

Numerické metody a programování

Lekce 8


Optimalizace

hledáme bod \mathbf{x} , ve kterém funkce jedné nebo více proměnných $f(\mathbf{x})$ má minimum (maximum)

- maximalizace $f(\mathbf{x})$ je totéž jako minimalizace $-f(\mathbf{x})$

Minimum funkce

- lokální: minimum na konečném okolí vyjma hranice
- globální: skutečné minimum
 - obtížný problém
 - obvykle se opakuje hledání lokálních minim z různých počátečních bodů




- minimalizace v přítomnosti/nepřítomnosti vazeb
- uzavření minima
 - obdoba uzavření kořene
 - body $a < b < c$, pro které zároveň platí $f(b) < f(a)$ a $f(b) < f(c)$

Metody v 1D nevyžadující derivace

dělení intervalu zlatým řezem

- obdoba bisekce
- na začátku je minimum uzavřené body $a < b < c$
- zvolíme bod x v jednom z intervalů např. $x \in (b, c)$
 - pokud je $f(b) < f(x)$ máme nový interval (a, b, x)
 - pokud je $f(b) > f(x)$ máme (b, x, c)
 - prostřední bod vždy představuje nejlepší odhad polohy minima
- toto dělení opakujeme dokud se interval dostatečně nezmenší




- optimální volba nového bodu x vede na zlatý řez
 - x symetricky položeno vzhledem k b v (a, c)
 - vždy rozdělen větší ze segmentů
 - x volíme ve vzdálenosti $\frac{3-\sqrt{5}}{2} \approx 0.38197$ délky delšího ze segmentů, měřeno od bodu b
 - rychlá konvergence ke zlatému řezu z původního poměru segmentů
 - $\epsilon_{n+1} = \frac{\sqrt{5}-1}{2} \epsilon_n \approx 0.61803 \epsilon_n$ (o něco pomalejší než bisekce)

Brentova metoda (parabolická interpolace)

- předpoklad: blízko minima se funkce chová jako parabola
- jeden krok stačí k nalezení minima
- minimum paraboly procházející body a, b, c :

$$x = b - \frac{1}{2} \frac{(b-a)^2[f(b)-f(c)] - (b-c)^2[f(b)-f(a)]}{(b-a)[f(b)-f(c)] - (b-c)[f(b)-f(a)]}$$



- kontrola konvergence: krok je akceptován pokud
 - padne do intervalu uzavírajícího minimum
 - krok se dostatečně rychle zpomaluje
- pokud není krok akceptován → zlatý řez

Minimalizace s použitím derivace

- interval (a, b, c) : derivace v bodě b ukazuje, ve kterém segmentu volit další bod
- hledáme kořen derivace
 - derivace v dosavadních dvou nejlepších bodech
 - metoda sečen (superlineární s exponentem 1.618 – zlatý řez!)
- kontrola konvergence, viz. Brentova metoda
- pokud problém s konvergencí → bisekce

Minimalizace ve více dimenzích

metoda “downhill simplex”

- simplex: těleso s $N + 1$ vrcholy v dimenzi N
 - trojúhelník v 2D
 - tetrahedron v 3D
- počáteční simplex v okolí bodu \mathbf{P}_0

$$\mathbf{P}_i = \mathbf{P}_0 + \lambda \mathbf{e}_j$$

\mathbf{e}_j - jednotkové vektory

λ - parametr (velikost)


- hledání minima pomocí transformací simplexu
 - zrcadlení nejhoršího bodu přes protilehlou stranu, beze změny objemu
 - expanze simplexu (prodloužení kroku)
 - kontrakce simplexu (např. průchod úzkým místem)
- hledání ukončeno pokud poslední krok byl kratší než tolerance
- kontrola “restartem” na místě minima

Metody založené na opakovaných 1D minimalizacích (Direction set methods)

obecná strategie

- bod \mathbf{P} a směr \mathbf{n}
- hledám minimum na přímce: $\min_{\lambda} f(\mathbf{P} + \lambda \mathbf{n})$

- multidimenzionální problém: opakovaná minimalizace na přímce
- metody se liší výběrem směrů pro 1D minimalizaci



naivní metoda

- ortonormální vektory $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_N$ definují N směrů hledání
- postupná minimalizace v každém směru, cyklicky se opakuje
- málo efektivní pro některé funkce, viz. obrázek

konjugované směry

rozvoj $f(\mathbf{x})$ v okolí bodu \mathbf{P} , počátek souřadnic volíme v bodě \mathbf{P}

$$f(\mathbf{P} + \mathbf{x}) \approx f(\mathbf{P}) + \mathbf{b}^T \mathbf{x} + \frac{1}{2} \mathbf{x}^T \mathbf{A} \mathbf{x}$$

$$\mathbf{b} = \nabla f(\mathbf{P}) \quad (\text{gradient})$$

$$\mathbf{A}_{ij} = \frac{\partial^2 f(\mathbf{P})}{\partial x_i \partial x_j} \quad (\text{Hessian})$$

gradient v okolí bodu \mathbf{P}

$$\nabla f = \mathbf{A} \mathbf{x} + \mathbf{b}$$

změna gradientu posunem v novém směru \mathbf{v}


$$\delta(\nabla f) = \mathbf{A} \mathbf{v}$$

po posunu požadují zachování vlastnosti $\nabla f \perp \mathbf{u}$, která je v bodě \mathbf{P} splněna pro starý směr \mathbf{u}

