

OPT skripta do kapsy

Kapitola 2 (Maticová algebra)

- $\mathbf{C} = \mathbf{AB} \rightarrow c_{ij} = \sum_{k=1}^p a_{ik} b_{kj}, \mathbf{A} \in \mathbb{R}^{m \times p}, \mathbf{B} \in \mathbb{R}^{p \times n}$
- $(\alpha \mathbf{A})^\top = \alpha \mathbf{A}^\top, (\mathbf{A}^\top)^\top = \mathbf{A}, (\mathbf{A} + \mathbf{B})^\top = \mathbf{A}^\top + \mathbf{B}^\top, (\mathbf{AB})^\top = \mathbf{B}^\top \mathbf{A}^\top$
- rank \mathbf{A} = rank \mathbf{A}^\top , rank $\mathbf{AB} \leq \min\{\text{rank } \mathbf{A}, \text{rank } \mathbf{B}\}$
- Pravá/levá inverze nemusí existovat nebo nemusí být jediná, je-li matici čtvercová a má jednu z nich, pak má i druhou a jsou se rovný.
- Pravá inverze existuje $\iff \mathbf{A} \in \mathbb{R}^{m \times n}$ má nezávislé řádky (rng $\mathbf{A} = \mathbb{R}^m$)
- Levá inverze existuje $\iff \mathbf{A} \in \mathbb{R}^{m \times n}$ má nezávislé sloupce (null $\mathbf{A} = \{0\}$)
- $(\mathbf{AB})^{-1} = \mathbf{B}^{-1} \mathbf{A}^{-1}, (\alpha \mathbf{A})^{-1} = \alpha^{-1} \mathbf{A}^{-1}, (\mathbf{A}^\top)^{-1} = (\mathbf{A}^{-1})^\top = \mathbf{A}^{-\top}$
- det $\mathbf{A} = \sum_\sigma \text{sgn } \sigma \prod_{i=1}^n a_{i\sigma(i)}$
- det(\mathbf{AB}) = (det \mathbf{A})(det \mathbf{B}), det $\mathbf{A} = \det \mathbf{A}^\top$, det $\mathbf{A} = 0 \iff \mathbf{A}$ je singulární
- Gausssova eliminace soustavy $\mathbf{Ax} = \mathbf{b}$: řádkové úpravy zachovají null \mathbf{A} , rng \mathbf{A}^\top , sloupcové úpravy zachovají rng \mathbf{A} , null \mathbf{A}^\top .

Kapitola 3 (Linearita)

- báz podprostoru X je LN množina vektorů generující X
- Věty: 1) Z každé množiny vektorů lze vybrat báz lin. obalu.
2) Každou LN množinu vektorů podprostoru lze doplnit na jeho bázi.
3) Každý lin. podprostor má (alespoň jednu) báz a každá jeho báze má stejný počet vektorů.
- X, Y množiny: $X \subseteq Y \rightarrow \dim X \leq \dim Y, X \subseteq Y \wedge \dim X = \dim Y \rightarrow X = Y$
- rng $\mathbf{A} = \{\mathbf{Ax} \mid \mathbf{x} \in \mathbb{R}^n\}$, null $\mathbf{A} = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = 0\}$ (obojí pro $\mathbf{A} \in \mathbb{R}^{m \times n}$)
- TFAE pro matici $\mathbf{A} \in \mathbb{R}^{m \times n}$: $\mathbf{AA}^\top \in \mathbb{R}^{m \times m}$ je regulární; rng $\mathbf{A} = \mathbb{R}^m$; $\mathbf{Ax} = \mathbf{y}$ má řešení $\forall \mathbf{y}$; rank $\mathbf{A} = m$; rádky \mathbf{A} nezávislé; zobr. $f(\mathbf{x}) = \mathbf{Ax}$ je surjektivní, tj. $f(\mathbb{R}^n) = \mathbb{R}^m$; \mathbf{A} má pravou inverzi
- TFAE: null $\mathbf{A} = \{0\}$; $\mathbf{Ax} = 0$ má jediné řešení $\mathbf{x} = 0$; rank $\mathbf{A} = n$; sloupce \mathbf{A} jsou LN; \mathbf{A} má levou inverzi; $\mathbf{A}^\top \mathbf{A}$ je regulární
- rng $\mathbf{AB} \subseteq$ rng \mathbf{A} (rovnost, pokud jsou řádky \mathbf{B} lineárně nezávislé)
- null $\mathbf{AB} \supseteq$ null \mathbf{B} (rovnost, pokud jsou sloupce \mathbf{A} lineárně nezávislé)
- Věta (rozklad podle hodnot): Pro každou matici $\mathbf{A} \in \mathbb{R}^{m \times n}$ hodnosti r existují $\mathbf{B} \in \mathbb{R}^{m \times r}$, $\mathbf{C} \in \mathbb{R}^{r \times n}$ t.z. $\mathbf{A} = \mathbf{BC}$
- rank $\mathbf{A} = \text{rank } \mathbf{A}^\top$
- Věta (o dimenzích): Pro matici $\mathbf{A} \in \mathbb{R}^{m \times n}$ platí: $\dim \text{rng } \mathbf{A} + \dim \text{null } \mathbf{A} = n$
- Je-li X lineární podprostor \mathbb{R}^n a $\mathbf{x} + \mathbf{y}$ je affiní podprostor \mathbb{R}^n . Je-li A affiní podprostor \mathbb{R}^n a $\mathbf{x} \in A$, pak $A - \mathbf{x}$ je lineární podprostor \mathbb{R}^n . Je-li A affiní podprostor \mathbb{R}^n a $\mathbf{x}, \mathbf{y} \in A$, pak $A - \mathbf{x} = A - \mathbf{y}$.
- Množina $A \subseteq \mathbb{R}^n$ je affiní podprostor \iff je množinou řešení nějaké lin. soustavy, tj. existují \mathbf{A}, \mathbf{b} t.z. $A = \{\mathbf{x} \in \mathbb{R}^n \mid \mathbf{Ax} = \mathbf{b}\}$
- Pro body $\mathbf{x}_1, \dots, \mathbf{x}_n \in \mathbb{R}^n$ TFAE: žádný bod není roven aff. komb. ostatních; vektory $\{\mathbf{x}_i - \mathbf{x}_1\}$ jsou LN; homogenní vektory s témito \mathbf{x}_i jsou LN

