

Ponovitev: matrike, sled, rang, lastne vrednosti,...

Polona Oblak

1. SLED

Sled matrike $A = [a_{i,j}] \in \mathbb{R}^{n \times n}$ (oznaka: $\text{tr}(A)$) je vsota vseh njenih diagonalnih elementov

$$\text{tr}(A) = \sum_{i=1}^n a_{i,i}.$$

Lastnosti sledi. Za matrike $A, B, P \in \mathbb{R}^{n \times n}$ velja

- (1) $\text{tr}(\alpha A) = \alpha \text{tr}(A)$,
- (2) $\text{tr}(A + B) = \text{tr}(A) + \text{tr}(B)$,
- (3) $\text{tr}(A^T) = \text{tr}(A)$,
- (4) $\text{tr}(AB) = \text{tr}(BA)$,
- (5) $\text{tr}(PAP^{-1}) = \text{tr}(A)$ za vsako obrnljivo matriko P .

2. RANG

Rang matrike $A \in \mathbb{R}^{m \times n}$ (oznaka: $\text{rank}(A) = \text{rk}(A)$) je

- število pivotov, ki jih dobimo v (reducirani) vrstično stopničasti obliki matrike A po Gaussovi eliminaciji
- število linearno neodvisnih vrstic matrike A ,
- dimenzija linearne ogrinjače vrstic matrike A ,
- število linearno neodvisnih stolpcev matrike A ,
- dimenzija linearne ogrinjače stolpcev matrike A ,
- $\dim C(A)$,
- $n - \dim N(A)$,
- velikost največje obrnljive (kvadratne) podmatrike matrike A .

3. PODOBNOST

Matriki $A \in \mathbb{R}^{n \times n}$ in $B \in \mathbb{R}^{n \times n}$ sta **podobni**, če obstaja takšna obrnljiva matrika $P \in \mathbb{R}^{n \times n}$, da je

$$A = PBP^{-1}.$$

Podobne matrike imajo isto:

- (1) sled,
- (2) determinanto,

- (3) karakteristični polinom,
- (4) lastne vrednosti,
- (5) rang.

4. DO NASLEDNJEGA TEDNA

- (1) Pokažite naslednje enakosti in neenakosti, ki veljajo za rang matrik:

- (a) $\text{rank}(A^T) = \text{rank}(A)$,
- (b) $\text{rank}(AB) \leq \text{rank}(A)$ in $\text{rank}(AB) \leq \text{rank}(B)$,
- (c) $\text{rank}(A + B) \leq \text{rank}([A|B])$,
- (d) $\text{rank}(A + B) \leq \text{rank}(A) + \text{rank}(B)$,
- (e) $\text{rank}([A|B]) \leq \text{rank}(A) + \text{rank}(B)$, kjer je za $A \in \mathbb{R}^{m \times n}$ in $A \in \mathbb{R}^{m \times p}$ matrika $[A|B] \in \mathbb{R}^{m \times (n+p)}$ razširjena matrika matrik A in B ,
- (f) $\text{rank}(A \oplus B) = \text{rank}(A) + \text{rank}(B)$, kjer je za $A \in \mathbb{R}^{m \times n}$ in $A \in \mathbb{R}^{p \times q}$ matrika $A \oplus B = \begin{bmatrix} A & 0 \\ 0 & B \end{bmatrix} \in \mathbb{R}^{(m+p) \times (n+q)}$ direktna vsota matrik A in B .

(Pri tem naj bosta matriki A in B v posameznih alinejah primernih velikosti za množenje, seštevanje,...)

- (2) Rešite kviz in preverite vaše znanje osnovnih pojmov linearne algebre.

5. NADALJNJE BRANJE

- (1) David A. Harville: Matrix Algebra From a Statistian's Perspective, Springer, 1997, razdelek 5.
- (2) 3Blue1Brown, Essence of linear algebra

6. (PRIPOROČLJIVA) DOMAČA NALOGA

- (1) David A. Harville: Matrix Algebra From a Statistian's Perspective, Springer, 1997, stran 53 (Exercise 1, 2, 3).
- (2) Dokazite, da je podobnost matrik tranzitivna lastnost.
- (3) Dokazite, da imajo podobne matrike isti karakteristični polinom.

**Schurov izrek, Frobeniusova norma matrike,
izrek Eckarta in Younga**

Polona Oblak

1. SCHUROV IZREK IN NJEGOVE POSLEDICE

Izrek 1 (Schur). Naj ima matrika $A \in \mathbb{R}^{n \times n}$ lastne vrednosti $\lambda_1, \lambda_2, \dots, \lambda_n$. Tedaj obstaja takšna ortogonalna matrika $Q \in \mathbb{R}^{n \times n}$, da je

$$Q^T A Q$$

zgornje trikotna $n \times n$ matrika z diagonalnimi elementi enakimi $\lambda_1, \lambda_2, \dots, \lambda_n$.

Opazimo:

- V izreku 1 lahko zgornjo trikotnost nadomestimo s spodnjo trikotnostjo.
- Pri tem niti matrika Q niti $Q^T A Q$ nista enolično določeni z matriko A .

Posledica 1. Vsaka matrika $A \in \mathbb{R}^{n \times n}$ je podobna zgornje trikotni matriki.

Posledica 2. Vsaka simetrična matrika $A \in \mathbb{R}^{n \times n}$ je ortogonalno podobna diagonalni matriki.

Posledica 3. Če ima matrika $A \in \mathbb{R}^{n \times n}$ lastne vrednosti enake $\lambda_1, \lambda_2, \dots, \lambda_n$, potem je

$$\text{tr}(A) = \lambda_1 + \lambda_2 + \dots + \lambda_n$$

in

$$\det(A) = \lambda_1 \lambda_2 \dots \lambda_n.$$

Posledica 4 (Cayley-Hamilton). Če je $\Delta_A(x) = \det(A - xI_n)$ karakteristični polinom matrike A , potem velja $\Delta_A(A) = 0$.

Izrek 2 (SVD - Razcep singularnih vrednosti). Za vsako matriko $A \in \mathbb{R}^{m \times n}$, $m \geq n$, obstajajo takšna matrika

$$\Sigma = \begin{bmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \ddots & \\ & & & \sigma_n \end{bmatrix} \in \mathbb{R}^{m \times n}$$

ter ortogonalni matriki $U \in \mathbb{R}^{m \times m}$ in $V \in \mathbb{R}^{n \times n}$, da velja

$$A = U \Sigma V^T.$$

2. FROBENIUSOVA NORMA MATRIKE

Za matriki $A \in \mathbb{R}^{m \times n}$ in $B \in \mathbb{R}^{m \times n}$ definiramo

$$\langle A, B \rangle = \text{tr}(A^T B).$$

Izrek 3. Za produkt $\langle A, B \rangle: \mathbb{R}^{m \times n} \times \mathbb{R}^{m \times n} \rightarrow \mathbb{R}$ velja za vse matrike $A, B, C \in \mathbb{R}^{m \times n}$

- (1) $\langle A, B \rangle = \langle B, A \rangle$,
- (2) $\langle \alpha A + \beta B, C \rangle = \alpha \langle A, C \rangle + \beta \langle B, C \rangle$, za vse $\alpha, \beta \in \mathbb{R}$,
- (3) $\langle A, A \rangle \geq 0$,
- (4) $\langle A, A \rangle = 0$ natanko tedaj, ko je $A = 0$.

Zato $\langle A, B \rangle$ imenujemo **skalarni produkt** matrik A in B .

Izrek 4. Za matrike $A \in \mathbb{R}^{m \times n}$, $B \in \mathbb{R}^{m \times k}$ in $C \in \mathbb{R}^{k \times n}$ velja

$$\langle A, BC \rangle = \langle B^T A, C \rangle = \langle AC^T, B \rangle.$$

Frobeniusova norma matrike $A = [a_{ij}] \in \mathbb{R}^{m \times n}$ je definirana kot

$$\|A\|_F = \|A\| = \sqrt{\langle A, A \rangle} = \sqrt{\text{tr}(A^T A)}.$$

Velja:

$$\|A\|_F^2 = \sum_{i=1}^n \sum_{j=1}^m a_{ij}^2 = \sum_{i=1}^{\min\{m,n\}} \sigma_i^2.$$

Izrek 5 (Eckart, Young). Naj bo $A = U \Sigma V^T$ razcep singularnih vrednosti matrike $A \in \mathbb{R}^{m \times n}$, $m \geq n$, kjer $U = [U^{(1)} U^{(2)} \dots U^{(m)}] \in \mathbb{R}^{m \times m}$ in $V = [V^{(1)} V^{(2)} \dots V^{(n)}] \in \mathbb{R}^{n \times n}$. Potem je matrika $A_k \in \mathbb{R}^{m \times n}$ ranga k , $k \leq n$, ki je med vsemi matrikami ranga k v Frobeniusovi normi najbližje matriki A , enaka

$$A_k = \sigma_1 U^{(1)} (V^{(1)})^T + \sigma_2 U^{(2)} (V^{(2)})^T + \dots + \sigma_k U^{(k)} (V^{(k)})^T$$

in velja $\|A - A_k\|_F = \sqrt{\sigma_{k+1}^2 + \dots + \sigma_n^2}$. (Velja torej $\|A - A_k\|_F \leq \|A - X\|_F$ za vse matrike $X \in \mathbb{R}^{m \times n}$, za katere velja $\text{rank}(X) = k$.)

3. NADALJNJE BRANJE

- (1) Roger A. Horn and Charles R. Johnson, *Matrix Analysis*, Cambridge, 2006, razdelka 2.3 and 2.4.
- (2) več matričnih norm: Roger A. Horn and Charles R. Johnson, *Matrix Analysis*, Cambridge, 2006, razdelek 5.6.
- (3) Gilbert Strang, *Linear algebra and Learning from Data*, Wellesley-Cambridge Press, Wellesley, 2019, razdelek I.9.

4. DOMAČA NALOGA

- ⚡ (1) Rešite kviz na spletni Učilnici.
- ★ (2) Uporabite Schurov izrek, da dokažete, da je rang kvadratne matrike A enak velikosti največje obrnljive (kvadratne) podmatrike matrike A .
- ★ (3) Dokažite Cayley-Hamiltonov izrek, posledica 4.
- ⚡ (4) Pokažite, da za simetrično matriko $A \in \mathbb{R}^{n \times n}$ velja

$$\|A\|_F = \sqrt{\lambda_1^2 + \dots + \lambda_n^2},$$

kjer so $\lambda_1, \dots, \lambda_n$ lastne vrednosti matrike A . Pokažite na primeru, da enakost ne velja za nesimetrične matrike.

- ⚡ (5) Naj bo $A = PDP^{-1}$ simetrična matrika. Pokažite, da je najboljša aproksimacija ranga ena matrike A v Frobeniusovi normi enaka $\lambda_1 v_1 v_1^T$, kjer je λ_1 po absolutni vrednosti največja lastna vrednost matrike A , v_1 pa normirani lastni vektor, ki pripada λ_1 .
- ★ (6) Roger A. Horn and Charles R. Johnson, *Matrix Analysis*, Cambridge, 2006, nalogi 2.3.P6 (str.107) in 2.4.P2 (str.124).

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov. Naloge, označene s ★ so težje, širijo vaše znanje in dopolnjujejo odpredavano snov.)

5. REŠITVE NALOG

- (2) Naj ima matrika $A \in \mathbb{R}^{n \times n}$ lastne vrednosti $\lambda_1, \dots, \lambda_n$. Po Schurovem izreku obstajata takšna ortogonalna matrika $Q \in \mathbb{R}^{n \times n}$ in takšna zgornje trikotna matrika $Z \in \mathbb{R}^{n \times n}$ z diagonalnimi elementi $\lambda_1, \dots, \lambda_n$, da je $Q^T A Q = Z$.

Matrika Z je zgornje trikotna, zato lahko s permutacijo vrstic (množenje Z s permutacijsko matriko $P \in \mathbb{R}^{n \times n}$ z leve) in s permutacijo stolpcev (množenje Z s permutacijsko matriko $R \in \mathbb{R}^{n \times n}$ z desne) dosežemo, da bo matrika PZR oblike

$$PZR = \begin{bmatrix} Z_1 & X \\ 0 & Z_2 \end{bmatrix},$$

kjer je $Z_1 \in \mathbb{R}^{r \times r}$ obrnljiva zgornje trikotna matrika, $Z_2 \in \mathbb{R}^{(n-r) \times (n-r)}$ pa zgornje trikotna matrika z ničlami na diagonalni. To pomeni, da ima matrika PZR obrnljivo $r \times r$ podmatriko Z_1 in da velja $\text{rank}(Z) \geq \text{rank } Z_1 = r$. Še več, ker ima Z_2 na diagonalni ničelne vrednosti, ima vsaka $(r+1) \times (r+1)$ podmatrika matrike Z ničelno determinanto.

