

PA081: Programování numerických výpočtů

7. Automatické vyhodnocení derivací

jaro 2016

- ▶ kromě funkce dokážeme vyhodnotit i její derivace
 - ▶ první, druhé, ...
 - ▶ parciální
- ▶ mnohé numerické problémy jsou lépe řešitelné metodami s dostupnou derivací
- ▶ metody s derivací zpravidla rychleji konvergují
 - ▶ Newton vs. metoda sečen

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

- ▶ kromě funkce dokážeme vyhodnotit i její derivace
 - ▶ první, druhé, ...
 - ▶ parciální
- ▶ mnohé numerické problémy jsou lépe řešitelné metodami s dostupnou derivací
- ▶ metody s derivací zpravidla rychleji konvergují
 - ▶ Newton vs. metoda sečen
- ▶ aproximace konečnou diferencí nestačí
- ▶ zpracovávaná funkce nebývá triviální
- ▶ analytické vyjádření derivace je náročné
 - ▶ zdroj nebezpečných chyb
 - ▶ komplikace při změnách

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

Ruční postup

- ▶ funkce je implementována jako program
- ▶ hledáme program, který vedle funkční hodnoty spočte i derivace
- ▶ <http://www.autodiff.org>

Motivace


Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

Ruční postup

- ▶ funkce je implementována jako program
- ▶ hledáme program, který vedle funkční hodnoty spočte i derivace
- ▶ <http://www.autodiff.org>
- ▶ příklad s majákem



- ▶ bod dopadu paprsku na nábřeží

$$y_1 = \frac{\nu \tan \omega t}{\gamma - \tan \omega t} \quad y_2 = \gamma y_1$$

Ruční postup

- ▶ vyjádřeno jako jednoduchý program

$$a := \tan \omega t; \quad y_1 := va/(y - a); \quad y_2 := \gamma y_1;$$

- ▶ chceme spočítat i rychlost pohybu, tj. derivaci v čase
- ▶ výpočet současně s původní funkcí

$$\begin{array}{ll} \dot{t} := 1 & \\ a_1 := \omega t & \dot{a}_1 := \omega \dot{t} \\ a := \tan a_1 & \dot{a} := \dot{a}_1 / (\cos a_1)^2 \\ a_2 := y - a & \dot{a}_2 := -\dot{a} \\ y_1 := va/a_2 & \dot{y}_1 := v(\dot{a}a_2 - a\dot{a}_2)/a_2^2 \\ y_2 := \gamma y_1 & \dot{y}_2 := \gamma \dot{y}_1 \end{array}$$

- ▶ pouze mechanická aplikace základních pravidel

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

Automatické derivování

- ▶ transformace zdrojového kódu (např. ADIC)
- ▶ přetížení operátorů a funkcí (ADOL-C)
- ▶ zjednodušený příklad

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

```
class adouble { double x; double dx; ... }

adouble operator * (adouble a, adouble b) {
    adouble r;
    r.x = a.x * b.x;
    r.dx = a.x * b.dx + a.dx * b.x;
    return r;
}

adouble v1, v2, v3;
...
v1 = v2 * v3;
```

- ▶ aktivní proměnná
 - ▶ nezávislé proměnné, podle kterých chceme derivovat
 - ▶ všechny další proměnné na nich během výpočtu závisející
- ▶ vyhrazený typ `adouble`
- ▶ přiřazení `adouble` → `double` je chybné
 - ▶ ztrácíme informaci o derivacích tam, kde je potřebná
 - ▶ explicitní přístup metodou `value()`
- ▶ více nezávislých proměnných
 - ▶ s každou aktivní proměnnou udržujeme vektor parciálních derivací

Typický program

```
#define NUMBER_DIRECTIONS 3
#define ADOLC_TAPELESS
#include <adolc/adouble.h>

func(adouble[], const adouble[]);

adouble x[3];
adouble y[4];
...
for (i=0; i<3; i++)
    for (j=0; j<3; j++)
        x[i].setADValue(j,i==j ? 1.0 : 0.0);

func(y,x);

for (i=0; i<4; i++) {
    cout << y.getValue() << ": ";
    for (j=0; j<3; j++) cout << y.getADValue(j) << ", ";
    cout << endl;
}
```