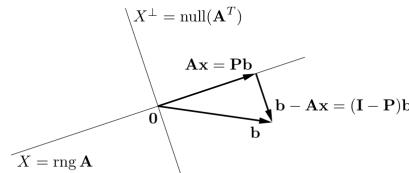
Kapitola 4 (Ortogonalita)

- Skalární součin: $\mathbf{x}^\top \mathbf{y} = \sum x_i y_i$, Úhel mezi \mathbf{x} a \mathbf{y} je $\cos \phi = \frac{\mathbf{x}^\top \mathbf{y}}{\|\mathbf{x}\| \|\mathbf{y}\|}$.
- CSB-nerovnost sk. součinu: $(\mathbf{x}^\top \mathbf{y})^2 \leq (\mathbf{x}^\top \mathbf{x})(\mathbf{y}^\top \mathbf{y})$.
- Euklidovská norma: $\|\mathbf{x}\| = \sqrt{\mathbf{x}^\top \mathbf{x}}$,
- Ortogonalní vektory: $\mathbf{x} \perp \mathbf{y} \iff \mathbf{x}^\top \mathbf{y} = 0$, \mathbf{y} je ortogonalní na množinu X , iff $\mathbf{x} \perp \mathbf{y} \forall \mathbf{y} \in X$ (stačí, je-li kolmý na bázové vektory X)
- Ortogonalní prostor: $X \perp Y$, je-li $\mathbf{x} \perp \mathbf{y} \forall \mathbf{x} \in X, \forall \mathbf{y} \in Y$, dále platí $X \perp Y \Rightarrow X \cap Y = \{0\}$.
- Ortogonalní doplněk: $X^\perp = \{\mathbf{y} \mid \mathbf{y} \perp X\}$.
- Platí $\forall X, Y \in \mathbb{R}^n$: 1) $\dim X + \dim X^\perp = n$, 2) $(X^\perp)^\perp = X$
3) $X \perp Y \wedge \dim X + \dim Y = n \Rightarrow Y = X^\perp$.
- $\forall \mathbf{A}$ platí: 1) $(\text{rng } \mathbf{A})^\perp = \text{null } (\mathbf{A}^\top)$, 2) $(\text{null } \mathbf{A})^\perp = \text{rng } (\mathbf{A}^\top)$.
- Mn. vektorů: $\{\mathbf{u}_1, \dots, \mathbf{u}_n\}$ je ortonormální, iff \mathbf{u}_i je normalizovaný a $\mathbf{u}_i^\top \mathbf{u}_j = \delta_{ij}$. \mathbf{u}_i ortonormální a $\mathbf{x} = \sum \alpha_i \mathbf{u}_i$, pak $\alpha_i = \mathbf{u}_i^\top \mathbf{x}$.
- Matici s ortonormálními sloupci: $\mathbf{U}^\top \mathbf{U} = \mathbf{I}$. Čtvercová \mathbf{U} je ortogonalní a platí pro ní navíc $\mathbf{U}^\top = \mathbf{U}^{-1}$, $\mathbf{UU}^\top = \mathbf{I}$.
- Matici s ortonormálními sloupci zachovává skalární součin a normu $f(\mathbf{x})^\top f(\mathbf{y}) = (\mathbf{Ux})^\top (\mathbf{Uy}) = \mathbf{x}^\top \mathbf{U}^\top \mathbf{Uy} = \mathbf{x}^\top \mathbf{y}$
- (Isometrie): $\|f(\mathbf{x})\| = \|\mathbf{Ux}\| = \|\mathbf{x}\|$ (viz výše)
- QR rozklad: $\mathbf{A} = \mathbf{QR}$, $\mathbf{Q} \in \mathbb{R}^{m \times m}$ ortogonalní $\mathbf{R} \in \mathbb{R}^{m \times n}$ horní trojúhelníková.
- Redukovaný QR: \mathbf{Q} stejné rozměry jak \mathbf{A} , \mathbf{R} čtvercová (v plném je jsou typicky poslední řádky R nulové, tak ty (a to s čím se násobí), můžeme ignorovat)
- Ortogonalní projekce: Pokud $\mathbf{U}^\top \mathbf{U} = \mathbf{I}$ tak projekce na rng \mathbf{U} : $\mathbf{x} = \mathbf{U}\mathbf{U}^\top \mathbf{z}$. Matice $\mathbf{P} = \mathbf{U}\mathbf{U}^\top$ je ortogonalní projektor na rng \mathbf{U} . $\mathbf{P}^2 = \mathbf{P} = \mathbf{P}^\top$. Platí $\text{rng } \mathbf{P} = X$, null $\mathbf{P} = X^\perp$. Ort. projektor na $\text{rng } (\mathbf{U})^\perp = (\mathbf{I} - \mathbf{P})\mathbf{z}$.

- pro ortogonální matici platí $\det \mathbf{U} = 1$ (rotace) nebo $\det \mathbf{U} = -1$ (reflexe)
- Vzdálenost bodu \mathbf{z} od lin. podp. $X^\perp : \|\mathbf{U}\mathbf{U}^\top \mathbf{z}\| = \|\mathbf{U}^\top \mathbf{z}\|$, (rng $\mathbf{U} = X$)
- Vzdálenost bodu \mathbf{z} od aff. podprostoru
 $A = \{\mathbf{x} \in \mathbb{R}^m \mid \mathbf{U}^\top \mathbf{x} = b\} = \{\mathbf{x} \in \mathbb{R}^m \mid \mathbf{U}^\top (\mathbf{x} - \mathbf{x}_0) = 0\} = X^\perp + \mathbf{x}_0$
 $\mathbf{U}^\top \mathbf{x} = b : \|\mathbf{U}^\top \mathbf{z} - \mathbf{b}\|$.
- vzdálenost bodu \mathbf{z} od nadroviny $\mathbf{a}^\top \mathbf{x} = b$ je $\frac{|\mathbf{a}^\top \mathbf{z} - b|}{\|\mathbf{a}\|}$

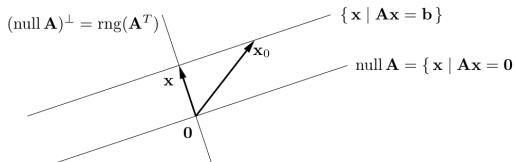
Kapitola 5 (Nehomogenní lin. soustavy)

- $\forall \mathbf{A}$ platí 1) $\text{rng } (\mathbf{A}^\top \mathbf{A}) = \text{rng } (\mathbf{A}^\top)$, 2) $\text{null } (\mathbf{A}^\top \mathbf{A}) = \text{null } (\mathbf{A})$.
- $\rightarrow \text{rank } (\mathbf{A}^\top \mathbf{A}) = \text{rank } \mathbf{A} = \text{rank } (\mathbf{A}^\top \mathbf{A}) = \text{rank } \mathbf{A}^\top$
- Platí 1) $\mathbf{A}^\top \mathbf{A}$ regulární iff \mathbf{A} LN sloupce, 2) $\mathbf{A} \mathbf{A}^\top$ regulární, iff \mathbf{A} LN řádky.