Matrika $Z = P^T A R^T$ ima tako tudi obrnljivo $r \times r$ podmatriko (vendar morda ne več v zgornjem levem vogalu) in posledično jo ima tudi matrika $A = Q Z Q^T$ (saj je Q obrnljiva). Ker sta matriki A in Z podobni, je torej $\text{rank}(A) = \text{rank}(Z) \geq r$. Zatorej je $\text{rank}(A)$ enak velikosti največje obrnljive podmatrike matrike A (=največji možni r).

Kroneckerjev produkt

Polona Oblak

1. KRONECKERJEV (TENZORSKI) PRODUKT

Kroneckerjev produkt (tudi *tenzorski produkt*) matrik $A = [a_{ij}] \in \mathbb{R}^{m \times n}$ in $B \in \mathbb{R}^{p \times q}$ je $mp \times nq$ matrika

$$A \otimes B = \begin{bmatrix} a_{11}B & a_{12}B & \dots & a_{1n}B \\ a_{21}B & a_{22}B & \dots & a_{2n}B \\ \vdots & \vdots & & \vdots \\ a_{m1}B & a_{m2}B & \dots & a_{mn}B \end{bmatrix} \in \mathbb{R}^{mp \times nq}.$$

Če so matrike A, B, C in D primernih velikosti, potem veljajo naslednje enakosti.

- (1) $0 \otimes A = A \otimes 0 = 0$
- (2) $\alpha \otimes A = A \otimes \alpha = \alpha A$ za vsak $\alpha \in \mathbb{R}$
- (3) $(\alpha A) \otimes B = A \otimes (\alpha B) = \alpha(A \otimes B)$
- (4) $(A + B) \otimes C = A \otimes C + B \otimes C$ in $A \otimes (B + C) = A \otimes B + A \otimes C$
- (5) $(A \otimes B)^T = A^T \otimes B^T$
- (6) $(A \otimes B) \otimes C = A \otimes (B \otimes C)$.
- (7) $(A \otimes B)(C \otimes D) = (AC) \otimes (BD)$.
- (8) $(A \otimes B)^{-1} = A^{-1} \otimes B^{-1}$
- (9) $\text{tr}(A \otimes B) = \text{tr}(A) \text{tr}(B)$
- (10) $\text{rang}(A \otimes B) = \text{rang}(A) \text{rang}(B)$
- (11) Če ima matrika $A \in \mathbb{R}^{n \times n}$ lastne vrednosti $\lambda_1, \dots, \lambda_m$ in ima matrika B lastne vrednosti $\mu_1, \dots, \mu_n$, potem je množica lastnih vrednosti matrike $A \otimes B$ enaka

$$\{\lambda_i \mu_j; \lambda_i \text{ lastna vrednost } A, \mu_j \text{ lastna vrednost } B\}.$$

- (12) Če $A \in \mathbb{R}^{n \times n}$ in $B \in \mathbb{R}^{m \times m}$, potem je $\det(A \otimes B) = (\det A)^m (\det B)^n$.

2. PRESLIKAVA vec

Za matriko $A \in \mathbb{R}^{m \times n}$ označimo *vektorizacijo matrike A* kot

$$\text{vec}(A) = \begin{bmatrix} A^{(1)} \\ A^{(2)} \\ \vdots \\ A^{(n)} \end{bmatrix} \in \mathbb{R}^{mn}.$$

vec je preslikava iz $\mathbb{R}^{m \times n}$ v $\mathbb{R}^{mn}$.

Izrek 1. Za matrike $A \in \mathbb{R}^{m \times n}$, $B \in \mathbb{R}^{n \times p}$ in $C \in \mathbb{R}^{p \times r}$ velja

$$\text{vec}(ABC) = (C^T \otimes A) \text{vec}(B).$$

3. NADALJNJE BRANJE

- (1) David A. Harville: Matrix Algebra From a Statistian's Perspective, Springer, 1997, razdelki 16.1., 16.2. in 16.3.
- (2) Roger A. Horn and Charles R. Johnson, *Topics in Matrix Analysis*, Cambridge, 2006, razdelek 4.2.
- (3) Charles F. Van Loan: The ubiquitous Kronecker product, Journal of Computational and Applied Mathematics 123 (2000) 85-100.

4. DOMAČA NALOGA

- (1) Rešite kviz na spletni Učilnici.
- (2) David A. Harville: Matrix Algebra From a Statistian's Perspective, Springer, 1997, stran 368 (Exercises 1, 2, 3, 4, 14, 15, 16).

Pozitivno semidefinitne matrike. Razcep Choleskega.

Polona Oblak

1. POZITIVNO SEMIDEFINITNE MATRIKE

Spomnimo se, da ima simetrična matrika $A \in \mathbb{R}^{n \times n}$ vse lastne vrednosti realne.

Simetrični matriki $A \in \mathbb{R}^{n \times n}$ pravimo

- (1) *pozitivno semidefinitna*, če je $x^T A x \geq 0$ za vse $x \in \mathbb{R}^n$.
- (2) *pozitivno definitna*, če je $x^T A x > 0$ za vse neničelne $x \in \mathbb{R}^n$.
- (3) *negativno semidefinitna*, če je $x^T A x \leq 0$ za vse $x \in \mathbb{R}^n$.
- (4) *negativno definitna*, če je $x^T A x < 0$ za vse neničelne $x \in \mathbb{R}^n$.
- (5) *nedefinitna*, če je $x^T A x > 0$ za nekatere $x \in \mathbb{R}^n$ in $y^T A y < 0$ za nekatere $y \in \mathbb{R}^n$.

Izrek 1. Simetrična matrika $A \in \mathbb{R}^{n \times n}$ je

- (1) *pozitivno semidefinitna natanko tedaj, ko ima vse lastne vrednosti nenegativne,*
- (2) *pozitivno definitna natanko tedaj, ko ima vse lastne vrednosti pozitivne,*
- (3) *negativno semidefinitna natanko tedaj, ko ima vse lastne vrednosti nepozitivne,*
- (4) *negativno definitna natanko tedaj, ko ima vse lastne vrednosti negativne,*
- (5) *nedefinitna natanko tedaj, ko ima tako pozitivne kot negativne lastne vrednosti.*

Izrek 2. (1) Simetrična matrika $A \in \mathbb{R}^{n \times n}$, $\text{rank}(A) = r$, je pozitivno semidefinitna natanko tedaj, ko obstaja takšna matrika $B \in \mathbb{R}^{n \times r}$, $\text{rank}(B) = r$, da je $A = B B^T$.

- (2) Simetrična matrika $A \in \mathbb{R}^{n \times n}$ je pozitivno definitna natanko tedaj, ko obstaja takšna obrnljiva matrika $B \in \mathbb{R}^{n \times n}$, da je $A = B B^T$.

Izrek 3 (Sylvester). Simetrična matrika A je pozitivno definitna natanko tedaj, ko so determinante vseh vodilnih glavnih podmatrik matrike A pozitivne.

Simetrična matrika A je negativno definitna natanko tedaj, ko je determinanta vsake $k \times k$ vodilne glavne podmatrike A pozitivna, če je k sodo število, ter negativna, če je k liho število.

Izrek 4 (Razcep Choleskega). Obrnljiva matrika $A \in \mathbb{R}^{n \times n}$ ima razcep Choleskega

$$A = L L^T,$$

kjer je $L \in \mathbb{R}^{n \times n}$ spodnje trikotna matrika, natanko tedaj, ko je A simetrična in pozitivno definitna.

2. NADALJNJE BRANJE

- ⚡ (1) David A. Harville: Matrix Algebra From a Statistian's Perspective, Springer, 1997, Poglavje 14.
- ⚡ (2) Gilbert Strang, *Linear algebra and Learning from Data*, Wellesley-Cambridge Press, Wellesley, 2019, razdelek I.7.
- ★ (3) Roger A. Horn and Charles R. Johnson, *Matrix Analysis*, Cambridge, 2006, Podpoglavja 7.0, 7.1, 7.2.
- ★ (4) Giorgio Giorgi: [Various Proofs of the Sylvester Criterion for Quadratic Forms](#), Journal of Mathematics Research; Vol 9, No 6, 2017.

3. DOMAČA NALOGA

- ⚡ (1) Rešite [kviz](#) na spletni Učilnici.
- ⚡ (2) Poiščite linearno spremembo spremenljivk $u = f(x, y, z)$, $v = g(x, y, z)$ and $w = h(x, y, z)$, v kateri ima

$$Q(x, y, z) = 3x^2 + 4xy - 4xz - 2yz$$
 diagonalno obliko.
- ⚡ (3) Če sta matriki $A \in \mathbb{R}^{n \times n}$ in $B \in \mathbb{R}^{m \times m}$ simetrični pozitivno semidefinitni matriki, pokažite, da je tudi $A \otimes B$ pozitivno semidefinitna matrika.
- ⚡ (4) Če je simetrična matrika A pozitivno semidefinitna, pokažite, da je tudi A^k pozitivno semidefinitna za vsak $k \in \mathbb{N}$.
- ⚡ (5) Naj bo $A = B^T B$ takšna pozitivno semidefinitna matrika velikosti $n \times n$, da za nek vektor $x \in \mathbb{R}^n$ velja $x^T A x = 0$. Pokažite, da je $Bx = 0$ in nato sklepajte, da velja tudi $Ax = 0$.
- ⚡ (6) Pokažite, da je bločna matrika $\begin{bmatrix} A & B \\ B^T & C \end{bmatrix}$ (simetrična) pozitivno semidefinitna natanko tedaj, ko je matrika $\begin{bmatrix} A & -B \\ -B^T & C \end{bmatrix}$ pozitivno semidefinitna. Pri tem je $A \in \mathbb{R}^{n \times n}$, $B \in \mathbb{R}^{n \times m}$ ter $C \in \mathbb{R}^{m \times m}$.
- ⚡ (7) Naj bo $A \in \mathbb{R}^{n \times n}$ simetrična pozitivno semidefinitna matrika z lastnimi vrednostmi $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_n$.
 - (a) Dokažite, da velja $\vec{x}^T A \vec{x} \leq \lambda_1 \|\vec{x}\|^2$ za vsak $\vec{x} \in \mathbb{R}^n$.
 - (b) Dokažite, da velja $\max_{\vec{x} \in \mathbb{R}^n} \frac{\vec{x}^T A \vec{x}}{\vec{x}^T \vec{x}} = \lambda_1$.
 - (c) Dokažite, da je tudi matrika $A - \lambda_1 I_n$ pozitivno semidefinitna.

- (8) Naj bosta $A, B \in \mathbb{R}^{n \times n}$ simetrični pozitivno semidefinitni matriki.
- ⚡ (a) Pokažite, da obstaja natanko pozitivno semidefinitna matrika K , da velja $K^2 = A$.
 - ★ (b) Pokažite, da obstaja natanko ena pozitivno semidefinitna matrika K , da velja $K^2 = A$. Pravimo tudi, da je $K = \sqrt{A}$ koren matrike A .
 - ⚡ (c) Pokažite, da je $\langle A, B \rangle = \|\sqrt{A}\sqrt{B}\|_F^2$.
 - ★ (9) Preberite in razumite vsaj enega od dokazov Sylvestrovega izreka.

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov. Naloge, označene s ★ so težje, širijo vaše znanje in dopolnjujejo odpredavano snov.)

Vektorski prostor in podprostor. Baza.

Polona Oblak

1. VEKTORSKI PROSTOR

Realni vektorski prostor V je množica *vektorjev* $v \in V$, za katere imamo definirani dve notranji operaciji

- seštevanje vektorjev ($u, v \in V \implies u+v \in V$) in
- množenje vektorjev z realnimi števili ($v \in V, \alpha \in \mathbb{R} \implies \alpha v = \alpha \cdot v \in V$),

z lastnostmi

(VP1) $u + v = v + u$ in $(u + v) + w = u + (v + w)$,

(VP2) obstaja *ničelni vektor* 0 in velja $v + 0 = 0 + v = v$,

(VP3) za vsak $v \in V$ obstaja *nasprotni vektor* $-v$, za katerega velja $v + (-v) = (-v) + v = 0$,

(VP4) $1 \cdot v = v$ za vsak $v \in V$,

(VP5) $(\alpha\beta) \cdot v = \alpha \cdot (\beta \cdot v)$,

(VP6) $(\alpha + \beta) \cdot v = \alpha \cdot v + \beta \cdot v$,

(VP7) $\alpha \cdot (u + v) = \alpha \cdot u + \alpha \cdot v$,

za poljubne $u, v, w \in V$ in $\alpha, \beta \in \mathbb{R}$.

Pri tem bomo, kot običajno v matematiki, simbol $\cdot$ pri produktu vektorja s številom večinoma izpuščali. Torej bomo pisali tudi $\alpha v = \alpha \cdot v$.

Izrek 1. *Naj bo V vektorski prostor. Potem velja*

- (1) V vsebuje ničelni vektor 0 ,
- (2) v vsakem vektorskem prostoru V je ničelni vektor 0 en sam,
- (3) $\alpha \cdot 0 = 0$ za vsak $\alpha \in \mathbb{R}$,
- (4) $0 \cdot v = 0$ za vsak $v \in V$.

Za vektorje $v_1, v_2, \dots, v_n \in V$ in skalarje $\alpha_1, \alpha_2, \dots, \alpha_n \in \mathbb{R}$ imenujemo vektor

$$\alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_n v_n$$

linearna kombinacija vektorjev $v_1, v_2, \dots, v_n$.

