

PA081: Programování numerických výpočtů

4. Optimalizace

Aleš Křenek

jaro 2015

- ▶ hledání minima funkce $f: \mathbb{R}^N \rightarrow \mathbb{R}$
 - ▶ maximum je minimum $-f(\mathbf{x})$, speciálně neřešíme
 - ▶ standardní metody hledají (nejbližší) lokální minimum
 - ▶ potřebujeme znát vlastnosti funkce a mít dobrý počáteční odhad
 - ▶ existují i rozšíření na globální minima
- ▶ celkově příjemnější problém než řešení rovnic
 - ▶ především ve více dimenzích
 - ▶ stačí „jít směrem dolů“ a minimum najdeme (kořen ne)
- ▶ žádná univerzální metoda opět neexistuje

Klasifikace metod

- ▶ jednorozměrné metody
 - ▶ zlatý řez – robustní, relativně pomalá
 - ▶ Brentova – interpolace parabolou
 - ▶ využití derivací je v 1D diskutabilní
 - ▶ většina vícerozměrných metod využívá jednorozměrné
- ▶ vícerozměrné metody
 - ▶ simplex (améba) – jednoduchá a robustní, pomalá
 - ▶ sdružené směry (Powell) – bez derivací, kvadratická konvergence
 - ▶ sdružené gradienty (Polak-Ribiere, Fletcher-Reeves) – s derivacemi
 - ▶ seminewtonovské (Davidon-Fletcher-Powell, Broyden-Fletcher-Goldfarb-Shanno) – s derivacemi, postupná aproximace druhých derivací
 - ▶ newtonovské – s explicitními druhými derivacemi, vhodné pro $\sum f_i(\mathbf{x})^2$
- ▶ globální metody
 - ▶ simulované žíhání


Metoda zlatého řezu

- ▶ analogie metody půlení intervalu pro řešení rovnic
- ▶ podobný pojem separace minima
- ▶ spojitá funkce f , trojice bodů $a < b < c$, platí

$$f(a) > f(b) \text{ a zároveň } f(b) < f(c)$$

potom f má v intervalu $[a, c]$ lokální minimum

- ▶ vybereme nový bod x např. z (b, c)
- ▶ je-li $f(x) > f(b)$, pokračujeme s a, b, x , jinak s b, x, c



Přehled

Metoda zlatého
řezuBrentova
metodaSimplexová
metodaNewtonovské
metodyMetody
sdružených
směrů

Domácí úkol

Globální
optimalizaceZákladní
metodaSimulované
žiháníChlazení a
délka krokuZměny
optimalizované
funkce

Metoda zlatého řezu


Určení poměru

- ▶ jak vybrat optimálně bod x ?
- ▶ uvažujme poměry

$$\frac{b-a}{c-a} = w \quad \text{a tedy} \quad \frac{c-b}{c-a} = 1-w$$

- ▶ nové x předpokládáme o z dál za b

$$\frac{x-b}{c-a} = z$$



- ▶ nový úsek bude $w + z$ nebo $1 - w$
- ▶ chceme se vyhnout nejhoršímu případu, položíme tedy $w + z = 1 - w$

Přehled

Metoda zlatého
řezuBrentova
metodaSimplexová
metodaNewtonovské
metodyMetody
sdružených
směrů

Domácí úkol

Globální
optimalizaceZákladní
metodaSimulované
žiháníChlazení a
délka krokuZměny
optimalizované
funkce

Metoda zlatého řezu

Určení poměru

- ▶ kde se vzalo w ? z dělení ve stejném poměru, tedy

$$\frac{z}{1-w} = w$$

- ▶ dostáváme rovnici $w^2 - 3w + 1 = 0$, tj.
 $w = \frac{3-\sqrt{5}}{2} \approx 0.38197$
- ▶ není-li původní a, b, c v tomto poměru, rychle se k němu přiblíží
- ▶ rychlost konvergence jen o málo horší než půlení intervalů
 - ▶ $n + 1$. interval je 0.61803 délky n -tého

Metoda zlatého řezu

Počáteční separace

- ▶ nevíme-li nic lepšího, začneme z libovolné dvojice a, b
- ▶ pokračujeme směrem „dolů“ podle $f(a), f(b)$
- ▶ kroky prodlužujeme konstantním faktorem,
- ▶ lze využít kvadratickou inter/extrapolaci
 - ▶ rychlejší postup a přesnější výsledek pro „hezké“ funkce
 - ▶ viz Brentova metoda
- ▶ má-li funkce globální minimum, musíme narazit na místo, kde se otočí

Metoda zlatého řezu

Kritérium zastavení

- ▶ naivní $|b - x| < |b|\epsilon$
- ▶ jsme poblíž minima, f je skoro plochá
 - ▶ musíme aplikovat na funční hodnoty, tj. $|f(b) - f(x)| < |f(b)|\epsilon$
- ▶ Taylorův rozvoj

$$f(x) \approx f(b) + \frac{1}{2}f''(b)(x - b)^2$$


a tedy po úpravách

$$|x - b| < \sqrt{\epsilon}|b|\sqrt{\frac{2|f(b)|}{b^2 f''(b)}}$$

- ▶ velký zkomek je pro „normální“ funkce ~ 1
- ▶ v x má tedy smysl relativní přesnost jen $\sqrt{\epsilon}$