Obrázek 1: Nejmenší čtverce

- Metoda nejmenších čtverců: hledáme $\min_x \|\mathbf{Ax} - \mathbf{b}\|^2$. Pak platí $\mathbf{A}^\top \mathbf{Ax}^* = \mathbf{A}^\top \mathbf{b}$. Z toho $\mathbf{x}^* = \mathbf{A}^+ \mathbf{b}$, kde $\mathbf{A}^+ = (\mathbf{A}^\top \mathbf{A})^{-1} \mathbf{A}^\top$, pokud $\mathbf{A}^\top \mathbf{A}$ regulární, jinak více řešení \mathbf{x} (affiní podprostor)
- Ortogonalní projekce: Když \mathbf{x} řeší norm. rovnici, pak $\mathbf{Ax} = \mathbf{Pb}$, $\mathbf{P} = \mathbf{AA}^+$ je projektor na rng \mathbf{A} .
- Reduk. QR rozkladem: po dosazení $\mathbf{A} := \mathbf{QR}$, $\mathbf{x} = \mathbf{R}^{-1} \mathbf{Q}^\top \mathbf{b}$. \mathbf{R} regulární pro \mathbf{A} LN sloupce.
- Lin. regrese: $\min_x \sum (y_i - f(x_i, \theta))^2$, pro f v θ lineární, $\|\mathbf{y} - \mathbf{A}\theta\|$.
- Vícekrit. nejmenší čtverce (nezáporná kombinace více kritérií):
 $\|\sqrt{\mu_i}(\mathbf{A}_i \mathbf{x} - \mathbf{b}_i)\|^2 = \|\left[\sqrt{\mu_1} \mathbf{A}_1 \mathbf{x} - \left[\sqrt{\mu_1} \mathbf{b}_1\right]\right]^2 = \|\left[\sqrt{\mu_i} \mathbf{A}_i \mathbf{x}\right] - \|\sqrt{\mu_i} \mathbf{b}_i\|^2 = \|\mathbf{A}' \mathbf{x} - \mathbf{b}'\|^2$.
Řešení $\mathbf{Ax} = \mathbf{b}$ pro malé \mathbf{x} je $\mathbf{x} = \mathbf{A}_\mu^+ \mathbf{b}$, $\mathbf{A}_\mu^+ = (\mathbf{A}' \mathbf{A} + \mu \mathbf{I})^{-1} \mathbf{A}'$.



Obrázek 2: Nejmenší norma

- NEJMENŠÍ NORMA: Řešení s nejmenší normou pro nedourčenou soustavu $\mathbf{Ax} = \mathbf{b}$: $\min\{\|\mathbf{x}\|^2 \mid \mathbf{x} \in \mathbb{R}^n, \mathbf{Ax} = \mathbf{b}\}$, pak pro \mathbf{x}^* platí $\mathbf{x}^* = \mathbf{A}^+ \mathbf{b} = \mathbf{A}^\top (\mathbf{AA}^\top)^{-1} \mathbf{b}$, tentokrát \mathbf{AA}^\top regulární, jinak více řešení \mathbf{x} (affiní podprostor)

Kapitola 6 (Spektrální rozklad a kvadratická forma)

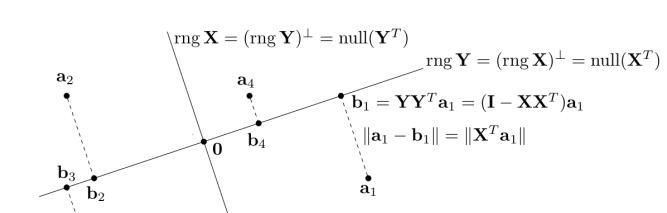
- polynom je homogenní, pokud jsou všechny monomy stejného stupně
- $\mathbf{A} \in \mathbb{R}^{n \times n}$, $\mathbf{Av} = \mathbf{v}\lambda$, $\mathbf{AV} = \mathbf{V}\Lambda$
- Pokud \mathbf{V} je reg. (tj. \mathbf{A} má n LN vlastních vek.), je invertovatelná a platí $\mathbf{A} = \mathbf{V}\Lambda\mathbf{V}^{-1}$.
- VĚTA: Nechť $\mathbf{A} \in \mathbb{R}^{n \times n}$ pak FSAE: \mathbf{A} je symetrická $\iff \forall$ vl. čísla \mathbf{A} jsou reálná a \mathbf{A} má n vlastních vektorů které jsou po dvojicích ortogonální.
- DŮSLEDEK: Pro každou sym. $\mathbf{A} = \mathbf{V}\Lambda\mathbf{V}^\top = \lambda_1 \mathbf{v}_1 \mathbf{v}_1^\top + \dots + \lambda_n \mathbf{v}_n \mathbf{v}_n^\top$ lze zvolit \mathbf{V} ortogonální. rank \mathbf{A} = rank Λ
- SYMETRIZACE: $\mathbf{A} = \frac{1}{2}(\mathbf{A} + \mathbf{A}^\top)$
- Definitnost kvadratické formy: Čtvercovou matici nazýváme:
– P[N]SD když pro každý \mathbf{x} platí $\mathbf{x}^\top \mathbf{Ax} \geq 0$ [$\mathbf{x}^\top \mathbf{Ax} \leq 0$]
– P[N]D když pro každý $\mathbf{x} \neq 0$ platí $\mathbf{x}^\top \mathbf{Ax} > 0$ [$\mathbf{x}^\top \mathbf{Ax} < 0$]
– INDEF když exist. \mathbf{x} a \mathbf{y} tak, že $\mathbf{x}^\top \mathbf{Ax} > 0$ a $\mathbf{y}^\top \mathbf{Ay} < 0$
- VĚTA: Symetrická matici je