Denimo, ničelni vektor $0 = 0 \cdot v_1 + 0 \cdot v_2 + \dots + 0 \cdot v_n$ je linearna kombinacija poljubnih vektorjev $v_1, v_2, \dots, v_n \in V$. Linearno kombinacijo z izključno ničelnimi koeficienti imenujemo *trivialna* linearna kombinacija.

2. VEKTORSKI PODPROSTOR

Če je podmnožica U vektorskega prostora V

(VPP1) zaprta za seštevanje ($u, v \in U \implies u + v \in U$) in

(VPP2) zaprta za množenje vektorjev z realnimi števili ($v \in U, \alpha \in \mathbb{R} \implies \alpha v \in U$),

potem jo imenujemo **vektorski podprostor** prostora V .

Izrek 2. Podmnožica U vektorskega prostora V je vektorski podprostor natanko tedaj, ko je poljubna linearna kombinacija $\alpha u + \beta v$ vektorjev $u, v \in U$ tudi vsebovana v U .

Vsak vektorski podprostor po (VPP2) vsebuje tudi vektor $0 \cdot v = 0$. Zatorej podmnožica vektorskega prostora, ki ne vsebuje ničelnega vektorja, ne more biti vektorski podprostor.

Ker lastnosti (VP1)-(VP7) veljajo za poljubne elemente vektorskega prostora V , veljajo tudi za vse elemente vektorskega podprostora U v V . Poleg tega je vektorski podprostor po definiciji zaprt za seštevanje in množenje s števili. Zatorej je vsak vektorski podprostor hkrati tudi vektorski prostor.

Linearna ogrinjača $\mathcal{L}\{v_1, v_2, \dots, v_n\}$ vektorjev $v_1, v_2, \dots, v_n$ je množica vseh linearnih kombinacij vektorjev $v_1, v_2, \dots, v_n$.

Ker je linearna kombinacija linearnih kombinacij vektorjev $v_1, v_2, \dots, v_n \in V$ zopet linearna kombinacija vektorjev $v_1, v_2, \dots, v_n$, je po Izreku 2 linearna ogrinjača $\mathcal{L}\{v_1, v_2, \dots, v_n\}$ linearni podprostor v V . Pravimo, da vektorji $v_1, v_2, \dots, v_n$ **napenjajo** prostor $\mathcal{L}\{v_1, v_2, \dots, v_n\}$.

Ne le, da je linearna ogrinjača vektorski prostor. Velja celo več.

Izrek 3. Linearna ogrinjača vektorjev $v_1, v_2, \dots, v_n$ vektorskega prostora V je najmanjši vektorski podprostor v V , ki vsebuje vektorje $v_1, v_2, \dots, v_n$.

3. BAZA VEKTORSKEGA PROSTORA

Vektorji $v_1, v_2, \dots, v_n \in V$ so **linearno odvisni**, ko obstaja vektor v_k , ki je linearna kombinacija ostalih $v_1, v_2, \dots, v_{k-1}, v_{k+1}, \dots, v_n$:

$$v_k = \alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_{k-1} v_{k-1} + \alpha_{k+1} v_{k+1} + \dots + \alpha_n v_n,$$

kjer $\alpha_i \in \mathbb{R}$.

Vektorji $v_1, v_2, \dots, v_n \in V$ so **linearno neodvisni**, če niso linearno odvisni. Ekvivalentno, $v_1, v_2, \dots, v_n \in V$ so linearno neodvisni, če je njihova trivialna linearna kombinacija edina njihova linearna kombinacija, ki je enaka ničelnemu vektorju 0 . Z drugimi besedami, $v_1, v_2, \dots, v_n \in V$ so linearno neodvisni, če iz

$$\alpha_1 v_1 + \alpha_2 v_2 + \dots + \alpha_n v_n = 0$$

sledi

$$\alpha_1 = \alpha_2 = \dots = \alpha_n = 0.$$

Če množica vektorjev vsebuje ničelni vektor 0 , potem lahko ničelni vektor izrazimo kot trivialno linearno kombinacijo ostalih vektorjev. Zato je vsaka množica, ki vsebuje ničelni vektor, linearno odvisna.

Naj vektorji $u_1, u_2, \dots, u_m$ napenjajo vektorski prostor $V = \mathcal{L}\{u_1, u_2, \dots, u_m\}$. Če so $u_1, u_2, \dots, u_m$ linearno odvisni, potem obstaja podmnožica $\{v_1, v_2, \dots, v_n\} \subseteq \{u_1, u_2, \dots, u_m\}$, ki prav tako napenja prostor V . Najmanjšo takšno podmnožico bomo imenovali *baza* vektorskega prostora. Dobimo jo tako, da iz množice $\{u_1, u_2, \dots, u_m\}$ izberemo čim manj vektorjev (torej bodo linearno neodvisni), a bodo še vedno napenjali prostor V .

Množica vektorjev $\{v_1, v_2, \dots, v_n\}$ je *baza* vektorskega prostora V , če

(B1) so $v_1, v_2, \dots, v_n$ linearno neodvisni in

(B2) $v_1, v_2, \dots, v_n$ napenjajo prostor V .

Izrek 4. Vsak vektorski prostor ima nešteto baz. Vse baze vektorskega prostora imajo enako število vektorjev.

Dimenzija prostora V je enaka moči (poljubne) baze prostora V . Označimo jo z $\dim V$.

Izrek 5. Za vsako bazo vektorskega prostora V je zapis poljubnega vektorja $v \in V$ kot linearna kombinacija baznih vektorjev vedno enoličen.

4. NADALJNJE BRANJE

- ⚡ (1) David Poole, Linear algebra, a modern introduction, Thomson, 2006, Podpoglavji 6.1 in 6.2.
- ⚡ (2) Tomaž Košir, Linearna algebra, poglavje VI: Vektorski prostori.

5. DOMAČA NALOGA

- ⚡ (1) Rešite kviz na [Učilnici](#).
- ⚡ (2) Drži ali ne drži?
 - (a) Množica vseh zgornje trikotnih $n \times n$ matrik vektorski podprostor v $\mathbb{R}^{n \times n}$.
 - (b) Množica vseh 3×3 matrik z vsemi diagonalnimi elementi enakimi 0 je vektorski podprostor v $\mathbb{R}^{3 \times 3}$.
 - (c) Množica vseh 4×4 matrik, ki imajo vse vrstice enake, je vektorski podprostor v $\mathbb{R}^{4 \times 4}$.
 - (d) Ravnina v $\mathbb{R}^3$, podana z enačbo $x + 2y + 3z = 4$, je vektorski podprostor v $\mathbb{R}^3$.
 - (e) Če so $x, y, z \in \mathbb{R}^3$ linearno odvisni vektorji, potem je linearna ogrinjača $\mathcal{L}\{x, y, z\}$ ravnina v $\mathbb{R}^3$ skozi koordinatno izhodišče.

- (f) Če je $\{v_1, v_2, \dots, v_7\}$ ortogonalna množica v vektorskem prostoru V dimenzije 7 in v_i neničelni vektorji, potem je $v_1, v_2, \dots, v_7$ baza prostora V .
- (g) Vsaka linearno neodvisna množica vektorjev v vektorskem prostoru dimenzije 9 vsebuje vsaj 9 elementov.
- (h) Vsaka baza prostora $\mathbb{R}^{2 \times 4}$ ima največ 4 elemente.
- (i) Če je U linearna ogrinjača vektorjev $v_1, v_2, \dots, v_k$, potem vektorji $v_1, v_2, \dots, v_k$ tvorijo bazo prostora U .
- ⚡ (3) Katere od naslednjih množic realnih $n \times n$ matrik so vektorski podprostorji v $\mathbb{R}^{n \times n}$? Za vsak podprostor določite tudi bazo.
- (a) Matrike, ki imajo prvo vrstico ničelno.
- (b) Matrike, ki imajo vsoto elementov v vsaki vrstici enako 1.
- (c) Vse matrike C , za katere velja $C^2 = I$.
- (d) Vse matrike D , ki so rešitve sistema $D\vec{x} = 0$. Bazo določite le v posebnem primeru, ko je $n = 2$ in $\vec{x} = [1 \ 2]^T$.
- (e) Vse matrike, katerih elementi so nenegativna realna števila.
- (f) Vse matrike F , za katere velja $F = F^T$.
- (g) Vse matrike G , za katere velja $G = -G^T$.
- (h) Vse matrike H , za katere velja $\text{rank } H = n$.
- (i) Vse matrike, katerih vse vrstice so med seboj enake.
- (j) Vse matrike X , katerih produkt z vnaprej dano matriko J je enak ničelni matriki. Bazo določite le v posebnem primeru, ko je $n = 2$ in $\vec{J} = \begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix}$.
- ⚡ (4) Naj bo V vektorski prostor ter $U, W \subseteq V$ vektorska prostora v V . Pokažite, da je tudi $U \cap W$ vektorski prodprostor v V .
- ⚡⚡ (5) Pokažite Izrek 1.
- ⚡ (6) Naj $\mathcal{C}[0, 2\pi]$ označuje vektorski prostor vseh zveznih funkcij na intervalu $[0, 1]$. Pokažite, da so vektorji

$$f(x) = 1, \quad g(x) = \cos(2x), \quad h(x) = \cos^2 x,$$

linearno odvisni v $\mathcal{C}[0, 1]$.

- ⚡⚡ (7) Naj bo $\mathcal{V}$ množica vseh simetričnih matrik oblike

$$\begin{bmatrix} A & S \\ -S & A \end{bmatrix},$$

kjer je $A \in \mathbb{R}^{n \times n}$ simetrična matrika ($A^T = A$), $S \in \mathbb{R}^{n \times n}$ pa poševno simetrična ($S^T = -S$).

- (a) Pokažite so, da je $\mathcal{V}$ vektorski prostor.
- (b) Poiščite bazo prostora $\mathcal{V}$ in določite $\dim \mathcal{V}$.
- (c) Dokažite, da je karakteristični polinom vsake matrike v $\mathcal{V}$ kvadrat.
- ⚡ (8) David Poole, Linear algebra, a modern introduction, Thomson, 2006, stran 446 (Exercises 24-50), strani 460-463 (Exercises 1-58).

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov. Naloga, označena s ⚡⚡ je nekoliko težja.)

Linearne preslikave

Polona Oblak

1. DEFINICIJA

Naj bosta V in U vektorska prostora. Preslikava $\tau: V \rightarrow U$ je *linearna preslikava*, če velja

(LP1) $\tau(v + u) = \tau(v) + \tau(u)$ za vsaka $v, u \in V$ in

(LP2) $\tau(\alpha v) = \alpha\tau(v)$ za vsak $v \in V$ in vsak $\alpha \in \mathbb{R}$.

Izrek 1. Preslikava $\tau: V \rightarrow U$ je linearna natanko tedaj, ko velja

$$(1) \quad \tau(\alpha v + \beta u) = \alpha\tau(v) + \beta\tau(u)$$

za vse $v, u \in V$ ter vse $\alpha, \beta \in \mathbb{R}$.

Trditev 1. Za poljubno linearno preslikavo $\tau: V \rightarrow U$ velja $\tau(0_V) = 0_U$.

2. OPERACIJE Z LINEARNIMI PRESLIKAVAMI

Naj bodo $\tau, \psi: V \rightarrow U$ ter $\theta: U \rightarrow W$ linearne preslikave in naj bo $\gamma \in \mathbb{R}$.

(1) *Vsota* $\tau + \psi: V \rightarrow U$ je preslikava, definirana s predpisom

$$(\tau + \psi)(v) = \tau(v) + \psi(v).$$

(2) *Produkt s skalarjem* $\gamma\tau: V \rightarrow U$ je preslikava, definirana s predpisom

$$(\gamma\tau)(v) = \gamma\tau(v).$$

(3) *Kompozitum* $\theta \circ \tau$ je preslikava $\theta \circ \tau: V \rightarrow W$ definirana s predpisom

$$(\theta \circ \tau)(v) = \theta(\tau(v)).$$

Izrek 2. Vsota, produkt s skalarjem in kompozitum linearnih preslikav so linearne preslikave.

Posledica 1. Množica vseh linearnih preslikav iz vektorskega prostora V v vektorski prostor U je vektorski prostor.

3. MATRIKE LINEARNE PRESLIKAVE

Naj bosta V in U vektorska prostora dimenzij m in n ter $\tau: V \rightarrow U$ linearna preslikava. Izberimo bazi $\mathcal{B} = \{b_1, b_2, \dots, b_m\}$ prostora V in $\mathcal{C} = \{c_1, c_2, \dots, c_n\}$ prostora U .

