

Tomáš Oberhuber

Faculty of Nuclear Sciences and Physical Engineering
Czech Technical University in Prague

Výpočet derivací

- derivace mnoha ztrátových funkcí nebo funkcionalů lze snadno napočítat ručně
- v řadě případů může být ztrátová funkce příliš složitá na ruční derivování
- pak lze použít některou z následujících metod
 - konečné diference – *finite differencing*
 - automatické derivování – *automatic differentiation*
 - symbolické derivování – *symbolic differentiation*
 - například programy Mathematica, Maple, Macsyma nebo Ginac
 - v této přednášce se symbolickým derivováním zabývat nebudeme

Konečné diference

- derivace lze nahrazovat pomocí konečných diferencí
- příkladem je dopředná diference pro aproximaci první derivace

$$\frac{\partial f(\vec{x})}{\partial x_i} \approx \frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon},$$

pro $f : \mathbb{R}^n \rightarrow \mathbb{R}$, kde \vec{e}_i je i -tý bazický vektor

- funkci f je tedy potřeba vyčíslit dvakrát
- otázkou je zde hlavně volba parametru ϵ
 - čím menší ϵ zvolíme, tím přesnější aproximaci dostaneme
 - když ϵ zvolíme příliš malé, můžeme narazit na přesnost počítačové aritmetiky

Připomeneme si definici množiny čísel s pohyblivou desetinnou čárkou s konečnou přesností:

Definition 1

Definujeme **množinu čísel s pohyblivou desetinnou čárkou** jako

$$\mathbb{F}(\beta, t, L, U) \equiv \{0\} \cup \left\{ x \in \mathbb{R} \mid x = (-1)^s \beta^e \sum_{i=1}^t a_i \beta^{-i} \right\},$$

kde $\beta \in \mathbb{N}, \beta > 1$ určuje základ rozvoje $t \in \mathbb{N}, t > 0$ určuje počet významných cifer, a pro exponent $e \in \mathbb{N}$ platí $L \leq e \leq U$.

Definition 2

Číslo $u = \beta^{-t-1}$ se označuje jako **zaokrouhlovací jednotky** (*unit roundoff*).
Někdy se také označuje jako **strojové epsilon** (*machine epsilon*).

Lemma 3

Pro libovolné reálné číslo $x \in [\beta^L, \beta^U]$ platí

$$fl(x) = x(1 + \delta) \text{ kde } |\delta| \leq u,$$

kde $fl(\cdot)$ značí projekci čísla x na nejbližší číslo z množiny \mathbb{F} .

Remark 4

Číslo u nám tedy vyjadřuje relativní chybu, které se dopouštíme při zaokrouhlování, tj. při projekci reálných čísel do množiny \mathbb{F} . Tato relativní chyba se vztahuje k velikosti čísla x .

- Pro jednoduchou přesnost je $u = 1.19 \cdot 10^{-7}$.
- Pro dvojitou přesnost je $u = 2.22 \cdot 10^{-16}$.

Nechť $|f(\vec{x})| \leq L_f$ na okolí bodu x . Pak platí

$$|f(f(\vec{x})) - f(\vec{x})| \leq uL_f, \quad (1)$$

$$|f(f(\vec{x} + \epsilon\vec{e}_i)) - f(\vec{x} + \epsilon\vec{e}_i)| \leq uL_f. \quad (2)$$

Konečné diference

- Z Taylorova rozvoje dále dostáváme

$$f(\vec{x} + \vec{p}) = f(\vec{x}) + \nabla f(\vec{x})\vec{p} + \frac{1}{2}\vec{p}^T \nabla^2 f(\vec{x} + \xi\vec{p})\vec{p},$$

kde $\xi \in (0, 1)$.

- Pokud je $f \in C^2(\mathbb{R}^n)$, pak existuje C takové, že

$$\|\nabla^2 f(\vec{x})\| < C$$

pro všechna $\vec{x} \in \mathbb{R}^n$.

- A potom platí

$$\|f(\vec{x} + \vec{p}) - f(\vec{x}) - \nabla f(\vec{x})\vec{p}\| \leq \frac{C}{2} \|\vec{p}\|^2. \quad (3)$$

- Volbou $\vec{p} = \epsilon \vec{e}_j$ dostáváme

$$\frac{\partial f(\vec{x})}{\partial x_j} \approx \frac{f(\vec{x} + \epsilon \vec{e}_j) - f(\vec{x})}{\epsilon} + \delta_\epsilon,$$

kde

$$|\delta_\epsilon| \leq \frac{C}{2} \|\epsilon \vec{e}_j\| = \frac{C\epsilon}{2},$$

- pro správnou volbu ϵ potřebujeme nyní vzít v úvahu zaokrouhlovací chyby.