- PD, právě když všechny vůdčí hlavní minory jsou kladné.
- PSD, právě když všechny hlavní minory jsou nezáporné.
- DIAG. KVADR. FORMY: $f(\mathbf{x}) = \mathbf{x}^\top \mathbf{Ax} = \mathbf{x}^\top \mathbf{V}\Lambda\mathbf{V}^\top \mathbf{x} = \mathbf{y}^\top \mathbf{Ly}$

- VĚTA: Symetrická matici je
– $\text{P[N]SD} \iff \forall$ vl. čísl. nezáporná [nekladná]
– $\text{P[N]D} \iff$ všechny vůdčí hlavní minory jsou kladné [záporná]
– INDEF \iff aspoň jedno kladné a jedno záporné.
- KVADRATICKÁ FUNKCE: $f(\mathbf{x}) = \mathbf{x}^\top \mathbf{Ax} + \mathbf{b}^\top \mathbf{x} + c$
- DOPLNĚNÍ NA ČTVEREC: $f(\mathbf{x}) = (\mathbf{x} - \mathbf{x}_0)^\top \mathbf{A}(\mathbf{x} - \mathbf{x}_0) - y_0$.
TRIK: $\mathbf{b} = -2\mathbf{Ax}_0$, $c = \mathbf{x}_0^\top \mathbf{Ax}_0 + y_0$ (vtip pro zoufale studenty při testu: „Víte, jak si utírá zadek kouzlení? Trikem“ (A ted’ běz zase počítat...))
- KVADRIKA: y nultá vrstevnice kvadratické funkce, tedy $\{x \in \mathbb{R}^n \mid \mathbf{x}^\top \mathbf{Ax} + \mathbf{b}^\top \mathbf{x} + c = 0\}$. Jedená je obecnější kuželoseček ($n=2$). Pokud lze doplnit na čtverec, tvary dle matici \mathbf{A} (PD, ND, INDEF: hyperboloid). Pokud rank $\mathbf{A} < n$, je kvadrika degenerovaná. Kvadrika může být \emptyset . Pokud kvadratická funkce nelze doplnit na čtverec, jsou tvary složitější než elipsa/hyperbola.

Kapitola 7 (Použití spektrálního rozkladu)

- Def. (stopa): tr $\mathbf{A} = a_{11} + \dots + a_{nn}$
- tr $(\mathbf{A} + \mathbf{B}) = \text{tr } \mathbf{A} + \text{tr } \mathbf{B}$, tr $(\mathbf{c}\mathbf{A}) = \alpha \text{tr } \mathbf{A}$, tr $(\mathbf{AB}) = \text{tr } (\mathbf{BA})$, cyklickost stopy,
Každá čtvercová matici: $\text{tr } (\mathbf{A}) = \lambda_1 + \dots + \lambda_n$
- Def. (skalární součin matic): $\langle \mathbf{A}, \mathbf{B} \rangle = \langle \mathbf{B}, \mathbf{A} \rangle = \langle \mathbf{A}^\top, \mathbf{B}^\top \rangle = \langle \mathbf{B}^\top, \mathbf{A}^\top \rangle$,
 $\langle \mathbf{A}, \mathbf{B} \rangle = \text{tr } (\mathbf{A}^\top \mathbf{B}) = \text{tr } (\mathbf{B}^\top \mathbf{A}) = \text{tr } (\mathbf{BA}^\top)$
- $\|\mathbf{A}\| = \sqrt{\langle \mathbf{A}, \mathbf{A} \rangle} = \sqrt{\text{tr } (\mathbf{A}^\top \mathbf{A})} = \left(\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2 \right)^{\frac{1}{2}}$
- Dále předpokládáme, že vl. čísla jsou řazena vzestupně $\lambda_1 \leq \dots \leq \lambda_n$
- NEJMENŠÍ STOPA: Platí $\min\{\text{tr } \mathbf{Ax} \mid \mathbf{x} \in \mathbb{R}^n, \mathbf{x}^\top \mathbf{x} = 1\} = \lambda_1$ a min. hodnota se nabývá pro $\mathbf{x} = \mathbf{v}_1$
VĚTA: Nechť $k < n$. Platí $\min\{\mathbf{x}^\top \mathbf{Ax} \mid \mathbf{x} \in \mathbb{R}^n, \mathbf{x}^\top \mathbf{x} = 1\} = \lambda_{k+1}$ a min. hodnota se nabývá pro $\mathbf{x} = \mathbf{v}_{k+1}$
VĚTA: Nechť $k \leq n$. Platí $\min\{\text{tr } (\mathbf{X}^\top \mathbf{AX}) \mid \mathbf{X} \in \mathbb{R}^{n \times k}, \mathbf{X}^\top \mathbf{X} = \mathbf{I}\} = \lambda_1 + \dots + \lambda_k$ a minimum se nabývá pro $\mathbf{X} = [\mathbf{v}_1 \dots \mathbf{v}_k]$