Brentova metoda

- ▶ analogie metody pro řešení rovnic
- ▶ v okolí minima lze funkci dobře aproximovat parabolou
 - ▶ optimistická hypotéza
 - ▶ platí pro mnoho reálně používaných funkcí



- ▶ parabolickou interpolací lze dosáhnout kvadratické konvergence

Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda

Simulované žihání

Chlazení a délka kroku

Změny optimalizované funkce

- ▶ extrém paraboly procházející body a, b, c

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

- ▶ možné problémy
 - ▶ vzorec najde maximum
 - ▶ jmenovatel je nulový nebo blízký nule
 - ▶ x zabloudí příliš daleko
- ▶ metoda problémy detekuje a vrací se k bezpečnému zlatému řezu
- ▶ důsledně zachovává separaci minima
- ▶ detaily viz literatura

Využití derivací

- ▶ naivní přístup - řešení $f'(x) = 0$
 - ▶ nerozliší minimum a maximum, potřebovali bychom ještě $f''(x) > 0$
- ▶ derivace nesouvisí přímo s bezpečnou separací
 - ▶ v jednom nebo obou krajních bodech může být směr „dolů“ zároveň „ven“
- ▶ derivace lze využít k přesnější aproximaci funkce
 - ▶ v jednom iteračním kroku se lépe přiblížíme skutečnému minimu
 - ▶ zlatý řez lineární, Brent kvadratický, ...

Využití derivací

- ▶ naivní přístup - řešení $f'(x) = 0$
 - ▶ nerozliší minimum a maximum, potřebovali bychom ještě $f''(x) > 0$
- ▶ derivace nesouvisí přímo s bezpečnou separací
 - ▶ v jednom nebo obou krajních bodech může být směr „dolů“ zároveň „ven“
- ▶ derivace lze využít k přesnější aproximaci funkce
 - ▶ v jednom iteračním kroku se lépe přiblížíme skutečnému minimu
 - ▶ zlatý řez lineární, Brent kvadratický, ...
- ▶ nemusí přinést očekávaný výsledek
 - ▶ polynom nepostihne exponenciální charakteristiky funkcí
 - ▶ výpočet derivací je zpravidla zatížen větší chybou
- ▶ celkově diskutabilní přínos
 - ▶ cena za vyhodnocení derivace je větší než potenciální zrychlení a zpřesnění výpočtu
 - ▶ zejména v případě hledání po přímce, kde reálně potřebujeme N parciálních derivací

Simplexová metoda

- ▶ také améba, resp. Nelder-Mead
- ▶ nevyžaduje derivace, robustní vůči singularitám apod.
- ▶ jednoduchá implementace
- ▶ nepříliš efektivní

Simplexová metoda

- ▶ také améba, resp. Nelder-Mead
- ▶ nevyžaduje derivace, robustní vůči singularitám apod.
- ▶ jednoduchá implementace
- ▶ nepříliš efektivní
- ▶ N -rozměrný **simplex** je konvexní lineární „těleso“
 - ▶ definované $N + 1$ body
 - ▶ trojúhelník, čtyřstěn, ...
- ▶ metoda nechává simplex „plazit se“ po funkční hyperploše dolů



Simplexová metoda

- ▶ počáteční odhad minima \mathbf{P}_0 , definujeme další body simplexu

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

kde λ odpovídá měřítku problému

- ▶ reflexe
 - ▶ nejvyšší bod simplexu (podle f) promítneme symetricky podle protilehlé stěny



Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda

Simulované žihání



Chlazení a délka kroku

Změny optimalizované funkce

Simplexová metoda



▶ expanze

- ▶ je-li výsledek reflexe lepší než nejnižší předchozí bod
- ▶ zkusíme protáhnout simplex na dvojnásobnou délku slibným směrem





▶ kontrakce

- ▶ v případě, kdy reflexe nepomohla
- ▶ simplex se smrskne v jednom rozměru od nejvyššího bodu





Simplexová metoda

- ▶ kontrakce ve více dimenzích
 - ▶ ani kontrakce v jednom rozměru nepomohla
 - ▶ simplex se smrskne v $N - 1$ rozměrech směrem k nejlepšímu bodu



Simplexová metoda

- ▶ kontrakce ve více dimenzích
 - ▶ ani kontrakce v jednom rozměru nepomohla
 - ▶ simplex se smrskne v $N - 1$ rozměrech směrem k nejlepšímu bodu



- ▶ kritérium ukončení
 - ▶ tolerance $\sqrt{\epsilon}$ v nezávislých proměnných, ϵ ve funkčních hodnotách, viz úvahy o jednorozměrném případě
 - ▶ v praxi

$$\frac{2(f(x_H) - f(x_L))}{|f(x_H)| + |f(x_L)|} < \epsilon$$

kde x_H, x_L jsou nevyšší a nejnižší body simplexu

Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda

Simulované žihání

Chlazení a délka kroku

Změny optimalizované funkce

- ▶ kvadratická funkce v jedné proměnné

$$f(x) = c + bx + \frac{1}{2}ax$$

- ▶ její derivace

$$f'(x) = b + ax, \quad f''(x) = a$$

- ▶ známe-li v libovolném x_0 hodnoty f' , f'' , umíme spočítat a, b
- ▶ řešení $f'(x) = 0$, tj. $x = -b/a$ je minimum f
 - ▶ za předpokladu $a > 0$