Konečné diference

- Nyní tedy budeme sledovat zaokrouhlovací chyby vzniklé při výpočtu konečné diference

$$\frac{\partial f(\vec{x})}{\partial x_i} = \frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon} + \delta_\epsilon.$$

- Platí

$$fl(f(\vec{x})) = f(\vec{x})(1 + \delta) \Leftrightarrow fl(f(\vec{x})) - f(\vec{x}) = f(\vec{x})\delta,$$

kde $|\delta| \leq u$.

- A tedy

$$|fl(f(\vec{x})) - f(\vec{x})| \leq L_f |\delta| \leq L_f u$$

- podobně lze ukázat i

$$|fl(f(\vec{x} + \epsilon \vec{e}_i)) - f(\vec{x} + \epsilon \vec{e}_i)| \leq L_f |\delta| \leq L_f u.$$

Konečné diference

- Celkem je tedy

$$\left| fl \left(\frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon} \right) - \frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon} \right| \leq 2 \frac{uL_f}{\epsilon}$$

- a pro chybu aproximace platí

$$\begin{aligned} & \left| \frac{\partial f(\vec{x})}{\partial x_i} - fl \left(\frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon} \right) \right| \leq \\ & \left| \frac{\partial f(\vec{x})}{\partial x_i} - \frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon} \right| + \left| \frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon} - fl \left(\frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x})}{\epsilon} \right) \right| \leq \\ & \delta_\epsilon + 2 \frac{uL_f}{\epsilon} \leq 2 \frac{uL_f}{\epsilon} + \frac{C\epsilon}{2}. \end{aligned}$$

- Dále lze ukázat, že

$$\arg \min_{\epsilon} \left(\frac{uL_f}{\epsilon} + \frac{C\epsilon}{2} \right) = \sqrt{\frac{4L_f u}{C}}.$$

Konečné diference

- Volíme tedy

$$\epsilon \approx u^{\frac{1}{2}}.$$

- Podobně lze dokázat, že pro centrální diferenci tvaru

$$\frac{\partial f(\vec{x})}{\partial x_i} \approx \frac{f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x} - \epsilon \vec{e}_i)}{\epsilon} + O(\epsilon^2)$$

je vhodné volit

$$\epsilon \approx u^{\frac{1}{3}}.$$

Výpočet Jakobiánů

- Bud' $\vec{f} : \mathbb{R}^n \rightarrow \mathbb{R}^m$, chceme napočítat Jakobián

$$\mathbb{J}_{\vec{f}}(\vec{x}) = \begin{pmatrix} \nabla f_1(\vec{x}) \\ \vdots \\ \nabla f_m(\vec{x}) \end{pmatrix} \in \mathbb{R}^{m,n}.$$

- Pomocí konečné difference

$$\frac{\vec{f}(\vec{x} + \epsilon \vec{e}_i) - \vec{f}(\vec{x})}{\epsilon} \approx \frac{\partial \vec{f}(\vec{x})}{\partial x_i} = \begin{pmatrix} \frac{\partial f_1(\vec{x})}{\partial x_i} \\ \vdots \\ \frac{\partial f_m(\vec{x})}{\partial x_i} \end{pmatrix}$$

získáme jeden sloupec celého Jakobiánu.

Výpočet Jakobiánů

- Jednou perturbací ve směru \vec{e}_i lze tedy napočítat jeden sloupec.
- Celkem tedy musíme vyčíslit hodnoty

$$\vec{f}(\vec{x}), \vec{f}(\vec{x} + \epsilon \vec{e}_1), \dots, \vec{f}(\vec{x} + \epsilon \vec{e}_n),$$

tj. celkem $(n + 1) \times$ vyčíslit funkci \vec{f} .

- Všechna vyčíslení jsou na sobě nezávislá a lze je případně provést paralelně.