Obrázek 3: Proložení bodů podprostorem

- PROLOŽENÍ BODŮ PODPROSTOREM: Máme body $a_1, \dots, a_m \in \mathbb{R}^n$, proložíme podprostorem $\text{rng } \mathbf{Y}$ dim $k \leq n$. Vzdálenost bodu od $\text{rng } \mathbf{Y}$ je délka projekce na jeho ort. doplněk $(\text{rng } \mathbf{Y})^\perp = \text{rng } \mathbf{X}$. Tedy $\|\mathbf{x}^\top \mathbf{A} \mathbf{a}_1\|^2 + \|\mathbf{x}^\top \mathbf{A} \mathbf{a}_m\|^2 = \|\mathbf{Ax}\|^2$. Tedy máme úlohu $\min\{\|\mathbf{Ax}\|^2 \mid \mathbf{x} \in \mathbb{R}^{n \times (n-k)}, \mathbf{X}^\top \mathbf{X} = \mathbf{I}\}$. Protože $\|\mathbf{Ax}\|^2 = \text{tr } (\mathbf{X}^\top \mathbf{A}^\top \mathbf{A} \mathbf{X})$, spočítáme spektr. rozklad $\mathbf{V}\Lambda\mathbf{V}^\top$ matici $\mathbf{A}^\top \mathbf{A}$. Máme $\mathbf{V} = [\mathbf{v}_1 \ \mathbf{v}_2 \ \dots \ \mathbf{v}_n] \in \mathbb{R}^{n \times n}$. \mathbf{X} je řešní úlohy proložení bodů podprostorem a \mathbf{Y} je Easy.
- MATICE NEJNIZŠÍ HODNOTI: $\min\{\|\mathbf{A} - \mathbf{B}\|^2 \mid \mathbf{B} \in \mathbb{R}^{m \times n}$, rank $\mathbf{B} \leq k\}$. Stejná opt. hodnota jako výše, stačí najít $\mathbf{B} = \mathbf{AYY}^\top = \mathbf{A}(\mathbf{I} - \mathbf{XX}^\top)$. Opt. hodnota je $\lambda_1 + \dots + \lambda_{n-k}$ (ze spektra matici $\mathbf{A}^\top \mathbf{A}$).
- Když chceme promítat na affiní podprostor, musíme body $a_1 \dots a_m$ posunout tak, aby jejich težiště $\bar{a} = \frac{1}{m}(a_1 + \dots + a_m)$ leželo v pocátku.
- SVD ROZKLAD: Každou matici $\mathbf{A} \in \mathbb{R}^{m \times n}$ lze rozložit jako $\mathbf{A} = \mathbf{USV}^\top = s_1 \mathbf{u}_1 \mathbf{v}_1^\top + \dots + s_p \mathbf{u}_p \mathbf{v}_p^\top$, kde $\mathbf{S} \in \mathbb{R}^{m \times n}$ je diag. s diag. prvky s_1, \dots, s_p (kde $p = \min\{m, n\}$) a $\mathbf{U} = [\mathbf{u}_1 \dots \mathbf{u}_m] \in \mathbb{R}^{m \times m}$ a $\mathbf{V} \in \mathbb{R}^{n \times n} = [\mathbf{v}_1 \dots \mathbf{v}_n]$ jsou ortogonální. DŮSLEDEK: nenulová sing. čísla

- matice \mathbf{A} jsou druhé odmocniny nenulových vl. čísel matic $\mathbf{A}^\top \mathbf{A}$ a $\mathbf{A} \mathbf{A}^\top$ (která jsou tudíž stejná).
- řešení úlohy MATICE NEJMENŠÍ HODNOSTI pomocí SVD rozkladu (Eckart - Young): Nechť $\mathbf{A} = \mathbf{U} \mathbf{S} \mathbf{V}^\top$ je SVD matice \mathbf{A} . Řešení úlohy je $\mathbf{B} = \mathbf{U}' \mathbf{S} \mathbf{V}^\top = s_{p-k+1} \mathbf{u}_{p-k-1} \mathbf{v}_{p-k+1}^\top + \dots + s_p \mathbf{u}_p \mathbf{v}_p^\top$, kde \mathbf{S}' se získá z matice \mathbf{S} vynulováním $p-k$ nejmenších diagonálních prvků (v sumě dryád (#joke) tedy předpokládáme $0 \leq s_1 \leq \dots \leq s_p$)

Kapitola 8 (Nelineární funkce a zobrazení)

- Nechť funkce $f, g : \mathbb{R}^n \rightarrow \mathbb{R}$ jsou spojité v bodě \mathbf{x} . Pak $f + g, f - g, fg$ jsou spojité. Pokud $g(\mathbf{x}) \neq 0$, je tam spojita i f/g . Skládání funkcí (vnější $\mathbb{R} \rightarrow \mathbb{R}$) spojitých je také spojité. Zobrazení $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$, jehož složky jsou spojité do \mathbb{R} , je také spojité.
 - Zobrazení f je v bodě \mathbf{x} spojite diferencovatelné, jestliže v bodě \mathbf{x} ex. všechny parciální derivace a jsou v tomto bodě spojité.
 - Je-li zobrazení v bodě spojite diferencovatelné, je v tomto bodě diferencovatelné.
- | | |
|--|--|
| $f(\mathbf{x}) = \mathbf{x}$ | $f'(\mathbf{x}) = \mathbf{I}$ |
| $f(\mathbf{x}) = \mathbf{a}^\top \mathbf{x}$ | $f'(\mathbf{x}) = \mathbf{a}^\top$ |
| $f(\mathbf{x}) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$ | $f'(\mathbf{x}) = \mathbf{x}^\top (\mathbf{A} + \mathbf{A}^\top)$ |
| $f(\mathbf{x}) = \mathbf{x} $ | $f'(\mathbf{x}) = \mathbf{x}^\top / \mathbf{x} $ |
| $f(\mathbf{x}) = \mathbf{g}(\mathbf{x})^\top \mathbf{h}(\mathbf{x})$ | $f'(\mathbf{x}) = \mathbf{g}(\mathbf{x})^\top \mathbf{h}'(\mathbf{x}) + \mathbf{h}(\mathbf{x})^\top \mathbf{g}'(\mathbf{x})$ |
- Směrová derivace $\varphi(\mathbf{a}) = \mathbf{f}(\mathbf{x} + \alpha \mathbf{v})$
 - Nechť zobrazení $f : \mathbb{R}^n \rightarrow \mathbb{R}^m$ je diferencovatelné v bodě \mathbf{x} . Pak jeho směrová derivace v bodě \mathbf{x} ve směru \mathbf{v} je rovna $f'(\mathbf{x})\mathbf{v}$.
 - Gradient je transpozicí derivace udává směr největšího růstu funkce.
 - Hesián je symetrický, pokud druhé parc. derivace existují a jsou spojité.
 - Taylorův polynom 2. řádu v bodě \mathbf{x}_0 je
 $T_2(\mathbf{x}) = f(\mathbf{x}_0) + f'(\mathbf{x}_0)(\mathbf{x} - \mathbf{x}_0) + \frac{1}{2}(\mathbf{x} - \mathbf{x}_0)^\top f''(\mathbf{x}_0)(\mathbf{x} - \mathbf{x}_0)$
 - Označme $B_\epsilon(\mathbf{x}) = \{\mathbf{y} \in \mathbb{R}^n \mid \|\mathbf{x} - \mathbf{y}\| \leq \epsilon\}$ (n-rozměrná koule bez hranice). Mějme množinu I , pod $\mathbf{x} \in \mathbb{R}^n$ nazaveme její:
- vnitřní bod iff $\exists \epsilon > 0$ t.z. $B_\epsilon \subseteq I$,
- hraniciční bod iff $\forall \epsilon > 0$ je $B_\epsilon(\mathbf{x}) \cap X \neq \emptyset \wedge B_\epsilon(\mathbf{x}) \cap (\mathbb{R}^n \setminus X) \neq \emptyset$

Kapitola 9 (Volné lokální extrémy)