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

Není to tak jednoduché

- ▶ nediferencovatelné funkce (**fmod**)
 - ▶ nelze použít
- ▶ absolutní hodnota (**fabs**)
 - ▶ v 0 pravá nebo levá derivace ± 1
 - ▶ případně položíme uměle rovnu 0
- ▶ minimum a maximum (**fmin**, **fmax**)
 - ▶ lze nahradit $(a + b \pm |a - b|)/2$
- ▶ nedefinované na celém \mathbb{R} (**sqrt**, **pow**, **tan**, ...)
 - ▶ derivaci položíme uměle **NaN**, resp. **Inf**

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

Zpětné vyhodnocení

- ▶ množství potřebných operací $O(mk)$ pro $f: \mathbb{R}^m \rightarrow \mathbb{R}^n$
 - ▶ m počet nezávislých proměnných
 - ▶ n počet závislých proměnných
 - ▶ k počet kroků výpočtu
- ▶ nepříjemné s rostoucím m
- ▶ velká třída problémů velkým m ale malým n
 - ▶ optimalizace funkce více proměnných ($n = 1$)

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

Zpětné vyhodnocení

- ▶ množství potřebných operací $O(mk)$ pro $f: \mathbb{R}^m \rightarrow \mathbb{R}^n$
 - ▶ m počet nezávislých proměnných
 - ▶ n počet závislých proměnných
 - ▶ k počet kroků výpočtu
- ▶ nepříjemné s rostoucím m
- ▶ velká třída problémů velkým m ale malým n
 - ▶ optimalizace funkce více proměnných ($n = 1$)
- ▶ počítali jsme citlivost pomocných proměnných na změny vstupu
- ▶ obrácený postup, citlivost výstupu (závislých proměnných) na změny pomocných
- ▶ výpočet od konce

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

Zpětné vyhodnocení

- ▶ triviální příklad $y = \sin x^2$
- ▶ tedy po krocích $a_1 = x^2$, $y = \sin a_1$
- ▶ formálním derivováním

$$\partial y / \partial a_1 = \cos a_1 \quad \partial a_1 / \partial x = 2x$$

- ▶ dostáváme $\partial y / \partial x = 2x \cos a_1$

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

Zpětné vyhodnocení

- ▶ triviální příklad $y = \sin x^2$
- ▶ tedy po krocích $a_1 = x^2$, $y = \sin a_1$
- ▶ formálním derivováním

$$\partial y / \partial a_1 = \cos a_1 \quad \partial a_1 / \partial x = 2x$$

- ▶ dostáváme $\partial y / \partial x = 2x \cos a_1$
- ▶ označujeme $\bar{a} = \partial y / \partial a$
- ▶ obecně v konkrétním kroku $a_i = f(a_j, a_k, \dots)$ derivujeme

$$\partial a_i / \partial a_j = g(a_j, a_k, \dots)$$

- ▶ spolu se známým $\bar{a}_i = \partial y / \partial a_i$ dostaneme

$$\bar{a}_j = \partial y / \partial a_j = g(a_j, a_k, \dots) \bar{a}_i$$

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

Zpětné vyhodnocení

- ▶ triviální příklad $y = \sin x^2$
- ▶ tedy po krocích $a_1 = x^2$, $y = \sin a_1$
- ▶ formálním derivováním

$$\partial y / \partial a_1 = \cos a_1 \quad \partial a_1 / \partial x = 2x$$

- ▶ dostáváme $\partial y / \partial x = 2x \cos a_1$
- ▶ označujeme $\bar{a} = \partial y / \partial a$
- ▶ obecně v konkrétním kroku $a_i = f(a_j, a_k, \dots)$ derivujeme

$$\partial a_i / \partial a_j = g(a_j, a_k, \dots)$$

- ▶ spolu se známým $\bar{a}_i = \partial y / \partial a_i$ dostaneme

$$\bar{a}_j = \partial y / \partial a_j = g(a_j, a_k, \dots) \bar{a}_i$$

- ▶ tyto konstrukce jsou pouze ilustrativní, zjednodušené a v principu nekorektní