Výpočet Jakobiánů

- V případě některých metod, jako *inexact Newton method*, se nepočítá inverze Jakobiánu, ale Jakobián se vždy aplikuje na určitý vektor \vec{p} .
- Pak lze použít přímo vztah

$$\mathbb{J}_{\vec{f}}(\vec{x})\vec{p} \approx \frac{\vec{f}(\vec{x} + \epsilon\vec{p}) - \vec{f}(\vec{x})}{\epsilon}.$$

- Funkci \vec{f} pak vyčíslujeme pouze dvakrát a šetříme paměť, protože Jakobián nemusíme ukládat v paměti explicitně.

Výpočet řídkého Jakobiánů

- V některých úlohách může být Jakobián řídký.
- Například u takto definované funkce

$$\vec{f}(\vec{x}) = \begin{pmatrix} 2(x_2^3 - x_1^2) \\ 3(x_2^3 - x_1^2) + 2(x_3^3 - x_2^2) \\ \vdots \\ 3(x_i^3 - x_{i-1}^2) + 2(x_{i+1}^3 - x_i^2) \\ \vdots \\ 3(x_{n-1}^3 - x_{n-2}^2) + 2(x_n^3 - x_{n-1}^2) \\ 3(x_n^3 - x_{n-1}^2) \end{pmatrix}.$$

Výpočet řídkého Jakobiánů

- Jakobián pak má následující tridiagonální vzor nenulových prvků

$$\begin{pmatrix} * & * & & & & & \\ * & * & * & & & & \\ & * & * & * & & & \\ & & * & * & * & & \\ & & & * & * & * & \\ & & & & * & * & * \\ & & & & & * & * \end{pmatrix}.$$

Výpočet řídkého Jakobiánů

- Zvolme například $n = 6$, pak je

$$\vec{f}(\vec{x}) = \begin{pmatrix} -2x_1^2 & 2x_2^3 & & & & \\ -3x_1^2 & 3x_2^3 - 2x_2^2 & 2x_3^3 & & & \\ & -3x_2^2 & 3x_3^3 - 2x_3^2 & 2x_4^3 & & \\ & & -3x_3^2 & 3x_4^3 - 2x_4^2 & 2x_5^3 & \\ & & & -3x_4^2 & 3x_5^3 - 2x_5^2 & 2x_6^3 \\ & & & & -3x_5^2 & 3x_6^3 - 2x_6^2 \end{pmatrix}.$$

- Pro výpočet $\frac{\partial \vec{f}}{\partial x_1}$ musíme napočítat perturbaci $\vec{f}(\vec{x} + \epsilon \vec{e}_1)$.

Výpočet řídkého Jakobiánů

- Perturbace vektorem $\epsilon \vec{e}_1$ ovlivní pouze první dvě složky f_1 a f_2

$$\frac{\partial \vec{f}(\vec{x})}{\partial x_1} \approx \begin{pmatrix} \frac{f_1(\vec{x} + \epsilon \vec{e}_1) - f_1(\vec{x})}{\epsilon} \\ \frac{f_2(\vec{x} + \epsilon \vec{e}_1) - f_2(\vec{x})}{\epsilon} \\ 0 \\ 0 \\ 0 \end{pmatrix}.$$

- Perturbace vektorem $\epsilon \vec{e}_4$ zase ovlivní pouze složky f_3, f_4 s f_5

$$\frac{\partial \vec{f}(\vec{x})}{\partial x_4} \approx \begin{pmatrix} 0 \\ 0 \\ \frac{f_3(\vec{x} + \epsilon \vec{e}_4) - f_3(\vec{x})}{\epsilon} \\ \frac{f_4(\vec{x} + \epsilon \vec{e}_4) - f_4(\vec{x})}{\epsilon} \\ \frac{f_5(\vec{x} + \epsilon \vec{e}_4) - f_5(\vec{x})}{\epsilon} \\ 0 \end{pmatrix}.$$

Výpočet řídkého Jakobiánů


- Pokud tedy napočítáme perturbaci vektorem $\epsilon \vec{p} = \epsilon(\vec{e}_1 + \vec{e}_4)$, dostaneme vektor