- Fermatova věta: Nechť je funkce $f : \mathbb{R} \rightarrow \mathbb{R}$ v bodě $x \in \mathbb{R}$ diferencovatelná a má v tomto bodě lokální extrém. Pak $f'(x) = 0$.
- Nechť $f : \mathbb{R}^n \rightarrow \mathbb{R}$ a $X \subseteq \mathbb{R}^n$. Nechť je vnitřní bod množiny X . Nechť je fce f v bode \mathbf{x} dvakrát diferencovatelná a platí $f'(\mathbf{x}) = 0$. Pak:
- Je-li x lok. min. [max] fce f na X, pak Hessova matici f'' je pos.[neg.] semidefinitní. Je-li pos.[neg.] definitní, pak je to ostré min.[max]. Je-li indefinitní, pak x není lok. extrém.
- Iterační metody: $\mathbf{x}_{k+1} = \mathbf{x}_k + \alpha \mathbf{v}_k$, směr \mathbf{v}_k je sestupný, jestliže: $f'(\mathbf{x}_k)\mathbf{v}_k < 0$.
- Gradientní metoda: $\alpha \mathbf{v}_k = -\alpha f'(\mathbf{x}_k)^\top = -\alpha \nabla f(\mathbf{x}_k)$. BACHA! Gradient se dělá z účelové fce, tedy z $g(\mathbf{x})^\top g(\mathbf{x})$, nikoli jen $g(\mathbf{x})$. (viz zápočták)
- Newtonova metoda (hledání kořenů): $\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^{-1} \mathbf{g}(\mathbf{x}_k)$
- Newtonova metoda - hledání min.: $\mathbf{x}_{k+1} = \mathbf{x}_k - f''(\mathbf{x}_k)^{-1} f'(\mathbf{x}_k)^\top$. Odvozeno z: $T_{\mathbf{x}_k}^2(\mathbf{x}) = f(\mathbf{x}_k) + f'(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k) + \frac{1}{2}(\mathbf{x} - \mathbf{x}_k)^\top f''(\mathbf{x})(\mathbf{x} - \mathbf{x}_k)$ nebo z hledání kořenů (výše) pro funkci $g = f''$
- Gauss-Newton (min $\|g(\mathbf{x})\|^2$): $\mathbf{x}_{k+1} = \mathbf{x}_k - \mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}(\mathbf{x}_k)$ Odvozeno z: Normální rovnice (kap. 5): $\mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}'(\mathbf{x}_k)(\mathbf{x} - \mathbf{x}_k) = -\mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}(\mathbf{x}_k)$ Metoda z jednotkovou délku kroku může vždy divergovat, vhodnou volbou α lze konvergenci zajistit.
- Levenberg-Marguardt: $\mathbf{x}_{k+1} = \mathbf{x}_k - (\mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}'(\mathbf{x}_k) + \mu \mathbf{I})^{-1} \mathbf{g}'(\mathbf{x}_k)^\top \mathbf{g}(\mathbf{x}_k)$ Pro malé μ se blíží Gauss-Newtonově metodě, pro velké gradienty.

Kapitola 10 (Lokální extrémy vázané rovnostmi)

- Lineární omezení: $\min \|A\mathbf{x} - \mathbf{b}\|^2$, za podmínek: $C\mathbf{x} = \mathbf{d}$ Převedeme:
 $f(\mathbf{x}) = \frac{1}{2}((A\mathbf{x} - \mathbf{b})^\top (A\mathbf{x} - \mathbf{b}))$, tedy podm. stacionarity:
 $A^\top A\mathbf{x} + C^\top \lambda = A^\top \mathbf{b} \wedge C\mathbf{x} = \mathbf{d}$, což lze převést na maticový tvar.
- Nechť je zobrazení \mathbf{g} v bodě $\mathbf{x} \in X$ a vektor $\mathbf{v} \in \mathbb{R}^n$ je tečný k X v bodě \mathbf{x} . Pak $\mathbf{g}'(\mathbf{x})\mathbf{v} = 0 \rightarrow$ Gradient je kolmý na vrstevnici.
- Pokud navíc $\text{rank } \mathbf{g}'(\mathbf{x}) = m$ (tj. LN řádky) a vektor \mathbf{v} je $\mathbf{g}'(\mathbf{x})\mathbf{v} = 0$, pak \mathbf{v} je tečné na X v bodě \mathbf{x} .
- Lagrangián: $L(\mathbf{x}, \lambda) = f(\mathbf{x}) + \lambda^\top \mathbf{g}(\mathbf{x}) = f(\mathbf{x}) + \lambda_1 g_1(\mathbf{x}) + \dots + \lambda_m g_m(\mathbf{x})$ a položíme parc. derivace podle všech proměnných rovny 0.

- Regulární bod:** Gradienty vazební fce $\mathbf{g}(\mathbf{x})$ na množině X jsou lin. nezávislé,

Kapitola 11 (Lineární programování)

- Stand. tvar: $\min \{c^\top \mathbf{x} \mid \mathbf{x} \in \mathbb{R}^n, A\mathbf{x} \geq b, \mathbf{b} \in \mathbb{R}^m\}$
- Stand. úpravy: $\max c^\top \mathbf{x} \equiv \min -c^\top \mathbf{x}, \quad \mathbf{a}^\top \mathbf{x} \leq \mathbf{b} \equiv -\mathbf{a}^\top \mathbf{x} \geq -\mathbf{b}$
- Rovnic. tvar: $\min \{c^\top \mathbf{x} \mid \mathbf{x} \in \mathbb{R}^n, A\mathbf{x} = \mathbf{b}, \mathbf{x} \geq 0\}$
- Slackové proměnné: $\mathbf{a}^\top \mathbf{x} \geq \mathbf{b} \rightarrow (\mathbf{a}^\top \mathbf{x} - \mathbf{b}) \geq 0, \mathbf{u} \geq +u$
- Neomezená proměnná: $\mathbf{x} \in \mathbb{R}^n \rightarrow x = x^+ - x^- \wedge (x^+, x^-) \geq 0$
- Po částečně affin funkce: $f(\mathbf{x}) = \max(c_i^\top \mathbf{x} + d_i)$. Chceme min:
 $\min \{f(\mathbf{x}) \mid A\mathbf{x} \geq \mathbf{b}\} = \min \{z \mid (\mathbf{x}, y) \in \mathbb{R}^{n+1}, \forall i : c_i^\top \mathbf{x} + d_i \leq z, A\mathbf{x} \geq \mathbf{b}\}$
- Axiomy normy: $\|\mathbf{x}\| = 0 \rightarrow \mathbf{x} = 0, \|\alpha \mathbf{x}\| = |\alpha| \|\mathbf{x}\|, \|\mathbf{x} + \mathbf{y}\| \leq \|\mathbf{x}\| + \|\mathbf{y}\|$
- Definice p-normy: $\|\mathbf{x}\|_p = (|x_1|^p + \dots + |x_n|^p)^{1/p}, p \geq 1$

- Typické normy: $\|\mathbf{x}\|_1 = \sum |x_i|, \|\mathbf{x}\|_2 = \sqrt{\sum x_i^2}, \|\mathbf{x}\|_\infty = \max\{|x_i|\}$
Pro \mathbf{A} s LN sloupce je také $\|\mathbf{A}\mathbf{x}\|$ normou.