Denimo, da poznamo slike $\tau(b_1), \tau(b_2), \dots, \tau(b_m)$ vektorjev baze $\mathcal{B}$ preko preslikave τ . Izberimo poljubni vektor $v \in V$ in ga zapišimo kot linearno kombinacijo

$$v = \beta_1 b_1 + \beta_2 b_2 + \dots + \beta_m b_m$$

baznih vektorjev množice $\mathcal{B}$. Ker je τ linearna preslikava, lahko nato sliko $\tau(v)$ vektorja izračunamo kot

$$\tau(v) = \tau(\beta_1 b_1 + \beta_2 b_2 + \dots + \beta_m b_m) = \beta_1 \tau(b_1) + \beta_2 \tau(b_2) + \dots + \beta_m \tau(b_m).$$

Tako smo ugotovili, da lahko s pomočjo slik baznih vektorjev izračunamo sliko poljubnega vektorja $v \in V$.

Sedaj pa razvijmo slike vektorjev baze $\mathcal{B}$, ki se nahajajo v vektorskem prostoru U , po bazi $\mathcal{C}$. Torej, za $j = 1, \dots, m$, vsako sliko $\tau(b_j)$ zapišimo kot linearno kombinacijo vektorjev množice $\mathcal{C} = \{c_1, c_2, \dots, c_n\}$:

$$\tau(b_j) = \alpha_{1j} c_1 + \alpha_{2j} c_2 + \dots + \alpha_{nj} c_n.$$

S tem smo dobili $m \cdot n$ enolično določenih koeficientov α_{ij} , $i = 1, 2, \dots, n$, $j = 1, \dots, m$. Naj bo $A_{\tau, \mathcal{B}, \mathcal{C}} = [\alpha_{ij}]$ matrika reda $n \times m$ sestavljena iz koeficientov v razvoju slik baznih vektorjev $\mathcal{B}$ po bazi $\mathcal{C}$.

Tako definirano matriko

$$A_{\tau, \mathcal{B}, \mathcal{C}} = \begin{bmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2m} \\ \vdots & \vdots & & \vdots \\ \alpha_{n1} & \alpha_{n2} & \dots & \alpha_{nm} \end{bmatrix}$$

imenujemo *matrika linearne preslikave τ iz baze $\mathcal{B}$ v bazo $\mathcal{C}$* .

V njej j -ti stolpec predstavlja koeficiente, s katerimi se slika j -tega vektorja baze $\mathcal{B}$ izraža kot linearna kombinacija vektorjev baze $\mathcal{C}$.

Matrika $A_{\tau, \mathcal{B}, \mathcal{C}}$ nam torej preslika koeficiente v razvoju vektorja po bazi $\mathcal{B}$ v koeficiente, če sliko vektorja razvijemo po bazi $\mathcal{C}$. Povedano formalno, če je $v = \sum_{j=1}^m \beta_j b_j$ in $\tau(v) = \sum_{i=1}^n \gamma_i c_i$, potem lahko koeficiente γ_j dobimo tudi z matričnim množenjem

$$(2) \quad \begin{bmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_n \end{bmatrix} = \begin{bmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2m} \\ \vdots & \vdots & & \vdots \\ \alpha_{n1} & \alpha_{n2} & \dots & \alpha_{nm} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \end{bmatrix}.$$

Posebej opozorimo, da je matrika $A_{\tau, \mathcal{B}, \mathcal{C}}$ odvisna od izbire baz $\mathcal{B}$ in $\mathcal{C}$ vektorskih prostorov V in U . Če bi si izbrali drugačni bazi (ali vsaj eno od

njiu), potem bi isti preslikavi priredili drugo matriko (ki ustreza koeficientom v razvoju po drugih bazah).

Dogovorimo se, da če bomo iskali matriko preslikave $\tau: V \rightarrow V$ iz baze $\mathcal{B}$ v bazo $\mathcal{B}$, bomo pri tem opustili enega od indeksov, t.j. $A_{\tau, \mathcal{B}} = A_{\tau, \mathcal{B}, \mathcal{B}}$.

Izrek 3. Naj bodo $\tau, \psi: V \rightarrow U$ ter $\theta: U \rightarrow W$ linearne preslikave in naj bo $\alpha \in \mathbb{R}$.

- (1) Matrika, ki ustreza vsoti preslikav $\tau + \psi$, je enaka vsoti matrik posameznih preslikav.

$$A_{\tau+\psi, \mathcal{B}, \mathcal{C}} = A_{\tau, \mathcal{B}, \mathcal{C}} + A_{\psi, \mathcal{B}, \mathcal{C}}$$

- (2) Matrika, ki ustreza produktu s skalarjem $\alpha\tau$, je enaka večkratniku matrike preslikave.

$$A_{\alpha\tau, \mathcal{B}, \mathcal{C}} = \alpha A_{\tau, \mathcal{B}, \mathcal{C}}$$

- (3) Matrika, ki ustreza kompozitumu preslikav, je enaka produktu matrik posameznih preslikav.

$$A_{\theta \circ \tau, \mathcal{B}, \mathcal{D}} = A_{\psi, \mathcal{C}, \mathcal{D}} \cdot A_{\theta, \mathcal{B}, \mathcal{C}}$$

- (4) Matrika, ki ustreza inverzu obrnljive preslikave, je enaka inverzu matrike te preslikave. Torej, če je ψ obrnljiva preslikava, je obrnljiva tudi matrika $A_{\psi, \mathcal{B}, \mathcal{C}}$. Velja

$$A_{\psi^{-1}, \mathcal{C}, \mathcal{B}} = (A_{\psi, \mathcal{B}, \mathcal{C}})^{-1}.$$

Denimo, da poznamo matriko $A = A_{\tau, \mathcal{B}, \mathcal{C}}$ linearne preslikave $\tau: V \rightarrow U$ iz baze $\mathcal{B}$ v $\mathcal{C}$. Radi bi zapisali matriko $A' = A_{\tau, \mathcal{B}', \mathcal{C}'}$ iste linearne preslikave τ , a iz neke (morda) druge baze $\mathcal{B}'$ v (morda) drugo bazo $\mathcal{C}'$.

Če si ogledamo spodnji diagram matrik, ki ustrežajo preslikavam, potem poznamo "zeleno" matriko $A = A_{\tau, \mathcal{B}, \mathcal{C}}$, želimo pa izračunati "rdečo" matriko $A' = A_{\tau, \mathcal{B}', \mathcal{C}'}$ linearne preslikave τ .

$$\begin{array}{ccc}
 (V, \mathcal{B}) & \xrightarrow{\text{A}} & (U, \mathcal{C}) \\
 \begin{array}{c} \uparrow \\ P^{-1} \\ \downarrow \end{array} & & \begin{array}{c} \downarrow \\ Q \\ \downarrow \end{array} \\
 (V, \mathcal{B}') & \xrightarrow{\text{A}' = QAP^{-1}} & (U, \mathcal{C}')
 \end{array}$$

Pri tem matrika $P = \mathcal{I}_{V, \mathcal{B}, \mathcal{B}'}$ ustreza identični preslikavi prostora V vase iz baze $\mathcal{B}$ v bazo $\mathcal{B}'$. Takšno matriko dobimo s koeficienti pri razvoju vektorjev baze $\mathcal{B}$ po vektorjih baze $\mathcal{B}'$. Podobno je $Q = \mathcal{I}_{U, \mathcal{C}, \mathcal{C}'}$ ustreza identični preslikavi prostora U vase iz baze $\mathcal{C}$ v bazo $\mathcal{C}'$ in je sestavljena iz koeficientov pri razvoju vektorjev baze $\mathcal{C}$ po vektorjih baze $\mathcal{C}'$. Če se v diagramu

sprehodimo po puščicah, vidimo, da bomo morali matriko A' sestaviti kot kompozitum preslikav. Zatorej je A' enak produktu pripadajočih matrik, t.j.

$$A' = QAP^{-1}.$$

4. LASTNE VREDNOSTI LINEARNE PRESLIKAVE

Neničelnemu vektorju $v \in V$ pravimo *lastni vektor* linearne preslikave $\tau: V \rightarrow V$, če velja

$$\tau(v) = \lambda v.$$

Številu λ pravimo *lastna vrednost* linearne preslikave τ .

Izrek 4. Vsaka lastna vrednost linearne preslikave τ je tudi lastna vrednost poljubne matrike A_τ , ki pripada preslikavi τ . Vse matrike, ki pripadajo dani linearni preslikavi τ imajo enake lastne vrednosti.

Pravimo, da je linearno preslikavo $\tau: V \rightarrow V$ mogoče *diagonalizirati*, če obstaja baza, v kateri pripada preslikavi τ diagonalna matrika.

Izrek 5. Linearno preslikavo $\tau: V \rightarrow V$ je mogoče diagonalizirati natanko tedaj, ko obstaja baza prostora V sestavljena iz lastnih vektorjev preslikave τ .

5. JEDRO IN SLIKA LINEARNE PRESLIKAVE

Naj bo $\tau: V \rightarrow U$ linearna preslikava vektorskega prostora V v vektorski prostor U .

Definicija 1. Jedro linearne preslikave τ je množica $\ker(\tau)$ vseh vektorjev $v \in V$, za katere velja

$$\tau(v) = 0.$$

Definicija 2. Slika linearne preslikave je množica $\operatorname{im}(\tau) = \{\tau(v) : v \in V\} \subseteq U$.

Izrek 6. Jedro $\ker \tau$ linearne preslikave $\tau: V \rightarrow U$ je vektorski podprostor v V , slika $\operatorname{im} \tau$ pa vektorski podprostor v U .

Izrek 7. Naj bo $\tau: V \rightarrow U$ linearna preslikava iz vektorskega prostora V v vektorski prostor U .

- (1) τ je injektivna natanko tedaj, ko je $\ker \tau = \{0\}$.
- (2) τ je surjektivna natanko tedaj, ko je $\operatorname{im} \tau = U$.

Naj bo A_τ matrika, ki pripada linearni preslikavi $\tau: V \rightarrow U$ iz baze $\mathcal{B}$ v bazo $\mathcal{C}$. Po definiciji je jedro linearne preslikave τ množica vseh vektorjev v , za katere velja $\tau(v) = 0$. Če razvijemo vektor v po bazi $\mathcal{B}$, so koeficienti v razvoju določeni s stolpcem $x = [\beta_1, \beta_2, \dots, \beta_m]^T$. Spomnimo se enakosti (2). Ker ima slika $\tau(v) = 0$ v razvoju po bazi $\mathcal{C}$ vse koeficiente enake 0, velja $A_\tau x = 0$. (Z drugimi besedami, vektorji koeficientov v razvoju vektorjev iz $\ker \tau$ po bazi $\mathcal{B}$ ustrezajo natanko ničelnemu prostoru matrike A_τ .)

Podobno si pomagamo z enakostjo (2), da bi določili $\text{im } \tau$. Po definiciji je $\text{im } \tau$ množica vseh slik linearne preslikave, torej množica vseh linearnih kombinacij slik vektorjev iz baze $\mathcal{B}$. Z drugimi besedami,

$$\begin{bmatrix} \gamma_1 \\ \gamma_2 \\ \vdots \\ \gamma_n \end{bmatrix} = \begin{bmatrix} \alpha_{11} & \alpha_{12} & \dots & \alpha_{1m} \\ \alpha_{21} & \alpha_{22} & \dots & \alpha_{2m} \\ \vdots & \vdots & & \vdots \\ \alpha_{n1} & \alpha_{n2} & \dots & \alpha_{nm} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_m \end{bmatrix} = A^{(1)}\beta_1 + A^{(2)}\beta_2 + \dots + A^{(m)}\beta_m,$$

kjer z A^j označimo j -ti stolpec matrike $A_\tau = [\alpha_{ij}]$. Torej so vektorji koeficientov $[\gamma_1, \gamma_2, \dots, \gamma_n]^T$ natanko vse linearne kombinacije stolpcev matrike A_τ . Sledi, da linearna ogrinjača stolpcev natanko določa koeficiente vektorjev v $\text{im } \tau$ pri razvoju po bazi $\mathcal{C}$. (Z drugimi besedami, koeficienti pri razvoju vektorjev iz $\text{im } \tau$ po bazi $\mathcal{C}$ ustrezajo stolpčnemu prostoru matrike A_τ .)

Izrek 8. Naj bo $\tau: V \rightarrow U$ linearna preslikava in naj bo $A = A_{\tau, \mathcal{B}, \mathcal{C}}$ matrika, ki pripada preslikavi τ . Potem je

- (1) $\dim(\text{im}(\tau)) = \text{rank}(A)$,
- (2) $\dim(\ker(\tau)) + \dim(\text{im}(\tau)) = \dim(V)$.

Posledica 2. Naj bo $\tau: V \rightarrow U$ linearna preslikava, $\dim V = \dim U = n$ in naj bo A neka matrika, ki pripada τ . Naslednje trditve so ekvivalentne:

- (1) τ je bijektivna.
- (2) τ je injektivna.
- (3) τ je surjektivna.
- (4) A je obrnljiva.
- (5) $\ker \tau = \{0\}$.
- (6) $N(A) = \{0\}$.
- (7) $\text{im } \tau = U$.
- (8) $C(A) = \mathbb{R}^n$.
- (9) Rang matrike A je n .
- (10) Vrstice matrike A so linearno neodvisne.
- (11) Vrstice matrike A razpenjajo $\mathbb{R}^n$.
- (12) Vrstice matrike A tvorijo bazo $\mathbb{R}^n$.
- (13) Stolpci matrike A so linearno neodvisni.
- (14) Stolpci matrike A razpenjajo $\mathbb{R}^n$.
- (15) Stolpci matrike A tvorijo bazo $\mathbb{R}^n$.

