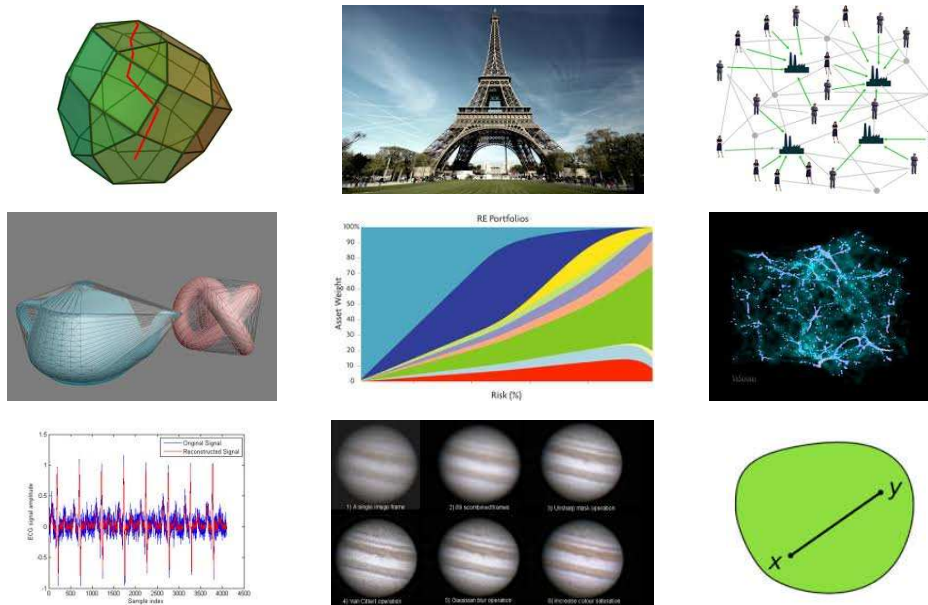


Konvexná optimalizácia - letný semester 2018

M. Trnovská, KAMŠ, FMFI UK



Téma 7: Aplikácie kónického lineárneho programovania

Optimalizácia portfólia s pravdepodobnostnými ohraničeniami

- premenná $x \in \mathbb{R}^n$; x_i je podiel aktíva i ;
- vektor cien p , $p \sim \mathcal{N}(\bar{p}, \Sigma)$;
- výnos portfólia r , $r \sim \mathcal{N}(\bar{r}, \sigma^2)$, $\bar{r} = \bar{p}^T x$, $\sigma^2 = x^T \Sigma x$

Úloha maximalizácie priemerného výnosu s ohraničením v tvare pravdepodobnosti:

$$\begin{aligned} \max \quad & \bar{p}^T x \\ & P(r \leq \alpha) \leq \beta, \\ & \sum_{i=1}^n x_i = 1, x \geq 0. \end{aligned} \tag{1}$$

Optimalizácia portfólia s pravdepodobnostnými ohraničeniami

Ohraničenie $P(r \leq \alpha) \leq \beta$ je ekvivalentné

$$P\left(\frac{r - \bar{r}}{\sigma} \leq \frac{\alpha - \bar{r}}{\sigma}\right) \leq \beta,$$

pričom $\frac{r - \bar{r}}{\sigma} \sim \mathcal{N}(0, 1)$.

Vyjadrenie pomocou kumulatívnej distribučnej funkcie $\phi(z) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^z e^{-\frac{t^2}{2}} dt$:

$$P\left(\frac{r - \bar{r}}{\sigma} \leq \frac{\alpha - \bar{r}}{\sigma}\right) = \phi\left(\frac{\alpha - \bar{r}}{\sigma}\right).$$

Optimalizácia portfólia s pravdepodobnostnými ohraničeniami

Úloha je ekvivalentná:

$$\begin{aligned} \max \quad & \bar{p}^T x \\ & \alpha - \bar{p}^T x \leq \phi^{-1}(\beta) \sqrt{x^T \Sigma x}, \\ & \sum_{i=1}^n x_i = 1, x \geq 0. \end{aligned} \tag{2}$$

- $\beta < \frac{1}{2}$ - konvexná SOCP úloha

- $\beta = \frac{1}{2}$ - úloha LP

- $\beta > \frac{1}{2}$ - nekonvexná úloha

Optimalizácia portfólia s pravdepodobnostnými ohraničeniami


Príklad.

