

Poznámky ke státnicím

Cyril Kotecký

Chapter 1

Úvod do složitosti a vyčíslitelnosti

1.1 Výpočetní modely (Turingovy stroje, RAM)

TM

Definition: TM

$$M = (Q, \Sigma, \delta, q_0, F)$$

- Q konečná množina stavů
 - Σ konečná abeceda
 - $\delta : Q \times \Sigma \rightarrow Q \times \Sigma \times \{R, N, L\} \cup \perp$ přechodová funkce (\perp nedefinovaný)
 - $q_0 \in Q$ počáteční stav
 - $F \subseteq Q$ přijímající stavy
1. **Počáteční stav:** Hlava na levém symbolu vstupního slova na pásce.
 2. **Krok:** Podle δ změním stav, přepíšeme znak a posuneme hlavu.
 3. **Konec:** Končíme když je přechod nedefinovaný, přijímáme pokud je stav v F .

Definition: Jazyky TM

- $L(M)$ jazyk přijímaný M
- $M(w) \downarrow$ výpočet na w skončí
- $M(w) \uparrow$ výpočet na w neskončí
- L je TM částečně rozhodnutelný/rekurzivně spočetný, pokud

$$\exists M : L = L(M) .$$

- L je TM rozhodnutelný/rekurzivní, pokud

$$\exists M : L = L(M) \wedge \forall w \in \Sigma^* : M(w) \downarrow .$$

Definition: Funkce TM

M počítá částečnou funkci $f_M : \Sigma^* \rightarrow \Sigma^*$, kde $f(w) \downarrow$ pokud $M(w) \downarrow$.
 f je TM vyčíslitelná pokud $\exists M$, který jí počítá.

Example: Převod vícepáskového na jednopáskový

- $\Sigma' := \Sigma \cup \{H, -\} \times \Sigma^k$
- Pásky zarovnáme podle pozic hlav a dorovnáme po posunu hlav.

Example: Převod oboustranného na jednostranný

Example: Převod vícehlavého na jednohlavého

UTM

Definition: *UTM*

1. **UTM** : \mathcal{U} na vstupu $\langle M, x \rangle$ simuluje práci M na x .
2. **LU** : $L_{\mathcal{U}} := \{ \langle M, x \rangle \mid x \in L(M) \}$
3. **DIAG** : $\text{DIAG} := \{ \langle M \rangle \mid \langle M \rangle \notin L(M) \}$

Theorem: Částečná rozhodnutelnost *LU*

1. $L_{\mathcal{U}} \in \text{PD}$
2. $\text{DIAG} \notin \text{PD}$
3. $L_{\mathcal{U}} \notin \text{DEC}$

Proof:

1. Z existence \mathcal{U} .
2. Jinak $\exists M_D$:
 - $\langle M_D \rangle \in \text{DIAG} \iff \langle M_D \rangle \notin L(M_D)$ z definice DIAG .
 - $\langle M_D \rangle \in \text{DIAG} \iff \langle M_D \rangle \in L(M_D)$ z DIAG definice $L(M_D)$.
3. Jinak $\exists M_{\mathcal{U}}$ a lze ho použít pro rozhodování DIAG

$$\forall M : \langle M \rangle \in \text{DIAG} \iff \langle M \rangle \notin L(M) \iff \langle M, \langle M \rangle \rangle \notin L_{\mathcal{U}} .$$

RAM

Definition: *RAM*

- Registry $\{r_i\}_{i \in \mathbb{N}}$ kde $r_i \in \mathbb{N}$ a inicializované na 0 .
 - $[r_i]$ obsah registru
 - $[[r_i]] := [r_{[r_i]}]$
- Program $P = I_0, \dots, I_l$ konečná posloupnost instrukcí.
 - $\text{LOAD, ADD, SUB, COPY, JNZ, READ, PRINT}$
- Pole A_1, \dots, A_p uložené jako $A_i[j] = r_{i+j(p+1)}$.
- Proměnné uložené jako $r_{i(p+1)}$.

Definition: *Jazyky RAM*

- R čte slovo $w = \sigma_{i_1} \dots \sigma_{i_n}$ jako posloupnost i_1, \dots, i_n zakončenou 0 .
 - R přijme w pokud $R(w) \downarrow$ a R jako první napíše 1 .
 - R odmítne w pokud $R(w) \downarrow$ a R napíše nic nebo nezačne 1 .
1. L je RAM **částečně rozhodnutelný** pokud $\exists R : L = L(R)$.
 2. L je RAM **rozhodnutelný** pokud $\exists R : L = L(R) \wedge \forall w \in \Sigma^* : R(w) \downarrow$.

Definition: *Funkce RAM*

R počítá částečnou aritmetickou $f : \mathbb{N}^n \rightarrow \mathbb{N}$ pokud pro vstup $x = x_1, \dots, x_n$:

- $f(x) \downarrow \implies R(x) \downarrow$ a R vypíše $f(x)$
- $f(x) \uparrow \implies R(x) \uparrow$

R počítá částečnou $f : \Sigma^* \rightarrow \Sigma$, pokud pro vstup $w = \sigma_{i_1} \dots \sigma_{i_n}$ daný jako $i_1, \dots, i_n, 0$:

- $f(w) \downarrow = \sigma_{j_1} \dots \sigma_{j_m} \implies R(w) \downarrow$ a R vypíše $j_1, \dots, j_m, 0$
- $f(w) \uparrow \implies R(w) \uparrow$

Převody

Algorithm: R

1. Jednostrannou pásku načteme do pole T ukončeného 0 .
2. $q = 0$, $h = 0$
3. Dokud $\delta(q, T[h]) \neq \perp$: aktualizujeme $T[h]$, h, q podle δ reprezentované jako posloupnost podmínek.
4. Pokud $q \in F$, vypíšeme 1 , jinak 0 .
5. Vypíšeme obsah pásky.

Algorithm: M

- **Vstupní páska a výstupní páska:** Čísla zapsaná binárně, oddělená znakem # .
- **RAM páska:** Registry r_{i_1}, \dots, r_{i_m} pro $i_1 < \dots < i_m$ reprezentujeme jako

$$(i_1)_B | ([r_{i_1}])_B \# (i_2)_B | ([r_{i_2}])_B \# \dots \# (i_m)_B | ([r_{i_m}])_B .$$

- **Pomocná páska:** Součty, rozdíly, nepřímá adresace, posuny etc.
- Číslo instrukce si pamatujeme ve stavu.
- Jedna instrukce R je posloupnost instrukcí M .
 1. Lokace registrů s operandy.
 2. Aritmetika s operandy.
 3. Výpočet adres.
 4. Úprava paměti (nový registr, úprava registr, posun pásky s pamětí).
- Výpis 1 jako první si pamatujeme ve stavu.
- Končíme po poslední instrukci.

1.2 Základní třídy složitosti a jejich vztahy

Základní třídy

Definition: *Složitost TM*

- M pracuje v čase $f(n)$ pokud $\forall x \in \Sigma^n$, $|x| = n$: M na x končí po $\leq f(n)$ krocích.
- M pracuje v prostoru $f(n)$ pokud $\forall x \in \Sigma^n$, $|x| = n$: M na x skončí a použije $\leq f(n)$ buněk pásky.
- N pracuje v čase $f(n)$ pokud $\forall x \in \Sigma^n$ a \forall výpočet M na x končí po $\leq f(n)$ krocích.
- N pracuje v prostoru $f(n)$ pokud $\forall x \in \Sigma^n$ a \forall výpočet M na x končí a použije $\leq f(n)$ buněk pásky.

Definition: *Třídy složitosti*

- TIME $(f(n))$ jazyky přijímané TM v čase $O(f(n))$.
- SPACE $(f(n))$ jazyky přijímané TM v prostoru $O(f(n))$.
- NTIME $(f(n))$ jazyky přijímané NTM v čase $O(f(n))$.
- NSPACE $(f(n))$ jazyky přijímané NTM v prostoru $O(f(n))$.

Observation: *Inkluze*

1. TIME $(f(n)) \subseteq$ SPACE $(f(n))$
2. TIME $(f(n)) \subseteq$ NTIME $(f(n))$
3. SPACE $(f(n)) \subseteq$ NSPACE $(f(n))$
4. L \subseteq NL \subseteq P \subseteq NP \subseteq PSPACE \subseteq EXPTIME \subseteq NEXPTIME \subseteq EXPSPACE

Theorem:

$$\text{NTIME}(f(n)) \subseteq \text{SPACE}(f(n))$$

Proof: Postupně prodlužujeme větve NTM podle kterých simulujeme, dokud NTM nepřijme. Jinak odmítneme.

Corollary:

$$\text{NP} \subseteq \text{PSPACE}$$

Theorem: Savičova věta

$$f(n) \geq \log_2 n \implies \text{NPSpace}(f(n)) \subseteq \text{SPACE}(f^2(n)) .$$

Proof:

Algorithm: M'

1. $i = 1$
2. Pokud Reachable $(C_0^x, C_{\text{acc}}, c_M i)$:
3. \forall konfiguraci C s prostorem $i + 1$:
4. Pokud Reachable (C_0^x, C, c_i) :
5. $i = i + 1$
6. Zpět na 2.
7. Odmítni

Algorithm: Reachable

- Prostor $O(f(n))$ na konfiguraci a $O(f(n))$ na k
 - Nejvyšší $O(f(n))$ instancí
1. Pokud $k = 0$
 2. Pokud $C_1 = C_2$ nebo $C_1, C_2 \in E$, odpověď **ano**
 3. Jinak **ne**
 4. \forall konfiguraci C_m v prostoru $f(n)$:
 6. Pokud Reachable $(C_1, C_m, k - 1)$ a Reachable $(C_m, C_2, k - 1)$, odpověď **ano**
 7. Odpověď **ne**

Corollary:

$$\text{NSPACE} = \text{PSPACE}$$

Corollary:

- $\text{NL} \subseteq \text{P}$
- $\text{NSPACE} \subseteq \text{EXPTIME}$

NP

Definition: Verifikátor

V pro L je V splňující $L = \{x \mid \exists y : V(x, y) \text{ přijme} \}$:

- Pracuje v čase $n^{O(1)}$.
- Předpokládáme $y \in n^{O(1)}$.

Definition: NP

Jazyky s polynomiálními verifikátory.

Theorem: Alternativní definice

$$\text{NP} = \bigcup_{k \in \mathbb{N}} \text{NTIME}(n^k)$$

Proof:

- \subseteq Nedeterministicky volíme znaky důkazu y .
- \supseteq Posloupnost větvení k přijetí dávají certifikát.

Theorem: Cook-Levin

SAT je NP-úplný.

Proof:

- NP: Splňující ohodnocení je certifikát.
- Úplnost:
 - Máme NTM pracující v čase n^k s jediným přijímajícím q_1 .
 - Řádky délky n^k jsou konfigurace M , stav zapsán před pozicí hlavy.
 - Řádky v tableau velikosti $n^k \times n^k$ následují podle přechodové funkce. Přechody jsou platné právě když jsou platná všechna okna 3×2 . Přípustná okna P .
 - Přijímající tableau obsahuje řádek s přijímající konfigurací.
 - Symboly tableau $S = Q \cup \Sigma \cup \{\#\}$. Proměnné $x_{i,j,s} = 1 \iff T[i,j] = s$.
 - Formule $\varphi = \varphi_{\text{cell}} \wedge \varphi_{\text{start}} \wedge \varphi_{\text{move}} \wedge \varphi_{\text{accept}}$.

$$\varphi_{\text{cell}} = \bigwedge_{i,j} \left(\left(\bigvee_s x_{i,j,s} \right) \wedge \left(\bigwedge_{s \neq t} (\neg x_{i,j,s} \vee \neg x_{i,j,t}) \right) \right)$$

$$\varphi_{\text{move}} = \bigwedge_{i,j} \varphi_{\text{legal}_{i,j}}$$

$$\varphi_{\text{accept}} = \bigvee_{i,j} x_{i,j,q_1}$$

$$\varphi_{\text{legal}_{i,j}} = \bigvee_{(s_1, \dots, s_6) \in P} (x_{i,j,s_1} \wedge x_{i,j+1,s_2} \wedge x_{i,j+2,s_3} \wedge x_{i+1,j,s_4} \wedge x_{i+1,j+1,s_5} \wedge x_{i+1,j+2,s_6})$$

1.3 Aproximační algoritmy a schémata

Aproximační algoritmy

Definition: Optimalizační problém

$$(\mathcal{I}, \mathcal{F}, f, g)$$

- \mathcal{I} : množina vstupů
- \mathcal{F} : $\forall I \in \mathcal{I}$: $F(I)$ přípustná řešení
- f : $\forall I \in \mathcal{I} \forall S \in F(I)$: $f(I, S) \rightarrow \mathbb{R}$ účelová funkce
- g : min / max

Definition: Aproximační algoritmus

A je α -aproximační pro optimalizační problém pokud:

- Spočítá $S \in F(I)$ v polynomiálním čase
- $\forall I \in \mathcal{I}$: $f(I, S) \leq \text{ROPT}(I)$ pro minimalizaci

Algorithm: Christofides

1. W liché vrcholy MST T .
2. M minimální perfektní párování na W .
3. Vratíme průchod $T \uplus M$.

Observation: Christofides analýza

- Handshaking lemma \implies perfektní párování existuje.
- $d(T) \leq \text{OPT}$, $d(M_1) + d(M_2) \leq \text{OPT}$

Algorithm: Rand-SAT

1. Nastavíme proměnné uniformně náhodně.

Observation: Rand-SAT analýza

- $P[Y_j = 1] = 1 - 2^{-l} \geq \frac{1}{2}$
- $\text{OPT} \leq \sum w_j \implies \frac{1}{2} \text{OPT} \leq \sum w_j \mathbb{E}[Y_j] = \mathbb{E}[W]$

Algorithm: Max-Cut

1. Vyřešíme SDP

$$\max \frac{1}{2} \sum_E w_{i,j} (1 - V_{i,j}) : V_{i,i} = 1, V \succeq 0 .$$

2. Vybereme uniformně náhodný $r \in S^{n-1}$.
3. Vrátime $\{i \mid v_i r \geq 0\}$.

Observation: Max-Cut analýza

- $\forall x \in (0, \pi) : \frac{x}{\pi} \geq 0.878 \frac{1 - \cos x}{2}$
- $P[i, j \text{ rozdělené}] = \frac{\theta_{i,j}}{\pi}$
- $\mathbb{E}[W] = \sum \frac{\theta_{i,j}}{\pi} \geq 0.878 \sum \frac{1 - \cos \theta_{i,j}}{2} = 0.878 \sum \frac{1 - V_{i,j}}{2}$.