- (16) $\det A \neq 0$.
 (17) *Homogeni sistem enačb $Ax = 0$ ima le trivialno rešitev.*
 (18) *Sistem enačb $Ax = b$ ima rešitev za vsak $b \in \mathbb{R}^n$.*

6. NADALJNJE BRANJE

- (1) David Poole, Linear algebra, a modern introduction, Thomson, 2006, Razdelki 6.4.-6.7.
 (2) Tomaž Košir, Linearna algebra, poglavje VII: Linearne preslikave.

7. DOMAČA NALOGA

- ⚡ (1) Rešite kviz na Učilnici.
 ⚡ (2) Dokažite izreka 2 and 7 ter posledico 2.
 ⚡ (3) Naj bosta $u, v \in V$ linearno neodvisna lastna vektorja linearne preslikave $\tau: V \rightarrow V$. Če je $u + v$ tudi lastni vektor za τ , potem pokažite, da u in v pripadata isti lastni vrednosti.
 ⚡ (4) Dokažite, da nobena linearna preslikava $\tau: \mathbb{R}^{2 \times 3} \rightarrow \mathbb{R}_4[x]$ ni injektivna.
 ⚡ (5) Definirajmo preslikavo $\tau: \mathbb{R}^{3 \times 3} \rightarrow \mathbb{R}$ s predpisom $\tau(A) = \text{tr}(A)$.
 (a.) Pokažite, da je τ linearna.
 (b.) Zapišite matriko, ki pripada τ v standardnih bazah $\mathbb{R}^{3 \times 3}$ in $\mathbb{R}$.
 (c.) Določite $\ker \tau$ in $\text{im } \tau$.
 ⚡ (6) Definirajmo preslikavo $\tau: \mathbb{R}_1[x] \rightarrow \mathbb{R}_2[x]$ s predpisom $\tau(p(x)) = x^2 p'(x)$.
 (a) Pokažite, da je τ linearna.
 (b) Zapišite matriko, ki ustreza preslikavi τ v standardnih bazah $\mathbb{R}_1[x]$ in $\mathbb{R}_2[x]$.
 (c) Določite $\ker \tau$ in $\text{im } \tau$.
 ⚡ (7) Aleksandra Franc, Rešene naloge iz linearne algebre, naloge poglavja 5.
 ⚡ (8) David Poole, Linear algebra, a modern introduction, Thomson, 2006,
 (a) strani 484-485, naloge 1-36,
 (b) strani 499-500, naloge 1-20,
 (c) strani 516-518, naloge 1-44,
 (d) strani 536-537, review questions 1-20.

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov.)

Izometrije

Polona Oblak

1. (N)ELINEARNE IZOMETRIJE

Izometrija je (morda nelinearna) preslikava $\mathcal{A}: \mathbb{R}^n \rightarrow \mathbb{R}^n$, za katero velja

$$\|x - y\| = \|\mathcal{A}(x) - \mathcal{A}(y)\|,$$

za vse $x, y \in \mathbb{R}^n$. To pomeni, da izometrije ohranjajo razdalje.

Izrek 1. Za linearno preslikavo $\tau: \mathbb{R}^n \rightarrow \mathbb{R}^n$ so naslednje trditve ekvivalentne:

- (1) τ je izometrija.
- (2) $\|x\| = \|\tau(x)\|$ za vse $x \in \mathbb{R}^n$.
- (3) $x^\top y = \tau(x)^\top \tau(y)$ za vse $x, y \in \mathbb{R}^n$.
- (4) Matrika, ki pripada τ , je ortogonalna.

Linearno izometrijo imenujemo *ortogonalna preslikava*.

Izrek 2. Izometrijo $\mathcal{A}: \mathbb{R}^n \rightarrow \mathbb{R}^n$ lahko enolično zapišemo kot

$$\mathcal{A}v = Qv + a,$$

kjer je $Q \in \mathbb{R}^{n \times n}$ ortogonalna matrika in $a \in \mathbb{R}^n$.

2. ORTOGONALNE PRESLIKAVE = LINEARNE IZOMETRIJE

Izrek 3. Vsaka ortogonalna preslikava $\tau: \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je ena od naslednjih:

- (1) Zrcaljenje čez premico $y = kx$, kjer $k = \tan \frac{\varphi}{2}$ in

$$Z_\varphi = \begin{pmatrix} \cos \varphi & \sin \varphi \\ \sin \varphi & -\cos \varphi \end{pmatrix}$$

je matrika, ki pripada τ v standardni bazi $\mathbb{R}^2$.

Lastni vrednosti zrcaljenja sta 1 in -1 , pripadajoča lastna vektorja sta v smeri premice, čez katero zrcalimo (pri lastni vrednosti 1), ter v smeri vektorja, pravokotnega na premico (pri lastni vrednosti -1).

- (2) Rotacija za kot φ okoli koordinatnega izhodišča v pozitivni smeri in

$$R_\varphi = \begin{pmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{pmatrix}$$

je matrika, ki pripada τ v standardni bazi $\mathbb{R}^2$.

Lastni vrednosti rotacije sta $\cos \varphi + i \sin \varphi$ in $\cos \varphi - i \sin \varphi$, pripadajoča lastna vektorja pa imata kompleksne vrednosti (razen v primeru, ko je $\varphi = k\pi$ za $k \in \mathbb{Z}$).

Izrek 4. Vsaka ortogonalna preslikava $\tau: \mathbb{R}^3 \rightarrow \mathbb{R}^3$ je ena od naslednjih:

- (1) Zrcaljenje čez ravnino Σ skozi koordinatno izhodišče $(0, 0, 0)$. V tem primeru ima τ dvojno lastno vrednost 1 in enojno lastno vrednost -1 . Pri tem je ravnina zrcaljenja $\Sigma = \mathcal{L}\{a, b\}$ napeta na lastni vektorja a in b pri lastni vrednosti 1. Matrika, ki pripada τ v bazi $\{a, b, n\}$, je enaka

$$A_\tau = \left[\begin{array}{cc|c} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & -1 \end{array} \right],$$

kjer je n normala na ravnino Σ .

- (2) Rotacija okoli premice p skozi koordinatno izhodišče $(0, 0, 0)$ za kot φ . Pri tem ima τ lastne vrednosti 1, $\cos \varphi + i \sin \varphi$ in $\cos \varphi - i \sin \varphi$ in je os rotacije p napeta na lastni vektor a pri lastni vrednosti 1. Matrika, ki pripada τ , je tako v bazi $\{a, b, c\}$ enaka

$$A_\tau = \left[\begin{array}{c|cc} 1 & 0 & 0 \\ 0 & \cos \varphi & -\sin \varphi \\ 0 & \sin \varphi & \cos \varphi \end{array} \right],$$

kjer sta vektorja b in c pravokotna na a .

- (3) Zrcalni zasuk, kjer je os rotacije p pravokotna na ravnino zrcaljenja Σ . Pri tem ima τ lastne vrednosti -1 , $\cos \varphi + i \sin \varphi$ in $\cos \varphi - i \sin \varphi$ in je os rotacije $p = \mathcal{L}\{n\}$ napeta na lastni vektor n pri lastni vrednosti -1 , kjer je n normala na Σ . Tako je matrika, ki pripada τ , v bazi $\{n, a, b\}$ enaka

$$A_\tau = \left[\begin{array}{c|cc} -1 & 0 & 0 \\ 0 & \cos \varphi & -\sin \varphi \\ 0 & \sin \varphi & \cos \varphi \end{array} \right],$$

kjer je $\Sigma = \mathcal{L}\{a, b\}$.

3. NADALJNJE BRANJE

- ⚡ (1) Joseph B. Kadane, [Principles of Uncertainty](#), strani 198-201.
- ★ (2) Tomaž Košir, [Linearna algebra](#), Razdelek 5.
- ★ (3) (še bolj geometrijski pogled) Walter Meyer, *Geometry and Its Applications*, 2006, Poglavje 4.

4. DOMAČA NALOGA

- ⚡ (1) Rešite kviz na [Učilnici](#).
- ⚡ (2) Zapišite primer izometrije $\mathcal{A}: \mathbb{R}^3 \rightarrow \mathbb{R}^3$, ki ni identiteta, vendar pa je $\mathcal{A}^3$ identična preslikava.
- ⚡ (3) Dokažite, da je vsaka rotacija v $\mathbb{R}^2$ kompozitum dveh zrcaljenj.

- ★ (4) Dokažite, da je vsaka rotacija v $\mathbb{R}^n$ kompozitum dveh zrcaljenj.
- ⚡ (5) David Poole, Linear algebra, a modern introduction, Thomson, 2006, strani 374-375, exercises 29-32, 34.

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov, naloga označena s ⚡⚡ pa je nekoliko težja. Naloga, označena s ★ je težja, širi vaše znanje in dopolnjuje odpredavano snov.)

Funkcije in vektorske funkcije več spremenljivk, ponovitev

Polona Oblak

1. FUNKCIJE VEČ SPREMENLJIVK

1.1. Definicija. *Funkcija več spremenljivk*

$$f: \mathcal{D}_f \subseteq \mathbb{R}^n \rightarrow \mathbb{R},$$

$$\mathbf{x} = (x_1, x_2, \dots, x_n) \mapsto f(x_1, x_2, \dots, x_n)$$

je funkcija, ki predpiše realno vrednost $f(\mathbf{x}) = f(x_1, x_2, \dots, x_n) \in \mathbb{R}$ vsaki točki $\mathbf{x} = (x_1, x_2, \dots, x_n) \in \mathcal{D}_f \subseteq \mathbb{R}^n$. Množici $\mathcal{D}_f$ pravimo *definijsko območje* funkcije f .

V primeru, ko je $n = 2$, je graf funkcije $f = f(x, y): \mathcal{D}_f \subseteq \mathbb{R}^2 \rightarrow \mathbb{R}$ ploskev

$$\Gamma_f = \{(x, y, f(x, y)): (x, y) \in \mathcal{D}_f\}$$

v $\mathbb{R}^3$. *Nivojska krivulja* (ali *nivojnica*) funkcije $f = f(x, y)$ je množica vseh točk $(x, y) \in \mathcal{D}_f$, za katere velja $f(x, y) = c$ za dano realno število $c \in \mathbb{R}$. Tako vsaka točka $(x, y) \in \mathcal{D}_f$ leži na natanko eni nivojski krivulji in zato se definijsko območje $\mathcal{D}_f$ razsloji na nivojske krivulje.

1.2. **Odводи.** *Parcialni odvod* funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$ v točki $\mathbf{a} = (a_1, a_2, \dots, a_n)$ *po spremenljivki x_i* definiramo kot

$$f_{x_i}(\mathbf{a}) = \frac{\partial f}{\partial x_i}(\mathbf{a}) = \lim_{h \rightarrow 0} \frac{f(a_1, \dots, a_{i-1}, a_i + h, a_{i+1}, \dots, a_n) - f(\mathbf{a})}{h}.$$

Tako nam torej parcialni odvod funkcije f po x_i v točki $\mathbf{a} = (a_1, a_2, \dots, a_n)$ pove relativno spremembo funkcijske vrednosti pri zelo majhni spremembi spremenljivke x_i , kjer so ostale spremenljivke fiksne.

Vektor

$$(\text{grad } f)(\mathbf{a}) = (f_{x_1}(\mathbf{a}), f_{x_2}(\mathbf{a}), \dots, f_{x_n}(\mathbf{a}))$$

imenujemo *gradient* funkcije f v točki $\mathbf{a}$.

Smerni odvod funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$ v točki $\mathbf{a} = (a_1, a_2, \dots, a_n)$ *v smeri vektorja $\vec{e}$* je enak

$$f_{\vec{e}}(\mathbf{a}) = (\text{grad } f)(\mathbf{a}) \cdot \frac{\vec{e}}{\|\vec{e}\|} = \sum_{i=1}^n f_{x_i}(\mathbf{a}) \frac{e_i}{\|\vec{e}\|}.$$

Za funkcijo $f: \mathbb{R}^n \rightarrow \mathbb{R}$ velja:

- (1) Gradient funkcije f v točki $\mathbf{a}$ kaže v smeri najhitrejšega naraščanja funkcije f v točki $\mathbf{a}$.
- (2) V primeru $n = 2$ je gradient funkcije $f = f(x, y)$ v točki $\mathbf{a}$ pravokoten na nivojsko krivuljo v tej točki.

(3) Smerni odvod $f_{\vec{e}}(\mathbf{a})$ je relativna sprememba funkcijske vrednosti $f(\mathbf{a})$ ob majhnem premiku iz točke $\mathbf{a}$ v smeri vektorja $\vec{e}$. Zato velja:

- Če je $f_{\vec{e}}(\mathbf{a}) > 0$, potem f ob majhnem pomiku iz točke $\mathbf{a}$ v smeri vektorja $\vec{e}$ narašča.
- Če je $f_{\vec{e}}(\mathbf{a}) < 0$, potem f ob majhnem pomiku iz točke $\mathbf{a}$ v smeri vektorja $\vec{e}$ pada.