Aproximace paraboloidem

- ▶ kvadratická funkce více proměnných

$$f(\mathbf{x}) = c + \mathbf{b}\mathbf{x} + \frac{1}{2}\mathbf{x}\mathbf{A}\mathbf{x}$$

- ▶ derivace

$$\nabla f = \mathbf{b} + \mathbf{A}\mathbf{x}, \quad \nabla^2 f = \mathbf{A}$$

- ▶ známe-li v libovolném \mathbf{x}_0 hodnoty $\nabla f, \nabla^2 f$, umíme spočítat \mathbf{A}, \mathbf{b}
- ▶ řešením $\mathbf{A}\mathbf{x} = -\mathbf{b}$ získáme minimum
 - ▶ je-li \mathbf{A} pozitivně definitní

Vlastnosti dané Hessiánem

- ▶ matice druhých parciálních derivací
 - ▶ v případě kvadratické formy konstantní
- ▶ znaménka vlastních hodnot
 - ▶ všechny kladné - minimum
 - ▶ všechny záporné - maximum
 - ▶ mix - sedlo

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

Globální
optimalizace

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

Vlastnosti dané Hessiánem

- ▶ matice druhých parciálních derivací
 - ▶ v případě kvadratické formy konstantní
- ▶ znaménka vlastních hodnot
 - ▶ všechny kladné - minimum
 - ▶ všechny záporné - maximum
 - ▶ mix - sedlo
- ▶ velikost vlastních hodnot
 - ▶ deformace základního tvaru

Vlastnosti dané Hessiánem

- ▶ matice druhých partiálních derivací
 - ▶ v případě kvadratické formy konstantní
- ▶ znaménka vlastních hodnot
 - ▶ všechny kladné - minimum
 - ▶ všechny záporné - maximum
 - ▶ mix - sedlo
- ▶ velikost vlastních hodnot
 - ▶ deformace základního tvaru
- ▶ vlastní vektory
 - ▶ rotace základního tvaru
 - ▶ (u symetrické matice jsou kolmé)

Newtonovské a odvozené metody

- ▶ známe-li ∇f , $\nabla^2 f$ a funkce je kvadratická, nalezneme minimum přímo
- ▶ funkci postupně aproximujeme paraboloidy
- ▶ snažíme se informaci odpovídající ∇f , $\nabla^2 f$ získat
- ▶ metody se liší explicitním výpočtem derivací a způsobem udržování této informace

Metoda sdružených směrů

- ▶ umíme minimalizovat funkci jedné proměnné
- ▶ minimalizace funkce $f(\mathbf{x})$ více proměnných z bodu \mathbf{P} ve směru \mathbf{n} je minimalizace


$$f(\mathbf{P} + \lambda \mathbf{n})$$

v jedné proměnné λ

- ▶ postupně volíme směry \mathbf{n}
- ▶ bod \mathbf{P} nahradíme minimem v tomto směru, tj. $\mathbf{P} + \lambda_{\min} \mathbf{n}$
- ▶ pokračujeme v jiném směru
- ▶ jádrem metody je stanovení těchto směrů

Metoda sdružených směrů

- ▶ naivní přístup – souřadné osy



- ▶ nevyvážené vlastní hodnoty matice druhých derivací

Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda


Simulované žihání

Chlazení a délka kroku

Změny optimalizované funkce

Metoda sdružených směrů

- ▶ následující krok „nepokazí“, co jsme získali předchozím
- ▶ předpokládejme, že směrem \mathbf{u} jsme minimalizovali
- ▶ v tomto bodě je ∇f kolmý k \mathbf{u} (tj. $\nabla f \mathbf{u} = 0$)
- ▶ chceme se vydat dál jen takovým směrem \mathbf{v} , že ∇f zůstane k \mathbf{u} kolmý



Metoda sdružených směrů

- ▶ v souřadném systému s počátkem \mathbf{P} lze psát

$$f(\mathbf{x}) = f(\mathbf{P}) + \sum_i \frac{\partial f}{\partial x_i} x_i + \frac{1}{2} \sum_{i,j} \frac{\partial^2 f}{\partial x_i \partial x_j} x_i x_j + \dots$$
$$\approx f(\mathbf{P}) - \mathbf{b}\mathbf{x} + \frac{1}{2} \mathbf{x}\mathbf{A}\mathbf{x}$$

kde

$$\mathbf{b} \equiv -\nabla f|_{\mathbf{P}} \quad [\mathbf{A}]_{ij} \equiv \left. \frac{\partial^2 f}{\partial x_i \partial x_j} \right|_{\mathbf{P}}$$

- ▶ potom derivováním

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

Metoda sdružených směrů

- ▶ změna ∇f ve směru \mathbf{v} tedy musí být také kolmá na \mathbf{u}
 - ▶ pro $N = 2$ znamená zachování směru ∇f
 - ▶ pro $N \geq 3$ je bohatší

$$\nabla f|_{\mathbf{x}+\mathbf{v}} - \nabla f|_{\mathbf{x}} = \mathbf{A}(\mathbf{x} + \mathbf{v}) - \mathbf{b} - \mathbf{A}\mathbf{x} + \mathbf{b} = \mathbf{A}\mathbf{v}$$