Řešení pětříček lin soustavy v p-normě, tedy: $\min_x \|\mathbf{Ax} - \mathbf{b}\|_p, x \in \mathbb{R}^n$
 $p = \infty: \min \{z \mid x \in \mathbb{R}^n, z \in \mathbb{R}, -z \leq A\mathbf{x} - \mathbf{b} \leq z\}$
 $p = 1: \min \{z \mid \mathbf{x} \in \mathbb{R}^n, z \in \mathbb{R}, -z \leq A\mathbf{x} - \mathbf{b} \leq z\}$
• LP relaxace: $\min \{c^\top \mathbf{x} \mid \mathbf{x} \in \{0, 1\}^n, A\mathbf{x} \geq \mathbf{b}\}$ pracujeme s: $x \in [0, 1]^n$ → tato „uvolněná“ úloha pak nemá větší optimální hodnotu než původní úloha, to proto že optimalizujeme přes větší množinu!

Kapitola 12 (Konvexní množiny a mnohostény)

- $X \subseteq \mathbb{R}^n$ se nazývá konvexní, iff: $x, y \in X, 0 \leq \alpha \leq 1 \rightarrow (1 - \alpha)x + \alpha y \in X$
Tedy každé dva body v množině propojíme úsečkou která je celá v této množině.
- Vážený součet $\alpha_1 \mathbf{x}_1 + \dots + \alpha_k \mathbf{x}_k$ vektorů $\mathbf{x}_i \in \mathbb{R}^n$ se nazývá jejich:
- lineární kombinace $\iff \alpha_i \in \mathbb{R}$
- affiní kombinace $\iff \alpha_i \in \mathbb{R}, \alpha_1 + \dots + \alpha_k = 1$
- nezáporná kombinace $\iff \alpha_i \in \mathbb{R}, \forall \alpha_i \geq 0$
- konvexní kombinace $\iff \alpha_i \in \mathbb{R}, \alpha_1 + \dots + \alpha_k = 1, \forall \alpha_i \geq 0$
- Konvex. (jiný) obal vektorů je množina všech jejich konv. (jiných) kombinací. Konvex obal množiny $X \subseteq \mathbb{R}^n$ je průnik všech konv. množin, které X obsahují.
- Množina uzavřená vůči kombinacím lineárním je lin. podprostor, affiním je affiní podp., nezáporný je konvexní kužel a konvexním je konvexní množina.
- DÚSDEK: Průnik (konečně či nekonečně) konv. množin je konv. množina.
- Konvexní mnohostěn je průnik konečně mnoha uzavřených poloprostorů, je to tedy množina: $\{x \in \mathbb{R}^n \mid Ax \geq b\}$. Příklady mnohostěnů: \emptyset, \mathbb{R}^n , intervaly $(-\infty, a], [a, \infty)$, každý aff podpr., $[-1, 1]^n$
- Co není polyedr: koule v $\mathbb{R}^n, n \geq 2$, interval $[0, a), \{x \in \mathbb{R}^n \mid Ax > b\}$
- Bod $x \in X$ je extremálním bodem, iff neexistuje dva různé body z X takové, že x je střed úsečky tyto body spojující.
- TFAE: x je extremální bod polyedru, $\exists I \subseteq \{1..m\}$ tak že $A_I \mathbf{x} = \mathbf{b}_I$ a A_I což má LN sloupce ($Ax = b$).
- Opěrná nadrovina konv. $X \subseteq \mathbb{R}^n$ je nadrovina $H = \{x \in \mathbb{R}^n \mid a^\top x = b\}$ a $H \cap X \neq \emptyset$. Množina $H \cap X$ se nazývá stěna mnohostěnu. Stěna dim 0 je vrchol, dim 1 je hrana a dim $X - 1$ je faseta. Každý extremální bod je vrchol.
- Je-li H opěrná nadrov. X , pak extr. bod $X \cap H$ je i extr. bod X .
- TFAE: polyedr má alespoň jeden extr. bod, polyedr neobsahuje přímku. Mějme konvexní mnohostěn, který neobsahuje přímku. Jestliže lineární funkce má na tomto mnohostěnu minimum, pak tato funkce nabývá na mnohostěnu minima až v jednom z jeho extremálních bodů.

Kapitola 14 (Dualita)

$$\begin{array}{ll} \min \{c^\top \mathbf{x}\} & \max \{b^\top \mathbf{y}\} \\ \text{za podmínek} & \text{za podmínek} \\ \left[\begin{array}{c} A \\ x \end{array} \right] \left[\begin{array}{c} x \\ y \end{array} \right] = \left[\begin{array}{c} b \\ \mathbf{0} \end{array} \right] & \left[\begin{array}{c} A^\top \\ y \end{array} \right] \left[\begin{array}{c} y \\ \mathbf{0} \end{array} \right] = \left[\begin{array}{c} \mathbf{0} \\ c \end{array} \right] \\ \left[\begin{array}{c} x \\ y \end{array} \right] \in \mathbb{R}^n & \left[\begin{array}{c} y \\ \mathbf{0} \end{array} \right] \in \mathbb{R}^m \end{array}$$

Dále: \mathbf{x} píp. primární řeš., \mathbf{y} píp. primární řeš.

- SLABÁ DUALITA: $c^\top \mathbf{x} \geq b^\top \mathbf{y}$

- pokud \mathbf{x}, \mathbf{y} jsou přípustná řešení primární a duální úlohy a $c^\top \mathbf{x} = b^\top \mathbf{y}$, pak jsou to optimální hodnoty obou úloh.