1.3. Linearna aproksimacija. Vrednost funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$ lahko v točki blizu $\mathbf{a}$ ocenimo z vrednostjo $f(\mathbf{a})$. Najprej si nazorno oglejmo, kako to naredimo za funkcijo dveh spremenljivk. Denimo, da želimo približno oceniti vrednost funkcije $f: \mathbb{R}^2 \rightarrow \mathbb{R}$ v točki blizu točke (a, b) . Točke, ki so "blizu" točki (a, b) so oblike $(a + h, b + k)$, kjer sta h in k dovolj majhni realni števili. Tangentna ravnina $\Sigma_{(a,b)}$ na graf $z = f(x, y)$ v točki $(a, b, f(a, b))$ vsebuje vektorja $[1, 0, f_x(a, b)]^T$ ter $[0, 1, f_y(a, b)]^T$. Normala na ravnino $\Sigma_{(a,b)}$ je tako enaka

$$\begin{bmatrix} 1 \\ 0 \\ f_x(a, b) \end{bmatrix} \times \begin{bmatrix} 0 \\ 1 \\ f_y(a, b) \end{bmatrix} = \begin{bmatrix} -f_x(a, b) \\ -f_y(a, b) \\ 1 \end{bmatrix},$$

ker pa ravnina vsebuje tudi točko $(a, b, f(a, b))$, je enačba tangentne ravnine enaka

$$-f_x(a, b)x - f_y(a, b)y + z = -f_x(a, b)a - f_y(a, b)b + f(a, b).$$

Če izrazimo tretjo koordinato z točke (x, y, z) na tangentni ravnini $\Sigma_{(a,b)}$, dobimo enačbo tangentne ravnine

$$z = f(a, b) + (x - a)f_x(a, b) + (y - b)f_y(a, b).$$

Če torej želimo izračunati približno funkcijsko vrednost $f(a + h, b + k)$, jo lahko ocenimo z višino točke $(a + h, b + k, z)$ na tangentni ravnini $\Sigma_{(a,b)}$. Torej je

$$f(a + h, b + k) \cong f(a, b) + f_x(a, b)h + f_y(a, b)k.$$

Pri tem bi lahko zadnja sumanda zapisali tudi kot skalarni produkt gradienta funkcije f v točki (a, b) in vektorja pomika (h, k) iz točke (a, b) . Tako lahko linearno aproksimacijo funkcije dveh spremenljivk posplošimo na funkcije več spremenljivk. Za dano funkcijo $f: \mathbb{R}^n \rightarrow \mathbb{R}$ lahko v točki $\mathbf{a} + \mathbf{h}$ blizu $\mathbf{a}$ njeno funkcijsko vrednost ocenimo s formulo

$$f(\mathbf{a} + \mathbf{h}) \cong f(\mathbf{a}) + (\text{grad } f)(\mathbf{a}) \cdot \mathbf{h}.$$

1.4. Višji odvodi. Parcialne odvode drugega reda izračunamo s parcialnim odvajanjem parcialnih odvodov prvega reda. Definiramo jih kot

$$f_{x_i x_j}(\mathbf{x}) = \frac{\partial^2 f}{\partial x_j \partial x_i}(\mathbf{x}) = \frac{\partial}{\partial x_j} \left(\frac{\partial f}{\partial x_i}(\mathbf{x}) \right).$$

$n \times n$ matriko

$$H_f(\mathbf{x}) = \left[\frac{\partial^2 f}{\partial x_j \partial x_i}(\mathbf{x}) \right]_{i,j=1,\dots,n}$$

imenujemo *Hessejeva matrika* funkcije f v točki $\mathbf{x}$. Če sta pri tem $f_{x_i x_j}$ in $f_{x_j x_i}$ zvezni funkciji, potem sta omenjena druga parcialna odvoda enaka. Zato je v primeru, ko so vsi parcialni odvodi $f_{x_i x_j}$ zvezni, Hessejeva matrika $H_f(x, y)$ matrika.

Če druge parcialne odvode še naprej odvajamo, dobimo parcialne odvode višjih redov. Če so zvezni, so neodvisni od vrstnega reda odvajanja. V tem primeru za funkcijo f dveh spremenljivk dobimo štiri različne parcialne odvode tretjega reda: $\frac{\partial^3 f}{\partial x^3}(a, b)$, $\frac{\partial^3 f}{\partial y \partial x^2}(a, b) = \frac{\partial^3 f}{\partial x \partial y \partial x}(a, b) = \frac{\partial^3 f}{\partial x^2 \partial y}(a, b)$, $\frac{\partial^3 f}{\partial y^2 \partial x}(a, b) = \frac{\partial^3 f}{\partial y \partial x \partial y}(a, b) = \frac{\partial^3 f}{\partial x \partial y^2}(a, b)$ in $\frac{\partial^3 f}{\partial y^3}(a, b)$.

2. VEKTORSKE FUNKCIJE VEČ SPREMENLJIVK

2.1. Definicija. Vektorska funkcija

$$\begin{aligned} F: \mathcal{D}_F \subseteq \mathbb{R}^n &\rightarrow \mathbb{R}^m, \\ \mathbf{x} &\mapsto [f_1(\mathbf{x}) \ f_2(\mathbf{x}) \ \dots \ f_m(\mathbf{x})]^\top \end{aligned}$$

je m -terica funkcij več spremenljivk.

2.2. Odvodi. *Jacobijeva matrika* vektorske funkcije $F: \mathcal{D}_F \subseteq \mathbb{R}^n \rightarrow \mathbb{R}^m$ je $m \times n$ matrika prvih odvodov funkcij $f_1, \dots, f_m$:

$$J_F(\mathbf{x}) = \begin{bmatrix} \frac{\partial f_1}{\partial x_1}(\mathbf{x}) & \frac{\partial f_1}{\partial x_2}(\mathbf{x}) & \dots & \frac{\partial f_1}{\partial x_n}(\mathbf{x}) \\ \frac{\partial f_2}{\partial x_1}(\mathbf{x}) & \frac{\partial f_2}{\partial x_2}(\mathbf{x}) & \dots & \frac{\partial f_2}{\partial x_n}(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1}(\mathbf{x}) & \frac{\partial f_m}{\partial x_2}(\mathbf{x}) & \dots & \frac{\partial f_m}{\partial x_n}(\mathbf{x}) \end{bmatrix}.$$

Absolutna vrednost determinante Jacobijeve matrike vektorske funkcije $F: \mathcal{D}_F \subseteq \mathbb{R}^n \rightarrow \mathbb{R}^n$ pove, za kakšen faktor funkcija lokalno raztegne prostornine.

3. NADALJNJE BRANJE IN GLEDANJE

- (1) James Stewart, Calculus, early transcendentals, 2016, Poglavja 14.1-14.6.
- (2) Khan Academy: [Unit: Derivatives of multivariable functions](#).

4. DOMAČA NALOGE

- (1) Rešite kviz na [Učilnici](#).
- (2) James Stewart, Calculus, early transcendentals, 2016, stran 945, exercise 5-6, 13-29, 35-48, stran 1020, exercise 1-6.

Večkratni integrali

Polona Oblak

1. DVOJNI INTEGRALNA PRAVOKOTNIKU

Formalno definiramo dvojni integral

$$\iint_R f(x, y) \, dx dy,$$

funkcije $f: R \rightarrow \mathbb{R}$ na pravokotniku $R = [a, b] \times [c, d]$ na naslednji način. Najprej razdelimo pravokotnik R na mn manjših pravokotničkov R_{ij} s stranicama dolžin $\Delta x = \frac{b-a}{n}$ ter $\Delta y = \frac{d-c}{m}$. V vsakem pravokotničku R_{ij} izberemo poljubno točko (x_{ij}^*, y_{ij}^*) . Prostornina telesa pod grafom $z = f(x, y)$ nad pravokotnikom R_{ij} je tako približno enaka

$$f(x_{ij}^*, y_{ij}^*) \Delta x \Delta y.$$

Dvojni integral funkcije f na pravokotniku $R = [a, b] \times [c, d]$ tako definiramo kot

$$\iint_R f(x, y) \, dx dy = \lim_{m, n \rightarrow \infty} \sum_{j=1}^m \sum_{i=1}^n f(x_{ij}^*, y_{ij}^*) \Delta x \Delta y,$$

če ta limita obstaja.

Izkaže se, da je integral $\iint_R f(x, y) \, dx dy$ neodvisen od izbire točke $(x_{ij}^*, y_{ij}^*) \in R_{ij}$. Če je f nenegativna funkcija, je $\iint_R f(x, y) \, dx dy$ enak prostornini telesa, ki je omejen s pravokotnikom R ter grafom $z = f(x, y)$.

Izrek 1 (Fubini). Če je $f: R \rightarrow \mathbb{R}$ zvezna funkcija na pravokotniku $R = [a, b] \times [c, d] \subseteq \mathbb{R}^2$, potem

$$\iint_R f(x, y) \, dx dy = \int_c^d \left(\int_a^b f(x, y) \, dx \right) dy = \int_a^b \left(\int_c^d f(x, y) \, dy \right) dx.$$

2. DVOJNI INTEGRAL

Če je $D \subseteq \mathbb{R}^2$ neko omejeno območje ter $f: D \rightarrow \mathbb{R}$ zvezna funkcija, izberimo tak pravokotnik R , da velja $D \subseteq R$. Sedaj definiramo *dvojni integral funkcije f na območju D* kot

$$\iint_D f(x, y) \, dx dy = \iint_R f(x, y) \, dx dy,$$

kjer

$$F(x, y) = \begin{cases} f(x, y), & (x, y) \in D \\ 0, & (x, y) \notin D. \end{cases}$$

Sedaj lahko zapišimo tudi Fubinijev izrek za nepravokotna območja.

Izrek 2 (Fubini). (1) Če je $D = \{(x, y); a \leq x \leq b \text{ in } \varphi_1(x) \leq y \leq \varphi_2(x)\} \subseteq \mathbb{R}^2$ in $f: D \rightarrow \mathbb{R}$ zvezna funkcija, potem je

$$\iint_D f(x, y) dx dy = \int_a^b \left(\int_{\varphi_1(x)}^{\varphi_2(x)} f(x, y) dy \right) dx.$$

(2) Če je $D = \{(x, y); \vartheta_1(y) \leq x \leq \vartheta_2(y) \text{ in } c \leq y \leq d\} \subseteq \mathbb{R}^2$ in $f: D \rightarrow \mathbb{R}$ zvezna funkcija, potem je

$$\iint_D f(x, y) dx dy = \int_c^d \left(\int_{\vartheta_1(y)}^{\vartheta_2(y)} f(x, y) dx \right) dy.$$

3. TROJNI INTEGRAL...

... je definiran na podoben način. Po Fubinijevem izreku lahko tudi trojne integrale na nekaterih območjih zapišemo kot trikratne integrale.

4. MENJAVA SPREMENLJIVK

Spomnimo se izreka prejšnjega tedna:

Izrek 3. Naj bo $f: D \rightarrow \mathbb{R}$ zvezna funkcija na $D \subseteq \mathbb{R}^2$. Če je $x = \varphi(u, v)$, $y = \vartheta(u, v)$, takšna menjava spremenljivk, da je $\det J_{\varphi, \vartheta} \neq 0$, potem

$$\iint_D f(x, y) dx dy = \int f(\varphi(u, v), \vartheta(u, v)) |\det J_{\varphi, \vartheta}| du dv.$$

Podobno, če je $f: D \rightarrow \mathbb{R}$ zvezna funkcija na $D \subseteq \mathbb{R}^3$ ter $x = \varphi(u, v, w)$, $y = \vartheta(u, v, w)$, $z = \psi(u, v, w)$ takšna menjava spremenljivk, da je $\det J_{\varphi, \vartheta, \psi} \neq 0$, potem evlja

$$\iiint_D f(x, y, z) dx dy dz = \int f(\varphi(u, v, w), \vartheta(u, v, w), \psi(u, v, w)) |\det J_{\varphi, \vartheta, \psi}| du dv dw.$$

Nekaj primerov menjave spremenljivk:

(1) *Polarne koordinate* v $\mathbb{R}^2$ so podane z

$$x = r \cos \varphi, y = r \sin \varphi,$$

$$r \geq 0, \varphi \in [0, 2\pi], \text{ in velja } |\det J_{\text{polar}}| = r.$$

- (2) *Cilindrične koordinate* v $\mathbb{R}^3$ so podane z

$$x = r \cos \varphi, y = r \sin \varphi, z = z,$$

$$r \geq 0, \varphi \in [0, 2\pi], z \in \mathbb{R}, \text{ in velja } |\det J_{\text{cylindric}}| = r.$$

- (3) *Sferične koordinate* v $\mathbb{R}^3$ so podane z

$$x = r \cos \varphi \cos \vartheta, y = r \sin \varphi \cos \vartheta, z = r \sin \vartheta.$$

$$r \geq 0, \varphi \in [0, 2\pi], \vartheta \in [-\frac{\pi}{2}, \frac{\pi}{2}] \text{ in velja } |\det J_{\text{spherical}}| = r^2 \cos \vartheta.$$

5. NADALJNJE BRANJE

- (1) James Stewart, Calculus, early transcendentals, 2016, Poglavje 15.
 (2) Wolfram Demonstrations: [Approximating a Double Integral with Cuboids](#).