- ▶ stačí tedy vyžadovat $\mathbf{u}\mathbf{A}\mathbf{v} = 0$
- ▶ postupná minimalizace v N lineárně nezávislých sdružených směrech přesně minimalizuje kvadratickou formu

Metoda sdružených směrů

Původní Powellův algoritmus

- ▶ začneme s $\mathbf{u}_i = \mathbf{e}_i$ a počátečním bodem \mathbf{P}_0
- ▶ postupně pro $i = 1, \dots, N$ minimalizujeme z \mathbf{P}_{i-1} směrem \mathbf{u}_i a získáme tak \mathbf{P}_i
- ▶ přejmenujeme směry $\mathbf{u}_i \leftarrow \mathbf{u}_{i+1}$ (zapomeneme tedy \mathbf{u}_1)
- ▶ nastavíme $\mathbf{u}_N \leftarrow \mathbf{P}_N - \mathbf{P}_0$
- ▶ minimalizujeme směrem \mathbf{u}_N a výsledek označíme jako nový \mathbf{P}_0

Metoda sdružených směrů

Původní Powellův algoritmus

- ▶ začneme s $\mathbf{u}_i = \mathbf{e}_i$ a počátečním bodem \mathbf{P}_0
- ▶ postupně pro $i = 1, \dots, N$ minimalizujeme z \mathbf{P}_{i-1} směrem \mathbf{u}_i a získáme tak \mathbf{P}_i
- ▶ přejmenujeme směry $\mathbf{u}_i \leftarrow \mathbf{u}_{i+1}$ (zapomeneme tedy \mathbf{u}_1)
- ▶ nastavíme $\mathbf{u}_N \leftarrow \mathbf{P}_N - \mathbf{P}_0$
- ▶ minimalizujeme směrem \mathbf{u}_N a výsledek označíme jako nový \mathbf{P}_0
- ▶ lze ukázat (Powell, 1964), že k opakování vygeneruje k sdružených směrů

Metoda sdružených směrů

Problémy původního algoritmu

- ▶ opakované zapomínání \mathbf{u}_1 postupně vede ke zvyšující se lineární závislosti \mathbf{u}_i
 - ▶ v numerickém smyslu, algebraicky v pořádku
- ▶ metoda se tedy pohybuje jen v podprostoru \mathbb{R}^N
 - ▶ při více iteracích spočítá falešné řešení

Metoda sdružených směrů

Problémy původního algoritmu

- ▶ opakované zapomínání \mathbf{u}_1 postupně vede ke zvyšující se lineární závislosti \mathbf{u}_i
 - ▶ v numerickém smyslu, algebraicky v pořádku
- ▶ metoda se tedy pohybuje jen v podprostoru \mathbb{R}^N
 - ▶ při více iteracích spočítá falešné řešení
- ▶ degenerující systém \mathbf{u}_i lze nahradit po $> N$ iteracích
 - ▶ znovu e_i
 - ▶ vlastními vektory \mathbf{A} , je-li k dispozici
- ▶ nezapomínat vždy \mathbf{u}_1 , ale ten směr, kterým jsme nevíce získali
 - ▶ odpovídá dosažení dna údolí
 - ▶ naruší striktní udržování sdruženosti směrů
 - ▶ je třeba kompenzovat - v jistých případech se ponechá původní sada \mathbf{u}_i

Ukázka chování algoritmu

- ▶ molekula cyklohexanu, v počáteční konformaci „židlička“
- ▶ násilím ji zdeformujeme vychýlením jednoho atomu
- ▶ minimalizujeme funkci „ošklivosti“
 - ▶ vyjádřena jako odchylky délek vazeb a úhlů mezi sousedními vazbami
 - ▶ přibližně odpovídá potenciální energii
- ▶ zpětná volání z minimalizační funkce
 - ▶ vizualizace chování metody minimalizace
- ▶ dvě varianty
 - ▶ zafixovaný vychýlený atom, polohu hledají jen dva další
 - ▶ uvolněný i vychýlený atom, vrátí se zpět nebo do „lodičky“

Využití derivací

Naivní přístup

- ▶ vedle funkčních hodnot umíme spočítat i gradient ∇f
- ▶ metoda největšího spádu
 - ▶ vektor $-\nabla f$ určuje směr „dolů“
 - ▶ tímto směrem minimalizujeme
 - ▶ v dalším kroku se vydáme opět po gradientu

Využití derivací

Naivní přístup

- ▶ vedle funkčních hodnot umíme spočítat i gradient ∇f
- ▶ metoda největšího spádu
 - ▶ vektor $-\nabla f$ určuje směr „dolů“
 - ▶ tímto směrem minimalizujeme
 - ▶ v dalším kroku se vydáme opět po gradientu
- ▶ stejné riziko postupu velmi krátkými kroky
 - ▶ ideálně funguje pouze pro nekonečně krátké kroky
 - ▶ v jednom kroku netrefíme dno údolí přesně
 - ▶ další musí být kolmo

Využití derivací

Sdružené gradienty

- ▶ posloupnost bodů \mathbf{P}_i , gradientů \mathbf{g}_i a směrů \mathbf{h}_i
 $\mathbf{g}_i \cdot \mathbf{g}_j = 0 \quad \mathbf{h}_i^T \mathbf{A} \mathbf{h}_j = 0 \quad \mathbf{g}_i \cdot \mathbf{h}_j = 0 \quad \text{pro } j < i$

