

1. Přednáška: úvod

Lidé i příroda optimalizuje:

- továrny minimalizují náklady, maximalizují zisk,
- fyzikální systémy mají tendenci zůstávat ve stavu minimální energie.

Matematická optimalizace (programování):

- **Cílová funkce** (objective function): kvantitativní míra kvality systému, který studujeme (čas, potenciální energie, zisk, kombinace veličin).
- **Proměnné, neznámé** (variables, unknowns): charakteristiky systému, na kterých cílová funkce závisí.
- **Omezení** (constraints): proměnné nemohou nabývat libovolných hodnot.
- Cílem je nalézt konkrétní hodnoty proměnných, ve kterých nabývá cílová funkce optimální hodnoty (min. nebo max.) → **optimalizační proces**
 - **Konstrukce modelu** (rozpoznání cílové funkce, proměnných, omezení) - jednoduchý × komplexní.
 - Použití **optimalizačních algoritmů** - nejsou univerzální, spíše konstruované pro určité typy úloh, chceme, aby byl rychlý a efektivní.
 - Rozpoznat to, zda algoritmus uspěl (zda jsou splněny **podmínky optimality**), pokud ne, může se řešení použít jako odhad a vylepšit, opravit model (interpretace řešení).

Matematická formulace:

Dáno:

- $x \in \mathbb{R}^n$... vektor proměnných,
- $f : \mathbb{R}^n \rightarrow \mathbb{R}$... cílová funkce (obvykle 2x spojitě diferencovatelná),
- $h_1(x), \dots, h_m(x)$, kde $h_i : \mathbb{R}^n \rightarrow \mathbb{R}$, $i = 1, \dots, m$
 $q_1(x), \dots, q_p(x)$, kde $q_j : \mathbb{R}^n \rightarrow \mathbb{R}$, $j = 1, \dots, p$... funkce definující omezení nějakou rovností nebo nerovností (obvykle spojitě diferencovatelné).

Úloha:

$$\min_{x \in \mathbb{R}^n} f(x) \quad \text{za podmínek} \quad \begin{array}{l} h(x) = 0 \dots \text{omezení typu rovnost,} \\ q(x) \leq 0 \dots \text{omezení typu nerovnost,} \end{array}$$

kde

$$h(x) = \begin{bmatrix} h_1(x) \\ \vdots \\ h_m(x) \end{bmatrix}, \quad q(x) = \begin{bmatrix} q_1(x) \\ \vdots \\ q_p(x) \end{bmatrix}, \quad x = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}.$$

Příklad: Příklad1.m

$$\min_{x \in \mathbb{R}^n} (x_1 - 2)^2 + (x_2 - 1)^2 \quad \text{za podmínek} \quad \begin{array}{l} x_1 + x_2 \leq 2, \\ x_1^2 - x_2 \leq 0. \end{array}$$

Klasifikace úloh:

- podle matematické povahy cílové funkce a omezení (lineární \rightarrow lineární programování, kvadratická, konvexní, atd.),
- podle počtu proměnných (velké \times malé úlohy),
- podle hladkosti funkcí (diferencovatelnost).

Klasifikace optimalizace:

- **diskrétní** \times **spojitá** (obvykle jednodušší) - zda proměnné uvažují diskrétní (např. binární) nebo v reálných číslech,
- **podmíněná** (s omezeními, vazbami) \times **nepodmíněná** (bez omezení, vznikne i z podmíněné optimalizace penalizací zohledňující omezení),
- **globální** (u lineárního nebo konvexního programování lokální = globální, obvykle velmi obtížné) \times **lokální** (obvykle u nelineárních funkcí),
- **stochastická** (závislost na neznámých, např. budoucích hodnotách, ekonomie) \times **deterministická** (model je znám).

Algoritmy matematické optimalizace:

- **Iterační:** začínají počátečním odhadem proměnných x a generují posloupnost dalších (lepších) odhadů (iterací), které zastaví při splnění zastavovací podmínky (pokud možno co nejbližší skutečnému řešení, ideálně v řešení).
- Strategie, jak se posunout - **line search**, trust region.
- Cíle: **Robustní** (lze použít na širokém spektru úloh) \times **Efektivní** (nízké výpočetní a paměťové nároky, rychle konvergují) \times **Přesný** (nalézt dostatečně přesné řešení bez přílišné citlivosti na chyby v datech, zaokrouhlování v průběhu výpočtu, atd.).