Zvoľme dáta

$$\bar{p} = \begin{pmatrix} 0.12 \\ 0.10 \\ 0.07 \\ 0.03 \end{pmatrix}, \quad \Sigma = 0.0001 \begin{pmatrix} 64 & 8 & -11 & 0 \\ 8 & 25 & 0 & 0 \\ -11 & 0 & 4 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}, \quad \alpha = 0.$$

Zaujímá nás optimálne portfólio, ak hodnota pravdepodobnosti straty je $\beta \in [10^{-4}, 10^{-1}]$

Optimalizácia portfólia s pravdepodobnostnými ohraničeniami



Vľavo: trade-off medzi pravdepodobnosťou straty a priemerným výnosom

Vpravo: optimálna alokácia portfólia

Optimalizácia portfólia s pravdepodobnostnými ohraničeniami

```
beta=logspace(-4, -1,100);
for i=1:100
    cvx_begin quiet
        variable x(4);
        maximize (p'*x)
        subject to
            p'*x+norminv(beta(i))*norm(Sigma^(1/2)*x,2)>=0;
            sum(x)==1;
            x>=0;
        cvx_end
        ER(i)=p'*x; X(:,i)=x;
        v1(i)=X(1,i); v2(i)=v1(i)+X(2,i); v3(i)=v2(i)+X(3,i);
    end;
subplot(1,2,1)
plot(beta,ER,'LineWidth',2)
xlabel('pravdepodobnost straty'); ylabel('priemerny vynos');
subplot(1,2,2)
plot(beta,v1,beta,v2,beta,v3,'LineWidth',2)
xlabel('pravdepodobnost straty'); ylabel('optimalna alokacia');
```


Optimálny návrh experimentov

Lineárny regresný model

$$y(x) = f(x)^T \theta + \varepsilon,$$

- $y(x)$ je vektor pozorovaní,
- $x \in X$, $X = \{x_1, \dots, x_n\}$ je množina reprezentujúca možné experimentálne podmienky (body merania)
- $f : X \rightarrow \mathbb{R}^m$ je vektor známych regresných funkcií,
- $\theta \in \mathbb{R}^m$ je vektor neznámych parametrov
- ε - vektor náhodných chýb, $\varepsilon \sim \mathcal{N}(0, I)$.

Optimálny návrh experimentov

- Chceme odhadnúť vektor θ z čiastkových experimentov alebo meraní v bodoch z X .
- Návrh experimentu veľkosti N je postupnosť N bodov z X , v ktorých budú vykonané merania.
- Označme N_i počet meraní v bode x_i , t. j. $N_1 + \dots + N_n = N$. V štatistike sa zvyčajne definuje **exaktný dizajn** ako diskretna miera ξ , kde $\xi(x_i) = \frac{N_i}{N}$, $x_i \in X$.

Optimálny návrh experimentov

- Základná otázka v optimálnom navrhovaní experimentov: Ako optimálne rozmiestniť N meraní do potenciálnych bodov z X , teda ako vybrať hodnoty N_1, \dots, N_n ?

- Takáto úloha je vo všeobecnosti ťažký kombinatorický problém. Preto sa diskkrétne premenné N_i nahradia reálnymi hodnotami w_i spĺňajúcimi

$$w_i \geq 0, \sum_{i=1}^n w_i = 1, Nw_i \in \mathbb{Z},$$

a posledná požiadavka sa ignoruje.

- Táto idea viedla k pojmu tzv. **asymptotického dizajnu**, ktorý sa v štatistike zvyčajne definuje ako diskrétna pravdepodobnostná miera ξ na X .