$$\nabla \vec{f} \vec{p} = \begin{pmatrix} \frac{f_1(\vec{x} + \epsilon(\vec{e}_1 + \vec{e}_4)) - f_1(\vec{x})}{\epsilon} \\ \frac{f_2(\vec{x} + \epsilon(\vec{e}_1 + \vec{e}_4)) - f_2(\vec{x})}{\epsilon} \\ \frac{f_3(\vec{x} + \epsilon(\vec{e}_1 + \vec{e}_4)) - f_3(\vec{x})}{\epsilon} \\ \frac{f_4(\vec{x} + \epsilon(\vec{e}_1 + \vec{e}_4)) - f_4(\vec{x})}{\epsilon} \\ \frac{f_5(\vec{x} + \epsilon(\vec{e}_1 + \vec{e}_4)) - f_5(\vec{x})}{\epsilon} \\ 0 \end{pmatrix} = \begin{pmatrix} \frac{f_1(\vec{x} + \epsilon(\vec{e}_1)) - f_1(\vec{x})}{\epsilon} \\ \frac{f_2(\vec{x} + \epsilon(\vec{e}_1)) - f_2(\vec{x})}{\epsilon} \\ \frac{f_3(\vec{x} + \epsilon(\vec{e}_4)) - f_3(\vec{x})}{\epsilon} \\ \frac{f_4(\vec{x} + \epsilon(\vec{e}_4)) - f_4(\vec{x})}{\epsilon} \\ \frac{f_5(\vec{x} + \epsilon(\vec{e}_4)) - f_5(\vec{x})}{\epsilon} \\ 0 \end{pmatrix} \approx \begin{pmatrix} \frac{\partial f_1(\vec{x})}{\partial x_1} \\ \frac{\partial f_2(\vec{x})}{\partial x_1} \\ \frac{\partial f_3(\vec{x})}{\partial x_4} \\ \frac{\partial f_4(\vec{x})}{\partial x_4} \\ \frac{\partial f_5(\vec{x})}{\partial x_4} \\ 0 \end{pmatrix}.$$

- První dvě složky tedy odpovídají prvnímu sloupci Jakobiánu a složky 3, 4 a 5 odpovídají čtvrtému sloupci Jakobiánu.

Výpočet řídkého Jakobiánů

- Abychom zjistili, které perturbace lze vzájemně kombinovat, sestrojíme si incidenční graf.
- Pro funkci $\vec{f} : \mathbb{R}^n \rightarrow \mathbb{R}^m$ má tento graf n uzlů.
- Mezi uzly i a k vede hrana právě když existuje f_j , které závisí na x_i a x_k .
- V grafu pak napočítáme vrcholové obarvení.
- Každé barvě pak lze přiřadit jeden perturbační vektor.



J. Nocedal, S. J. Wright, Numerical Optimization, Springer, 2006.

Výpočet Hessiánu

- Mějme funkci $f \in C^2(\mathbb{R}^n; \mathbb{R})$ a chceme napočítat Hessián $\nabla^2 f(\vec{x}) \in \mathbb{R}^{n,n}$.
- Lze postupovat stejně jako při výpočtu Jakobiánu funkce $\nabla f(\vec{x})$.
- Hessián je však symetrický a díky numerickým chybám může být symetrie porušena.
- Někdy se proto vyplatí provést průměrování příslušných transponovaných prvků.
- Pokud potřebujeme výsledný Hessián pouze aplikovat na určitý vektor \vec{p} , pak si lze opět pomoci konečnou diferencí, tj.

$$\nabla^2 f(\vec{x})\vec{p} \approx \frac{\nabla f(\vec{x} + \epsilon\vec{p}) - \nabla f(\vec{x})}{\epsilon}.$$

Výpočet Hessiánu

- Hessián lze také počítat podle vztahu

$$\frac{\partial^2 f(\vec{x})}{\partial x_i \partial x_j} \approx \frac{f(\vec{x} + \epsilon \vec{e}_i + \epsilon \vec{e}_j) - f(\vec{x} + \epsilon \vec{e}_i) - f(\vec{x} + \epsilon \vec{e}_j) + f(\vec{x})}{\epsilon^2} + O(\epsilon).$$

- Tento postup vyžaduje celkem

$$\frac{n(n-1)}{2} + 2n + 1 = O(n^2)$$

vyčíslení funkce f .

Výpočet řídkého Hessiánu

- V řadě úloh může být Hessián řídký. Pak lze použít podobný postup jako pro výpočet řídkého Jakobiánu aplikovaný na $\nabla f(\vec{x})$.
- Obecně je potřeba sestavit adjacenční graf o n uzlech.
- Uzly i a j , $i \neq j$ jsou spojené hranou pokud platí

$$\frac{\partial^2 f(\vec{x})}{\partial x_i \partial x_j} \neq 0.$$

- Následně hledáme obarvení, kde každé dva uzly spojené hranou mají různou barvu a každá cesta v grafu délky tři obsahuje alespoň tři barvy.