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

Globální
optimalizace

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

Využití derivací

Sdružené gradienty

- ▶ posloupnost bodů \mathbf{P}_i , gradientů \mathbf{g}_i a směrů \mathbf{h}_i
 $\mathbf{g}_i \cdot \mathbf{g}_j = 0 \quad \mathbf{h}_i^T \mathbf{A} \mathbf{h}_j = 0 \quad \mathbf{g}_i \cdot \mathbf{h}_j = 0 \quad \text{pro } j < i$
- ▶ algoritmus Fletcher-Reeves
 - ▶ minimalizace z \mathbf{P}_i směrem \mathbf{h}_i , získáme \mathbf{P}_{i+1}
 - ▶ $\mathbf{g}_{i+1} := -\nabla f(\mathbf{P}_{i+1})$
 - ▶ $\mathbf{h}_{i+1} := \mathbf{g}_{i+1} + \gamma_i \mathbf{h}_i$ kde $\gamma_i = \frac{\mathbf{g}_{i+1} \cdot \mathbf{g}_{i+1}}{\mathbf{g}_i \cdot \mathbf{g}_i}$
 - ▶ důkaz pro kvadratickou formu mechanický

Využití derivací

Sdružené gradienty

- ▶ posloupnost bodů \mathbf{P}_i , gradientů \mathbf{g}_i a směrů \mathbf{h}_i
 $\mathbf{g}_i \cdot \mathbf{g}_j = 0 \quad \mathbf{h}_i^T \mathbf{A} \mathbf{h}_j = 0 \quad \mathbf{g}_i \cdot \mathbf{h}_j = 0 \quad \text{pro } j < i$
- ▶ algoritmus Fletcher-Reeves
 - ▶ minimalizace z \mathbf{P}_i směrem \mathbf{h}_i , získáme \mathbf{P}_{i+1}
 - ▶ $\mathbf{g}_{i+1} := -\nabla f(\mathbf{P}_{i+1})$
 - ▶ $\mathbf{h}_{i+1} := \mathbf{g}_{i+1} + \gamma_i \mathbf{h}_i$ kde $\gamma_i = \frac{\mathbf{g}_{i+1} \cdot \mathbf{g}_{i+1}}{\mathbf{g}_i \cdot \mathbf{g}_i}$
 - ▶ důkaz pro kvadratickou formu mechanický
- ▶ varianta Polak-Ribiere

$$\gamma_i = \frac{(\mathbf{g}_{i+1} - \mathbf{g}_i) \cdot \mathbf{g}_{i+1}}{\mathbf{g}_i \cdot \mathbf{g}_i}$$

- ▶ pro kvadratickou formu ekvivalentní
- ▶ empiricky lepší výsledky pro složitější funkce
- ▶ když dojde dech, vrací se ke gradientům

Využití derivací

Má to smysl?

- ▶ menší sklon k degeneraci
 - ▶ použití gradientu vnáší čerstvou informaci do sady směrů
 - ▶ neubývá dimenzí prohledávaného prostoru

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

Globální
optimalizace

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

Využití derivací

Má to smysl?

- ▶ menší sklon k degeneraci
 - ▶ použití gradientu vnáší čerstvou informaci do sady směrů
 - ▶ neubývá dimenzí prohledávaného prostoru
- ▶ Powellova metoda potřebuje N^2 minimalizací v 1D
 - ▶ minimalizace v 1D cca. 5–10 vyhodnocení funkce (kvadratická konvergence, přesnost $\sqrt{\epsilon}$)
- ▶ Fletcher-Reeves – stačí N kroků
 - ▶ $1 \times$ minimalizace v 1D
 - ▶ výpočet N parciálních derivací
 - ▶ derivace mohou recyklovat společné podvýrazy
- ▶ stejná asymptotická složitost, menší celkový počet operací

Newtonovské a seminewtonovské metody

PA081:
Programování
numerických
výpočtů

A. Křenek

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

Globální
optimalizace

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

- ▶ přímo dostupný Hessián
 - ▶ velmi speciální případy
 - ▶ explicitní výpočet Hessiánu je náročný ($O(N^2)$)
 - ▶ přínost přesného výpočtu diskutabilní
 - ▶ nejčastěji pro $\sum f_i(\mathbf{x})^2$
- ▶ explicitně udržovaná aproximace Hessiánu
 - ▶ resp. přímo její inverze
 - ▶ Davidon-Fletcher-Powell, Broyden-Fletcher-Goldfarb-Shanno
 - ▶ robustnější – Hessián skutečných funkcí není vždy pozitivně definitní
- ▶ výsledky srovnatelné s metodou sdružených gradientů
- ▶ detaily viz literatura

Domácí úkol

Vybranou minimalizační metodou implementujte jednoduchý model interakce dvou molekul.