Kalkulus funkce více proměnných

- Nechť $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je diferencovatelná, tj. $\frac{\partial f}{\partial x_i}$, $i = 1, \dots, n$ existují, potom vektor

$$\nabla f = \text{grad} f = \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{bmatrix}$$

nazýváme gradient.

- Nechť $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je 2x diferencovatelná, tj. $\frac{\partial^2 f}{\partial x_i \partial x_j} = \frac{\partial}{\partial x_i} \left(\frac{\partial f}{\partial x_j} \right)$ existují pro $\forall i, j$, potom matici

$$H = \begin{bmatrix} \frac{\partial^2 f}{\partial x_1^2} & \cdots & \frac{\partial^2 f}{\partial x_1 \partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial^2 f}{\partial x_n \partial x_1} & \cdots & \frac{\partial^2 f}{\partial x_n^2} \end{bmatrix}$$

nazýváme Hessova matice a její determinant Hessián.

- Pokud je f 2x spojitě diferencovatelná, jsou 2. parciální derivace záměnné (nezávisí na pořadí derivování), tj. $\frac{\partial^2 f}{\partial x_i \partial x_j} = \frac{\partial^2 f}{\partial x_j \partial x_i}$.
- Nechť $h : \mathbb{R}^n \rightarrow \mathbb{R}^m$ je diferencovatelná, tj. $\frac{\partial h_i}{\partial x_j}$, $i = 1, \dots, m$, $j = 1, \dots, n$ existují, potom matici

$$J = \begin{bmatrix} \frac{\partial h_1}{\partial x_1} & \cdots & \frac{\partial h_1}{\partial x_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial h_m}{\partial x_1} & \cdots & \frac{\partial h_m}{\partial x_n} \end{bmatrix}$$

nazýváme Jacobiho maticí a její determinant Jacobián.

- Složené funkce:

– Nechť $f : \mathbb{R}^n \rightarrow \mathbb{R}$, x závisí na skalární proměnné $t \in \mathbb{R}$, tj. $x = \begin{bmatrix} x_1(t) \\ \vdots \\ x_n(t) \end{bmatrix}$,

potom

$$\frac{d}{dt} [f(x(t))] = \frac{d}{dt} f(x_1(t), \dots, x_n(t)) = \frac{\partial f}{\partial x_1} \frac{dx_1}{dt} + \cdots + \frac{\partial f}{\partial x_n} \frac{dx_n}{dt} = \left[\frac{dx_1}{dt}, \dots, \frac{dx_n}{dt} \right] \cdot \nabla f.$$

– Nechť $f : \mathbb{R}^n \rightarrow \mathbb{R}$, x závisí na vektorové proměnné $t = \begin{bmatrix} t_1 \\ \vdots \\ t_m \end{bmatrix}$, označme

$$h(t) = f(x(t)), h : \mathbb{R}^m \rightarrow \mathbb{R}, \text{ potom } \frac{\partial h}{\partial t_j} = \left[\frac{\partial x_1}{\partial t_j}, \dots, \frac{\partial x_n}{\partial t_j} \right] \cdot \nabla f, j = 1, \dots, m, \text{ tj.}$$

vektorově

$$\begin{bmatrix} \frac{\partial h}{\partial t_1} \\ \frac{\partial h}{\partial t_2} \\ \vdots \\ \frac{\partial h}{\partial t_m} \end{bmatrix} = \begin{bmatrix} \frac{\partial x_1}{\partial t_1} & \cdots & \frac{\partial x_n}{\partial t_1} \\ \vdots & \ddots & \vdots \\ \frac{\partial x_1}{\partial t_m} & \cdots & \frac{\partial x_n}{\partial t_m} \end{bmatrix} \begin{bmatrix} \frac{\partial f}{\partial x_1} \\ \frac{\partial f}{\partial x_2} \\ \vdots \\ \frac{\partial f}{\partial x_n} \end{bmatrix},$$

$$\nabla_t h = J^T \nabla_x f,$$

kde J je Jacobiho matice zobrazení $x : \mathbb{R}^m \rightarrow \mathbb{R}^n$.