Optimálny návrh experimentov

- V prípade konečnej množiny X je asymptotický dizajn určený hodnotami $w_i = \xi(x_i)$. BUNV budeme pod asymptotickým dizajnom rozumieť vektor w zo simplexu

$$\mathbb{S}^n = \left\{ w \in \mathbb{R}_+^n \mid \sum_{i=1}^n w_i = 1 \right\}.$$

- Kvalita dizajnu závisí od tzv. informačnej matice

$$M(w) = \sum_{i=1}^n w_i f(x_i) f(x_i)^T,$$

ktorá je kladne definitná, pokiaľ vektory $f(x_1), \dots, f(x_n)$ generujú \mathbb{R}^m a $w > 0$.

Optimálny návrh experimentov

- Úloha v optimálnom navrhovaní experimentov:

$$\max_{w \in \mathbb{S}^n} M(w)$$

- V štatistike existuje niekoľko kritérií optimality, t.j. funkcií

$$\Phi : \mathcal{S}_{++}^n \rightarrow \mathbb{R}$$

ktoré slúžia ako miera veľkosti matice.

- kritérium E-optimality: $\Phi_E(M) = \lambda_{\min}(M)$;
- kritérium A-optimality: $\Phi_A(M) = [\text{tr}(M^{-1})]^{-1}$;
- kritérium D-optimality: $\Phi_D(M) = \log \det(M)$;

Optimálny návrh experimentov

Pri hľadaní E-optimálneho dizajnu rieši optimalizačná úloha

$$\max_{w \in \mathbb{S}^n} \lambda_{\min}(M(w))$$

Kedže

$$t \leq \lambda_{\min}(M(w)) \Leftrightarrow M(w) \succeq tI,$$

predchádzajúca úloha sa dá naformulovať ako úloha SDP

$$\begin{aligned} \max \quad & t \\ & M(w) - tI \succeq 0, \\ & w \in \mathbb{S}^n. \end{aligned} \tag{3}$$

Optimálny návrh experimentov

Duálna úloha k úlohe E-optimálneho dizajnu

Úlohu (3) si preformulujeme do nasledovného minimalizačného tvaru:

$$\begin{aligned} \min \quad & \frac{1}{t} \\ & \sum_{i=1}^n w_i f_i f_i^T - tI \succeq 0, \\ & w \geq 0, \sum_{i=1}^n w_i = 1. \end{aligned}$$

Lagrangeova funkcia k tejto úlohe je $L : (\mathbb{R}^n \times \mathbb{R}_{++}) \times (\mathcal{S}_+^n \times \mathbb{R}_+^n \times \mathbb{R}) \rightarrow \mathbb{R}$ definovaná ako

$$\begin{aligned} L(w, t; Z, y, \alpha) &= \frac{1}{t} - \text{tr} \left(Z \left(\sum_{i=1}^n w_i f_i f_i^T - tI \succeq 0 \right) \right) - y^T w + \alpha \left(\sum_{i=1}^n w_i - 1 \right) \\ &= \frac{1}{t} + t \text{tr}(Z) - \sum_{i=1}^n w_i (f_i^T Z f_i + y_i - \alpha) - \alpha. \end{aligned}$$

Optimálny návrh experimentov

Lagrangeova duálna funkcia je definovaná ako

$$g(Z, y, \alpha) = \inf_{w, t} L(w, t; Z, y, \alpha).$$

Odvodíme

$$g(Z, y, \alpha) = \begin{cases} 2\sqrt{\text{tr}(Z)} - \alpha & f_i^T Z f_i + y_i - \alpha = 0, \\ -\infty & \text{inak.} \end{cases}$$

Optimálny návrh experimentov

Lagrangeovu duálnu úlohu môžeme preto naformulovať ako

$$\begin{aligned} \max \quad & 2\sqrt{\text{tr}(Z)} - \alpha \\ & f_i^T Z f_i + y_i - \alpha = 0, \quad i = 1, \dots, n \\ & y \geq 0, Z \succeq 0, \end{aligned}$$