- ▶ je dána cílová poloha - energetické minimum (pdb)
- ▶ volné proměnné pro minimalizaci:
 - ▶ vektor polohy \mathbf{x} - molekula se může volně pohybovat
 - ▶ vyjádření rotace - tři úhly nebo kvaternion
- ▶ minimalizovat začínáme z vychýlené polohy
- ▶ při vyjádření rotace kvaternionem je třeba silně penalizovat jeho odchylku od jednotkového (molekula by se deformovala)
- ▶ odchýlení od cílové polohy penalizujte modelem vhodně tuhé pružiny

$$F = k\Delta\mathbf{x} \quad \text{tj.} \quad E = \frac{1}{2}k|\Delta\mathbf{x}|^2$$

- ▶ libovolná dvojice atomů na sebe působí van der Waalsovou silou, odpovídá energii

$$E = \frac{\sigma^{12}}{r^{12}} - \frac{\sigma^6}{r^6}$$

kde r je vzálenost atomů. Působí mírně přitažlivě na
dálku, silně odpudivě na blízko. Použijte realistické
 $\sigma = 2.7$

- ▶ pro vizualizaci použijte VMD
<http://www.ks.uiuc.edu/Research/vmd/>
 - ▶ připojení k serveru příkazem „imd connect hostname port“
 - ▶ implementaci serveru použijte z ukázkového příkladu

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

Globální
optimalizace

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

- ▶ přijďte se zeptat, nebudete-li si vědět rady
- ▶ můžete si vymyslet i jiný obdobně složitý příklad
- ▶ kvalitní implementace – zápočet nebo 2 body ke zkoušce

- ▶ popsané metody směřují k nějakému lokálnímu minimu
- ▶ to ale nemusí být řešení, které chceme
 - ▶ mnoho reálných problémů
- ▶ ne vždy víme, kde začít hledat
- ▶ globální metody – jak se dostat k nejlepšímu minimu
- ▶ místo sestupu potřebujeme dynamiku

- ▶ systematické prohledání stavového prostoru
 - ▶ případně heuristické metody
- ▶ vhodné pro diskrétní problémy, ve spojitém případě problematické
 - ▶ diskrétní vzorkování každé proměnné
 - ▶ i při malém počtu příliš náročné (M^N)

- ▶ technika řešení problému postavená na více či méně naivním očekávání
 - ▶ sledování gradientu
 - ▶ náhodné vzorkování
- ▶ negarantuje nalezení optimálního řešení
- ▶ s vysokou pravděpodobností přijatelné řešení v přijatelném čase

- ▶ Monte Carlo
- ▶ Las Vegas
- ▶ Macao

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

**Globální
optimalizace**

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

- ▶ Monte Carlo
 - ▶ vede k výsledku jen s jistou pravděpodobností
 - ▶ deterministická délka výpočtu
- ▶ Las Vegas
 - ▶ vždy vede k výsledku
 - ▶ délka výpočtu záleží na průběhu náhodných čísel
- ▶ Macao
 - ▶ vždy vede k výsledku
 - ▶ deterministická délka výpočtu

Základní algoritmus

- ▶ pracujeme s jedním konkrétním stavem \mathbf{x}
- ▶ vygenerujeme jednoho nebo více kandidátů $\mathbf{x}' = \mathbf{x} + \Delta\mathbf{x}$
- ▶ v těchto bodech vypočteme hodnotu cílové funkce $f(\mathbf{x})$
- ▶ podle nějakého kritéria rozhodneme o přijetí nebo odmítnutí kandidáta

Základní algoritmus

- ▶ pracujeme s jedním konkrétním stavem \mathbf{x}
- ▶ vygenerujeme jednoho nebo více kandidátů $\mathbf{x}' = \mathbf{x} + \Delta\mathbf{x}$
- ▶ v těchto bodech vypočteme hodnotu cílové funkce $f(\mathbf{x})$
- ▶ podle nějakého kritéria rozhodneme o přijetí nebo odmítnutí kandidáta

- ▶ konkrétní metody se liší strategií (heuristikami)
 - ▶ volba směru a velikosti kroku
 - ▶ kritérium rozhodnutí o přijetí
 - ▶ průběžné modifikace parametrů těchto strategií

Základní algoritmus

- ▶ pracujeme s jedním konkrétním stavem \mathbf{x}
- ▶ vygenerujeme jednoho nebo více kandidátů $\mathbf{x}' = \mathbf{x} + \Delta\mathbf{x}$
- ▶ v těchto bodech vypočteme hodnotu cílové funkce $f(\mathbf{x})$
- ▶ podle nějakého kritéria rozhodneme o přijetí nebo odmítnutí kandidáta
- ▶ konkrétní metody se liší strategií (heuristikami)
 - ▶ volba směru a velikosti kroku
 - ▶ kritérium rozhodnutí o přijetí
 - ▶ průběžné modifikace parametrů těchto strategií
- ▶ dělení podle použití paměti
 - ▶ čistě Markovovské – nepamatují si nic
 - ▶ využívající historie různé délky
 - ▶ seznamy tabu

Triviální strategie přijetí

- ▶ náhodná procházka: $p(\mathbf{x} \rightarrow \mathbf{x}') = 1$
 - ▶ má smysl v kombinaci s propracovanější strategií volby kroku
 - ▶ funguje dobře pro problémy typu golfového hřiště

Triviální strategie přijetí

- ▶ náhodná procházka: $p(\mathbf{x} \rightarrow \mathbf{x}') = 1$
 - ▶ má smysl v kombinaci s propracovanější strategií volby kroku
 - ▶ funguje dobře pro problémy typu golfového hřiště
- ▶ přímý sestup

$$p(\mathbf{x} \rightarrow \mathbf{x}') = \begin{cases} 1 & \text{když } f(\mathbf{x}') < f(\mathbf{x}) \\ 0 & \text{jinak} \end{cases}$$