- Nechť $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je diferencovatelná v bodě x , d je jednotkový směr, potom

$$\frac{\partial f(x)}{\partial d} = D(f, d) = \lim_{\varepsilon \rightarrow 0} \frac{f(x + \varepsilon d) - f(x)}{\varepsilon}$$

je derivace funkce f ve směru vektoru d a platí $\frac{\partial f(x)}{\partial d} = \nabla f(x)^T d$.

- **Taylorova věta:** Nechť $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je spojitě diferencovatelná v konvexní otevřené množině $\Omega \subset \mathbb{R}^n$. Nechť $x \in \Omega$ a $d \in \mathbb{R}^n$ je takový, že $x + d \in \Omega$, potom existuje $z \in (x, x + d)$ tak, že

$$f(x + d) = f(x) + \nabla f^T(z) d,$$

tj. $f(x + d) = f(x) + \nabla f^T(x + td) d$, pro nějaké $t \in (0, 1)$.

Pokud je f 2x spojitě diferencovatelná

$$f(x + d) = f(x) + \int_0^1 \nabla^2 f(x + td) d dt$$

a $f(x + d) = f(x) + \nabla f^T(x) d + \frac{1}{2} d^T \nabla^2 f(x + td) d$, pro nějaké $t \in (0, 1)$.

Příklady:

Priklady1.nb

Základní vlastnosti řešení

Úloha:

$$\min_{x \in \Omega} f(x),$$

kde $x \in \mathbb{R}^n$, $n \geq 1$ a $f : \mathbb{R}^n \rightarrow \mathbb{R}$ je dvakrát spojitě diferencovatelná, Ω je přípustná oblast, pro nepodmíněnou optimalizaci $\Omega = \mathbb{R}^n$.

Definice: x^* je bod lokálního minima (lokální minimizér) funkce f na Ω , pokud existuje $\varepsilon > 0$ tak, že $f(x) \geq f(x^*)$, $\forall x \in \Omega : |x - x^*| < \varepsilon$. Nastane-li $\forall x \neq x^*$, $|x - x^*| < \varepsilon$ ostrá nerovnost, tj. $f(x) > f(x^*)$, potom jde o bod ostrého lokálního minima.

x^* je bod globálního minima (globální minimizér) funkce f na Ω , pokud platí $f(x) \geq f(x^*)$, $\forall x \in \Omega$. Pokud platí $f(x) > f(x^*)$, $\forall x \in \Omega, x \neq x^*$, pak x^* je bodem ostrého globálního minima.

- Slabé lokální minimum, izolované lokální minimum.
- Lokální minimum je globálním za určitých předpokladů, kladených na fci f (konvexita) a oblast Ω .
- Úloha $\max_{x \in \Omega} f(x) = \min_{x \in \Omega} -f(x)$.

Jak poznat lokální minimum, aniž bychom zkoušeli všechny funkční hodnoty na nějakém okolí?

Nutné podmínky prvního řádu:

Definice: Necht' $\Omega \subseteq \mathbb{R}^n$. Vektor d nazveme přípustným směrem v x , pokud $\exists \bar{\alpha} > 0$, takové, že $x + \alpha d \in \Omega$, $\forall \alpha : 0 \leq \alpha \leq \bar{\alpha}$.

Věta: Necht' $\Omega \subseteq \mathbb{R}^n$ a necht' $f \in C^1(\Omega)$. Je-li x^* lokální minimum f na Ω , potom pro všechny přípustné směry $d \in \mathbb{R}^n$ v x^* platí

$$\nabla f(x^*)^T d \geq 0.$$

Důsledek: Nutná podmínka pro lokální minimum ve vnitřním bodě Ω , nebo pokud $\Omega = \mathbb{R}^n$:

$$\nabla f(x^*) = 0.$$

Body, ve kterých tato podmínka platí nazýváme stacionární body.