Ekvivalentná formulácia (po zjednodušení):

$$\begin{aligned} \max \quad & \text{tr}(W) \\ & f_i^T W f_i \leq 1, \quad i = 1, \dots, n \\ & W \succeq 0, \end{aligned} \tag{4}$$

Optimálny návrh experimentov


Dané sú dáta $m = 2, n = 20$ a hodnoty regresných funkcií uložené v $n \times n$ matici F . Dátové body (riadky matice F) sú vykreslené na obrázku.

Zdroj: <http://cvxopt.org/examples/book/expdesign.html>

Pomocou CVX spočítame hodnotu optimálneho dizajnu:

$$w_i^* = \begin{cases} 0.2 & i = 10; \\ 0.8 & i = 20; \\ 0 & \text{inak.} \end{cases}$$

Optimálny návrh experimentov



Elipsa na obrázku zodpovedá optimálnej matici W^* z duálnej úlohy. Všimnime si, že body zodpovedajúce kladným hodnotám w_i^* ležia na hranici elipsy, čo je dôsledok podmienok komplementarity.

Optimálny návrh experimentov

CVX kód:

```
n=size(F,1);
m=size(F,2);
cvx_begin sdp
    variable w(n,1)
    variable t
    dual variable Z
    dual variable alfa
    maximize t
    subject to
        Z:F'*diag(w)*F-t*eye(m)>=0;
        w>=0;
        alfa:sum(w)==1;
cvx_end
```

Úloha minimálnej plochy

Uvažujme diferencovateľnú funkciu $f : C \subset \mathbb{R}^2 \rightarrow \mathbb{R}$. Plocha daná grafom funkcie f je vyjadrená ako

$$A(f) = \int_C \sqrt{1 + \|\nabla f(x)\|_2^2} dx = \int_C \left\| \begin{pmatrix} \nabla f(x) \\ 1 \end{pmatrix} \right\|_2 dx.$$

Úloha minimalizácie plochy je o nájdení funkcie f , pre ktorú je za daných ohraničení plocha A minimálna.

- $C = [0, 1] \times [0, 1]$ - diskretizuje sa mriežkou s bodmi (ih, jh) , $0 \leq i, j \leq K$, kde K je celé číslo a $h = 1/K$ je (rovnomerné) delenie
- **Premenné:** hodnoty f_{ij} funkcie f v bodoch (ih, jh) , čo možno reprezentovať maticou $F \in \mathbb{R}^{(K+1) \times (K+1)}$, $F_{ij} = f(ih, jh)$

Úloha minimálnej plochy

Aproximácia parciálnych derivácií funkcie f pomocou pomerných diferencií

$$\frac{\partial f(x)}{\partial x_1} \approx \frac{f(x_1 + h, x_2) - f(x_1, x_2)}{h}, \quad \frac{\partial f(x)}{\partial x_2} \approx \frac{f(x_1, x_2 + h) - f(x_1, x_2)}{h}.$$

Aproximácia gradientu funkcie f v bode $x = (ih, jh)$:

$$\nabla f(x) \approx K \begin{bmatrix} f_{i+1,j} - f_{i,j} \\ f_{i,j+1} - f_{i,j} \end{bmatrix}$$

Aproximácia plochy danej grafom funkcie f :

$$A(f) \approx A_{disk}(f) = \frac{1}{K^2} \sum_{i,j=0}^{K-1} \left\| \begin{pmatrix} K(f_{i+1,j} - f_{i,j}) \\ K(f_{i,j+1} - f_{i,j}) \\ 1 \end{pmatrix} \right\|_2.$$

Úloha minimálnej plochy

Možno uvažovať rôzne ohraničenia na f_{ij} , napr. ohraničenia na hraničné hodnoty C .

$$\begin{aligned} \min \quad & A_{disk} \\ & f_{0,j} = l_j, \quad j = 0, 1, \dots, K, \\ & f_{K,j} = r_j, \quad j = 0, 1, \dots, K, \end{aligned} \tag{5}$$

kde l, r sú vektory hraničných hodnôt (ktoré možno získať diskretizáciou daných jednorozmerných funkcií).