T. F. Coleman, J. J. Moré, *Estimation of sparse hessian matrices and graph coloring problems*,
Mathematical Programming vol. 28, pp. 243–270, 1984.

Automatické derivování

- Pod tímto názvem se rozumí postupy pro derivování funkcí vyjádřených ve formě výpočetního kódu.
- Výpočet každé funkce lze rozdělit jako posloupnost několika základních operací.
- Stačí pak odvodit derivace těchto základních operací.
- Dále se využívá pravidlo pro derivaci složené funkce – *chain rule*

$$\nabla_{\vec{x}} h(y(\vec{x})) = \sum_{i=1}^m \frac{\partial h}{\partial y_i} \nabla y_i(\vec{x}),$$

pro $y : \mathbb{R}^n \rightarrow \mathbb{R}^m, h : \mathbb{R}^m \rightarrow \mathbb{R}$.

Automatické derivování

Existují dva základní přístupy:

- **dopředný** – *forward*,
- **zpětný** – *reverse*.

Předvedeme si je na následujícím příkladu:

$$f(\vec{x}) = \frac{x_1 x_2 \sin(x_3) + \exp(x_1 x_2)}{x_3}.$$

To lze vyhodnotit takto:

$$x_4 = x_1 x_2,$$

$$x_5 = \sin(x_3),$$

$$x_6 = \exp(x_4),$$

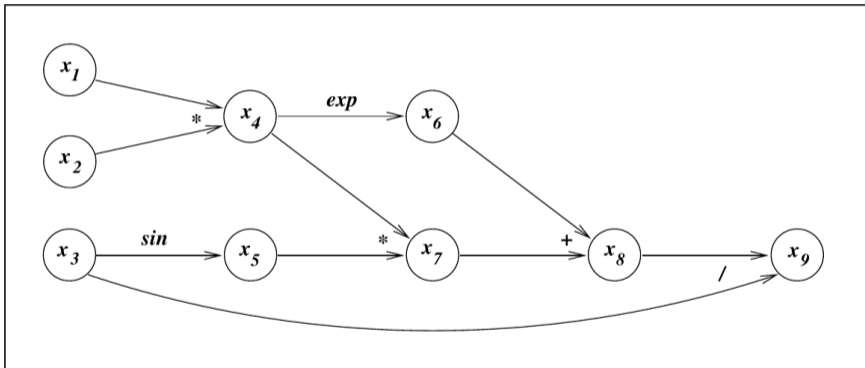
$$x_7 = x_4 x_5,$$

$$x_8 = x_6 + x_7,$$

$$x_9 = x_8 / x_3.$$

Automatické derivování

Vyčíslení lze také vyjádřit pomocí následujícího grafu:



J. Nocedal, S. J. Wright, Numerical Optimization, Springer, 2006.

Dopředný mód

- Cílem je vypočítat směrovou derivaci funkce f ve směru $\vec{p} \in \mathbb{R}^n$
 - $n = 3$ v našem příkladu.
- Toho lze dosáhnout tak, že budeme postupně napočítávat

$$D_{\vec{p}}x_i = \nabla x_i \cdot \vec{p} = \sum_{j=1}^3 \frac{\partial x_i}{\partial x_j} p_j \text{ pro } i = 1, 2, \dots, 9,$$

kde

$$\nabla x_i = \left(\frac{\partial x_i}{\partial x_1}, \frac{\partial x_i}{\partial x_2}, \frac{\partial x_i}{\partial x_3} \right).$$

- Platí totiž

$$D_{\vec{p}}f = D_{\vec{p}}x_9$$

- Snadno vidíme, že platí

$$\begin{pmatrix} \nabla x_1 \\ \nabla x_2 \\ \nabla x_3 \end{pmatrix} \vec{p} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix} \vec{p} = \vec{p},$$

tj.

$$\begin{pmatrix} D_{\vec{p}} x_1 \\ D_{\vec{p}} x_2 \\ D_{\vec{p}} x_3 \end{pmatrix} = \begin{pmatrix} p_1 \\ p_2 \\ p_3 \end{pmatrix} = \vec{p}.$$