Aproximační schémata**Definition: (FPTAS)**

- **PTAS:** Množina $(1 - \epsilon)$ -aproximačních algoritmů pro všechna $\epsilon > 0$.
- **FPTAS:** PTAS kde každý algoritmus běží v čase $p(|I|, \frac{1}{\epsilon})$.

Algorithm: Knapsack pseudopoly

- Tabulka s řádky $0 \leq k \leq n$ a sloupci $0 \leq c \leq C = \sum c_i$.
- $A_k(c)$ minimální hmotnost batohu s předměty z $[k]$ s cenou c .

$$A_k(c) = \min \begin{cases} h_k + A_{k-1}(c - c_k) & \text{pokud } c \geq c_k \\ A_{k-1}(c) \end{cases}$$

$$A_0(0) = 0, A_0(1) = \dots = A_0(C) = \infty$$

- $B_k(c)$ může ukládat poslední přidaný předmět.
- $c^* := \max\{c : A_k(c) \leq H\}$
- $O(nC)$

Algorithm: Knapsack FPTAS

1. Odstraníme předměty těžší než H
2. $c_{\max} = \max c_i$
3. $M := \lceil \frac{n}{\epsilon} \rceil$
4. $\forall i \in [n] : \tilde{c}_i = \lfloor c_i \frac{M}{c_{\max}} \rfloor$

5. Vyřešíme dynamický program

Observation: Analýza

$$\tilde{C} \leq nM \in O\left(\frac{n^2}{\epsilon}\right) \implies O(n\tilde{C}) \in O\left(\frac{n^3}{\epsilon}\right)$$

- $\tilde{c}(\text{OPT}) = \sum_{i \in \text{OPT}} \tilde{c}_i = \sum_{i \in \text{OPT}} \left\lfloor c_i \frac{M}{c_{\max}} \right\rfloor \geq \left(\sum_{i \in \text{OPT}} c_i \frac{M}{c_{\max}} \right) - n = c(\text{OPT}) \frac{M}{c_{\max}} - n$
- $c(A) = \sum_{i \in A} c_i \geq \sum_{i \in A} \tilde{c}_i \frac{c_{\max}}{M} = \tilde{c}(A) \frac{c_{\max}}{M} \geq \tilde{c}(\text{OPT}) \frac{c_{\max}}{M}$
- $c(A) \geq \left(c(\text{OPT}) \frac{M}{c_{\max}} - n \right) \frac{c_{\max}}{M} \geq c(\text{OPT}) - \frac{nc_{\max}}{\epsilon} \geq c(\text{OPT}) - \epsilon c_{\max} \geq (1 - \epsilon)c_{\text{OPT}}$.

Chapter 2

Datové struktury

2.1 Vyhledávací stromy ((a,b)-stromy, splay stromy).

(a, b) -stromy

Definition: (a, b -strom)

$$2 \leq a, 2a - 1 \leq b$$

- Vnitřní vrcholy mají a až b potomků.
- Kořen má 2 až b potomků.
- Listy na stejné hladině.

Lemma:

Hloubka s n klíči je $\Omega(\log_b n)$, $O(\log_a n)$.

Proof:

- Minimální počty vrcholů po hladinách 0, 1, 2a, 2a², ... , minimální počty klíčů v hladinách 1, a-1, a-1, ...
- A_h minimální počet klíčů na hloubku h. Inverzní funkce dává maximální hloubku. Minimum analogicky.

$$A_h = 1 + \sum_{i \in [h-1]} 2a^{i-1}(a-1) = 2a^{h-1} - 1$$

Definition: Operace

- **Find:** $O(\log_a n \log_2 b) = O(\log n \frac{\log b}{\log a}) \in O(\log n)$
- **Insert:** $\theta(b \log_a n)$
 - Vkládáme na nejhlubší nalezenou vnitřní hladinu.
 - Pokud přeteče, štěpíme. Prostřední klíč dáme do rodiče a vrchol rozdělíme. Případně rekurzíme.
- **Delete:** $\theta(b \log_a n)$
 - Převědeme na mazání z nejhlubší vnitřní hladiny nahrazením následníkem.
 - Pokud podteče, slučujeme. Pokud máme malého sourozence, slučíme se s ním a s klíčem v rodiči. Pokud máme velké sourozence, vezmeme klíč z rodiče a do rodiče dáme klíč ze sourozence.

Theorem:

m insertů do prázdného (a, b) -stromu změní O(m) vrcholů.

Proof: Počet štěpení je nejvýš takový jako počet vrcholů na konci.

Theorem:

m insertů a deletů do prázdného (a, 2a) -stromu změní O(m) vrcholů.

Proof:

- $\Phi = \sum_{v \neq r} f(k(v))$, kde $f(k(v))$ je příspěvek vrcholu v s $k(v)$ klíči.

$$\bullet \text{ Zvolíme } f(k) = \begin{cases} 2 & k = a - 2 \\ 1 & k = a - 1 \\ 0 & \dots \quad \text{aby:} \\ 2 & k = 2a - 1 \\ 4 & k = 2a \end{cases}$$

- Konstantní změny způsobí konstantní změny: $|f(i) - f(i+1)| \in O(1)$.
- Slučování zdarma: $f(2a) \geq f(a) + f(a-1) + O(1)$.
- Štěpení zdarma: $f(a-2) + f(a-1) \geq f(2a-2) + O(1)$.

- Insert přidá klíč $O(1)$ a změní potenciál o $O(1)$. Štěpení amortizovaně zdarma.
- Delete smaže klíč $O(1)$ a půjčí si nejvýš jeden klíč $O(1)$. Slučování amortizovaně zdarma.

Splay stromy

Definition: Splay operace

1. **Zig:** $x : (C, y), y : (A, B) \rightarrow x : (A, y), y : (B, C)$.
2. **Zig-zig:** $x : (A, B), y : (x, C), z : (y, D) \rightarrow x : (A, y), y : (B, z), z : (C, D)$.
3. **Zig-zag:** $x : (B, C), y : (A, x), z : (y, D) \rightarrow x : (y, z), y : (A, B), z : (C, D)$

Definition: Potenciál

$$\Phi := \sum_{u \in V} r(u) \text{ pro } r(u) := \log_2 s(u) \text{ a } s(u) = |T(u)|.$$

Definition: Operace

- Cestu z kořene načítujeme rotacím. Ty se uamortizují na $O(\log n)$.
- **Find:** Splayujeme nejhlubší nalezený vrchol.
- **Insert:**
 - Pokud vrchol neexistuje, přidání listu l změní potenciál na cestě $v_1, \dots, v_k : s'(l) = 1, r'(l) = 0$.
 - Protože $s'(v_i) = s(v_i) + 1 \leq s(v_{i-1}) \implies r'(v_i) \leq r(v_{i-1})$, dostaneme

$$\Delta\Phi = r'(l) + \sum_{i \in [k]} r'(v_i) - r(v_i) \leq r'(v_1) - r(v_k) \in O(\log n).$$
- **Delete:**
 - Smazání listu nebo smazání rodiče jednoho vrcholu triviální.
 - Smazání rodiče dvou vrcholů: vyměníme za minimum podstromu a pak smažeme.

Theorem:

$$\text{Amortizovaná cena splaye je } \leq 3(r'(x) - r(x)) + 1 \in O(\log n)$$

Proof:

- V jedné rotaci se mění pouze rank rotovaných vrcholů.
- **Zig:** $r'(y) \leq r'(x), r(y) \geq r(x)$

$$A = r'(x) - r(x) + r'(y) - r(y) + 1 \leq 2r'(x) - 2r(x) + 1$$

- **Zig-zig:** $r'(y) \leq r'(x), r(y) \geq r(x), r(z) = r'(x)$

$$r(x) + r'(z) = \log s(x) + \log s'(z) \leq 2 \log(s(x) + s'(z)) - 2 \leq 2r'(x) - 2$$

$$A = r'(x) - r(x) + r'(y) - r(y) + r'(z) - r(z) + 2 \leq 3r'(x) - 3r(x) + 2$$

- **Zig-zag:** $r(y), r(w) \geq r(x)$

$$\begin{aligned} r'(w) - r'(y) &= \log s'(w) - \log s'(y) \leq 2 \log(s'(w) + s'(y)) - 2 \leq 2r'(x) - 2 \\ A &\leq r'(x) - r(x) + r'(y) - r(y) + r'(w) - r(w) + 2 \leq 3r'(x) - 3r(x) \end{aligned}$$

- Nejvýš jeden zig za splay.

$$3 \left(\sum_{i \in [k]} r_i(x) - r_{i-1}(x) \right) + 1 = 3(r_k(x) - r_0(x)) + 1$$

Corollary:

m splayů na n vrcholech trvá $O((n+m) \log n)$

Proof:

$$\begin{aligned} \sum_{i \in [m]} R_i &= \sum_{i \in [m]} A_i + \Phi_0 - \Phi_m, \\ \sum_{i \in [m]} A_i &\in O(m \log n), \\ \Phi_0 - \Phi_m &\in O(n \log n). \end{aligned}$$

2.2 Haldy (regulární, binomiální).

	d -ary	Fibonacci
Insert	$O(\log_d n)$	$O(1)$
Min	$O(1)$	$O(1)$
ExtractMin	$O(d \log_d n)$	$O(\log n)$
Increase	$O(d \log_d n)$	$O(\log n)$
Decrease	$O(\log_d n)$	$O(1)$
Delete	$O(d \log_d n)$	$O(\log n)$
Build	$O(n)$	$O(n)$

d -regulární halda

Definition: Operace

- **Insert:** Přidáme na konec a vybubláme.
- **Delete:** Prohodíme s posledním prvkem a zabubláme.
- **Min:** Hodnota kořene.
- **ExtractMin:** Kořen prohodíme s posledním prvkem a zabubláme.
- **Increase:** Změníme hodnotu a zabubláme.
- **Decrease:** Změníme hodnotu a vybubláme.

Binomická halda

Definition: Binomický strom

B_k řádu k je kořen s podstromy B_0, \dots, B_{k-1} .

Observation: Binomický strom

1. B_k má 2^k vrcholů, výšku k a max. stupeň k .
2. B_k vytvoříme tak, že dáme B_{k-1} další B_{k-1} jako poslední dítě.
3. B_k je kostra k -hyperkostky.

Definition: Binomická halda

Les T_1, \dots, T_l binomických stromů splňujících:

1. $r(T_i) < r(T_{i+1})$
2. Každý vrchol obsahuje jediný prvek.
3. Každý strom má haldové seřazení.

Observation: Binomická halda

1. $r(T_i) \leq \log n \implies \leq 1 + \log n$ stromů
2. Přítomnost stromů podle bitů $\langle n \rangle_2$.

Definition: Reprezentace vrcholu

1. Prvek a priorita
2. Rank jako počet dětí
3. Pointer na první dítě
4. Pointer na rodiče
5. Pointery na dva vedlejší sourozence (cyklicky).
6. Stromy spojuje pseudokořen

Definition: Operace

- **Merge:** $O(\log n)$ Sléváme stromy od nejmenších.
 - Jediný daného řádu rovnou do výsledné haldy.
 - Dva stejného řádu sloučíme pod menší z kořenů.
 - Pro tři stejné sloučíme dva z nich a třetí rovnou do výsledné haldy.
- **Insert:** $O(\log n)$ Vytvoříme B_0 a sloučíme.
- **Delete:** $O(\log n)$ Decrease na $-\infty$ a ExtractMin.
- **Min:** $O(\log n)$ Najdeme nejmenší kořen.
- **ExtractMin:** $O(\log n)$
 - Najdeme minimální kořen.
 - Odstraníme kořen, strom se rozpadne na haldu.
 - Sloučíme haldy.
- **Increase:** $O(\log n)$ Delete a insert.
- **Decrease:** $O(\log n)$ Vybubláváme uvnitř stromu.
- **Build:** $O(n)$ amortizovaně
 - Vkládáme prvky po jednom.
 - V půlce případů $O(1)$. Každé spojení stromů odstraní jeden strom, takže umartizujeme.

Definition: Lazy operace

- **Merge:** $O(1)$ Přidáme spoj.
- **Insert:** $O(1)$
- **Konsolidace:** $O(t + \log n)$
 - Připravíme $\log n$ chlívků.
 - Přidáváme stromy do chlívků. Pokud je chlívěk zabraný, spojíme.
 - Každé spojení odstraní strom, proto $O(t)$ spojení.
- **ExtractMin:** $O(t + \log n)$
 1. Konsolidujeme
 2. Najdeme minimální kořen

3. Odstraníme kořen.
4. Merge s haldou.

- **Build:** $O(n)$

Definition: *Lazy potenciál*

$\Phi :=$ počet stromů v haldách.

- **Merge:** $O(1)$
- **Insert:** $O(1)$
- **Konsolidace:** $O(\log n)$ protože $\Delta\Phi \leq \log n - t$.
- **ExtractMin:** $O(\log n)$ vyjma konsolidace.

Fibonacci halda

Definition: *Decrease*

- Pokud porušíme vztah s rodičem, odrůzneme ho jako nový strom.
- Pokud rodič není kořen a je neoznačený, označíme.
- Pokud rodič není kořen a je označený, odrůzneme ho a pokračujeme na jeho rodiče.
- Pokud smažeme kořen stromu, smažeme značky dětí.
- Proto každý nekořen ztratí nejvýš jedno dítě.

Observation: *Fibonacciho čísla*

1. $F_n \in \theta(\varphi^n)$ pro $\varphi = \frac{1+\sqrt{5}}{2} \approx 1.618$
2. $F_0 + \dots + F_k = F_{k+2} - 1$

Lemma:

Podstrom řádu k má aspoň F_{k+1} vrcholů,
proto rank je $O(\log n)$.