- ▶ problémy blízké jednomu lokálnímu minimu

Simulované žíhání

Fyzikální analogie

- ▶ při vysokých teplotách se molekuly volně pohybují
- ▶ s poklesem teploty se pohyb zpomaluje
- ▶ látky postupně krystalizují
- ▶ rychlé schlazení – velké množství malých krystalů
 - ▶ odpovídá lokální optimalizaci
 - ▶ výsledek není to energeticky optimální stav
 - ▶ nízká teplota nedovoluje přeskupení
- ▶ pomalé schlazení – velké krystaly
- ▶ kritická je rychlost ochlazování

Simulované žíhání

Fyzikální analogie

- ▶ Boltzmanova distribuce pravděpodobnosti

$$\pi(\sigma) = \frac{1}{Z} e^{-\frac{E(\sigma)}{kT}} = \frac{1}{Z} e^{-\beta E(\sigma)}$$

- ▶ i za nízké teploty existuje malá pravděpodobnost dosažení vysoce energetického stavu
- ▶ systém může přejít i „nahoru“

- ▶ rovnovážný stav

$$\forall \sigma: \sum_{\tau} \pi(\sigma) p(\sigma \rightarrow \tau) = \sum_{\tau} \pi(\tau) p(\tau \rightarrow \sigma)$$

- ▶ vhodnou volbou p libovolná počáteční distribuce konverguje k této rovnováze

- ▶ Metropolisovo kritérium

$$p(\sigma \rightarrow \tau) = \min \left\{ 1, e^{-\beta(f(\tau) - f(\sigma))} \right\}$$

- ▶ kritérium teplotního rezervoáru

$$p(\sigma \rightarrow \tau) = \frac{1}{2} (1 - \tanh(\beta(f(\tau) - f(\sigma))))$$

- ▶ kritérium prostého prahu

$$p(\sigma \rightarrow \tau) = \begin{cases} 1 & f(\tau) - f(\sigma) < T \\ 0 & \text{jinak} \end{cases}$$

- ▶ nekonverguje přesně k Boltzmanově distribuci
- ▶ méně výpočetně náročné

Simulované žíhání

Základní algoritmus

- ▶ začínáme z počátečního stavu σ_0 a s vysokou teplotou T_0 (resp. malým β)
- ▶ provedeme jeden nebo více kroků simulace
 - ▶ vygenerování kandidáta na další stav
 - ▶ přijetí podle jednoho z kritérií na základě náhodně generovaného čísla
- ▶ snížíme teplotu
- ▶ končíme dosažením nulové (nebo dostatečně nízké) teploty

- ▶ vždy je dosaženo lokálního minima
- ▶ globální minimum to je jen s jistou pravděpodobností
 - ▶ blíží se k 1 při nekonečně pomalém chlazení
- ▶ restartování simulace
 - ▶ pamatujeme si nejlepší výsledek
 - ▶ je-li při nízké teplotě řešení výrazně horší, vracíme se
 - ▶ pokračujeme jiným kandidátem
- ▶ simulace na celé populaci stavů
 - ▶ může běžet paralelně (i masivně)
 - ▶ nakonec vybereme nejlepší

- ▶ kde vůbec začít?
 - ▶ reálné systémy mají „bod tání“
 - ▶ musíme začít s vyšší teplotou

- ▶ kde vůbec začít?
 - ▶ reálné systémy mají „bod tání“
 - ▶ musíme začít s vyšší teplotou
- ▶ průzkumná náhodná procházka
 - ▶ několik desítek až tisíc kroků
 - ▶ hledáme maximální rozdíl f
 - ▶ T_0 nastavíme na $10\times$ více než by byl třeba k překonání tohoto rozdílu

Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda

Simulované žihání

Chlazení a délka kroku

Změny optimalizované funkce

- ▶ lineární

$$T = a - bt$$

- ▶ exponenciální

$$T = ab^t$$

- ▶ adaptivní

- ▶ pomocné výpočty ke zhodnocení globálního dopadu změny teploty
- ▶ viz Schneider & Kirkpatrick

- ▶ nemonotónní

- ▶ např. opakovaně „zahříváme“ na $T_B < T_0$
- ▶ další různé strategie stanovení T_B

Délka kroku

Lokální prohledávání

- ▶ problém je přiměřeně spojitý, malá změna \mathbf{x} nezpůsobí velkou změnu $f(\mathbf{x})$
- ▶ máme-li už poměrně dobré řešení, krátkým krokem ho můžeme zlepšit
- ▶ větší pravděpodobnost zlepšení než zcela náhodný skok
- ▶ nebezpečí uváznutí v lokálním minimu
- ▶ paradoxně příliš dlouhé kroky

Délka kroku

Proměnlivá délka kroku

- ▶ postup základní délkou kroku, dokud dochází ke zlepšení
- ▶ krok délky 2 - úspěšný
 - ▶ zpět k základní délce kroku
- ▶ krok délky 2 - neúspěšný
 - ▶ rekurzivně prodlužujeme krok
 - ▶ při úspěchu se vracíme přímo k základní délce nebo jen zkrácení o 1
- ▶ další varianty jsou možné

- ▶ modifikace simulovaného žíhání
- ▶ přijetí kroku závisí na hodnotě f , ne její změně:

$$p(\sigma \rightarrow \tau) = \begin{cases} 1 & f(\tau) < T \\ 0 & \text{jinak} \end{cases}$$