Podmínky druhého řádu:

Věta: Necht' $\Omega \subseteq \mathbb{R}^n$ a necht' $f \in C^2(\Omega)$. Je-li x^* lokální minimum f na Ω , potom pro všechny přípustné směry $d \in \mathbb{R}^n$ v x^* platí

- $\nabla f(x^*)^T d \geq 0$,
- pokud $\nabla f(x^*)^T d = 0$, potom $d^T \nabla^2 f(x^*) d \geq 0$.

Důsledek: Pro lokální minimum ve vnitřním bodě Ω , nebo pokud $\Omega = \mathbb{R}^n$:

- $\nabla f(x^*) = 0$,
- $d^T \nabla^2 f(x^*) d \geq 0, \forall d \in \mathbb{R}^n$ (pozitivně semidefiniční Hessova matice).

Věta: (Postačující podmínky) Necht' $\Omega \subseteq \mathbb{R}^n$, $f \in C^2(\Omega)$ a x^* je vnitřním bodem Ω . Předpokládejme, že jsou splněny podmínky

- $\nabla f(x^*) = 0$,
- $H(x^*) = \nabla^2 f(x^*)$ je pozitivně definitní Hessova matice,

potom je x^* bodem ostrého lokálního minima funkce f na Ω .

Poznámky, příklady:

- Sylvestrovo rozhodovací kritérium: pokud Δ_i jsou levé horní subdeterminanty, potom
 - pokud $\Delta_i > 0$ pro $\forall i$ jde o minimum,
 - pokud $\Delta_1 < 0, \Delta_2 > 0, \Delta_3 < 0, \dots, (-1)^n \Delta_n > 0$ jde o maximum.
- Sedlový bod: $\nabla f(x) = 0$, ale funkce v tomto bodě nenabývá ani svého lokálního maxima ani lokálního minima (typ minmax - koňské sedlo, jiné druhy).
- Prikklady2.m

Konvexita:

Definice: Množina $\Omega \subset \mathbb{R}^n$ je konvexní, pokud pro $\forall x, y \in \Omega$ platí $\alpha x + (1 - \alpha)y \in \Omega, \forall \alpha \in \langle 0, 1 \rangle$.

Definice: Funkce f definovaná na konvexní množině Ω je konvexní, pokud pro $\forall x, y \in \Omega$ platí, $f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y)$, pro $\forall \alpha \in \langle 0, 1 \rangle$.

Definice: Funkce f definovaná na konvexní množině Ω je ostře konvexní, pokud pro $\forall x, y \in \Omega, x \neq y$ platí, $f(\alpha x + (1 - \alpha)y) < \alpha f(x) + (1 - \alpha)f(y)$, pro $\forall \alpha \in (0, 1)$.

Poznámky:

- f definovaná na konvexní množině Ω je konkávní, pokud $-f$ je konvexní,
- f definovaná na konvexní množině Ω je ostře konkávní, pokud $-f$ je ostře konvexní.

Lemma: Jsou-li f_1 a f_2 konvexní na konvexní množině Ω , potom i $f_1 + f_2$ je konvexní na Ω .

Lemma: Je-li f konvexní na konvexní množině Ω , potom i $a \cdot f$ je konvexní na Ω pro $\forall a \geq 0$.

Důsledek: Nezáporná lineární kombinace konvexních funkcí na konvexní množině je konvexní funkcí.

Lemma: Necht f je konvexní funkce na konvexní množině Ω . Potom je množina $\Gamma_c \equiv \{x : x \in \Omega, f(x) \leq c\}$ konvexní pro $\forall c \in \mathbb{R}$.

Omezení jsou ve tvaru $q_1(x) \leq c_1, \dots, q_m(x) \leq c_m$, pokud jsou $q_i(x), \forall i$ konvexní, potom je i přípustná množina konvexní (průnik konvexních množin je konvexní množina).

Věta: Necht f je konvexní funkce na konvexní množině Ω . Potom je množina Γ , kde f nabývá svého minima, konvexní, a každé lokální minimum funkce f je globálním minimum. Pokud je navíc f diferencovatelná, potom každý stacionární bod je globálním minimum funkce f .

Priklady2.nb