

# Přednáška 4 - aritmetika PC

- opět z minule:
- pro Chebyshev. interpolaci jsou dostali přesnost pouze na úrovni cca  $10^{-16}$
  - pro Vandamond. interpolaci a Lagrange interpolaci jsou dostali dost jiné výsledky v PC, přestože jsou matem. ekvivalentní
  - pro barycentrického Lagrange jsou dostali lepší výsledky než pro klasického, přestože jsou matem. (barycentrický lagr. -avíba) ekvivalentní

## Jak jsou čísla uložena v PC?

→ existuje standardizace (od 1985 - do té doby divoký západ, nekompatibilita a soutěž trhu o lepší design)

DEE E754  
(wiki)

→ sponzoroval, ale matné konverenze musí  
⇒ nerealistické uložit přesně  $\pi, \sqrt{2}, e, \dots$   
ale dokonce nevádáme ani lehčí

→ nepřijde do detailů, pouze ukážkou tři konkrétní čísla

$x \in \mathbb{R}$  --- číslo co lze reprezentovat v PC  
 $x_{FPA} \in \mathbb{R}$  --- to číslo, které správně v PC máme  
 (FPA  $\equiv$  floating-point precision arithmetic)  
 (též finite precision arithmetic)

$\rightsquigarrow$  povede podlejdeme, že  $x = x_{FPA}$  nebo  $x \approx x_{FPA}$

$$x = 6 \cdot 10^1 + 1 \cdot 10^0 = 61 \quad \text{--- dekadický zápis}$$

$$x = 32 + 16 + 8 + 4 + 1 = 1 \cdot 2^5 + 1 \cdot 2^4 + 1 \cdot 2^3 + 1 \cdot 2^2 + 0 \cdot 2^1 + 1 \cdot 2^0$$

$$x_{FPA} = 111101 \quad \text{--- binární zápis}$$

$\rightsquigarrow$  a  $\{0,1\}$  my v PC užíváme

$\rightsquigarrow$  opravdu  $x = x_{FPA}$

$$x = 0.15625$$

$$= (+1) \cdot 10^{-1} \cdot 15625 = (+1) \cdot 10^{-1} \cdot (1 \cdot 10^0 + 5 \cdot 10^{-1} + 6 \cdot 10^{-2} + 2 \cdot 10^{-3} + 5 \cdot 10^{-4})$$

$$= (+1) \cdot 2^{-3} \cdot 1.25 = (+1) \cdot 2^{-3} \cdot (1 \cdot 2^0 + 0 \cdot 2^{-1} + 1 \cdot 2^{-2})$$

$$= (+1) \cdot 2^{\text{exp}} \cdot [101] \quad \& \quad \text{exp} = -[11]^1$$

$$= (+1) \cdot 11^{-[11]^1} \cdot 11[101] = -(1 \cdot 2^1 + 1 \cdot 2^0)$$

$$x_{FPA} = \{1\}, -\{1,1\}, \{101\} \Rightarrow x = x_{FPA}$$

$$x = 1.3 = (+1) \cdot 10^0 \cdot 1.3 = (+1) \cdot 10^0 \cdot (1 \cdot 10^0 + 3 \cdot 10^{-1})$$

$$= (+1) \cdot 2^0 \cdot (1 \cdot 2^0 + 0 \cdot 2^{-1} + 1 \cdot 2^{-2} + 0 \cdot 2^{-3} + 0 \cdot 2^{-4} + 1 \cdot 2^{-5} + 1 \cdot 2^{-6} + 0 \cdot 2^{-7} + 0 \cdot 2^{-8} + 1 \cdot 2^{-9} + 1 \cdot 2^{-10} + \dots)$$

$$= (+1) \cdot 2^0 \cdot [101001100110011\dots]$$

$$\Rightarrow x_{FPA} \neq x \quad \text{--- musíme ten nekonečný binární rozvoj někde zahnut}$$

Standard ve všech PC: tzv. double precision = fp64 formát  
 = {1 bit znaménko, 11 bitů exponent, 52 bitů  
 na binární rozvoj}

$$\text{Platí: } \forall x \in (-10^{308}, -10^{-38}) \cup (10^{-38}, 10^{308}) \exists x_{\text{FPA}} : \frac{|x - x_{\text{FPA}}|}{|x|} \leq 2 \cdot 10^{-16}$$

Všechny operace v PC se provádějí pouze s  $x_{\text{FPA}}$ , tj. rovnou  
 na těch listech  $\{0, 1\}^{64}$ .

všechna data & naše manipulace/výpočty  
 s nimi jsou (snad jen trochu) nepřesné/spatné

### Potenciální problém 1

- existují matematické problémy pro které malá perturbace (změna vstupních dat/parametrů) může vést k velké změně v přesném řešení toho problému → → tzn. efekt motylých krídel
- takovým problémům se říká „špatně podmínené“ (ill-conditioned) opakem jsou „dobře podmínené“ problémy  
 $\Rightarrow$  podmínenost je vlastnost problému a pro extrémně špatně podmínené problémy je jen malá naděje na numerický výpočet řešení.

### Potenciální problém 2

- tu nepravidelnou vlastnost „efektu motylých krídel“ může mít ale také náměrně navržený numerický algoritmus: zaokrouhlovací chyby se mohou akumulovat a i pro dobré podmínený problém dát zkreslenou/spatnou odpověď.
- obecně mluvíme o stabilitě algoritmu, viz níže.

## Obecná strategie pro analyzování:

Krok 1: analyzujeme matematický problém a zjistíme jeho podmíněnost = citlivost řešení na změnu vstupních dat / parametrů.

Krok 2: analyzujeme nás algoritmus jako „přesný výpočet pro nepřesné data“.

Príklad - algoritmus pro sčítání 2 skalarů  $\alpha, \beta \in \mathbb{R}$ :

tužka + papír:  $\alpha + \beta = \gamma$  vs. algoritmus:  $\alpha +_{pc} \beta = \hat{\gamma} \approx \gamma$

analýza stability: dokážeme existenci  $\tilde{\alpha}, \tilde{\beta} \in \mathbb{R}$  t. že

$$\bullet \tilde{\alpha} + \tilde{\beta} = \hat{\gamma} \quad \bullet \tilde{\alpha} \approx \alpha \quad \bullet \tilde{\beta} \approx \beta$$

Pak algoritmus je „stabilní“ (= zpětně stabilní), pokud

$$\frac{\max\{|\alpha - \tilde{\alpha}|, |\beta - \tilde{\beta}|\}}{\max\{|\alpha|, |\beta|\}} \approx C \cdot \varepsilon_{mach}$$

Krok 3:  $x_{pc} =$  výstup ze stabilního algoritmu pro dobré  
„podmínečný“ problém  
stabilní // algoritmus

$x_{pc} =$  výstup z výpočtu „tužka + papír“)  $\Rightarrow x_{pc} \approx x_{tužka-a-papír}$   
„pro trochu změněná“ vstupní data dobré podmínečný  
problém