Dopředný mód

Podobně

Dále dostáváme ($x_4 = x_1 x_2$)

$$\begin{aligned}\nabla x_4 &= \frac{\partial x_4}{\partial x_1} \nabla x_1 + \frac{\partial x_4}{\partial x_2} \nabla x_2 \\ &= x_2 \nabla x_1 + x_1 \nabla x_2\end{aligned}$$

a tedy

$$\begin{aligned}D_{\vec{p}} x_4 &= \frac{\partial x_4}{\partial x_1} D_{\vec{p}} x_1 + \frac{\partial x_4}{\partial x_2} D_{\vec{p}} x_2 \\ &= x_2 D_{\vec{p}} x_1 + x_1 D_{\vec{p}} x_2.\end{aligned}$$

$$x_5 = \sin(x_3) \Rightarrow D_{\vec{p}} x_5 = \frac{\partial x_5}{\partial x_3} D_{\vec{p}} x_3 = \cos(x_3) D_{\vec{p}} x_3$$

$$x_6 = \exp(x_4) \Rightarrow D_{\vec{p}} x_6 = \frac{\partial x_6}{\partial x_4} D_{\vec{p}} x_4 = \exp(x_4) D_{\vec{p}} x_4$$

$$\begin{aligned}x_7 = x_4 x_5 &\Rightarrow D_{\vec{p}} x_7 = \frac{\partial x_7}{\partial x_4} D_{\vec{p}} x_4 + \frac{\partial x_7}{\partial x_5} D_{\vec{p}} x_5 \\ &= x_5 D_{\vec{p}} x_4 + x_4 D_{\vec{p}} x_5\end{aligned}$$

$$\begin{aligned}x_8 = x_6 + x_7 &\Rightarrow D_{\vec{p}} x_8 = \frac{\partial x_8}{\partial x_6} D_{\vec{p}} x_6 + \frac{\partial x_8}{\partial x_7} D_{\vec{p}} x_7 \\ &= D_{\vec{p}} x_6 + D_{\vec{p}} x_7\end{aligned}$$

$$\begin{aligned}x_9 = x_8 / x_3 &\Rightarrow D_{\vec{p}} x_9 = \frac{\partial x_9}{\partial x_8} D_{\vec{p}} x_8 + \frac{\partial x_9}{\partial x_3} D_{\vec{p}} x_3 \\ &= \frac{1}{x_3} D_{\vec{p}} x_8 - \frac{x_8}{x_3^2} D_{\vec{p}} x_3\end{aligned}$$

Dopředný mód

- Výpočetně se vše provádí tak, že pro každou proměnnou u si program pro AD napočítává i příslušnou derivaci $D_{\vec{p}}u$.
- To pak použije, pokud je to potřeba pro výpočet směrových derivací odvozených proměnných.
- Na příkladu

$$z := \frac{w}{y} \quad \rightarrow \quad D_{\vec{p}}z := \frac{1}{y} D_{\vec{p}}w - \frac{w}{y^2} D_{\vec{p}}y.$$

- vidíme, že výpočet derivace může vyžadovat násobně více operací.
- Pokud chceme napočítat gradient ∇f , musíme vše provádět souběžně pro n vektorů

$$\vec{p} = \vec{e}_1, \dots, \vec{e}_n.$$

- Celkově může tak počet potřebných operací a místo v paměti výrazně narůst

Dopředný mód

- Dopředný mód může být implementovaný jako:
 - součástí překladače,
 - formou precompileru,
 - pomocí přetížení operátorů v C++ – [autodiff](#).

Zpětný mód

- V tomto režimu nevyčísľujeme gradient souběžně s funkcí samotnou.
- Místo toho nejprve vyčísľíme kompletně funkci f a následně dopočítáváme gradient.
- Ve zpětném módu využíváme pomocné proměnné \tilde{x}_i asociované z každým uzlem výpočetního grafu.
- Tyto proměnné se někdy označují jako adjungované – *adjoint*.
- Vycházíme opět ze vztahu pro derivování složené funkce

$$\frac{\partial f}{\partial x_i} = \sum_{j \in \text{potomek}(i)} \frac{\partial f}{\partial x_j} \frac{\partial x_j}{\partial x_i}.$$