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

- ▶ např. funkce $y = \sin(x_1/x_2)e^{x_3}$

$$a_1 := x_1/x_2$$

$$a_2 := \sin a_1$$

$$a_3 := e^{x_3}$$

$$y := a_2 a_3$$

$$\bar{y} := 1$$

$$\bar{a}_2 := a_3 \bar{y}$$

$$\bar{a}_3 := a_2 \bar{y}$$

$$\bar{x}_3 := e^{x_3} \bar{a}_3$$

$$\bar{a}_1 := \bar{a}_2 \cos a_1$$

$$\bar{x}_2 := -\bar{a}_1/x_2$$

$$\bar{x}_1 := \bar{a}_2/x_2$$

- ▶ v $O(nk)$ operacích máme všechny $\partial y / \partial x_i$

Motivace

Ruční postup

Automatické
derivováníZpětné
vyhodnocení

- ▶ derivace se vyhodnocují od konce
 - ▶ tj. až poté, co proběhl výpočet funkce
 - ▶ proto „zpětné“ (reverse) vyhodnocení
- ▶ výpočet funkce je nutné nějak zaznamenat
- ▶ ADOL-C: datová struktura (i soubor) **páska** (tape)
- ▶ záznam posloupnosti operací, nikoli konkrétních hodnot
 - ▶ lze recyklovat pro jiný vstup
 - ▶ případné rozdílnosti vyhodnocení ($a > b ? c : d$) jsou detekovány
- ▶ použije se pro vyhodnocení funkce, gradientu/Jakobiánu, Hessiánu, ...

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

Instrumentace pro zpětné vyhodnocení

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

```
#include <adolc/adouble.h>

void func(
    double px[4],    /* vstup */
    double py[4],    /* vystup */
) {
    adouble x[4],y[4],aux;
    trace_on(0);      /* paska 0 */
    for (i=0; i<4; i++) x[i] <<= px[i];
    aux = x[1] * x[4] + exp(x[2]);    /* vlastni vypocet */
    ...
    y[4] = sin(aux);
    for (i=0; i<4; i++) y[i] >>= py[i];
    trace_off();
}
```

- ▶ ADOL-C poskytuje celou řadu „driver“ funkcí
 - ▶ vstupem je vždy páska a konkrétní vstupní hodnoty
 - ▶ driver provede výpočet na základě záznamu na pásce
- ▶ funkční hodnota funkce $\mathbb{R}^n \rightarrow \mathbb{R}^m$
 - ▶ `function(short tag, int m, int n, double x[n],double y[m])`
- ▶ gradient funkce $\mathbb{R}^n \rightarrow \mathbb{R}$
 - ▶ `gradient(short tag, int n, double x[n],double g[n])`
- ▶ Jakobián funkce $\mathbb{R}^n \rightarrow \mathbb{R}^m$
 - ▶ `jacobian(short tag, int m, int n, double x[n],double J[m][n])`
- ▶ Hessián (matice druhých derivací) funkce $\mathbb{R}^n \rightarrow \mathbb{R}$
 - ▶ `hessian(short tag, int m, int n, double x[n],double H[n][n])`

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

- ▶ optimalizované varianty pro Newtonovu metodu
- ▶ řešení různých typů diferenciálních rovnic
- ▶ speciální varianty pro řídké Jakobiány a Hessiány
- ▶ tenzory vyšších derivací
- ▶ implicitně definované funkce

$$G(\mathbf{x}, \mathbf{y}) = 0$$

- ▶ obecné - plná kontrola nad zpracováním pásky

Rekapitulace zpětného vyhodnocení

- ▶ aktivní proměnné deklarovat jako `adouble`
- ▶ výpočet označit `trace_on()` ... `trace_off()`
- ▶ zavolat instrumentovanou funkci `jednou`
 - ▶ s typickými hodnotami vstupů
 - ▶ vyprodukuje záznam výpočtu - pásku
- ▶ opakovaně volat potřebné drivery
 - ▶ případně na různé vstupy
- ▶ pro jinou posloupnost výpočtu zavolat instrumentovanou funkci s jinou páskou

Motivace

Ruční postup

Automatické
derivování

Zpětné
vyhodnocení

- ▶ rozsáhlá problematika, řada implementací
- ▶ včetně obsáhlé teorie
- ▶ <http://www.autodiff.org>
 - ▶ přehled nástrojů, FAQ, ...
- ▶ <https://projects.coin-or.org/ADOL-C>
 - ▶ implementace a dokumentace ADOL-C
 - ▶ včetně řady příkladů
- ▶ Griewank, Walter. *Evaluating Derivatives*. 2008