- PODM. KOMPL.: $c^\top \mathbf{x} = b^\top \mathbf{y}$ iff na každém rádku alespoň jedna rovnost (aktivní podmínka)

- SILNÁ DUALITA: Primární má opt. řeš. iff duální má opt. řeš. \mathbf{x} a duální má opt. řeš. \mathbf{y} , pak $c^\top \mathbf{x} = b^\top \mathbf{y}$

primární/duální	má optimum	neomezená	nepřípustná
má optimum	ano	ne	ne
neomezená	ne	ne	ano
nepřípustná	ne	ano	ano

- STÍNOVÉ CENY:

$f: \mathbb{R}^n \rightarrow \mathbb{R}, f(\mathbf{b}) = \min \{c^\top \mathbf{x} \mid \mathbf{x} \geq \mathbf{b}, \mathbf{x} \geq 0\} = \max \{b^\top \mathbf{y} \mid A^\top \mathbf{y} \leq \mathbf{c}, \mathbf{y} \geq 0\}$ (přičemž primář i duál mají opt. řeš.) Pokud má duální úloha pro dané \mathbf{b} jediné opt. řeš. \mathbf{y}^* , pak je fce f v bodě \mathbf{b} diferencovatelná a $\frac{\partial f(\mathbf{b})}{\partial b_i} = \mathbf{y}_i^*$.

Kapitola 15 (Konvexní funkce)

- Funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ na množině $X \subseteq \mathbb{R}^n$ se nazývá konvexní, iff:
 $x, y \in X, 0 \leq \alpha \leq 1 \rightarrow f((1 - \alpha)x + \alpha y) \leq (1 - \alpha)f(x) + \alpha f(y)$
- konvexní je funkce na množině iff $-f$ je konvexní na množině
- Jensenova nerovnost zobecuje podmínek konvexitetu fce:
 $x_i \in X, \alpha_i \geq 0, \sum \alpha_i = 1 \rightarrow f(\alpha_1 x_1 + \dots + \alpha_k x_k) \leq \alpha_1 f(x_1) + \dots + \alpha_k f(x_k)$
- Př: $f(x) = \max(x_i) \rightarrow f((1 - \alpha)x + \alpha y) = \max((1 - \alpha)x_i + \alpha y_i) \leq \max((1 - \alpha)x_i) + \max(\alpha y_i) = (1 - \alpha)f(x) + \alpha f(y)$. fce je konvexní
- Příklady konvexních fcí: $f(x) = e^{ax}$ a $\in \mathbb{R}$ na \mathbb{R} , $f(x) = a^\top \mathbf{x} + b$ je zároveň konv. i konk., $f(x) = \mathbf{x}^\top \mathbf{A} \mathbf{x}$ konk. pro \mathbf{A} PSD, každá norma je konv., $x \log x$ je konvexní na \mathbb{R}_{++}
- Příklady konkávních fcí: $f(x) = \log(x)$ na \mathbb{R}_{++} , $\mathbf{x}^\top \mathbf{A} \mathbf{x}$ konk. pro \mathbf{A} NSD, $f(x) = x^a$ $0 \leq a \leq 1$ na \mathbb{R}_{++}
- Epigraf fce je množina $\{(x, y) \in \mathbb{R}^{n+1} \mid f(x) \leq y\}$. množina nad grafem fce
- Subkontura výsky u je $\{x \in \mathbb{R}^n \mid f(x) \leq y\}$
- Funkce je konvexní iff její epigraf je konvexní. Oboustranná implikace.
- Každá subkontura konv. fce je konvexní množina. Obrácená implikace neplatí.
- At je $f: \mathbb{R}^n \rightarrow \mathbb{R}$ difrakrátně diferencovatelná. Pak je f konvexní na \mathbb{R}^n , iff v každém $x \in \mathbb{R}^n$ je $f''(x)$ PSD.
- At $g_1..g_k: \mathbb{R}^n \rightarrow \mathbb{R}$ jsou konvexní, pak pro $\alpha_i \geq 0$ je $f = \alpha_1 g_1 + \dots + \alpha_k g_k$ také konvexní. Může se stát, že i takováto kombinace nekonvexní. fce f je nakonec konvexní fce ($f(x) = x^3 - x^7$).
- Skládání konvex. fcí nemusí být konvex. fce. Např.
- At fce $g: \mathbb{R}^m \rightarrow \mathbb{R}$ je konvex., $\mathbf{A} \in \mathbb{R}^{m \times n}, \mathbf{b} \in \mathbb{R}^m$, pak fce $h(\mathbf{x}) = g(\mathbf{A}\mathbf{x} + \mathbf{b})$ je konvexní.
- At I je libovolná množina, $g_i: \mathbb{R}^n \rightarrow \mathbb{R}$ jsou konv. fce. Pak: $f(x) = \max_{i \in I}(g_i(x))$ je konv fce, předpokládáme že pro každé x maximum existuje. Dané tím, že epigraf f je průnikem epigrafů g_i .

Kapitola 16 (Konvexní optimalizace)

- Nechť funkce $f: \mathbb{R}^n \rightarrow \mathbb{R}$ je konvexní na konvexní množině $X \subseteq \mathbb{R}^n$ (tj. je to konvexní optimální úloha). Pak každě lok. min. fce f na X je zároveň globální.
- Příklady konvexních úloh: lineární programování, kvadratické programování, kvadratické programování s kvadratickými omezeními, programování na kuželu druhého rádu, semidefinitní programování.
- Příklad nepřípustné úlohy: $\max \{b \mid b = z + s + 100p, b \leq 40, b \geq 20\}$, kde $z...z$ znalosti, $s...s$ štěstí, $p...p$ tento přehled, $b...b$ body ze zkoušky
- Konvexní relaxace: když mám konv. fci na složité (nekonv.) množině, vezmu její konv. podmnožinu a získám alespoň horní odhad minima.

Autorství

Vytvořeno podmožinou S ($|S| = 8$) členů (ne)chvalně (ne)proslulé tajné skupiny zvané *Memy pro zoufalce na B3B33* (značíme M). Za obsah nikdo (rozhodně ani množina S , ani M) nikomu neručí - je možné, že jsme si vše jen zlovně vymysleli. :-)

Pokud byste chtěli zdrojový kód, ozvěte se na hodandom@fel.cvut.cz. Šetřete papír, tiskněte naši jednostránkovou verzi!

Hodně štěstí ke zkoušce, nechť vás provází sfla a nejmenší čtverce!