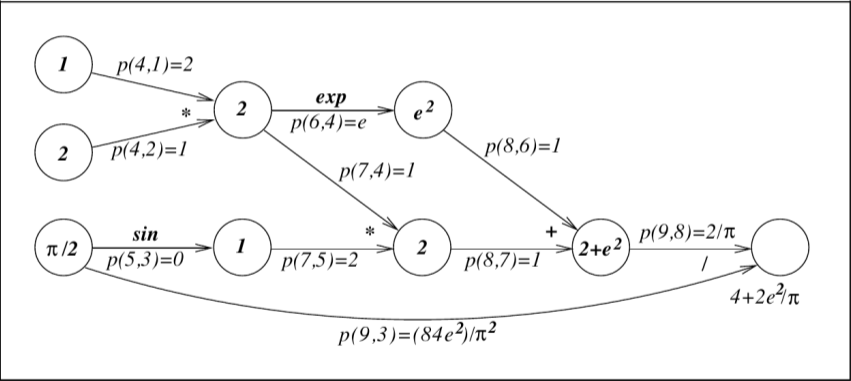
- Pro každou proměnnou \tilde{x}_i provádíme update

$$\tilde{x}_{i+} = \frac{\partial f}{\partial x_j} \frac{\partial x_j}{\partial x_i}$$

jakmile jsou jednotliví členové celé sumy známé.

Zpětný mód

Zpětný mód si předvedeme na předchozím příkladu v bodě $\vec{x} = (1, 2, \pi/2)$




J. Nocedal, S. J. Wright, Numerical Optimization, Springer, 2006.

Zpětný mód

- Nejprve inicializujeme všechny adjungované proměnné $\tilde{x}_i = 0$.
- Pouze u poslední platí $\tilde{x}_9 = 1 = \frac{\partial f}{\partial x_9}$, kde $x_9 = f$.
- Uzel 9 závisí na uzlech 8 a 3
- Vidíme, že

$$\frac{\partial f}{\partial x_8} = \frac{\partial f}{\partial x_9} \frac{\partial x_9}{\partial x_8},$$
$$\frac{\partial f}{\partial x_3} = \frac{\partial f}{\partial x_9} \frac{\partial x_9}{\partial x_3} + \underbrace{\frac{\partial f}{\partial x_5}}_{\text{neznáme}} \frac{\partial x_5}{\partial x_3}.$$



- Dostáváme

$$\tilde{x}_8 = \frac{\partial f(\vec{x})}{\partial x_8} + = \frac{\partial f(\vec{x})}{\partial x_9} \frac{\partial x_9(\vec{x})}{\partial x_8} = \tilde{x}_9 \frac{1}{x_3} = 1 \cdot \frac{1}{\pi/2} = \frac{2}{\pi},$$

$$\frac{\partial f(\vec{x})}{\partial x_3} + = \frac{\partial f(\vec{x})}{\partial x_9} \frac{\partial x_9(\vec{x})}{\partial x_3} = 1 \frac{-x_8}{x_3^2} = -\frac{2 + e^2}{(\pi/2)^2} = \frac{-8 - 4e^2}{\pi^2}.$$

- Uzel 3 má za potomka uzel 5, takže ještě není plně vyřešen.
- Uzel 8 již jiného potomka nemá, můžeme ho tedy označit za vyřešený.
- Díky znalosti uzlu 8 můžeme pokročit k uzlům 6 a 7.

Zpětný mód

- Dostáváme ($x_8 = x_6 + x_7$)

$$\frac{\partial f(\vec{x})}{\partial x_6} = \frac{\partial f(\vec{x})}{\partial x_8} \frac{\partial x_8(\vec{x})}{\partial x_6},$$

$$\frac{\partial f(\vec{x})}{\partial x_7} = \frac{\partial f(\vec{x})}{\partial x_8} \frac{\partial x_8(\vec{x})}{\partial x_7}$$

a tedy

$$\tilde{x}_6 = \frac{\partial f(\vec{x})}{\partial x_6} + = \tilde{x}_8 \cdot 1 = \frac{2}{\pi},$$

$$\tilde{x}_7 = \frac{\partial f(\vec{x})}{\partial x_7} + = \tilde{x}_8 \cdot 1 = \frac{2}{\pi}$$

- Oba uzly 6 a 7 jsou nyní již kompletní.