Proof:

- Indukcí podle hloubky.
1. Listy mají rank 0 a jeden vrchol.
 2.
 - x_1, \dots, x_n děti u v pořadí přidání pod něj.
 - r_1, \dots, r_n jejich ranky.
 - $\forall i \geq 2 : r_i \geq i - 2$
 - * Některé ranky můžou chybět.
 - * Když jsme přidávali x_i , u měl aspoň $i - 1$ dětí.
 - * Spojování spojuje stejné ranky, takže x_i měl rank aspoň $i - 1$.
 - * Od té doby x_i nebyl kořenem, ztratil nejvýš jedno dítě, proto má rank aspoň $i - 2$.
 - Z IP mají stromy aspoň $F_2, F_2, F_3, \dots, F_k$ vrcholů $+1$ za u .

$$F_2 + F_2 + F_3 + \dots + F_k + 1 \geq F_0 + \dots + F_k + 1 = F_{k+2}.$$

Observation: *Analýza*

$\Phi :=$ počet stromů v haldách + dvojnásobek označených vrcholů.

- **ExtractMin:** $O(\log n)$
- **Cut:** $O(1)$
 - Buď nekaskádujeme a přidáme $+3$.
 - Nebo kaskádujeme. Přidáme $+1$ za nový strom a -2 za označený vrchol.
- **Merge, Insert, Decrease:** $O(1)$
- **Delete:** Drahé.

2.3 Hašování, řešení kolizí, univerzální hašování, výběr hašovací funkce.

Definition: *c-univerzální rodina*

Rodina $\mathcal{H} : \mathcal{U} \rightarrow [m]$ je *c-univerzální*,
pokud $\forall x, y \in \mathcal{U}, x \neq y : P_{h \in \mathcal{H}}[h(x) = h(y)] \leq \frac{c}{m}$.

Definition: *(k, c)-nezávislá rodina*

Rodina $\mathcal{H} : \mathcal{U} \rightarrow [m]$ je *(k, c)-nezávislá*,
pokud $\forall x_1, \dots, x_k \in \mathcal{U}$ různá a $\forall i_1, \dots, i_k \in [m]$:
 $P_{h \in \mathcal{H}}[h(x_1) = i_1 \wedge \dots \wedge h(x_k) = i_k] \leq \frac{c}{m^k}$.

Lemma: K

- $r \geq 2km$
- $\mathcal{H} : \mathcal{U} \rightarrow [r]$ je *(k, c)-nezávislá*

$\mathcal{H} \bmod m$ je *(k, 2c)-nezávislá*.

Proof:

- Máme nejvýš $\lceil \frac{r}{m} \rceil \leq \frac{r+m-1}{m}$ možností pro každé z i_1, \dots, i_k .

$$\frac{c}{r^k} \left(\frac{r+m-1}{m} \right)^k = \frac{c}{m^k} \left(\frac{r+m-1}{r} \right)^k \leq \frac{c}{m^k} \left(1 + \frac{m}{r} \right)^k \leq \frac{ce \frac{mk}{r}}{m^k} \leq \frac{2c}{m^k}$$

Hashovací funkce

Definition: *Lineární hashovací funkce*

$\mathcal{L} := \{h_{a,b} | a \in [p]_0 \setminus \{0\} \wedge b \in [p]_0\}$ pro $h_{a,b}(x) = (ax + b \bmod p) \bmod m$.

Observation: *Lineární hashovací funkce*

\mathcal{L} je 1-univerzální.

Proof:

- Pro $x \neq y$ a a, b jsou jednoznačně určené $r = ax + b \bmod p$, $s = ay + b \bmod p$.
- Pro fixní r máme $\lceil \frac{p}{m} \rceil - 1 \leq \frac{p+m-1}{m} - 1 = \frac{p-1}{m}$ špatných s . Celkem $\frac{p(p-1)}{m}$ špatných dvojic, pravděpodobnost jedné $\frac{1}{m}$.

Definition: *Polynomiální hashovací funkce*

$\mathcal{P}_k := \{h_t | t \in \mathbb{Z}_p^d\}$ pro $h_t(x) = \sum_{i \in [k]_0} t_i x^i$ a \mathbb{Z}_p těleso.

Observation: *Polynomiální hashovací funkce*

- \mathcal{P}_k je *(k, 1)-nezávislá*.
- Složitost $O(d)$
- $p \geq 2km \implies \mathcal{P}_k \bmod m$ je *(k, 2)-nezávislá*.

Proof:

- Mějme $x_1, \dots, x_k \in \mathbb{Z}_p$ různá a $a_1, \dots, a_k \in \mathbb{Z}_p$ chlívky.
- Právě jeden polynom stupně nejvýš k splňuje $\forall i \in [k] : h(x_i) = a_i$. Proto pravděpodobnost $\frac{1}{p^k}$.

Definition: *Tabulační hašování*

$\mathcal{T} : [2^{kt}] \rightarrow [2^m] : h(x) = \bigotimes_{i \in [t]_0} T_i[x \langle ik : (i+1)k \rangle]$

- Vygenerujeme t tabulek T_0, \dots, T_{t-1} s 2^k řádky a m sloupci.
- Pro aspoň dvě tabulky je 3 -nezávislá rodina.

Definition: *Skalární součin*

$$\mathcal{S} = \{h_{t,b} \mid t \in \mathbb{Z}_p^d, b \in \mathbb{Z}_p\} \text{ pro } h_{t,b}(x) = t^T x + b$$

Observation: *Skalární součin*

- \mathcal{S} je $(2, 1)$ -nezávislá.
- Složitost $O(d)$
- $p \geq 4m \implies \mathcal{S} \text{ mod } m$ je $(2, 2)$ -nezávislá.

Proof:

- $a^T x_1 + b = y_1, a^T x_2 + b = y_2, d := x_1 - x_2 \implies a^T d = y_1 - y_2$
- $\exists j : d_j \neq 0 \implies a_j = \frac{1}{d_j}(y_1 - y_2 - a_j^T d_j)$
- Proto máme nejvýš p^{k-1} řešení z p^{k+1} funkcí.

Řešení kolizí

Definition: *Separované řetězce*

- Tabulka obsahuje x_1, \dots, x_n . Vybíráme h uniformně náhodně z c -univerzální rodiny.
- Neúspěšné hledání v přihrádce ověří průměrně $\frac{cn}{m}$ prvků. Úspěšné hledání x_i má složitost jako insert x_i .
- **Insert** ověří že y ještě v přihrádce není.
- **Find** prohledá přihrádku.
- **Delete** prohledá přihrádku.

Observation: *Separované řetězce*

Pro $m \in \Omega(n)$ máme $O(1)$.

Definition: *Kukaččí funkce*

- Tabulky T_1, T_2 a funkce $h_1 : \mathcal{U} \rightarrow [m], h_2 : \mathcal{U} \rightarrow [m]$.
- **Lookup:** x je v $T_1[h_1(x)]$ nebo v $T_2[h_2(x)]$.
- **Insert:**
 - Vložíme x do $T_1[h_1(x)]$.
 - Pokud tam byl y , opakujeme postup s $T_2[h_2(y)]$.
 - Po timeoutu přehashujeme.
- **Delete:** Smažeme prvek v jednom z polí.

Observation: *Kukaččí funkce*

- $\epsilon > 0$
- $m \geq (2 + \epsilon)n$
- $t = \lceil 6 \log n \rceil$
- h_1, h_2 uniformně náhodně z t -nezávislého systému

Insert s timeoutem t má $\mathbb{E}[\text{čas}] \in O(1)$.

Definition: *Otevřená adresace*

- V každé buňce jeden prvek.
- Přístupová posloupnost $f : \mathcal{U} \times [m] \rightarrow [m]$
- **Insert:** Postupně zkouší buňky a uloží do první volné.
- **Find:** Postupně zkouší buňky dokud nenajde prvek nebo prázdnou.
- **Delete:** Pomníčky.

Definition: *Lineární přidávání*

- Přídávací sekvence $h(x) + i \pmod m$.
- WLOG $n \leq \frac{m}{3}$, maximalizuje počet přístupů.
- Bloky B velikosti 2^t na indexech podle stromu.

Observation: *Lineární přidávání*

- Kritický blok je $z > \frac{2}{3}$ plný. $P[B \text{ kritický}] \leq (\frac{\epsilon}{4})^{\frac{|B|}{3}}$.
 - x_1, \dots, x_n vložené prvky, X_1, \dots, X_n indikátory $h(x_i) \in B$
 - $X = \sum X_i \implies \mathbb{E}[X] = \sum \mathbb{E}[X_i] = n \frac{|B|}{m} \leq \frac{|B|}{3}$
 - $P[X > 2 \frac{|B|}{3}] < (\frac{\epsilon}{4})^{\frac{|B|}{3}}$ z Černoffa.
- R cyklický běh délky $2^{t+1} \implies$ jeden z B_0, \dots, B_3 nejlevějších bloků velikosti 2^t v R je kritický.
- R běh s $h(x)$, $|R| \in [2^{t+2}, 2^{t+3}) \implies$ jeden z 12 bloků $|B| = 2^t$, kde devátý obsahuje $h(x)$, je kritický.
- $P[|R| \in [2^{t+2}, 2^{t+3})] \leq P[\text{nějaký kritický}] \leq 12P[\text{specifický kritický}] \leq 12(\frac{\epsilon}{4})^{\frac{|B|}{3}}$

Theorem: *Lineární přidávání*

- $m = 2^k$
- $n \leq \frac{m}{3}$
- $h : \mathcal{U} \rightarrow [m]$ uniformně náhodná

$$\mathbb{E}[\# \text{ počet buněk navštívený při hledání } x] \in O(1)$$

Proof:

- BÚNO $n = \lfloor \frac{m}{3} \rfloor$. Běh R obsahuje $h(x)$.

$$\begin{aligned} \mathbb{E}[|R|] &= \mathbb{E}[|R| \mid |R| \leq 3] P[|R| \leq 3] + \sum_{t \geq 0} \mathbb{E}[|R| \mid |R| \in [2^{t+2}, 2^{t+3})] P[|R| \in [2^{t+2}, 2^{t+3})] \\ &\leq 3 + \sum_{t \geq 0} 2^{t+3} 12 (\frac{\epsilon}{4})^{\frac{|B|}{3}} \leq 3 + 96 \sum_{i \geq 0} i (\frac{\epsilon}{4})^{\frac{i}{3}} \in O(1) \end{aligned}$$

Chapter 3

Nelineární programování

3.1 Vlastnosti konvexních množin a konvexních funkcí.

Definition: Konvexita

- $S \subseteq \mathbb{R}^n$ je konvexní pokud $\forall x, y \in S : \overline{xy} \in S$.
- $f : M \rightarrow \mathbb{R}$ je konvexní pokud ekvivalentně:
 1. $\forall x_1, x_2 \in M \forall \lambda \in [0, 1] : f(\lambda x_1 + (1 - \lambda)x_2) \leq \lambda f(x_1) + (1 - \lambda)f(x_2)$
 2. $\{(x, z) \in \mathbb{R}^{n+1} : x \in M, z \geq f(x)\}$ je konvexní
 3. $f(x_2) - f(x_1) \geq \nabla f(x_1)^T(x_2 - x_1)$
 4. $\forall x \in M : \nabla^2 f(x) \succeq 0$

Observation: Konvexita

- Množiny uzavřené na průnik.
- Funkce uzavřené na součet a škálování.

Theorem: Separační věta

1. $C, D \subseteq \mathbb{R}^n$ konvexní, $C \cap D = \emptyset \implies$ oddělitelné.
2. Uzavřené a aspoň jedna omezená \implies oddělitelné striktně.

Theorem: Konvexní optimalizace

$\min f(x) : x \in M$ pro f, M konvexní:

1. Lokální optima jsou globální.
2. Optimální množina je konvexní.
3. f ryze konvexní \implies nejvýš jedno optimum.

3.2 Zobecnění konvexních funkcí.

Definition: Zobecněná konvexita

$f : M \rightarrow \mathbb{R}$ pro $\emptyset \neq M$ konvexní je:

- **Kvazikonvexní:**

$$\forall \lambda \in [0, 1] \forall x_1, x_2 \in M : f(\lambda x_1 + (1 - \lambda)x_2) \leq \max(f(x_1), f(x_2))$$

- **Explicitně Kvazikonvexní:** kvazikonvexní a

$$\forall \lambda \in [0, 1] \forall x_1, x_2 \in M, f(x_1) \neq f(x_2) : f(\lambda x_1 + (1 - \lambda)x_2) < \max(f(x_1), f(x_2))$$

• **Pseudokonvexní:**

$$\forall x_1, x_2 \in M : \nabla f(x_1)^T(x_2 - x_1) \geq 0 \implies f(x_2) \geq f(x_1)$$

Theorem: Hierarchie

1. Konvexní \implies explicitně kvazikonvexní \implies kvazikonvexní.
2. Konvexní \implies pseudokonvexní \implies kvazikonvexní.

Proof:

1. $f(\lambda x_1 + (1 - \lambda)x_2) \leq \lambda f(x_1) + (1 - \lambda)f(x_2) \leq \max(f(x_1), f(x_2))$
2. Spor a MVT.

Theorem: Charakterizace sublevelem

$$f \text{ je kvazikonvexní} \iff \forall \alpha \in \mathbb{R} : L_\alpha = \{x \mid f(x) \leq \alpha\} \text{ je konvexní.}$$

Theorem: Charakterizace gradientem

$$\text{Diferenciovatelná } f \text{ je kvazikonvexní} \iff \forall x_1, x_2 : f(x_1) \geq f(x_2) \implies \nabla f(x_1)^T(x_2 - x_1)$$

Proof:

- \implies Definice gradientu.
 \Leftarrow Spor a MVT.

Theorem: Globální optima

$$f \text{ explicitně kvazikonvexní} \implies \text{lokální optima jsou globální optima}$$

Proof:

- Pro spor $\exists y$ a $x = \lambda x^* + (1 - \lambda)y$.
- Pak pro malé λ platí $f(x) \leq \max(f(x^*), f(y))$.

Theorem: Množina optim

$$f \text{ kvazikonvexní} \implies \text{množina optim je } L_{f(x)} \text{ konvexní.}$$

3.3 Nutné a postačující podmínky optimality pro volné a vázané extrémní úloh nelineárního programování.

Theorem: Podmínky optimality

1. x^* lokální minimum:

$$\begin{aligned} - f \in \mathcal{C}^1 \text{ na } B(x^*, \epsilon) &\implies \nabla f(x^*) = 0 \\ - f \in \mathcal{C}^2 \text{ na } B(x^*, \epsilon) &\implies \nabla^2 f(x^*) \succeq 0 \end{aligned}$$

2. $f \in \mathcal{C}^2$ na $B(x^*, \epsilon)$, pak $\nabla f(x^*) = 0 \wedge \nabla^2 f(x^*) \succ 0 \implies x^*$ ostré lokální minimum.