6. DOMAČA NALOGA

- ⚡ (1) James Stewart, Calculus, early transcendentals, 2016, strani 1022-23, Exercises 3-52.

- ⚡ (2) Naj bo (u, v) novi koordinatni sistem v $\mathbb{R}^2$, definiran z

$$x = e^u \cos v, y = e^u \sin v,$$

kjer $u \in \mathbb{R}$ and $v \in [0, 2\pi]$. Določite determinanto Jacobijeve matrike $J_{u,v} = \frac{\partial(x,y)}{\partial(u,v)}$.

- ⚡ (3) Naj bodo (u, v, w) nove koordinate v $\mathbb{R}^3$, definirane s predpisom

$$x = u \cos v, y = 2u \sin v, z = 3w.$$

kjer je $u \geq 0, v \in [0, 2\pi]$ in $w \in \mathbb{R}$. Izračunajte determinanto Jacobijeve matrike $J_{u,v,w} = \frac{\partial(x,y,z)}{\partial(u,v,w)}$.

- ⚡ (4) Naj bo (u, v, w) koordinatni sistem v $\mathbb{R}^3$ definiran z

$$x = 3ue^v, y = 2we^u, z = u.$$

Določite determinanto Jacobijeve matrike $J_{u,v,w} = \frac{\partial(x,y,z)}{\partial(u,v,w)}$.

- ⚡ (5) Naj bo $a \in \mathbb{R}$ neničelno število. Za pišite naslednji integral s spremembo v polarni koordinatni sistem

$$\int_0^a \left(\int_0^{\sqrt{a^2-y^2}} f(x,y) dx \right) dy.$$

- ⚡ (6) Zamenjajte vrstni red integracije:

$$\int_0^1 \left(\int_0^{\sqrt{y}} f(x,y) dx \right) dy = \int_{\text{?}}^{\text{?}} \left(\int_{\text{?}}^{\text{?}} f(x,y) dy \right) dx$$

⚡ (7) Zapišite integral

$$\int_{-1}^1 \left(\int_{-\sqrt{1-y^2}}^{\sqrt{1-y^2}} \left(\int_{\sqrt{x^2+y^2}}^1 f(x, y, z) dz \right) dx \right) dy$$

v cilindričnih koordinatah.

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov.)

Optimizacija. 1. del.

Polona Oblak

1. KLASIFIKACIJA LOKALNIH EKSTREMOV

Naj bo $f: \mathbb{R}^n \rightarrow \mathbb{R}$ ter a v definicijskem območju funkcije f .

Če za vse točke $x \neq a$, ki so "dovolj blizu" točke a (tj. $\|x - a\| < \varepsilon$ za nek dovolj majhen ε) velja $f(x) < f(a)$, potem pravimo, da ima funkcija f v točki a **lokalni maksimum**.

Če za vse točke $x \neq a$, ki so "dovolj blizu" točke a (tj. $\|x - a\| < \varepsilon$ za nek dovolj majhen ε) velja $f(x) > f(a)$, potem pravimo, da ima funkcija f v točki a **lokalni minimum**.

Če je funkcija f zvezno parcialno odvedljiva, potem je jasno, da ima lahko lokalne ekstreme le v stacionarnih točkah. Torej je potreben pogoj za lokalni ekstrem funkcije f v točki a :

$$(\text{grad } f)(a) = 0,$$

kar pomeni, da moramo lokalne ekstreme iskati zgolj med stacionarnimi točkami.

Izrek 1. *Naj bo a stacionarna točka dvakrat parcialno zvezno odvedljive funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$.*

- (1) *Če so vse lastne vrednosti matrike $H_f(a)$ pozitivne, ima f v a lokalni minimum.*
- (2) *Če so vse lastne vrednosti matrike $H_f(a)$ negativne, ima f v a lokalni maksimum.*
- (3) *Če so vse lastne vrednosti matrike $H_f(a)$ neničelne, vendar različno predznačene, lokalnega ekstrema v a ni.*
- (4) *Če je kakšna od lastnih vrednosti matrike $H_f(a)$ enaka 0, o lokalnih ekstremih funkcije f v točki a iz matrike $H_f(a)$ ne moremo sklepati.*

2. LOKALNI EKSTREMI

Pogosto naletimo na problem iskanja ekstremalnih vrednosti funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$ pri pogojih

$$g_1(\mathbf{x}) = g_2(\mathbf{x}) = \dots = g_m(\mathbf{x}) = 0.$$

Izkaže se, da lahko lokalni ekstremini funkcije f pri pogojih $g_i(\mathbf{x}) = 0$, $i = 1, \dots, m$, nastopijo le v stacionarnih točkah funkcije

$$L = f - \lambda_1 g_1 - \dots - \lambda_m g_m,$$

ki je funkcija $n + m$ spremenljivk $x_1, x_2, \dots, x_n, \lambda_1, \lambda_2, \dots, \lambda_m$.

Funkciji L pravimo *Lagrangeova funkcija*, novim spremenljivkam $\lambda_1, \lambda_2, \dots, \lambda_m$ pa *Lagrangevi multiplikatorji*.

Omenjeni pogoj ni zadosten. Nekatere kritične točke funkcije L so ekstremalne točke funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$ pod pogoji $g_1(\mathbf{x}) = g_2(\mathbf{x}) = \dots = g_m(\mathbf{x}) = 0$, ostale pa ne.

3. NADALJNJE BRANJE

- (1) James Stewart, Calculus, early transcendentals, 2016, Razdelek 14.8.
- (2) Wolfram Demonstrations: [The Geometry Of Lagrange Multipliers](#).

4. DOMAČA NALOGA

- ⚡ (1) Rešite kviz na [Spletni učilnici](#).
- ⚡ (2) James Stewart, Calculus, early transcendentals, 2016, strani 940-941, vse naloge.
- ⚡ (3) Naj bo $f: \mathbb{R}^3 \rightarrow \mathbb{R}^3$ dvakrat zvezno odvedljiva funkcija treh spremenljivk. Za vsako od točk $P, R \in \mathbb{R}^3$ določite in utemeljite, ali sta lokalni minimum, lokalni maksimum, ali nista ekstremalni točki ali pa iz danih podatkov ne moremo ugotoviti, katerega tipa sta točki.
 - (a.) $f_x(P) = f_y(P) = f_z(P) = 0$, $f_{xx}(P) = 3$, $f_{yy}(P) = -1$, $f_{xy}(P) = 0$.
 - (b.) $f_x(R) = f_y(R) = f_z(R) = 1$, $f_{xx}(R) = f_{yy}(R) = f_{zz}(R) = 1$, $f_{xy}(R) = f_{yz}(R) = f_{xz}(R) = 0$.
- ⚡ (4) Ali obstaja takšna dvakrat zvezno odvedljiva funkcija $f: \mathbb{R}^2 \rightarrow \mathbb{R}$, da je

$$\frac{\partial^2 f}{\partial x^2}(0, 0) = 4, \frac{\partial^2 f}{\partial x \partial y}(0, 0) = 1, \frac{\partial^2 f}{\partial y^2}(0, 0) = 2,$$

in ima v točki $(x, y) = (0, 0)$

- (a) lokalni minimum? (Če da, zapišite primer. Če ne, razložite, zakaj ne.)
- (b) lokalni maksimum? (Če da, zapišite primer. Če ne, razložite, zakaj ne.)

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov.)

Optimizacija. 2. del.
Odvodi vektorskih funkcij. Vezani ekstremi v vektorski obliki.

Polona Oblak

Naj bo $F: \mathbb{R}^n \rightarrow \mathbb{R}^m$, $F(\mathbf{x}) = \begin{bmatrix} f_1(\mathbf{x}) \\ f_2(\mathbf{x}) \\ \vdots \\ f_m(\mathbf{x}) \end{bmatrix}$ vektorska funkcija n spremenljivk

$\mathbf{x} = (x_1, \dots, x_n)$. Da bomo poudarili, da sta lahko n in m večja od 1, bomo

označili vektor spremenljivk $\mathbf{x} = (x_1, \dots, x_n)$ tudi kot $\vec{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}$ in vektorsko

funkcijo kot $F = \vec{F}$.

Spomnimo se, da je *odvod vektorske funkcije $\vec{F}$ po vektorju spremenljivk $\vec{x}$* je definiran kot

$$(1) \quad \frac{\partial \vec{F}}{\partial \vec{x}} = J_{\vec{F}}(\mathbf{x}) = \begin{bmatrix} \frac{\partial f_1}{\partial x_1}(\mathbf{x}) & \frac{\partial f_1}{\partial x_2}(\mathbf{x}) & \dots & \frac{\partial f_1}{\partial x_n}(\mathbf{x}) \\ \frac{\partial f_2}{\partial x_1}(\mathbf{x}) & \frac{\partial f_2}{\partial x_2}(\mathbf{x}) & \dots & \frac{\partial f_2}{\partial x_n}(\mathbf{x}) \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial f_m}{\partial x_1}(\mathbf{x}) & \frac{\partial f_m}{\partial x_2}(\mathbf{x}) & \dots & \frac{\partial f_m}{\partial x_n}(\mathbf{x}) \end{bmatrix}$$

Drugi odvod funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$ (tu $m = 1$) pa kot

$$\frac{\partial^2 f}{\partial \vec{x}^2} = \frac{\partial}{\partial \vec{x}} \left(\frac{\partial f}{\partial \vec{x}} \right)^\top.$$

Funkcija $f: \mathbb{R}^n \rightarrow \mathbb{R}$ je *konveksna* na $\mathcal{D}$, če velja

$$f(t\mathbf{x} + (1-t)\mathbf{y}) \leq t f(\mathbf{x}) + (1-t) f(\mathbf{y})$$

za vse $\mathbf{x}, \mathbf{y} \in \mathcal{D}$ in za vse $t \in [0, 1]$. Funkcija f je *konkavna* na $\mathcal{D}$, če je funkcija $-f$ konveksna na $\mathcal{D}$.

Izrek 1. Dvakrat zvezno odvedljiva funkcija $f: \mathcal{D} \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$ je konveksna natanko tedaj, ko je $\frac{\partial^2 f}{\partial \vec{x}^2}$ pozitivno semidefinitna matrika na $\mathcal{D}$, in je konkavna natanko tedaj, ko je $\frac{\partial^2 f}{\partial \vec{x}^2}$ negativno semidefinitna na $\mathcal{D}$.

Nekaj pravil:

(1) $\frac{\partial \vec{x}}{\partial \vec{x}} = I_n$

(2) Če je $A \in \mathbb{R}^{m \times n}$, potem $\frac{\partial A\vec{x}}{\partial \vec{x}} = A$.

- (3) Če je $\vec{a} \in \mathbb{R}^n$, potem $\frac{\partial \vec{a}^T \vec{x}}{\partial \vec{x}} = \vec{a}^T$.
- (4) Če je $A \in \mathbb{R}^{n \times n}$, potem $\frac{\partial (\vec{x}^T A \vec{x})}{\partial \vec{x}} = \vec{x}^T (A + A^T)$.
- (5) Če je $A \in \mathbb{R}^{n \times n}$ simetrična matrika, potem velja $\frac{\partial (\vec{x}^T A \vec{x})}{\partial \vec{x}} = 2\vec{x}^T A$.
- (6) $\frac{\partial \|\vec{x}\|^2}{\partial \vec{x}} = 2\vec{x}^T$.
- (7) Če $\vec{z} = \vec{z}(\vec{x})$ in $\vec{y} = \vec{y}(\vec{x})$, potem $\frac{\partial (\vec{y}^T \vec{z})}{\partial \vec{x}} = \vec{z}^T \frac{\partial \vec{y}}{\partial \vec{x}} + \vec{y}^T \frac{\partial \vec{z}}{\partial \vec{x}}$.
- (8) Če $G: \mathcal{D}_G \subseteq \mathbb{R}^m \rightarrow \mathbb{R}^n$ in $F: \mathcal{D}_F \subseteq \mathbb{R}^n \rightarrow \mathbb{R}^p$ in $H = F \circ G$, potem $\frac{\partial \vec{H}}{\partial \vec{x}} = \frac{\partial (\vec{F} \circ \vec{G})}{\partial \vec{x}} = \frac{\partial \vec{F}}{\partial \vec{G}}(\vec{G}(\vec{x})) \cdot \frac{\partial \vec{G}}{\partial \vec{x}}$.

Primer 1. Naj bo $A \in \mathbb{R}^{m \times n}$, $\text{rank } A = m$, $\vec{b} \in \mathbb{R}^m$. Poiščite tisto rešitev sistema $A\vec{x} = \vec{b}$, ki ima najmanjšo normo. (Rešitev)

1. NADALJNJE BRANJE

- (1) David A. Harville: Matrix Algebra From a Statistician's Perspective, Springer, 1997, Poglavlje 15.
- (2) J.E. Gentle: Matrix Algebra, Theory, Computations, in Applications in Statistics, Springer, 2017, Poglavlje 4.
- (3) K.B. Petersen, M.S. Pedersen: The Matrix Cookbook.

