mu - x_\nu} \right| \leq 1, \quad (4)$$

ili u ekvivalentnom obliku

$$\max_{x \in \{x_\mu, x_\nu\}} \left| \sum_{i \in \{\mu, \nu\}} (x_i - x) \text{sign}(a^*x_i + b^* - y_i) \right| < |x_\mu - x_\nu|. \quad (5)$$

Teorem 4 Neka su (x_i, y_i, z_i) , $i = 1, \dots, m$ podaci takvi da (x_i, y_i) ne leže na nekom pravcu. Ravnina $z = a^*x + b^*y + c^*$ koji prolazi točno trima točkama podataka (x_μ, y_μ, z_μ) i (x_ν, y_ν, z_ν) , (x_k, y_k, z_k) $\mu, \nu, k \in I$, $I = \{1, \dots, m\}$, je najbolja LAD ravnina onda i samo onda ako vrijede sljedeće tri nejednakosti

$$\left| \sum_{i=1}^m \text{sign}(a^*x_i + b^*y_i + c^* - z_i) [(y_k - y_\nu)x_i + (x_\nu - x_k)y_i + (x_k y_\nu - x_\nu y_k)] \right| \leq |x_\mu(y_\nu - y_k) + x_\nu(y_k - y_\mu) + x_k(y_\mu - y_\nu)|$$

$$\left| \sum_{i=1}^m \text{sign}(a^*x_i + b^*y_i + c^* - z_i) [(y_k - y_\mu)x_i + (x_\mu - x_k)y_i + (x_k y_\mu - x_\mu y_k)] \right| \leq |x_\mu(y_\nu - y_k) + x_\nu(y_k - y_\mu) + x_k(y_\mu - y_\nu)|$$

$$\left| \sum_{i=1}^m \text{sign}(a^*x_i + b^*y_i + c^* - z_i) [(y_\nu - y_\mu)x_i + (x_\mu - x_\nu)y_i + (x_\nu y_\mu - x_\mu y_\nu)] \right| \leq |x_\mu(y_\nu - y_k) + x_\nu(y_k - y_\mu) + x_k(y_\mu - y_\nu)|$$

Literatura

- [1] G. E. Watson, *Approximation Theory and Numerical Methods*, John Wiley&Sons, New York, 1980.