Theorem: Explicitně kvazikonvexní podmínka optimality

$$\begin{aligned} &f(x) \text{ diferenciovatelná, explicitně kvazikonvexní,} \\ &\text{pak } x \in M \text{ optimum pokud } \forall y \in M \setminus \{x\} : \nabla f(x)^T(y - x) > 0. \end{aligned}$$

Theorem: Pseudokonvexní podmínka optimality

$$f \text{ pseudokonvexní a } \nabla f(x) = 0 \implies x \text{ optimum.}$$

3.3. NUTNÉ A POSTAČUJÍCÍ PODMÍNKY OPTIMALITY PRO VOLNÉ A VÁZANÉ EXTRÉMY ÚLOH NELINEÁRNÍ

Theorem: Pseudokonvexní podmínka optimality

f diferenciovatelná a pseudokonvexní,
pak $x \in M$ je optimum $\iff \forall y \in M : \nabla f(x)^T(y - x) > 0$.

Lemma: Gordanova

$Ax < 0$ řešitelná $\iff A^T y = 0, y \geq 0$ neřešitelná.

Lemma: Fritz John

x lokální minimum $\implies \nexists d : \nabla f(x)^T d < 0 \wedge \forall i \in I(x) : \nabla g_i(x)^T d < 0$

Proof:

- $\exists d \implies 0 > \nabla f(x)^T d = \lim_{\alpha \rightarrow 0^+} \frac{f(x + \alpha d) - f(x)}{\alpha} \implies f(x + \alpha d) > f(x)$ pro malé α .
- To samé pro omezení \implies spor s optimalitou.

Theorem: Fritz John

x lokální optimum $\implies \exists \mu, \lambda \geq 0$:

1. $\mu \nabla f(x) + \lambda^T g(x) = 0$
2. $\lambda^T g(x) = 0$

Proof:

- Lemma a Gordanova věta.

Definition: KKT podmínky

$\exists \lambda \geq 0$:

1. $\nabla f(x) + \lambda^T g(x) = 0$
2. $\lambda^T g(x) = 0$

Theorem: KKT LNZ

- x lokální optimum
- $\{g_i(x)\}_{i \in I(x)}$ LNZ

Pak platí KKT.

Theorem: KKT Slater

- x lokální optimum
- $f, \{g_i(x)\}_{i \in I(x)}$ konvexní
- \exists Slater point

Pak platí KKT.

Proof:

- Z konvexity $\nabla g_i(x)(x^s - x) \leq g_i(x^s) - g_i(x) < 0$ a obdobně pro f .
- Pro $d = x^s - x$ z Gordanovy věty $\nabla g(x)^T \lambda = 0, (\lambda, \mu) \geq 0$ a z Fritze-Johna $\mu \neq 0$.

Theorem: Postačující KKT

- $x \in M$ splňuje KKT
- f pseudokonvexní

- $\{g_i(x)\}_{i \in I(x)}$ kvazikonvexní

Pak x je optimum.

Proof:

- $y \in M \implies \forall j \in I(x) : g_j(y) \leq 0 = g_j(x) \implies \nabla g_j(x)^T (y - x) \leq 0$ z kvazikonvexity.
- Aplikujeme pseudokonvexitu na

$$\nabla f(x)^T (y - x) = -\lambda^T \nabla g(x)^T (y - x) = -\sum_{j \in I(x)} \lambda_j \nabla g_j(x)^T (y - x) \geq 0 .$$

3.4 Kvadratické programování.

Problem: Kvadratické programování

$$\min x^T Q x + q^T x : x \in M \text{ pro } M \text{ konvexní polyedr.}$$

Theorem: Těžkost

$$\max x^T Q x : x \in M \text{ je NP-těžká.}$$

Proof: Vyjádříme set partition:

$$\max \|x\|^2 : \alpha^T x = 0, x \in [-1, 1] .$$

3.5 Semidefinitní programování.

Problem: Semidefinitní programování

- **P:** $f^* := \min c^T x : A_0 + \sum x_i A_i \preceq 0, A_i$ symetrické
- **D:** $d^* := \max \text{tr}(A_0 Z) : Z \succeq 0, \forall i \in [n] : c_i + \text{tr}(A_i Z) = 0$
 - $L(x, Z) := c^T x + \text{tr} \left(\left(A_0 + \sum x_i A_i \right) Z \right) = \text{tr}(A_0 Z) + \sum (c_i + \text{tr}(A_i Z)) x_i$
 - $L(Z) = \inf_{x \in \mathbb{R}^n} L(x, Z) = \begin{cases} \text{tr}(A_0 Z) & \forall i \in [n] : c_i + \text{tr}(A_i Z) = 0 \\ -\infty & \end{cases}$

Example: Semidefinitní programy

- **LP:**

$$\begin{pmatrix} A_{1,*}x - b_1 & \dots & 0 \\ & \ddots & \\ 0 & \dots & A_{m,*}x - b_m \end{pmatrix} \preceq 0$$

- **Kuželové QP:**

$$\|x\|_2 \leq z \iff \begin{pmatrix} zI_n & 0 \\ 0 & z - \frac{1}{2}x^T x \end{pmatrix} \approx \begin{pmatrix} zI_n & x \\ x^T & z \end{pmatrix} \succeq 0$$

- **Vlastní čísla**

$$\lambda_{\max} = \min z : Iz \succeq A .$$

- **Max-cut APX**

Theorem: Slabá dualita

$$Z \succeq 0 \implies d^* = L(Z) \leq f^*$$

Proof:

- Použijeme $A, B \succeq 0 \implies \text{tr} AB \geq 0$. Protože $A = LL^T$ a $L^T BL \succeq 0$, máme $\text{tr}(AB) = \text{tr}(L^T BL) \geq 0$.
- Pak $Z \succeq 0 \implies \forall x \in M : \text{tr} \left(\left(A_0 + \sum x_i A_i \right) Z \right) \leq 0 \implies L(x, Z) \leq f(x)$ a proto

$$L(Z) = \inf_{x \in \mathbb{R}^n} L(x, Z) \leq \inf_{x \in M} L(x, Z) \leq \inf_{x \in M} f(x) = f^* .$$

Corollary:

Z konvexity můžeme použít Slatera $\exists x \in \mathbb{R}^n : A_0 + \sum x_i A_i \prec 0$.

3.6 Dualita v nelineárním programování.

Definition: Duální úloha

- **P:** $f^* = \min f(x) : g(x) \leq 0, h(x) = 0, x \in D \neq \emptyset$
- $L(x, \lambda, \mu) = f(x) + \lambda^T g(x) + \mu^T h(x)$
- $L(\lambda, \mu) = \inf_{x \in D} L(x, \lambda, \mu)$
- **D:** $\max L(\lambda, \mu) : \lambda \geq 0, \mu \in \mathbb{R}^n$

Theorem: Slabá dualita

$$d^* \leq f^*$$

Proof:

- $\forall \lambda \geq 0 \forall \mu \in \mathbb{R}^n \forall x \in M :$

$$L(x, \lambda, \mu) = f(x) + \lambda^T g(x) + \mu^T h(x) \leq f(x)$$

- Proto

$$L(\lambda, \mu) = \inf_{x \in D} L(x, \lambda, \mu) \leq \inf_{x \in M} L(x, \lambda, \mu) \leq f^*$$

- Tedy $\forall \lambda \geq 0 \forall \mu \in \mathbb{R}^n : L(\lambda, \mu) \leq f^*$

Theorem: Silná dualita

- $f, \{g_j\}_{j \in J}$ konvexní
- $\{h_i\}_{i \in I}$ lineární
- D konvexní
- \exists Slater point

$$d^* = f^*$$

Proof:

- BÚNO $f^* \in \mathbb{R}$, $h(x) = Ax = 0$ a A má LNZ řádky.
- Množiny

$$A = \{(u, v, w) \mid \forall x \in D : u \geq g(x), v \geq h(x), w \geq f(x)\}$$

$$B = \{(0, 0, s) \mid s < f^*\}$$

jsou konvexní a $A \cap B = \{(0, 0, f^*)\}$.

- Oddělíme s $\lambda^T u + \mu^T v + \nu w = \alpha$ pro $(\lambda, \mu, \nu) \neq 0$:

$$\forall (u, v, w) \in A : \lambda^T u + \mu^T v + \nu w \geq \alpha$$

$$\forall (u, v, w) \in B : \lambda^T u + \mu^T v + \nu w \leq \alpha .$$

- Pokud $\lambda < 0$, pak $(g(x^s) + \gamma, h(x^s), f(x^s)) \in A$ pro $\gamma > 0$ neomezená, spor s α . Obdobně $\nu \geq 0$.
- Pro $(0, 0, f^*) \in B$ platí $\nu w = \nu f^* \leq \alpha$ a dosazením

$$\forall (u, v, w) \in A : \nu w \geq \alpha \geq \nu f^* ,$$

$$\text{tedy } \forall x \in D : \lambda^T g(x) + \mu^T h(x) + \nu f(x) \geq \nu f^* .$$

1. $\nu > 0 \implies \forall x \in D : f^* \leq \frac{\lambda^T}{\nu} g(x) + \frac{\mu^T}{\nu} h(x) + f(x) = L(\nu, \frac{\lambda}{\nu}, \frac{\mu}{\nu})$ a $d^* \geq L(\frac{\lambda}{\nu}, \frac{\mu}{\nu}) \geq f^*$.
2. $\nu = 0 \implies \forall x \in D : \lambda^T g(x) + \mu^T h(x) \geq 0 \implies \lambda^T g(x^s) \geq 0 \implies \lambda = 0 \wedge \mu \neq 0 \implies \forall x \in D : \mu^T h(x) \geq 0$. Z linearit y a $\mu^T h(x^s) = 0$ máme $h(x) = 0$, ale $0 = \mu^T h(x) = \mu^T (Ax - b)$ je ve sporu s linearitou.

Theorem: Analýza citlivosti

$$\text{Silná dualita} \implies f^*(u, v) \geq f^*(0, 0) - (\lambda^*)^T u - (\mu^*)^T v ,$$

$$\text{kde } f(u, v) = \min f(x) : g(x) \leq u, h(x) = v, x \in D .$$

Proof:

- $f^* = f^*(0, 0) = L(\lambda^*, \mu^*) = d^* = \inf_{x \in D} f(x) + (\lambda^*)^T g(x) + (\mu^*)^T h(x)$
- $M_{u,v} \subseteq D \implies \forall x \in M_{u,v} : \leq f(x) + (\lambda^*)^T g(x) + (\mu^*)^T v$
- Ale pak $\forall x \in M_{u,v} : \leq f(x) + (\lambda^*)^T g(x) + (\mu^*)^T h(x) \leq f^*(0, 0) \leq f^*(u, v) + (\lambda^*)^T u + (\mu^*)^T v$

Corollary:

$$\text{Silná dualita a } f^*(u, v) \text{ diferenciovatelná,}$$

$$\text{pak } \frac{\partial}{\partial u_i} f^*(u, v) = -(\lambda^*)_i \text{ a } \frac{\partial}{\partial v_j} f^*(u, v) = -(\mu^*)_j .$$

Example: Efektivní úloha bez duality

$$\min x^T Qx + q^T x : \|x\| \leq 1$$

- NP-těžké pro $\|x\|_2 \leq 1$, jinak lehké.

3.7 Metody řešení úloh na volný a vázaný extrém, včetně penalizačních a bariérových metod.

NEPODMÍNĚNÁ OPTIMALIZACE

Definition: Globální konvergence

$$\text{Optimalizační metoda je globálně konvergentní pokud}$$

$$\forall x^0 \in \mathbb{R}^n : \liminf_{k \rightarrow \infty} \|\nabla f(x_k)\| = 0 .$$

SPÁDOVÉ SMĚRY

Algorithm: Spádové směry

1. Vybereme spádový směr d_k aby $d_k^T \nabla f(x_k) < 0$ nebo $\cos \theta_k = -\frac{d_k^T \nabla f(x_k)}{\|d_k\| \|\nabla f(x_k)\|} > 0$.
2. Vybereme α_k minimalizací jednorozměrné $\Phi(\alpha) := f(x_k + \alpha d_k)$ nebo aby $f(x_k + \alpha_k d_k) < f(x_k)$.

Algorithm: Největší spád

$$d_k = -\nabla f(x_k)$$

Observation: Největší spád

1. Globálně konvergentní

3.7. METODY ŘEŠENÍ ÚLOH NA VOLNÝ A VÁZANÝ EXTRÉM, VČETNĚ PENALIZAČNÍCH A BARIÉROVÝCH M

2. Pomalé

Algorithm: Newtonova metoda

- Z Taylorova rozvoje

$$f(x_k + d) \approx m_k(d) := f(x_k) + d^T \nabla f(x_k) + \frac{1}{2} d^T \nabla^2 f(x_k) d$$

- Pro $\nabla^2 f(x_k) \succ 0$ hledáme d pro $\alpha = 1$ jako $\operatorname{argmin} m_k(d)$. Položením derivace rovné nule

$$d_k = -(\nabla^2 f(x_k))^{-1} \nabla f(x_k).$$

Observation: Newtonova metoda

1. Potřebujeme Hessián
2. Není globálně konvergentní
3. Konverguje kvadraticky

Algorithm: Kwazinewtinovské metody

$$B_k \approx \nabla^2 f(x_k)$$

TRUST REGION

Algorithm: Trust region

- Aproximujeme f . Udržujeme poloměr Δ_k , ve kterém aproximaci věříme.
- Minimalizujeme aproximaci

$$\operatorname{argmin} m_k(x_k + d) : \|d\| \leq \Delta_k.$$

Volíme $d := -B_k^{-1} \nabla f(x_k)$ pokud $\|d\| \leq \Delta_k$. (A)

- Poměr reálné a modelované redukce $\rho_k := \frac{f(x_k) - f(x_k + d_k)}{m_k(0) - m_k(d_k)}$.