$$\mathbf{0} = \mathbf{u}^T \delta(\nabla f) = \mathbf{u}^T \mathbf{A} \mathbf{v} \quad (\text{vektory } \mathbf{u}, \mathbf{v} \text{ jsou konjugované})$$

kvadratická forma: přesné řešení minimalizací podél N nezávislých konjugovaných směrů

obecná funkce – kvadratická konvergence v blízkosti minima





Powellova metoda

- inicializace směrů: $\mathbf{u}_i = \mathbf{e}_i$
- počáteční bod \mathbf{P}_0
- nyní opakujeme
 - postupně N minimalizací ve směrech \mathbf{u}_i , získáme \mathbf{P}
 - aktualizace směrů $\mathbf{u}_{i+1} \rightarrow \mathbf{u}_i$, $i = 1, 2, \dots, N-1$
 - $\mathbf{u}_N = \mathbf{P} - \mathbf{P}_0$
 - vlastní krok: posun \mathbf{P} do minima ve směru $\mathbf{u}_N \rightarrow \mathbf{P}_0$
- každé opakování generuje jeden konjugovaný směr, t.j. N opakování vede k přesné minimalizaci kvadratické formy

Metoda konjugovaného gradientu

- znalost gradientu může zkrátit výpočetní čas
- naivní použití gradientu vede k neefektivním metodám, např. “steepest descent”



- konstrukce konjugovaných směrů pomocí gradientu
- stačí N 1D minimalizací pro přesnou lokalizaci minima kvadratické formy

kvazi-Newtonovy metody

v okolí bodu \mathbf{P} jsme měli

$$\nabla f(\mathbf{P} + \mathbf{x}) = \nabla f(\mathbf{P}) + \mathbf{A} \mathbf{x}$$

hledáme místo, kde gradient vymizí

$$\mathbf{0} = \mathbf{A} \mathbf{x} + \nabla f(\mathbf{P})$$

tedy

$$\mathbf{x} = -\mathbf{A}^{-1} \nabla f(\mathbf{P})$$

neznáme ovšem \mathbf{A}^{-1}

BGFS (Broyden-Fletcher-Goldfarb-Shanno) algoritmus

- postupná aproximace (aktualizace) \mathbf{A}^{-1} v každém kroku na základě funkčních hodnot a gradientů
- daleko od minima – pohyb ve směru poklesu funkce
- blízko minima
 - dobrá aproximace hessianovské matice
 - kvadratická konvergence Newtonovy metody

Lineární programování

obecný problém:

maximalizovat $\mathbf{c}^T \mathbf{x}$ (minimalizovat $-\mathbf{c}^T \mathbf{x}$)

s M vazbami $\mathbf{A} \mathbf{x} = \mathbf{b}$ (zahrnuje i nerovnosti)


a $\mathbf{x} \geq \mathbf{0}$ (primární vazby)

kde x_1, x_2, \dots, x_N jsou proměnné a $\mathbf{b}, \mathbf{c}, \mathbf{A}$ jsou známé vektory (matice) koeficientů

- popisuje mnoho problémů ekonomie, inženýrství, plánování, dopravy apod.
- nezápornost je vlastnost množství různých komodit
- lineární vazby zahrnují přirozené požadavky na maximální cenu, existující zdroje apod.

terminologie

- maximalizovaná veličina – *objective function* (cílová funkce)
- vektor \mathbf{x} splňující vazby – *feasible vector* (přípustný vektor)
- *feasible vector* maximalizující objective function – *optimal feasible vector*



příklad (podobný problému na obrázku):

maximalizovat $x_1 + 2x_2$

$$2x_1 + x_2 \leq 2$$

$$x_1 - x_2 \leq 1/2$$

$$2x_1 + 10x_2 = 11$$

řešení:

$$x_1 = 1/2, \quad x_2 = 1$$

přípustný prostor je vymezen vazbami


- rovnost určuje přípustnou hyperplochu
- nerovnost rozděluje N -dimenzionální prostor na přípustnou a nepřípustnou část

optimalizace lineární cílové funkce

- maximum je na hranici v jednom z vrcholů
- každý vrchol je určen N rovnostmi obsaženými v $M + N$ vazbách (včetně primárních)
 - řešení se redukuje na hledání této podmnožiny
 - pokud $M < N$, je $N - M$ souřadnic vrcholu rovno nula (nutno použít primární vazby)
- numerické algoritmy
 - simplexový algoritmus – prohledávání vrcholů (kombinatorika)
 - metoda vnitřních bodů – iterační postup konvergující k optimálnímu bodu zevnitř přípustné oblasti

Nelineární programování

minimalizovat $f(\mathbf{x})$ za podmínek $c_i(\mathbf{x}) \geq 0, i=1, \dots, m$



logaritmická bariéra

$$g(\mathbf{x}, \mu) = f(\mathbf{x}) - \mu \sum_i \ln[c_i(\mathbf{x})]$$

- bariéra drží aproximace uvnitř přípustné oblasti
- postupným snižováním výšky bariéry, $\mu \rightarrow 0$, konverguje minimum $g(\mathbf{x}, \mu)$ k minimu $f(\mathbf{x})$

Metody simulovaného temperování (simulated annealing)

simulovaný fyzikální proces, kdy systém při chladnutí dosahuje minima energie

- krok je generován náhodně
- někdy jsou akceptovány i kroky opačným směrem (do kopce)
 - možnost uniknout z blízkosti lokálního minima
- postupně je snižována “teplota”
- $T = 0$ odpovídá metodě “downhill simplex” a konvergenci k lokálnímu minimu
- použito na složité optimalizační problémy: obchodní cestující, návrhy složitých integrovaných obvodů atd.