Úloha minimálnej plochy



SOCP reformulácia:

$$\min \sum_{i,j=0}^{K-1} t_{ij}$$

$$\left\| \begin{pmatrix} K(f_{i+1,j} - f_{i,j}) \\ K(f_{i,j+1} - f_{i,j}) \\ 1 \end{pmatrix} \right\|_2 \leq t_{ij}, \quad i, j = 0, 1, \dots, K-1 \quad (6)$$
$$f_{0,j} = l_j, \quad j = 0, 1, \dots, K,$$
$$f_{K,j} = r_j, \quad j = 0, 1, \dots, K,$$



Úloha minimálnej plochy

Grafický výstup (CVX/Matlab):



Úloha minimálnej plochy

Grafický výstup (CVX/Matlab):



Klasifikácia dát

Dané sú dve množiny bodov

$$X = \{x_1, \dots, x_N\} \subset \mathbb{R}^n \text{ a } Y = \{y_1, \dots, y_M\} \subset \mathbb{R}^n.$$

Úlohou je nájsť funkciu $f : \mathbb{R}^n \rightarrow \mathbb{R}$ (z danej riedy funkcií) takú, že

$$f(x_i) < 0, \quad i = 1, \dots, N, \quad f(y_i) > 0, \quad i = 1, \dots, M.$$

Pokiaľ sú tieto nerovnosti splnené, tak hovoríme, že množina

$$\{x \mid f(x) = 0\}$$

separuje množiny bodov X, Y .

Klasifikácia dát

Lineárna diskriminácia

Ak zvolíme pre klasifikáciu triedu afínnych funkcií, t. j.

$$f(x) = a^T x + b,$$

hovoríme a lineárnej diskriminácii.

Úloha: nájsť nadrovinu $\{x \mid a^T x - b = 0\}$ ktorá separuje množiny bodov X a Y , t.j. platí


$$a^T x_i - b > 0, \quad i = 1, \dots, N, \quad a^T y_i - b < 0, \quad i = 1, \dots, M.$$

Homognita nerovností v premenných (a, b) - ekvivalentné nerovnosti

$$a^T x_i - b \geq 1, \quad i = 1, \dots, N, \quad a^T y_i - b \leq -1, \quad i = 1, \dots, M.$$

Takáto úloha sa dá riešiť ako **lineárna úloha prípustnosti**.

Klasifikácia dát



Ak sú dátové množiny v \mathbb{R}^2 separovateľné, lineárnou úlohou prípustnosti možno nájsť separujúcu priamku.

Klasifikácia dát

Prípád neseparovateľných dátových množín (SVM)

Zavedú sa nové **nezáporné** premenné u_1, \dots, u_N a v_1, \dots, v_M .

Lineárne ohraničenia sa relaxujú:

$$a^T x_i - b \geq 1 - u_i, \quad i = 1, \dots, N, \quad a^T y_i - b \leq -1 + v_i, \quad i = 1, \dots, M.$$

LP formulácia:

$$\begin{aligned} \min_{a,b,u,v} \quad & \mathbf{e}^T u + \mathbf{e}^T v \\ & a^T x_i - b \geq -1 - u_i, \quad i = 1, \dots, N, \\ & a^T y_i - b \leq 1 + v_i, \quad i = 1, \dots, M, \\ & u, v \geq 0. \end{aligned}$$