- a) $\rho_k \approx 1 \implies$ dobrá shoda, zvětšujeme.
- b) $\rho_k \approx 0 \implies$ špatná shoda, zmenšujeme.
- c) $\rho_k < 0 \implies f$ rostoucí, zamítáme.
- d) Jinak necháváme

0. $\bar{\Delta} > 0$, $\Delta_0 \in (0, \bar{\Delta})$, $\mu \in [0, \frac{1}{4})$

1. $\forall k \geq 0$:

2. Pokud $\rho_k < \frac{1}{4}$, pak $\Delta_{k+1} = \frac{1}{4} \Delta_k$

3. Jinak pokud $\rho_k > \frac{3}{4}$ a $\|d_k\| = \Delta_k$, pak $\Delta_{k+1} = \min(2(\Delta_k), \bar{\Delta})$

4. Jinak $\Delta_{k+1} = \Delta_k$

5. Pokud $\rho_k > \mu$, pak $x_{k+1} = x_k + d_k$

6. Jinak $x_k = x_k$.

KONJUGOVANÉ GRADIENTY

Algorithm: Konjugované gradienty

- Pro $A \succ 0$ řešíme $Ax = b$, tedy $\min \|Ax - b\|_2^2$.

PODMÍNĚNÁ OPTIMALIZACE

AKTIVNÍ PODMÍNKY

Algorithm: *Aktivní podmínky*

- Podobné simplexové metodě.
- Pro $K := \{j \in [m] \mid g_i(x_k) = 0\}$ řešíme pomocnou úlohu

$$\min f(x) : h(x) = 0, g_K(x) = 0 .$$

- Nové aktivní podmínky přidáme do K .
- Lokální optimum x^* splňuje KKT podmínky

$$\nabla f(x^*) + \mu^T \nabla h(x^*) + \lambda^T \nabla g_K(x^*) = 0 .$$

- Pokud $\lambda_j \geq 0$, přidáme j do K , v opačném případě odstraníme.

PENALIZAČNÍ METODA

Algorithm: *Penalizační metoda*

- Řešíme $\min f(x) : x \in M$ pro f spojitou a $M \neq \emptyset$ uzavřenou.
- Pro **penalizační funkci** $p(x) \begin{cases} = 0 & x \in M \\ > 0 & x \notin M \end{cases}$ a $c > 0$ přeformulujeme na $\min g(x)$ pro $g(x) := f(x) + cp(x)$.
- Můžeme c zvětšovat jako $c_k \rightarrow \infty$.

Example: *Penalizační funkce*

- $g(x) \leq 0 \rightarrow p(x) := \sum \max(0, g_j(x))^2$
- $h(x) = 0 \rightarrow p(x) := \sum h_j(x)^2$

Theorem: *Penalizační metoda*

Pokud optimum x^k konvergují k x^* , pak x^* je optimum původní úlohy.

Proof:

- Pro $x^* \notin M \implies \exists k^* \forall k \geq k^* : x_k \notin M$, proto $g(x_k) \rightarrow \infty$!
- Jinak $\exists x' \in M : f(x') < f(x^*)$ a $\forall k \in \mathbb{N} : f(x') = g(x') < g(x^*) = f(x^*)$. Pro dost velké k pak $g(x') < g(x_k)$!

BARIÉROVÉ METODA

Algorithm: *Bariérová metoda*

- Řešíme $\min f(x) : x \in M$ pro f spojitou a $M \neq \emptyset$ souvislou a uzavřenou.
- Pro **bariérovou funkci** $b(x)$ splňující $b(x) \rightarrow \infty$ pro $x \rightarrow \partial M$ a $c > 0$ přeformulujeme na $\min g(x)$ pro $g(x) = f(x) + \frac{1}{c_k} b(x)$.
- Opět $c_k \rightarrow \infty$.

Example: *Bariérové funkce*

- $g(x) \leq 0 \rightarrow b(x) := -\sum \frac{1}{g_j(x)}$ nebo $-\sum \log(-g_j(x))$ u interior point.
- $X \succeq 0 \rightarrow -\log \det X$

Theorem: *Bariérová metoda*

Pokud optimum x^k konvergují k x^* , pak x^* je optimum původní úlohy.

Proof: Jinak $\exists x' \in M : f(x') < f(x^*)$ a $\exists x'' \in \int M : f(x'') < f(x^*)$. Pro dost velké k pak $g(x'') < g(x^*)$ a pro dost velké k také $g(x'') < g(x_k)$.

3.8 Jednorozměrná optimalizace.

Problem: *Line search*

$\min f(x)$ pro $f : \mathbb{R} \rightarrow \mathbb{R}$ spojitou, případně diferenciovatelnou.

Definition: *Armijo-Golstein podmínky*

Předpokládáme $f'(0) < 0$

1. **Armijo:** $f(x) - f(0) \leq \epsilon_1 f'(0)x$
2. **Goldstein:** AC a $f(x) - f(0) \geq \epsilon_2 f'(0)x$ pro $\epsilon_2 < \epsilon_1$

Algorithm: *Armijův test*

1. $\beta \in \{2, 10\}$, $x > 0$
2. Dokud platí podmínka: $x := \beta x$
3. Pokud podmínka neplatí: $x := \frac{x}{\beta}$

Definition: *Wolfeho podmínky*

Předpokládáme $f'(0) < 0$

1. **Slabý Wolfe:** AC a $f'(x) \geq \epsilon_2 f'(0)$
2. **Silný Wolfe:** AC a $|f'(x)| \geq \epsilon_2 |f'(0)|$

Algorithm: *Newtonova metoda*

- Iterativně hledáme kořen f jako $x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}$. Pro minimalizaci chceme kořen derivace, tedy $x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$.
- Ekvivalentně iterativně minimalizujeme aproximace druhého řádu. Chceme

$$g(x_k) = f(x_k), \quad g'(x_k) = f'(x_k), \quad g''(x_k) = f''(x_k).$$

Volíme

$$g(x) = f(x_k) + f'(x_k)(x - x_k) + \frac{1}{2}f''(x_k)(x - x_k)^2.$$

Chapter 4

Vícekriteriální a celočíselné programování

4.1 Různé přístupy k řešení úloh s více kritérii.

TYP I: BEZ DODATEČNÉ INFORMACE

GLOBALNÍ CÍLOVÁ FUNKCE

Definition: Globální cílová funkce Za předpokladu $F_i := \min_{x \in M} f_i(x) > 0$ řešíme

$$\min \left\| \left(\frac{f_1(x) - F_1}{F_1}, \dots, \frac{f_s(x) - F_s}{F_s} \right) \right\|_p : x \in M .$$

- $p = 1$ Zachovává linearitu a konvexitu.
- $p = 2$ Zachovává konvexitu.
- $p = \infty$ Maximum schováme do podmínek. Zachovává linearitu a konvexitu.

Theorem: Globální cílová funkce

Pro x^* optimum úlohy platí $x^* \in \mathcal{E}$ pokud:

1. $1 \leq p < \infty$
2. $p = \infty$ a řešení je jednoznačné

Proof: Jinak $\exists x \in M : f(x) \not\geq f(x^*)$ a $\forall i \in [s] : \frac{f_i(x) - F_i}{F_i} \leq \frac{f_i(x^*) - F_i}{F_i}$ a aspoň jedna ostrá.

1. Pak $\sum_{i \in [s]} \left(\frac{f_i(x) - F_i}{F_i} \right)^p < \left(\frac{f_i(x^*) - F_i}{F_i} \right)^p$ je spor.
2. Pak $\max_{i \in [s]} \frac{f_i(x) - F_i}{F_i} \leq \max_{i \in [s]} \frac{f_i(x^*) - F_i}{F_i}$ je ve sporu s jednoznačností.

BENSONOVA METODA

Definition: Bensonova metoda

$$\max e^T y : 0 \leq y \leq f(x^0) - f(x), x \in M \text{ pro } x^0 \in M .$$

- Zachovává linearitu a konvexitu.
- Testujeme eficientnost x^0 a hledá jiné eficientní řešení.
- Vždy přípustné pro $(x^0, 0)$.

Theorem: Bensonova metoda

1. $x^0 \in \mathcal{E} \iff$ optimální hodnota je 0.
2. (x^*, y^*) optimum $\implies x^* \in \mathcal{E}$
3. Úloha neomezená na M konvexní \implies

- a) $\mathcal{E}^V = \emptyset$
 b) $f(M)$ uzavřená $\implies \mathcal{E} = \emptyset$

Proof:

1. \implies Jinak $\exists(x, y) : e^T y > 0$, tedy $y = f(x^0) - f(x) \not\geq 0$ a $f(x^0) \not\geq f(x)$.
 \Leftarrow Jinak $\exists x \in M : f(x) \not\leq f(x^0)$ a pro $y := f(x^0) - f(x)$ máme $e^T y > 0$.
2. Jinak $\exists x \in M : f(x) \not\leq f(x^*)$ a pro $y := f(x^0) - f(x) \geq f(x^0) - f(x^*) = y^* \geq 0$ máme $e^T y > e^T y^0$.
3. a) – Jinak $\exists x^*$ optimum $\max_{x \in M} \lambda^T f(x) : x \in M$ pro $\lambda > 0$ a z neomezenosti
 $\forall \alpha > 0 \exists x, y : 0 \leq y = f(x^0) - f(x), x \in M, e^T y > \alpha$.
 – Pro $\lambda_{\min} = \min \lambda_i > 0$ máme $\lambda^T y \geq \lambda_{\min} e^T y > \lambda_{\min} \alpha$. Dosazením $\alpha := \frac{\lambda^T (f(x^0) - f(x^*))}{\lambda_{\min}}$ dostaneme
 $\lambda^T (f(x^0) - f(x)) > \lambda^T (f(x^0) - f(x^*))$, tedy $\lambda^T f(x) < \lambda^T f(x^*)$.

TYP II: INFORMACE PŘEDEM

VÁŽENÝ SOUČET (SKALARIZACE)

ϵ -OMEZENÍ

Definition: ϵ -omezení

- Dostaneme $\epsilon_1, \dots, \epsilon_s$ maxima.
- Máme $M_k := \{x \in M \mid \forall i \neq k : f_i(x) \leq \epsilon_i\}$

$$P_k : \min f_k(x) : x \in M_k .$$

Theorem: ϵ -omezení

1. x^* jednoznačné optimum $\implies x^* \in \mathcal{E}$.
2. Pro $x^* \in M : x^* \in \mathcal{E} \iff \exists \epsilon \forall k : x^*$ optimum P_k

Proof:

1. Jinak $\exists x \in M : f(x) \not\leq f(x^*)$ a $x \in M_k$.
2. \implies Jinak $\exists x \in M_k : f_k(x) < f_k(x^*)$, tedy $x \in M$. Pro $\epsilon := f(x^*)$ máme $f_i(x) \leq \epsilon_i = f_i(x^*)$, tedy $f(x) \not\leq f(x^*)$.
 \Leftarrow Jinak $\exists x \in M : f(x) \not\leq f(x^*)$, tedy $\exists k : f_k(x) < f_k(x^*)$ a $x \in M_k$.

LEXIKOGRAFICKÁ METODA

Algorithm: *Lexikografická metoda*

Hledáme $\text{lexmin}_{x \in M} f(x)$ postupným řešením pro $k \in [s]$:

1. $k = 0, M_1 = M$
2. Pokud x^k optimum $\min_{x \in M_k} f(x)$ je jednoznačné, konec.
3. Jinak opakujeme s:
4. $k = k + 1$
5. $M_k = \{x \in M \mid \forall i < k : f_i(x) \leq f_i(x^i)\}$

Theorem: *Lexikografická metoda*

Optimum je eficientní.

Proof:

- Jinak $\exists x \in M : f(x) \not\leq f(x^*)$ a $f(x) < f(x^*)$ lexikograficky.

TYP III: INFORMACE V PRŮBĚHU.**STEM****Algorithm: STEM**

1. $\forall i \in [s]$:
2. $F_i := \min_{x \in M} f_i(x)$ (předpokládáme $F_i > 0$)
3. $x^i := \operatorname{argmin}_{x \in M} f_i(x)$
4. $F_i^{\max} := \max_{j \in [s]} f_i(x^j)$
5. $\lambda_i := \frac{F_i^{\max} - F_i}{F_i \|C_{i,*}\|}$
6. Najdeme optimum (x^*, y^*)

$$\min y : x \in M, \forall i \in [s] : \lambda_i (f_i(x) - F_i) \leq y .$$

7. Uživatel vrátí:
8. $I \subset [s]$ pro $f_i(x^*)$ vyhovující
9. $J \subset [s]$, kde se $f_i(x^*)$ může zhoršit o Δf_j
10. Opakujeme s úlohou $\min y : x \in M$ s:
11. $\forall i \notin I : \lambda_i (f_i(x) - F_i) \leq y$
12. $\forall i \in I \setminus J : f_i(x) \leq f_i(x^*)$
13. $\forall i \in J : f_i(x) \leq f_i(x^*) + \Delta f_i$

ALGORITMY DIALOGU**Algorithm: Algoritmus dialogu**

1. Uživatel zadá $\lambda^0, \lambda^1 > 0$
2. Řešíme $\min(\lambda^0)^T Cx : x \in M$
3. Řešíme $\min(\lambda^0 + t(\lambda^1 - \lambda^0))^T Cx : x \in M$ pro $t \in [0, 1]$
4. Postupně procházíme obory stability pro nová optima
5. Uživatel může změnit koncový směr

TYP IV: INFORMACE PO SKONČENÍ.**VNITŘNÍ A VNĚJŠÍ APROXIMACE****Definition: Vnitřní a vnější aproximace**

- A^I vnitřní aproximace $\forall y \in f(\mathcal{E}) \exists z \in A^I : y \preceq z$
- A^O vnější aproximace $\forall y \in f(\mathcal{E}) \exists z \in A^O : z \preceq y$

Observation: Vnitřní a vnější aproximace

$$f(\mathcal{E}) \subseteq A^0 + \mathbb{R}_+^s \cap A^I + R_-^s$$

Example: Odhady

- **Jedobodový odhad:** F jako A^0
- **Konvexní odhad:** pro konvexní úlohy
 - Pro A^I vezmeme konvexní obal bodů z \mathcal{E}
 - Pro A^O vezmeme tečné nadroviny k bodům z \mathcal{E}
- **Intervalová obálka:** pomocí BB obalíme boxy.

NORMAL BOUNDARY INTERSECTION

Definition: *CHIM*

$$\text{CHIM} := \text{conv}\{f(x^1), \dots, f(x^2)\} \text{ pro } f(x^i) := \text{argmin } f_i(x) : x \in M .$$

Algorithm: *Normal boundary intersection*

1. Vybereme $\binom{p+s-1}{s-1}$ bodů z CHIM rozdělením $[0, 1]$ na p částí.
2. Spočteme normálu jako $v \in \text{Ker} \begin{pmatrix} f(x^2) - f(x^1) \\ \dots \\ f(x^s) - f(x^1) \end{pmatrix}$.
3. Najdeme průměr na hranici $x_i := \text{argmax } \alpha : f(x^i) + \alpha d = f(x), x \in M$.
4. Nemusíme dostat eficientní řešení, lze použít Bensonovu metodu.