(Pazite na to, da so v vseh treh zgoraj omenjenih referencah odvodi definirani kot transponiranje matrike (1).)

2. DOMAČA NALOGA

- ⚡ (1) Denimo, da funkcija $f: \mathbb{R}^2 \rightarrow \mathbb{R}$ doseže maksimalno vrednost na krivulji $x^2 + 2y^2 = 3$ v točki $(1, 1)$. Ali sta $(\text{grad } f)(1, 1)$ in $[1, 2]^T$ linearno odvisna?
- ⚡ (2) Naj bosta $\vec{a}, \vec{b} \in \mathbb{R}^n$ in funkciji $f, g: \mathbb{R}^n \rightarrow \mathbb{R}$ definirani kot $f(\vec{x}) = \vec{x}^T \vec{a}$ in $g(\vec{x}) = \vec{x}^T \vec{b}$. Izračunajte $\frac{\partial (f(\vec{x})g(\vec{x}))}{\partial \vec{x}}$.
- ⚡ (3) Naj bo $A \in \mathbb{R}^{n \times n}$ matrika z lastnostjo $A^T = -A$. Izračunajte $\frac{\partial}{\partial \vec{x}} (\vec{x}^T A \vec{x} + \|\vec{x}\|^2)$.
- ⚡ (4) Za matriko $A \in \mathbb{R}^{n \times n}$ izračunajte $\frac{\partial \|A\vec{x}\|^2}{\partial \vec{x}}$.
- ⚡ (5) Naj bodo $B, C, D \in \mathbb{R}^{n \times n}$ in $\vec{b}, \vec{d} \in \mathbb{R}^n$. Za funkcijo

$$f(\vec{x}) = (B\vec{x} + \vec{b})^T C (D\vec{x} + \vec{d})$$

izračunajte $\frac{\partial f}{\partial \vec{x}}$ in $\frac{\partial^2 f}{\partial \vec{x}^2}$.

- ⚡ (6) Naj bo $A \in \mathbb{R}^{n \times n}$ simetrična pozitivno definitna matrika ter $\vec{b} \in \mathbb{R}^n$. Poiščite in klasificirajte lokalne ekstreme funkcije $f: \mathbb{R}^n \rightarrow \mathbb{R}$, definirane s predpisom

$$f(\vec{x}) = \frac{1}{2} \vec{x}^T A \vec{x} - \vec{x}^T \vec{b}.$$

- (7) Pokažite, da so naslednje funkcije konveksne:

- ⚡ (a) $f(x, y) = e^y - \log x$,
 - ⚡ (b) $g(\vec{x}) = \frac{1}{2} \vec{x}^T A \vec{x}$, kjer je A pozitivno semidefinitna matrika,
 - ⚡ (c) $h(\vec{x}) = \|\vec{x}\|^2$,
 - ⚡ (d) $k(\vec{x}) = \vec{a}^T \vec{x}$, kjer je $\vec{a} \in \mathbb{R}^n$.
- ⚡ (8) Za dane vektorje $\vec{a}_1, \vec{a}_2, \dots, \vec{a}_k \in \mathbb{R}^n$ poiščite takšne $\vec{x} \in \mathbb{R}^n$, da bo povprečna kvadratna razdalja med vektorjem $\vec{x}$ in vektorji $\vec{a}_1, \vec{a}_2, \dots, \vec{a}_k$ najmanjša možna.
- (9) Naj bosta $\vec{a} \in \mathbb{R}^n$ ter $b \in \mathbb{R}$.
- ⚡ (a) Poiščite najmanjšo in največjo vrednost $\vec{a}^T \vec{x}$ za vse vektorje $\vec{x} \in \mathbb{R}^n$ s predpisano dolžino $\|\vec{x}\| = b$.
 - ⚡ (b) Geometrijsko razložite svojo rešitev iz (9a) v primeru, ko je $n = 3$.
- ⚡⚡ (10) Za pozitivno semidefinitno matriko $A \in \mathbb{R}^{n \times n}$, simetrično matriko $B \in \mathbb{R}^{n \times n}$ ter neničelni $b \in \mathbb{R}$ poiščite najmanjšo in največjo vrednost kvadratne forme $\vec{x}^T A \vec{x}$ pri pogoju $\vec{x}^T B \vec{x} = b$.

- ⚡ (11) Naj bodo dani vektorji in matriki

$$P = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix}, \vec{q} = \begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix}, \vec{r} = \begin{bmatrix} 1 \\ 2 \\ 3 \end{bmatrix}, A = \begin{bmatrix} 1 & 1 & 0 \\ 0 & 1 & 1 \end{bmatrix} \text{ in } \vec{b} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}.$$

Poiščite najmanjšo vrednost funkcije $\vec{x}^T P \vec{x} + \vec{q}^T \vec{x} + \vec{r}$ pri pogoju, da $\vec{x}$ reši linearni sistem $A \vec{x} = \vec{b}$.

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov. Naloga, označena s ⚡⚡ je nekoliko težja.)

Optimizacija. 3. del.
Prirejena funkcija. Karush-Kuhn-Tuckerjevi pogoji.

Polona Oblak

Naj bodo $f, g_i, h_j: \mathbb{R}^n \rightarrow \mathbb{R}$ dane funkcije več spremenljivk. Radi bi našli rešitev naslednjega problema

$$(P\star) \quad \begin{aligned} &\text{minimizirajmo}_{\vec{x}} f(\vec{x}) \\ &\text{pri pogojih } g_i(\vec{x}) \leq 0 \text{ za } i = 1, 2, \dots, m \\ &\quad h_j(\vec{x}) = 0 \text{ za } j = 1, 2, \dots, r. \end{aligned}$$

Definirajmo še množice $\mathcal{D}_{g_i} = \{x \in \mathbb{R}^n; g_i(x) \leq 0\}$ za $i = 1, 2, \dots, m$, $\mathcal{D}_{h_j} = \{x \in \mathbb{R}^n; h_j(x) = 0\}$ za $j = 1, 2, \dots, r$, in

$$\mathcal{D} = \mathcal{D}_f \cap (\cap_{i=1}^m \mathcal{D}_{g_i}) \cap (\cap_{j=1}^r \mathcal{D}_{h_j}).$$

Sedaj lahko problem $(P\star)$ zapišemo ekvivalentno kot

$$(P\star) \quad \min_{\vec{x} \in \mathcal{D}} f(\vec{x}).$$

Definirajmo Lagrangevo funkcijo

$$\begin{aligned} L(\vec{x}, \vec{\lambda}, \vec{\mu}) &= f(\vec{x}) - \vec{\lambda}^\top \vec{G}(\vec{x}) - \vec{\mu}^\top \vec{H}(\vec{x}) = \\ &= f(\vec{x}) - \sum_{i=1}^m \lambda_i g_i(\vec{x}) - \sum_{j=1}^r \mu_j h_j(\vec{x}), \end{aligned}$$

kjer je

$$\vec{G}(\vec{x}) = \begin{bmatrix} g_1(\vec{x}) \\ \vdots \\ g_m(\vec{x}) \end{bmatrix}, \vec{H}(\vec{x}) = \begin{bmatrix} h_1(\vec{x}) \\ \vdots \\ h_r(\vec{x}) \end{bmatrix}, \vec{\lambda} = \begin{bmatrix} \lambda_1 \\ \vdots \\ \lambda_m \end{bmatrix}, \text{ in } \vec{\mu} = \begin{bmatrix} \mu_1 \\ \vdots \\ \mu_r \end{bmatrix}.$$

Funkcijo

$$K(\vec{\lambda}, \vec{\mu}) = \inf_{\vec{x} \in \mathcal{D}} L(\vec{x}, \vec{\lambda}, \vec{\mu}) = \inf_{\vec{x} \in \mathcal{D}} \left\{ f(\vec{x}) - \vec{\lambda}^\top \vec{G}(\vec{x}) - \vec{\mu}^\top \vec{H}(\vec{x}) \right\}$$

imenujemo *prirejena funkcija* problema $(P\star)$. Pri tem spremenljivke $\vec{\lambda}$ in $\vec{\mu}$ imenujemo *prirejene spremenljivke*. Opazimo:

- (1) $K(\vec{\lambda}, \vec{\mu})$ je konkavna funkcija (neodvisno od lastnosti funkcij f , g_i , h_j originalnega problema).
- (2) Če je $\lambda_i \leq 0$ za $i = 1, 2, \dots, m$, potem velja $K(\vec{\lambda}, \vec{\mu}) \leq \min_{\vec{x} \in \mathcal{D}} f(\vec{x})$ za vse $\vec{\lambda} \leq \vec{0}$ ter vse $\vec{\mu}$.

Problem

$$\text{maksimizirajmo}_{\vec{\lambda}, \vec{\mu}} K(\vec{\lambda}, \vec{\mu})$$

$$(D\star) \quad \text{pri pogoju } \lambda_i \leq 0 \text{ za } i = 1, 2, \dots, m$$

imenujemo *prirejeni problem* problema $(P\star)$.

Označimo z $\vec{x}^*$ vektor iz $\mathcal{D}$, ki reši problem $(P\star)$ in z $\vec{\lambda}^*$ in $\vec{\mu}^*$ prirejeni spremenljivki, ki rešita prirejeni problem $(D\star)$. Naj bo torej $p^* = f(\vec{x}^*)$ rešitev problema $(P\star)$ in $d^* = K(\vec{\lambda}^*, \vec{\mu}^*)$ rešitev problema $(D\star)$. Potem iz (2) sledi

$$d^* \leq p^*.$$

Če

- je $(P\star)$ linearni program (t.j. f je linearna in h_j so afine funkcije), ali če
- so f, g_i konveksne funkcije in h_j afine,

potem velja $d^* = p^*$.

V primeru, ko je $d^* = p^*$, sledi, da morajo $\vec{x}^*, \vec{\lambda}^*$ in $\vec{\mu}^*$ zadoščati *Karush–Kuhn–Tuckerjevim pogojem*:

$$(KKT) \quad \begin{aligned} \frac{\partial L(\vec{x}, \vec{\lambda}^*, \vec{\mu}^*)}{\partial \vec{x}}(\vec{x}^*) &= 0, \\ g_i(\vec{x}^*) &\leq 0 \quad \text{za } i = 1, 2, \dots, m, \\ h_j(\vec{x}^*) &= 0 \quad \text{za } j = 1, 2, \dots, r, \\ \lambda_i^* &\leq 0 \quad \text{za } i = 1, 2, \dots, m, \\ \lambda_i^* g_i(\vec{x}^*) &= 0 \quad \text{za } i = 1, 2, \dots, m. \end{aligned}$$

1. NADALJNJE BRANJE

- (1) Wilhelm Forst, Dieter Hoffmann: [Optimization - Theory in Practice, Springer, 2010.](#)

2. DOMAČA NALOGA

- ⚡ (1) Območje A v $\mathbb{R}^n$ je konveksno, če je za poljubni točki $x, y \in A$ tudi točka $tx + (1 - t)y \in A$. Pokažite, da je presek konveksnih množic konveksna množica.
- ⚡ (2) Naj bodo $g_i: \mathcal{D} \subseteq \mathbb{R}^n \rightarrow \mathbb{R}$, $i = 1, 2, \dots, m$, konveksne funkcije na konveksni množici $\mathcal{D}$. Pokažite, da je tedaj območje

$$\mathcal{D}_0 = \{x \in \mathcal{D}; g_i(x) \leq 0 \text{ za } i = 1, 2, \dots, m\}$$

konveksna množica.

⚡ (3) Rešite naslednji problem:

$$\begin{aligned} &\text{minimizirajte}_{x,y} (x-2)^2 + 2(y-1)^2 \\ &\text{pri pogojih } x+4y \leq 3, \\ &\quad y-x \leq 0. \end{aligned}$$

⚡ (4) Zapišite Karush–Kuhn–Tuckerjeve pogoje naslednjih problemov:

(a)

$$\begin{aligned} &\text{minimizirajte}_{x,y,z} x + y^2 + z^2 \\ &\text{pri pogojih } x^2 + 2y^2 \leq 4 \\ &\quad x + y + z = 1. \end{aligned}$$

(b)

$$\begin{aligned} &\text{minimizirajte}_{x,y,z} xyz \\ &\text{pri pogojih } x^2 + 2y^2 \leq 4 \\ &\quad x^2 + y^2 + z^2 = 3 \end{aligned}$$

(c)

$$\begin{aligned} &\text{minimizirajte}_{x,y,z} 2x + 2y^2 + xz \\ &\text{pri pogojih } x^2 + y^2 = 1 \\ &\quad x + z = 0 \\ &\quad xy \geq 0 \end{aligned}$$

(Naloge, označene s ⚡ preverjajo razumevanje osnovnih pojmov in so primeri nalog s teoretičnih izpitov.)