Klasifikácia dát

Kvadratická diskriminácia

Ak zvolíme pre klasifikáciu triedu konvexných kvadratických funkcií

$$f(x) = x^T P x + q^T x + r,$$

hovoríme a kvadratickej (elipsoidnej) diskriminácii. Úlohou je nájsť $P \in \mathcal{S}_{++}^n, q \in \mathbb{R}^n, r \in \mathbb{R}$ platí

$$x_i^T P x_i + q^T x_i + r < 0, i = 1, \dots, N, y_i^T P y_i + q^T y_i + r > 0, i = 1, \dots, M.$$

Homogenita premenných (P, q, r) - ekvivalentné nerovnosti

$$x_i^T P x_i + q^T x_i + r \leq -1, i = 1, \dots, N, y_i^T P y_i + q^T y_i + r \geq 1, i = 1, \dots, M.$$

Klasifikácia dát

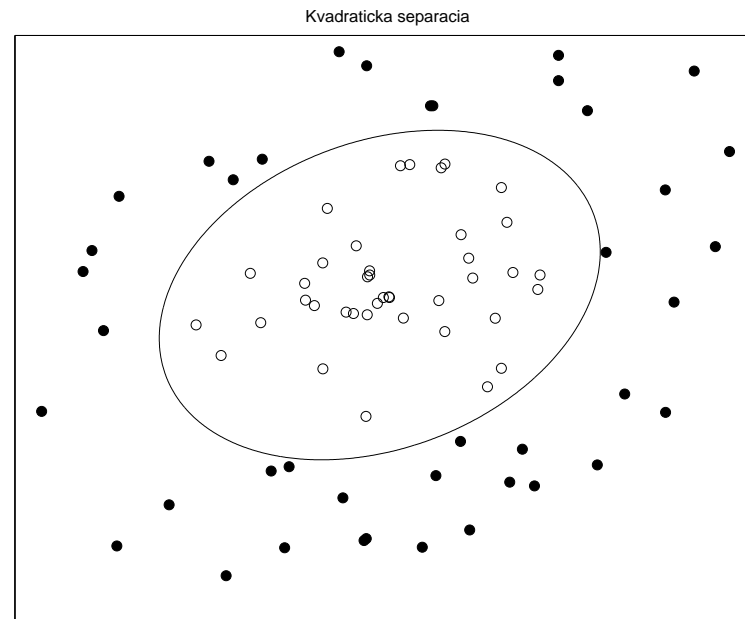
Kvadratická (elipsoidná) diskriminácia

Semidefinitná úloha prípustnosti: nájsť P, q, r také, že

$$\begin{aligned}x_i^T P x_i + q^T x_i + r &\leq -1, \quad i = 1, \dots, N, \\y_i^T P y_i + q^T y_i + r &\geq 1, \quad i = 1, \dots, M, \\P &\succeq I,\end{aligned}$$

kde podmienku $P \in \mathcal{S}_{++}^n$ môžeme kvôli homogenite premenných nahradiť LMI ohraničením $P \succeq I$.

Klasifikácia dát



Ak sú dátové množiny v \mathbb{R}^2 separovateľné, semidefinitnou úlohou prípustnosti možno nájsť separujúcu elispu.

Klasifikácia dát

Prípád neseparovateľných dátových množín (SVM)

Zavedú sa nové **nezáporné** premenné u_1, \dots, u_N a v_1, \dots, v_M .

Kvadratické ohraničenia sa relaxujú:

$$\begin{aligned}x_i^T P x_i + q^T x_i + r &\leq -1 + u_i, \quad i = 1, \dots, N, \\y_i^T P y_i + q^T y_i + r &\geq 1 - v_i, \quad i = 1, \dots, M,\end{aligned}$$

SDP formulácia:

$$\begin{aligned}\min_{a,b,u,v} \quad & \mathbf{e}^T u + \mathbf{e}^T v \\ & x_i^T P x_i + q^T x_i + r \leq -1 + u_i, \quad i = 1, \dots, N, \\ & y_i^T P y_i + q^T y_i + r \geq 1 - v_i, \quad i = 1, \dots, M, \\ & u, v \geq 0, P \succeq I.\end{aligned}$$