4.2 Funkcionál přiřazený k dané úloze vektorového programování.

Problem: *Skalarizace*

$$\min \lambda^T f(x) : x \in M$$

Theorem: *Eficientní řešení*

$$\bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda) \subseteq \mathcal{E}$$

Proof:

- Jinak pro $\lambda \geq 0$ a $x^* \in M_{\text{OPT}}$ a $x^* \notin \mathcal{E}$ máme $\exists x : f(x) \leq f(x^*)$ a $\lambda^T f(x) < \lambda^T f(x^*)$.

Theorem: *Vlastní eficientní řešení*

$$\bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda) \subseteq \mathcal{E}^V$$

Proof:

- Jinak pro $\lambda \geq 0$ máme $x^* \in M_{\text{OPT}}$ a $x^* \notin \mathcal{E}^V$.
- Pro $\beta := (s-1) \max_{i,j} \frac{\lambda_i}{\lambda_j}$ musí $\exists x \in M \exists i \in [s] : f_i(x) < f_i(x^*)$ a $\forall k \neq i : f_i(x^*) - f_i(x) > \beta(f_k(x) - f_k(x^*))$.
- Pak $\forall k \neq i :$

$$f_i(x^*) - f_i(x) > (s-1) \frac{\lambda_k}{\lambda_i} (f_k(x) - f_k(x^*))$$

a proto

$$\begin{aligned} \sum_{k \neq i} \lambda_i (f_i(x^*) - f_i(x)) &> (s-1) \sum_{k \neq i} \lambda_k (f_k(x) - f_k(x^*)) \\ \lambda_i (f_i(x^*) - f_i(x)) &> \sum_{k \neq i} \lambda_j (f_k(x) - f_k(x^*)) \\ \lambda^T f(x^*) &> \lambda^T f(x) . \end{aligned}$$

Observation: *Inkluze*

- **Konvexní:**

$$\bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda) = \mathcal{E}^V \subseteq \mathcal{E} \subseteq \bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda) .$$

- **Ryze Konvexní:**

$$\bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda) = \mathcal{E}^V \subseteq \mathcal{E} = \bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda) .$$

- **Lineární:**

$$\bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda) = \mathcal{E}^V = \mathcal{E} \subseteq \bigcup_{\lambda \geq 0} .$$

4.3 Pareto-optimální řešení.

Problem: Vícekriteriální problém

$\min f(x) : x \in M$ pro $M \subseteq \mathbb{R}^m$ a \min pro všechny složky.

Definition: Eficientní řešení

- $\mathcal{E} = \{x \in M \mid \nexists y \in M : f(y) \preceq f(x)\}$
- $\mathcal{E}^V = \{x \in M \mid \exists \beta > 0 \forall i \in [s] \forall y \in M : f_i(y) < f_i(x) \implies \exists k \in [s] : f_k(y) > f_k(x) \text{ a } f_i(x) - f_i(y) \leq \beta(f_k(y) - f_k(x))\}$

Observation: Eficientní řešení

1. $y \in f(\mathcal{E}) \iff \mathbb{R}_-^s(y) \cap f(M) = \{y\}$
2. $f(\mathcal{E}) \subseteq \partial f(M)$

Theorem: Charakterizace eficientních řešení

$$x \in \mathcal{E} \iff \forall i \in [s] : f_i(x) = \min f_i(y) : y \in M, \forall k \neq i : f_k(y) \leq f_k(x)$$

Proof:

\implies Jinak $\exists i \in [s] \exists y \in M : f_k(y) \leq f_k(x) \wedge f_i(y) < f_i(x)$, spor.

\impliedby Jinak $\exists y \in M : f_k(y) \leq f_k(x) \wedge f_i(y) < f_i(x)$ je ve sporu s optimalitou úlohy i .

4.4 Úlohy lineární a nelineární vektorové optimalizace.

Konvexní vícekriteriální programy

Problem: Konvexní vektorový program

$\min f(x) : x \in M$ pro f, M konvexní.

Theorem: Konvexní eficientní řešení

$$\mathcal{E} \subseteq \bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda)$$

Proof:

- Mějme $x^* \in \mathcal{E}$, $y^* = f(x^*)$ a $K = \{y \in \mathbb{R}^s \mid \exists x \in M : y \geq f(x)\}$.
- $K \cap \mathbb{R}_-^s(y^*) = \{y^*\}$
 - \supseteq Triviální
 - \subseteq Jinak $\exists y^* \neq y \in K \cap \mathbb{R}_-^s(y^*) \implies \exists x \in M : f(x) \leq y \preceq y^*$ je spor s $x^* \in \mathcal{E}$.
- Oddělíme
 - a) $\forall y \in K : \lambda^T y \geq \lambda^T y^*$
 - b) $\forall y \in \mathbb{R}_-^s(y^*) : \lambda^T y \leq \lambda^T y^*$.
- Z b) $\lambda \geq 0$ a $y^* - e_i \in \mathbb{R}_-^s(y^*)$. Dosadíme $\lambda^T(y^* - e_i) \leq \lambda^T y^*$ a $\lambda_i \geq 0$.
- Z a) $\forall y \in K : \lambda^T y \geq \lambda^T y^*$ tedy $\forall x \in M : \lambda^T f(x) \geq \lambda^T f(x^*)$.

Observation: Konvexní eficientní řešení

$$\lambda \geq 0 \text{ a } M_{\text{OPT}}(\lambda) = \{x^*\} \text{ jednoznačné optimum } \implies x^* \in \mathcal{E}$$

Proof: Jinak $\exists x \in M : f(x) \preceq f(x^*) \implies \lambda^T f(x) < \lambda^T f(x^*)$ je spor.

Corollary: Ryzí konvexitá

$$f \text{ ryze konvexní} \implies \mathcal{E} = \bigcup_{\lambda \geq 0} M_{\text{OPT}}(\lambda)$$

Theorem: Geoffrion

$$\mathcal{E}^V = \bigcup_{\lambda > 0} M_{\text{OPT}}(\lambda)$$

Proof:

⊇ Už víme ze skalarizace.

$$\subseteq - x^* \in \mathcal{E}^V \implies \exists \beta \geq 0 \forall x \in M \forall i \in [s] : f_i(x) < f_i(x^*)$$

– Pak $\exists k \in [s] : f_k(x) > f_k(x^*) \wedge f_i(x^*) - f_i(x) \leq \beta(f_k(x) - f_k(x^*))$. Neboli $f_i(x^*) + \beta f_k(x^*) \leq f_i(x) + \beta f_k(x)$.

– Pro fixní i mějme $F_j^i(x) := \begin{pmatrix} f_i(x) + \beta f_j(x) & i \neq j \\ f_i(x) & i = j \end{pmatrix}$ konvexní funkci.

– $\nexists x \in M : F^i(x) < F^i(x^*)$ jinak spor s prvním bodem.

– $y^i = F^i(x^*)$ a $K^i = \{y \mid \exists x \in M : F^i(x) \leq y\}$ konvexní.

– $\int K^i \cap \int \mathbb{R}_-^s = \emptyset$ jinak $\exists x \in M : F^i(x) \leq y \leq y^i$ pro y v průniku.

– Oddělíme

$$\text{a) } \forall y \in K^i : (\lambda^i)^T y \geq (\lambda^i)^T y^*$$

$$\text{b) } \nexists y \in \mathbb{R}_-^s(y^i) : (\lambda^i)^T y \leq (\lambda^i)^T y^*$$

– Znormujeme na $e^T \lambda^i = 1$ a $\lambda^i \geq 0$ z b).

– Z a) $\forall x \in M : (\lambda^i)^T F^i(x) \geq (\lambda^i)^T F^i(x^*)$ tj

$$\begin{aligned} \sum_{j \in [s]} \lambda_j^i f_j(x) + \sum_{j \neq i} \lambda_j^i \beta f_j(x) &\geq \sum_{j \in [s]} \lambda_j^i f_j(x^*) + \sum_{j \neq i} \lambda_j^i \beta f_j(x^*) , \\ \sum_{j \neq i} \lambda_j^i \beta f_j(x) &\geq \sum_{j \neq i} \lambda_j^i \beta f_j(x^*) . \end{aligned}$$

– Přes všechna i

$$\begin{aligned} \sum_{i \in [s]} f_i(x) + \sum_{j \neq i} \lambda_j^i \beta f_j(x) &\geq \sum_{i \in [s]} f_i(x^*) + \sum_{j \neq i} \lambda_j^i \beta f_j(x^*) \\ \sum_{i \in [s]} f_i(x) + \sum_{i \neq j} \lambda_i^j \beta f_i(x) &= \sum_{i \in [s]} (1 + \sum_{j \neq i} \beta \lambda_i^j) f_i(x) \geq \sum_{i \in [s]} (1 + \sum_{j \neq i} \beta \lambda_j^i) f_i(x^*) \end{aligned}$$

– Pro $0 < \lambda_i^* := 1 + \sum_{j \neq i} \beta \lambda_j^i$ dostaneme $\forall x \in M :$

$$(\lambda^*)^T f(x) \geq (\lambda^*)^T f(x^*) .$$

Theorem: Postačující KKT podmínky

$$x^* \in \mathcal{E}^V \implies \exists \lambda, \nu \geq 0 :$$

$$1. \lambda^T \nabla f(x^*) + \nu^T \nabla g(x^*) = 0$$

$$2. \nu^T g(x^*) = 0$$

Proof:

• $x^* \in \mathcal{E}^V \implies$ řeší $\min \lambda^T f(x) : g(x) \leq 0$ pro $\lambda \geq 0$.

Theorem: Postačující KKT podmínky

$x^* \in M$ a splňuje KKT podmínky:

$$1. \lambda \geq 0, \nu \geq 0$$

$$2. \lambda^T \nabla f(x^*) + \nu^T \nabla g(x^*) = 0$$

$$3. \nu^T g(x^*) = 0$$

Pak $x^* \in \mathcal{E}^V$.

Proof:

• Podle KKT podmínek x^* řeší $\min \lambda^T f(x) : g(x) \leq 0$.

Lineární vícekriteriální programování**Problem:** *Lineární vektorový program*

$$\min Cx : Ax = b, x \geq 0 .$$

Theorem: *Vlastnosti eficientních řešení*

$$\text{Pro } x^0 \in M \text{ a } (*): \max e^T y : x \in M, Cx + y = Cx^0, y \geq 0 :$$

1. $x^0 \in \mathcal{E} \iff$ úloha má optimum $(x^0, 0)$.
2. (x^*, y^*) optimum úlohy $\implies x^* \in \mathcal{E}$.
3. $\mathcal{E} = \emptyset \iff$ úloha neomezená.

Proof:

1. \implies Jinak x a $y \geq 0$ přípustné v $(*)$ a $Cx \leq Cx^0$.
 \iff Jinak pro $Cx \leq Cx^0$ máme $y := Cx^0 - Cx \geq 0$ a $e^T y > 0$.
2. Jinak pro $Cx \leq Cx^* \leq Cx^0$ máme $y = Cx^0 - Cx \geq Cx^0 - Cx^* = y^*$, tedy $e^T y > e^T y^*$.
3. \implies Omezená má optimum, které je eficientní.
 \iff * Jinak $x^1 \in \mathcal{E}$ a z Isermanna $\exists \lambda > 0 \forall x \in M : \lambda^T Cx^1 \leq \lambda^T Cx$.
 * Z neomezenosti $\exists \alpha \in \mathbb{R} \exists x, y : x \in M, Cx + y = Cx^0, e^T y > \alpha$. Pro $\lambda_{\min} := \min \lambda_i > 0$ máme spor

$$\begin{aligned} \lambda^T (Cx^0 - Cx) &= \lambda^T y > \lambda_{\min} \alpha \\ \lambda^T Cx &< \lambda^T Cx^0 - \lambda_{\min} \alpha \end{aligned}$$

Theorem: *Isermann*

$$\bigcup_{\lambda \geq S} M_{\text{OPT}}(\lambda) = \mathcal{E}$$

Proof: \subseteq Z KKT podmínek. \supseteq – Pro $x^0 \in \mathcal{E}$ máme

$$0 = \max e^T y : x \in M, y = Cx^0 - Cx \geq 0$$

– Platí $b^T u^* + (Cx^0)^T v^* = 0$ pro optimum duálu

$$\min b^T u + (Cx^0)^T v : A^T u + C^T v \geq 0, v \geq e .$$

– Pro $v := v^*$ je u^* optimum

$$\min b^T u : A^T u \geq -C^T v .$$

– Duál

$$- \min (v^*)^T Cx : Ax = b, x \geq 0$$

má optimum x^0 , protože

$$(-C^T v^*)^T x^0 = -(x^0)^T C^T v^* = b^T u^* .$$

Observation: *Hledání řešení*

1. Pokud $\mathcal{E} \neq \emptyset$, tak najdeme eficientní řešení z $(*)$.
2. Aby skalarizace s $\lambda > 0$ byla omezená, duál $A^T y \leq C^T \lambda, \lambda \geq e$ musí mít řešení.

Theorem: *Geometrie optim* \mathcal{E} je sjednocení navazujících stěn M .**Proof:**

- $M_{\text{OPT}}(\lambda)$ je stěna M .
- Spojité posouvání λ chodí mezi kužely určující obory stability pro různé báze.

4.5 Metody pro získání Pareto-optimálních řešení.

4.6 Úlohy lineárního programování s podmínkami celočíselnosti, resp. s binárními proměnnými.