- ▶ vytváří izolované ostrovy
- ▶ ve více dimenzích zůstávají únikové cesty

Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda

Simulované žíhání

Chlazení a délka kroku

Změny optimalizované funkce

- ▶ modifikace simulovaného žihání
- ▶ přijetí kroku závisí na hodnotě f , ne její změně:

$$p(\sigma \rightarrow \tau) = \begin{cases} 1 & f(\tau) < T \\ 0 & \text{jinak} \end{cases}$$

- ▶ vytváří izolované ostrovy
- ▶ ve více dimenzích zůstávají únikové cesty
- ▶ urychlení konvergence

$$p(\sigma \rightarrow \tau) = \begin{cases} 1 & f(\tau) < T \text{ nebo } f(\tau) < f(\sigma) \\ 0 & \text{jinak} \end{cases}$$

Změny optimalizované funkce

Vyhlazování

- ▶ cílem je vyhlazení rušivých lokálních minim
- ▶ dobře do jde při plné znalosti funkce
 - ▶ pak ale nepotřebujeme optimalizovat

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

Globální
optimalizace

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

Změny optimalizované funkce

Vyhlazování

- ▶ cílem je vyhlazení rušivých lokálních minim
- ▶ dobře do jde při plné znalosti funkce
 - ▶ pak ale nepotřebujeme optimalizovat
- ▶ řízení přesnosti výpočtu f parametrem α
 - ▶ s rostoucím α méně detailů
- ▶ začneme s velkým α , výpočet lokálního minima
- ▶ postupně α snižujeme, start lokální optimalizace v předchozím výsledku

- ▶ modifikace simulovaného žihání
- ▶ náhrada f transformací

$$f'(\sigma) = 1 - e^{-\gamma(f(\sigma) - f_{\min})}$$

- ▶ výrazně prohloubí nižší minima
- ▶ potlačí bariéry

- ▶ více instancí s jinou inicializací
 - ▶ různé startovací body
 - ▶ různá náhodná čísla
 - ▶ vybereme nejlepší řešení
 - ▶ primitivní, ale účinné
- ▶ rozděl a panuj
 - ▶ smysluplné rozdělení stavového prostoru
 - ▶ výpočet $f(\mathbf{x})$ závisí na velkých datech, podle nich rozdělujeme
- ▶ s výměnou informací
 - ▶ složitější varianty algoritmů
 - ▶ např. nejlepší dosud nalezené řešení

Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda

Simulované žihání

Chlazení a délka kroku

Změny optimalizované funkce

Přehled

Metoda zlatého
řezu

Brentova
metoda

Simplexová
metoda

Newtonovské
metody

Metody
sdružených
směrů

Domácí úkol

Globální
optimalizace

Základní
metoda

Simulované
žihání

Chlazení a
délka kroku

Změny
optimalizované
funkce

- ▶ 216 citací v Schneider & Kirkpatrick

- ▶ 216 citací v Schneider & Kirkpatrick
- ▶ neuronové sítě
- ▶ genetické algoritmy
- ▶ a další ...

Modifikovaná simplexová metoda

- ▶ zachovává operace reflexe, expanze, a kontrakce
- ▶ počítá s **modifikovanými funkčními hodnotami**
 - ▶ náhodná funkce, velikost úměrná teplotě T
 - ▶ **přičtená** k hodnotě uložené ve vrcholu simplexu
 - ▶ **odečtená** od hodnoty v nově zkoušené bodě
- ▶ je-li nemodifikovaný krok „dolů“, je přijat
- ▶ úměrně teplotě jsou někdy přijaty i kroky „nahoru“
- ▶ při nenulové teplotě se simplex roztáhne na celou dosažitelnou oblast
- ▶ postupným schlazením se zachytí v nejhlubším minimu
 - ▶ nikoli jistě, pouze pravděpodobně

- ▶ různé strategie chlazení
 - ▶ exponenciální: snížení T na $T(1 - \epsilon)$ po každých m krocích
 - ▶ lineární: snížení na $T_0(1 - k/K)$ po m krocích
 k, K jsou počty provedených/plánovaných kroků
 - ▶ a další ...
- ▶ restart metody
 - ▶ některý vrchol simplexu je nahrazen dosavadním nejlepším bodem
 - ▶ nesmí být uvnitř

- ▶ hledání minima funkcí jedné nebo více proměnných
- ▶ jednorozměrné metody
 - ▶ zlatý řez - odpovídá půlení intervalu pro řešení rovnic
 - ▶ Brentova metoda (přímá analogie řešení rovnic)
 - ▶ v 1D nemá příliš smysl používat derivace
 - ▶ základ vícerozměrných optimalizací
- ▶ vícerozměrné metody
 - ▶ jednoduchá simplexová
 - ▶ sdružené směry bez i s derivacemi (Powell, Fletcher-Reeves)
 - ▶ (semi)newtonovské metody (Hessián)
- ▶ globální metody
 - ▶ exaktní - příliš náročné, omezené použití
 - ▶ stochastické - nezaručují plný úspěch, prakticky použitelné

Přehled

Metoda zlatého řezu

Brentova metoda

Simplexová metoda

Newtonovské metody

Metody sdružených směrů

Domácí úkol

Globální optimalizace

Základní metoda

Simulované žihání

Chlazení a délka kroku

Změny optimalizované funkce