- Dále napočítáme uzly 4

($x_6 = \exp(x_4)$, $x_7 = x_4 x_5$) a 5 ($x_7 = x_4 x_5$)

$$\frac{\partial f(\vec{x})}{\partial x_4} = \frac{\partial f(\vec{x})}{\partial x_6} \frac{\partial x_6(\vec{x})}{\partial x_4} + \frac{\partial f(\vec{x})}{\partial x_7} \frac{\partial x_7(\vec{x})}{\partial x_4},$$

$$\frac{\partial f(\vec{x})}{\partial x_5} = \frac{\partial f(\vec{x})}{\partial x_7} \frac{\partial x_7(\vec{x})}{\partial x_5}$$

a tedy

$$\tilde{x}_4 = \frac{\partial f(\vec{x})}{\partial x_4} + = \tilde{x}_6 \exp x_4 + \tilde{x}_7 x_5 = \frac{2}{\pi} e^2 + \frac{2}{\pi} \cdot 1$$

$$\tilde{x}_5 = \frac{\partial f(\vec{x})}{\partial x_5} + = \tilde{x}_7 x_4 = \frac{2}{\pi} \cdot 2.$$

- Nakonec můžeme už dopočítat $\tilde{x}_1, \tilde{x}_2, \tilde{x}_3$

$$\frac{\partial f(\vec{x})}{\partial x_1} = \frac{\partial f(\vec{x})}{\partial x_4} \frac{\partial x_4}{\partial x_1} \text{ ze vztahu } (x_4 = x_1 x_2),$$

$$\frac{\partial f(\vec{x})}{\partial x_2} = \frac{\partial f(\vec{x})}{\partial x_4} \frac{\partial x_4}{\partial x_2} \text{ ze vztahu } (x_4 = x_1 x_2),$$

$$\frac{\partial f(\vec{x})}{\partial x_3} = \frac{\partial f(\vec{x})}{\partial x_5} \frac{\partial x_5}{\partial x_3} \text{ ze vztahu } (x_5 = \sin(x_3)),$$

a tedy

$$\tilde{x}_1 = \frac{\partial f(\vec{x})}{\partial x_1} = \tilde{x}_4 x_2 = \frac{2}{\pi} (e^2 + 1) \cdot 2,$$

$$\tilde{x}_2 = \frac{\partial f(\vec{x})}{\partial x_2} = \tilde{x}_4 x_1 = \frac{2}{\pi} (e^2 + 1) \cdot 1,$$

$$\tilde{x}_3 = \frac{\partial f(\vec{x})}{\partial x_3} = \tilde{x}_5 \cos(x_3) = \frac{4}{\pi} \cos\left(\frac{\pi}{2}\right) = 0.$$

- Nesmíme ale zapomenout na původní hodnotu $\tilde{x}_3 = \frac{-8-4e^2}{\pi^2}$.
- Celkem tedy platí

$$\nabla f(\vec{x}) = \left(4\frac{e^2 + 1}{\pi}, 2\frac{e^2 + 1}{\pi}, -4\frac{2 + e^2}{\pi^2} \right).$$

Zpětný mód

- Můžeme si všimnout, že výpočet se hodně podobá algoritmu zpětné propagace (*backpropagation*)
- Výsledkem zpětného módu je gradient funkce f .
- Směrové derivace pak lze snadno počítat ze znalosti gradientu.
- Dále si všimneme, že u dopředného módu jsme potřebovali pomocnou proměnnou pro každou složku gradientu.
- Počet operací a paměťová náročnost je tedy úměrná dimenzi gradientu (pokud nebudeme počítat jednu složku po druhé).
- U zpětného chodu na velikosti gradientu nijak nezáleží.
- Proto je zpětný chod výhodnější.
- Nevýhoda zpětného chodu je nutnost udržovat v paměti výpočetní graf, který může zabírat také hodně paměti.
- Implementace v C/C++ např. [ADOL-C](#).

Omezení automatického derivování

- Ukazuje se, že AD může být náchylné na zaokrouhlovací chyby vznikající pro numerických výpočtech jako je např. řešení parciálních diferenciálních rovnic pomocí FDM, FVM nebo FEM.
- Další překážkou mohou být podmínky v kódu.
- Např. tento kód pro (bizární) výpočet funkce $f(x) = x - 1$

```
1  if ( x == 1.0 )
2      f = 0.0
3  else
4      f = x - 1.0;
```

- Výsledek AD bude, že $f'(1) = 0$.

Další zdroje:

- 1 www.autodiff.org
- 2 juliadiff.org
- 3 A. G. Baydin, B. A. Pearlmutter, A. A. Radul, J. M. Siskind, *Automatic differentiation in machine learning: a survey*, Journal of Machine Learning Research, vol. 18, pp. 1–43, 2018.