Problem: IP

- MILP $\max c^T x : Ax \leq b, A, b, c \in \mathbb{Q}, C \subseteq [n], \forall i \in C : x_i \in \mathbb{Z}$
- IP $C = [n]$
- bIP $l \leq x \leq u$
- BP $x \in \{0, 1\}^n$

Observation: MILP

$$\text{Omezený IP} \rightarrow \text{BP } 0 \leq x \leq u \implies x_i = \sum_{k=0}^{\lceil \log u \rceil} 2^k (\langle x_i \rangle_2)_k$$

UM / TUM

Theorem: M_I

$$M_I := \text{conv } M \cap \mathbb{Z}^n \text{ je konvexní polyedr.}$$

Proof:

- $x \in M \implies x = \sum \alpha_i v_i + \sum \beta_j h_j$

$$Q := \{ \sum \alpha_i v_i + \sum \beta_j h_j \mid \alpha_i \geq 0, e^T \alpha = 1, \beta_j \in [0, 1] \}$$

$$C := \{ \sum \beta_j h_j \mid \beta_j \geq 0 \}$$

- $M = Q + C$, chceme ukázat $M_I = Q_I + C$

$$\subseteq \text{ Máme } x \in M \cap \mathbb{Z}^n \implies x - \sum \lfloor \beta_j \rfloor h_j = \sum \alpha_i v_i + \sum \{\beta_j\} h_j \in Q \cap \mathbb{Z}^n. \text{ Proto } x \in (Q_I + C) \text{ a } M_I = \text{conv}(M \cap \mathbb{Z}^n) \subseteq (Q_I + C).$$

$$\supseteq Q_I + C \subseteq M_I + C = M_I + C_I \subseteq (M + C)_I = M_I.$$

Definition: UM / TUM

- $A \in \mathbb{Z}^{m \times n}$ je **UM** pokud $\forall mxm$ subdeterminant je v $\{-1, 0, 1\}$.
- $A \in \mathbb{Z}^{m \times n}$ je **TUM** pokud \forall subdeterminant je v $\{-1, 0, 1\}$.

Theorem: Hoffman / Kruskal

1. $P := \{x \mid Ax = b, x \geq 0\}$ pro $A \in \mathbb{Z}^{m \times n}$ řádu m je celočíselný $\forall b \in \mathbb{Z}^m \iff A$ je UM.
2. $P := \{x \mid Ax \leq b, x \geq 0\}$ pro $A \in \mathbb{Z}^{m \times n}$ je celočíselný $\forall b \in \mathbb{Z}^m \iff A$ je TUM.

Proof:

1. \implies Mějme $x = y + A_B^{-1} e_i \geq 0$ pro B přípustnou, $y \in \mathbb{Z}^n$ dost velký a $b := A_B x = A_B y + e_i \in \mathbb{Z}^n$. Pak x doplněný nulama je vrchol, proto $A_B^{-1} e_i = x - y \in \mathbb{Z}^n$. Tedy $A_B^{-1} \in \mathbb{Z} \wedge \det(A_B) \det(A_B^{-1}) = 1 \implies \det(A_B) = 1$.

$$\iff \text{ Pro } x \text{ vrchol s bází } B \text{ máme } A_B x_B = b \text{ a } x \in \mathbb{Z}^n \text{ z Cramerova pravidla } x_i = \frac{\det(A_i)}{\det(A)}.$$

2. Použijeme 1. na $\{x \mid Ax + Ix' = b, x, x' \geq 0\}$, která je UM.

Theorem: UM / TUM

1. Neorientovaná I_G je TUM $\iff G$ je bipartitní.
2. Orientovaná I_G je TUM

4.6. ÚLOHY LINEÁRNÍHO PROGRAMOVÁNÍ S PODMÍNKAMI CELOČÍSELNOSTI, RESP. S BINÁRNÍMI PROMĚNNÝMI

Proof:

1. \implies BÚNO bez izolovaných vrcholů. Polyedr daný $A^T x = e$, $x \geq 0$ je neprázdný ($\frac{1}{2}e$) a omezený (suma řádků $a^T x = |V|$ pro $a > 0$). Celočíselný vrchol je řešení dávající partity podle $x_i = 0$.
 \Leftarrow Indukcí podle velikosti podmatice.
 - a) Dvě jedničky v každém sloupci dají stejné součty řádků podle partit a $\det = 0$.
 - b) Pokud máme někde jednu jedničku, pak Laplaceův rozvoj a IP.

Theorem: Cook

IP je silně NP-těžké.

Proof:

1. Těžkost redukci SAT. $(x \vee \neg y) \rightarrow x + (1 - y) \geq 1$.
2. Pro φ složitost zápisu řádku $(A|b)$. Pokud $M \cap \mathbb{Z}^n \neq \emptyset$, pak $\exists x^* \in \mathbb{Z}^n$ vrchol M_I se složitostí $O(\varphi n^2)$.

METODY

Algorithm: *l*-metoda

- **Tabulka:** $\begin{bmatrix} -c & 0 \\ -I & 0 \\ A & b \end{bmatrix}$
- **Inicializace:** Pokud neplatí $R_1, \dots, R_n \succ 0$, přidáme $e^T x \leq L$ a provedeme na něm pivot.
- **Iterace:**

– Pro

$$k = \operatorname{argmin}\{R_{i,0} \mid R_{i,0} < 0\}, \quad R_l := \operatorname{arglexmin}\left\{\frac{R_j}{|R_{k,j}|} \mid R_{k,j} < 0\right\}$$

pivot

$$R'_l := \frac{1}{-R_{k,l}} R_l, \quad R'_j := R_j - \frac{R_{k,j}}{R_{k,l}} R_l.$$

$$- R_l \succ 0 \wedge R_{k,l} < 0 \wedge R_{k,0} < 0 \wedge R'_0 = R_0 - \frac{R_{k,0}}{R_{k,l}} R_l \implies R'_0 = R_0 \frac{R_{k,0}}{R_{k,l}} R_l \prec R_0.$$

- **Terminace:**

1. $R_{k,0} < 0 \wedge R_{k,0} \geq 0 \implies$ neřešitelné.
2. $R_0 \geq 0 \implies$ optimum.
3. Neomezenost s $L \implies$ neomezená.

Algorithm: *První Gomoryho*

1. Vyřešíme relaxaci
2. Pokud řešení není celočíselné, přidáme řez a opakujeme.

$$\sum \{R_{k,j}\} x_{N_j} = \{R_{k,j}\}$$

Theorem: *První Gomoryho*

1. $x^* \in H^-$
2. $M \cap \mathbb{Z}^n \subseteq H^+$

Proof:

Algorithm: *Druhý Gomoryho*

1. Vyřešíme relaxaci
2. Pokud řešení není celočíselné, přidáme řez a opakujeme.

$$\sum \gamma_j x_{N_j} = \{R_{k,0}\} \text{ pro } \gamma_j := \begin{cases} \{R_{k,j}\} & N_j \in C, \{R_{k,0}\} \geq \{R_{k,j}\} \\ \frac{\{R_{k,0}\}}{1-\{R_{k,0}\}}(1 - \{R_{k,j}\}) & N_j \in C, \{R_{k,0}\} < \{R_{k,j}\} \\ R_{k,j} & N_j \notin C, R_{k,j} \geq 0 \\ \frac{\{R_{k,0}\}}{1-\{R_{k,0}\}}(-R_{k,j}) & N_j \notin C, R_{k,j} < 0 \end{cases}$$

Theorem: Druhý Gomoryho

1. Pro $y \leq x + b$, $x, y \geq 0$, $x \in \mathbb{R}$, $y \in \mathbb{Z}$ je $y \leq \frac{1}{1-\{b\}}x + \lfloor b \rfloor$ přípustná.
2. $x^* \in H^-$
3. $M_C \subseteq H^+$

Algorithm: Branch and Bound

1. Vyřešíme relaxaci
2. Nemáme optimum \implies neexistuje.
3. Optimum $x \in M_C \implies$ konec.
4. Jinak zvolíme $k \in C$, $x_k \notin M_C$ a rekurzíme na:

$$M_1 := \{x \in M \mid x_k \leq \lfloor x_k^0 \rfloor\}$$

$$M_2 := \{x \in M \mid x_k \geq \lfloor x_k^0 \rfloor + 1\}$$

Observation: Branch and Bound

1. **Výběr proměnné:** $k := \operatorname{argmax}_{i: x_i^* \notin \mathbb{Z}} \min(d_i^-, d_i^+)$
 - a) $d_i^- = \{x_i^*\}$, $d_i^+ = 1 - \{x_i^*\}$
 - b) $d_i^- = d_i^+ = |c_i|$
 - c) $d_i^- = \{x_i^*\}|c_i|$, $d_i^+ = (1 - \{x_i^*\})|c_i|$
2. **Řezy:** Přidáváme řádek do tabulky:
 - M_1 dá $\sum R_{k,j} x_{N_j} \geq \{R_{k,0}\}$
 - M_2 dá $\sum R_{k,j} x_{N_j} \leq \{R_{k,0}\} - 1$

4.7 Nelineární optimalizační problémy s podmínkami celočíselnosti.

BENDERSOVA DEKOMPOZICE

Problem: Bendersova dekompozice

$$\max c^T x + d^T y : Ax + By \leq b, x \geq 0, y \in Y \neq \emptyset.$$

- Označíme

- $P(y) : \max\{c^T x \mid Ax \leq b - By, x \geq 0\}$
- $D(y) : \min\{(b - By)^T u \mid A^T u \geq c, u \geq 0\}$
- $U := \{u \mid A^T u \geq c, u \geq 0\} \neq \emptyset$ jinak M neomezená nebo prázdná. Generátory $v_1, \dots, v_V, h_1, \dots, h_H$. Předpokládáme $(b - By)^T h_j \geq 0$, jinak $D(y)$ neomezená a $P(y)$ nepřípustná.

- Přepíšeme

$$\begin{aligned} & \max_{y \in Y} \{d^T y + P(y)\} \\ & \max_{y \in Y} \{d^T y + D(y)\} \\ & \max \{d^T y + \min_{i \in [V]} (b - By)^T v_i : y \in Y, \forall j \in [H] : (b - By)^T h_j \geq 0\} \\ & \max z : y \in Y, \forall i \in [V] : z \leq d^T y + (b - By)^T v_i, \forall j \in [H] : (b - By)^T h_j \geq 0 \end{aligned}$$

- Řešíme $*P_{i,j}$

$$\max z : \forall i \in I : z \leq d^T y + (b - By)^T v_i, \forall j \in J : (b - By)^T h_j \geq 0$$

Algorithm: Bendersova dekompozice

1. Vyřeš $P_{I,J}$.
 - Optimum (y^*, z^*) .
 - Neomezená (y^*, z^*) vrchol s neomezenou hranou
 - Nepřípuštná \implies konec.
2. Vyřeš $D(y^*)$.
 - Neomezená s h^* v v^* , přidej do I, J a od začátku.
 - Optimum v^* .
 - a) Pokud $z^* \leq d^T y^* + (b - By^*)^T v^*$, pak $\forall i \in [V] : z^* \leq d^T y^* + (b - By^*)^T v_i \implies z^*$ hodnota optima y^* , x^* dopočítáme.
 - b) Jinak přidej do I .

LAGRANGEOVA DEKOMPOZICE

Problem: Lagrangeova relaxace

- $P \max c^T x : Ax \leq b, Dx \leq d, 0 \leq x \in \mathbb{Z}^n$
- $P_u \max c^T x + u^T(b - Ax) : x \in Q$
- $LR \min P_u : u \geq 0$
- $Q := \{x \in \mathbb{Z}^n \mid Dx \leq d, x \geq 0\}$.

Theorem: Lagrangeova relaxace

1. $\forall u \geq 0 : P \leq P_u$
2. $(LR) = \max\{c^T x \mid Ax \leq b, x \in \text{conv } Q\}$
3. $P \leq LR \leq R$
4. Q polyedr $\implies LR = R$

Proof:

1. Přípustná řešení v P jsou přípustná v P_u a $c^T x \leq c^T x + u^T(b - Ax)$.
2. BÚNO $Q = \text{conv}\{v_1, \dots, v_V\}$. Pak

$$\begin{aligned} \min u \geq 0 P_u &= \min_{u \geq 0} \max_{i \in [q]} c^T v_i + u^T(b - Av_i) = \min z : u \geq 0, \forall i \in [q] : z \geq c^T v_i + u^T(b - Av_i) \\ &= \max \sum_{i \in [q]} (c^T v_i) y_i : e^T y = 1, y \geq 0, \sum_{i \in [q]} (b - Av_i) y_i \geq 0 \end{aligned}$$

Definition: Subgradient

Subgradient v u^* pro $f : \mathbb{R}^n \rightarrow \mathbb{R}$ konvexní je $d \in \mathbb{R}^n$ splňující $\forall u \in \mathbb{R}^n : f(u) \geq f(u^*) + d^T(u - u^*)$.

Theorem: Subgradient

$$x^* \text{ optimum } P(u^*) \implies f(u) \text{ má v } u^* \text{ subgradient } b - Ax^* .$$

Proof:

- Pro $u \geq 0$ chceme

$$\max_{i \in [q]} (b - Av_i)^T u + c^T v_i \geq (b - Ax^*)^T u^* + c^T x^* + (b - Ax^*)^T (u - u^*) = (b - Ax^*)^T u^* + c^T x^*$$

Algorithm: *Subgradient*

1. Vyřeš $P(u^k)$
2. $u^{k+1} = \max(u^k - \alpha_k(b - Ax_k), 0)$ pro $\alpha_k \rightarrow \infty$ a $\sum \alpha_k \rightarrow \infty$.
3. $k = k + 1$

Chapter 5

Parametrické programování a intervalové metody

5.1 Parametrická skalarizace ve vícekriteriální optimalizaci a vztah s eficientními řešeními, speciální výsledky pro konvexní a lineární úlohy.

5.2 Intervalová soustava lineárních rovnic a nerovnic, různé typy řešení.

Definition: Intervalová matice

- $*A = [\underline{A}, \overline{A}] = \{A \in \mathbb{R}^{m \times n} \mid \underline{A} \leq A \leq \overline{A}\}$
- $A^c := \frac{\underline{A} + \overline{A}}{2}$, $A^\Delta := \frac{\overline{A} - \underline{A}}{2}$
- $A_{s,t} := A^c - D_s A^\Delta D_t$
- $b_s := b^c + D_s b^\Delta$
- $*A^S := \{A \in *A \mid A = A^T\}$

Definition: Množina řešení

Pro $*A, *b$:

- $\Sigma^{\leq} := \{x \in \mathbb{R}^n \mid \exists A \in *A, \exists b \in *b : Ax \leq b\}$
- $\Sigma^= := \{x \in \mathbb{R}^n \mid \exists A \in *A, \exists b \in *b : Ax = b\}$
- $\Sigma_S^{\leq} := \{x \in \mathbb{R}^n \mid \forall A \in *A, \forall b \in *b : Ax \leq b\}$
- $\Sigma_S^= := \{x \in \mathbb{R}^n \mid \forall A \in *A, \forall b \in *b : Ax = b\}$

Pro $*A^\vee, *A^\exists, *b^\vee, *b^\exists$:

- $\Sigma_{\forall\exists} := \{x \in \mathbb{R}^n \mid \forall A^\vee \in *A^\vee \forall b^\vee \in *b^\vee \exists A^\exists \in *A^\exists \exists b^\exists \in *b^\exists : (A^\vee + A^\exists)x = b^\vee + b^\exists\}$

Theorem: Oettli-Prager a Gerlach

1. $\Sigma^= = \{x \in \mathbb{R}^n \mid |A^c x - b^c| \leq A^\Delta |x| + b^\Delta\}$
2. $\Sigma^{\leq} = \{x \in \mathbb{R}^n \mid A^c x \leq A^\Delta |x| + \bar{b}\}$

Corollary:

- $*Ax = *b \approx *Ax \leq *b \wedge *Ax \geq *b$
- Množina řešení je konvexní polyedr v každém ortantu.

Theorem: Rohn

$$\Sigma_{\bar{S}}^{\leq} = \{x \in \mathbb{R}^n \mid x = x^+ - x^-, \bar{A}x^+ - \underline{A}x^- \leq b, x^+, x^- \geq 0\}$$

Theorem: Rohn

$$*Ax = *b, x \geq 0 \text{ silně řešitelná} \iff \forall s \in \{1\}^n : A_{s,e}x = b_s, x \geq 0$$

Theorem: Rohn

$$\Sigma_{\forall \exists} = \{x \in \mathbb{R}^n \mid |A^c x - b^c| \leq ((A^{\exists})^{\Delta} - (A^{\forall})^{\Delta})|x| + (b^{\exists})^{\Delta} - (b^{\forall})^{\Delta}\}$$

5.3 Vlastnosti intervalových matic: regularita, vlastní čísla.

REGULARITA

Definition: Regularita

$*A$ je regulární pokud $\forall A \in *A$ je regulární.

Theorem: Jansson

Pro $\Sigma \neq \emptyset$:

1. $*A$ regulární $\implies \Sigma$ souvislá a kompaktní
2. $*A$ není regulární \implies každý komponenta souvislosti neomezená

Proof:

1. $x = A^{-1}b$ spojitá funkce na kompaktu
2. – Pokud je komponenta K omezená, máme $A^0 x^0 = b^0$ s A^0 regulární a $\exists A^1$ singularní.
 - Na úsečce z A^0 do A^1 najdeme $0 < \lambda^* := \inf\{\lambda \in [0, 1] : A(\lambda) \text{ singularní}\}$.
 - $x(\lambda)$ je spojitá funkce $\lambda \in [0, \lambda^*)$, takže $x(\lambda) \in K$.
 - Najdeme posloupnost v $[0, \lambda^*) \rightarrow \lambda^*$ a podposloupnost aby $x(\lambda_i) \rightarrow x^* \in K$. Pak

$$A(\lambda^*)x^* = \lim_{i \rightarrow \infty} A(\lambda_i) \lim_{i \rightarrow \infty} x(\lambda_i) = \lim A(\lambda_i)x(\lambda_i) = b^0.$$
 - Ze singularity $A(\lambda^*)$ je množina řešení $A(\lambda^*)x^* = b^0$ neomezená a v K !

Theorem: Postačující podmínka

Pokud $A^c = I_n$ a $\rho(A^{\Delta}) < 1$, pak je $*A$ regulární.

Proof:

- Pro $A \in *A$ máme $|A - I_n| = |A - A_{\Delta}| \leq A_{\Delta}$, tedy $\rho(A - I_n) \leq \rho(A^{\Delta}) < 1$.

Corollary: Beeck

$$\rho(|(A^c)^{-1}|A^{\Delta}) < 1 \implies *A \text{ regulární.}$$

Theorem: Nutná podmínka

$$\exists i \in [n] : (A_{\Delta}|(A^c)^{-1}|)_{i,i} \geq 1 \implies *A \text{ není regulární.}$$

Proof:

- Vezmeme x jako i -tý sloupec (A^c) a pak $*A(A^c)^{-1} = [I_n - A^{\Delta}|(A^c)^{-1}|, I_n + A^{\Delta}|(A^c)^{-1}|]$.
- Pak i -tý sloupec obsahuje nulu $\iff (A_{\Delta}|(A^c)^{-1}|)_{i,i} \geq 1$.

Theorem: Těžkost

Test regularity $*A$ je co-NP těžké i pro $A^c \geq 0$, $A^c \succ 0$, $A^c \in \mathbb{Q}^{n \times n}$ a $A^{\Delta} = ee^T$.

VLASTNÍ ČÍSLA

Definition: Vlastní čísla

$$\lambda_i(*A^S) := \{\lambda_i(A) \mid A \in *A^S\}$$

Observation: Vlastní čísla

1. Kompaktní interval ze spojitosti vlastních čísel.
2. Jeden nemůže být ve vnitřku jiného.

Theorem: Vlastní čísla

$$\lambda_i(*A^S) \subseteq [\lambda_i(A^c) - \rho(A^\Delta), \lambda_i(A^c) + \rho(A^\Delta)]$$

Proof:

- Podle Weylovy věty:

$$\text{Pro } B, C \text{ symetrické: } \lambda_i(B) + \lambda_n(C) \leq \lambda_i(B + C) \leq \lambda_i(B) + \lambda_1(C) .$$

- Pro $A \in *A$ máme

$$\lambda_i(A) = \lambda_i(A^c + (A - A^c)) \leq \lambda_i(A^c) + \lambda_1(A - A^c) \leq \lambda_i(A^c) + \rho(A - A^c) \leq \lambda_i(A^c) + \rho(|A - A^c|) \leq \lambda_i(A^c) + \rho(A^\Delta) .$$

Theorem: Hertz

1. $\bar{\lambda}_1(*A^S) = \max_{s \in \{1\}^n} \lambda_i(A_{-s,s})$
2. $\underline{\lambda}_n(*A^S) = \min_{s \in \{1\}^n} \lambda_n(A_{s,s})$

Proof:

- Jinak $\exists A \in *A^S : \lambda_1(A) > \max_{s \in \{1\}^n} \lambda_i(A_{-s,s})$, tedy $Ax = \lambda_1(A)x$ pro $x \neq 0$ a $\|x\|_2 = 1$.
- Pro $s := \text{sgn}(x)$ z Rayleigh-Ritz věty:

$$\begin{aligned} \lambda_1(A) &= \max_{x: \|x\|_2=1} x^T A x , \\ \lambda_n(A) &= \min_{x: \|x\|_2=1} x^T A x . \end{aligned}$$

dostaneme spor

$$\lambda_1(A) = x^T A x = \sum_{i,j \in [n]} x_i x_j A_{i,j} \leq \sum_{i,j \in [n]} x_i x_j (A_{-s,s})_{i,j} = x^T A_{-s,s} x \leq \max_{y: \|y\|_2=1} y^T A_{-s,s} y = \lambda_1(A_{-s,s}) .$$

Theorem: Těžkost

Následující testy jsou NP-těžké:

1. $\bar{\lambda}_1(*A^S) > 0$
2. $\bar{\lambda}_1(*A^S) \geq 0$
3. $\underline{\lambda}_n(*A^S) < 0$
4. $\underline{\lambda}_n(*A^S) \leq 0$

5.4 Deterministická globální optimalizace, horní a dolní odhady na účelovou funkci a optimální hodnotu.

Problem: Globální optimalizace

$$f^* := \min f(x) : \text{pro } h, g \text{ spojité:}$$

- $\forall i \in I : h_i(x) = 0$
- $\forall j \in J : g_j(x) \leq 0$
- $x \in *x^0$

Observation: Těžkost

- Řešitelnost diofantických rovnic $p(x) = 0$ je těžká.
- Řešitelnost $p(x)^2 - \sum \sin(x_i\pi)^2 = 0$ je těžká.
- Proto minimalizace levé strany je těžká.

Algorithm: Branch and Bound

1. $L := \{*x^0\}$, $S = \emptyset$
2. $c^* := \infty$
3. While $L \neq \emptyset$:
4. Vybereme $*x \in L$.
5. Kontrahujeme $*x$.
6. Pro $x \in *x$ přípustné aktualizujeme c^* .
7. Pokud $\max x_i^\Delta \leq \epsilon$, pak $S < - *x$.
8. Jinak $L < -\{*x_i\} < - *x$.
9. Vratíme S

Observation: Kontrakce

- Zmenšujeme $*x$, aniž bychom odstranili globální minima. Můžeme dostat $*x = \emptyset$.
- Přidáme $f(x) \leq c^*$ jako podmínku.

1. Pokud $*x \subseteq M$:
 - Přidáme podmínku $\nabla f(x) = 0$.
 - Pokud $\nabla^2 f(*x)$ neobsahuje PSD matici, vyhodíme $*x$.
2. Jinak použijeme KKT podmínky a dostaneme čtvercový systém $\exists \lambda \geq 0, \mu, x$:
 - a) $\nabla f(x) + \lambda^T \nabla g(x) + \mu^T \nabla h(x) = 0$
 - b) $\lambda^T g(x) = 0$
 - c) $x \in M$

3. Použijeme Newtonův nebo Krawczykův kontraktor.

Observation: Dělení boxu

- Dělení boxu v ose k :
 - a) $k := \operatorname{argmax} x_i^\Delta$
 - b) $k := \operatorname{argmax} x_i^\Delta \left(\frac{\nabla f(x)}{\nabla x_i}(*x) \right)^\Delta$
 - c) Lookahead

OBRAZ FUNKCE

Algorithm: Intervalová aritmetika

- Přirozené intervalové rozšíření nebo
- Pro polynomy použijeme Hornerovo schéma.

Algorithm: Test monotónnosti

- Spočteme obálku $*f'_{x_i}(*x)$ a testujeme, jestli překračuje nulu.

Algorithm: MVF

- Z MVT $\forall a, x \in *x \exists x \in *x : f(x) = f(a) + \nabla f(x)^T(x - a)$. Intervalové rozšíření

$$f(*x) \subseteq f(a) + \nabla *f(*x)^T(*x - a) = \sum f'_{x_i}(*x_1, \dots, *x_n)(*x_i - a).$$

Pro $a = x^c$ a $\nabla *f(*x)$ isotonní v inkluzi je MVT isotonní v inkluzi.

- Těsnější obálku dostaneme po složkách

$$\begin{aligned} f(x) &= f(\{x_i\}_{i \in [n-1]}, a_n) + f'_{x_n}(\{x_i\}_{i \in [n-1]}, c_n)(x_n - a_n) \\ &= \\ f(\{x_i\}_{i \in [n-2]}, \{a_i\}_{i \in [n] \setminus [n-2]}) &+ f'_{x_{n-1}}(\{x_i\}_{i \in [n-2]}, c_{n-1}, a_n)(x_{n-1} - a_{n-1}) + f'_{x_n}(\{x_i\}_{i \in [n-1]}, c_n)(x_n - a_n) \\ &\dots \\ &= f(x) + \sum_{k \in [n]} f'_{x_k}(\{x_i\}_{k-1}, c_k, \{a_i\}_{[n] \setminus [k]})(x_k - a_k) \end{aligned}$$

proto

$$f(*x) \subseteq f(a) + \sum_{k \in [n]} f'_{x_k}(\{*x_i\}_{k-1}, c_k, \{a_i\}_{[n] \setminus [k]})(*x_k - a_k)$$

Algorithm: Slopes

- Protože $f(x) = f(a) + \frac{f(x)-f(a)}{x-a}(x-a)$, definujeme

$$S_f(x, a) := \begin{cases} \frac{f(x)-f(a)}{x-a} & x \neq a \\ f'(x) & x = a \end{cases}.$$

- Intervalové rozšíření

$$f(*x) \subseteq f(a) + S_f(*x, a)(*x - a).$$

- Můžeme aplikovat aritmetická pravidla pro výpočet $S_f(x, a)$

OBÁLKY NELINEÁRNÍCH SYSTÉMŮ

Algorithm: Intervalová linearizace

- Z MVT $\forall a, x \in *x \exists c \in *x \forall x \in *x : f(x) = f(a) + \nabla f(x)^T(x - a)$. Intervalové rozšíření $\forall x \in x$

$$f(x) \subseteq f(a) + \nabla f(*x)^T(x - a),$$

takže obalujeme lineární intervalovou funkcí. Pro $x^* \in *x$ kořen $0 \in f(x^0) + \nabla f(*x)^T(x^* - a)$

$$0 \in f(a) + \nabla f(*x)^T(x^* - a)$$

Algorithm: Newtonův kontraktor

$$N(*x, x^0) := \square\{x \in \mathbb{R}^n \mid \exists A \in \nabla f(*x) : A(x - x^0) = -f(x^0)\}$$

- Najdeme obálku $*y$ pro $\nabla f(*x)y = -f(x^0)$ a vrátíme $N(*x, x^0) = x^0 + *y$.

Algorithm: Krawczykův kontraktor

$$K(*x, x^0, C) := x^0 - Cf(x^0) + (I_n - C\nabla f(*x))(*x - x^0)$$

- Často $C \approx \nabla f(x^0)^{-1}$.

OBÁLKY PODMÍNEK

Algorithm: *Branch and Prune*

Algorithm: *Constraint propagation*

HORNÍ ODHADY

- **Bez rovnic:** Libovolné řešení.
- **S rovnicemi:** Zafixujeme $n - |I|$ proměnných např podle nejmenšího gradientu. Na čtvercový systém $h(x) = 0$ aplikujeme intervalovou Newtonovou metodu.

DOLNÍ ODHADY

Algorithm: *Konvezní underestimator pro bilineární funkce*

- Pro $y \in *y$, $z \in *z$ máme $yz \geq \max\{\underline{y}z + y\underline{z} - \underline{y}z, \bar{y}z + y\bar{z} - \bar{y}z\}$
- Můžeme použít pro $xyz = xy'$.

Algorithm: *Konvezní underestimator pro obecné funkce*

- Pro $f(x) \in \mathcal{C}^2$ a parametry α definujeme $g(x) := f(x) + (x - \underline{x})^T D_\alpha (x - \bar{x})$.
- Hledáme α aby $\nabla^2 f(*x) + 2D_\alpha \succeq 0$ nebo jednodušeji β aby $\nabla^2 f(*x) + 2\beta I_n \succeq 0$.
- Položíme $\beta := -\frac{1}{2}\lambda_n(\nabla^2 f(*x))$.