

# Predavanje 1

## Uvod v numerične metode

Prvi sklop izročkov

Fakulteta za računalništvo in informatiko  
Univerza v Ljubljani

4. oktober 2021

# Viri in obveznosti

Viri:

- ▶ Bojan Orel, Osnove numerične matematike, Založba FE in FRI.
- ▶ Bor Plestenjak: Razširjen uvod v numerične metode, DMFA založništvo.

Obveznosti:

- ▶ Predavanja: 3 ure na teden
- ▶ Vaje: 2 uri na teden
- ▶ 3 domače naloge: 50% ocene
- ▶ Pisni izpit iz teorije: 50% ocene

# Vsebina predmeta

1. Računanje in vloga napak pri numerični matematiki
2. Reševanje sistemov linearnih enačb
  - ▶ Gausova eliminacija in LU razcep - cena in problemi
  - ▶ Pivotiranje
  - ▶ Iterativne metode - Jacobijeva in Seidlova iteracija
3. Reševanje nelinearnih enačb
  - ▶ Tangentna oz. Newtonova metoda
  - ▶ Metoda fiksne točke
4. Aproksimacija in interpolacija
  - ▶ Lagrangeov in Newtonov interpolacijski polinom
  - ▶ Aproksimacija po metodi najmanjših kvadratov
5. Numerično odvajanje in integriranje
  - ▶ Trapezna metoda
  - ▶ Simpsonova metoda
  - ▶ Rombergova metoda
6. Numerično reševanje diferencialnih enačb
  - ▶ Eulerjeva metoda
  - ▶ Runge-Kutta metode

# Numerično in simbolno računanje

## Numerično računanje:

- ▶ Takoj v formulo vstavljamo števila
- ▶ Pridemo do numeričnega rezultata - numerične rešitve

## Simbolno računanje:

- ▶ simboli predstavljajo števila
- ▶ izraz preoblikujemo s simbolnim račuanjem do novega simbolnega izraza - analitična rešitev

## Primer

- ▶ Numerično:

$$\frac{(17.36)^2 - 1}{17.36 + 1} = 16.36; \quad 0.25, \quad 0.33333\dots (?), \quad 3.14159\dots (?)$$

- ▶ Simbolno:

$$\frac{x^2 - 1}{x + 1} = x - 1; \quad \frac{1}{4}, \quad \frac{1}{3}, \quad \pi, \quad \tan 83$$

# Kaj zanima numerično matematiko?

Metoda... matematična konstrukcija, s katero rešujemo problem

Algoritem... koraki metode

Implementacija... zapis algoritma v izbranem jeziku

**Kaj pomeni 'biti numerično dober'?**

majhna sprememba podatkov     $\Rightarrow$     majhna napaka rezultata

**Tipična vprašanja numerične matematike:**

- ▶ Ali je problem občutljiv?
- ▶ Ali je metoda 'dobra'?
- ▶ Ali je algoritem robusten - deluje na širokem spektru problemov?
- ▶ Ali je implementacija hitra - časovna in prostorska zahtevnost?

## Občutljivih problemov NM ne more rešiti

Problem je **občutljiv**, če se ob majhni spremembi začetnih podatkov točen rezultat zelo spremeni.

Občutljivost je odvisna le od narave problema in ne od izbrane numerične metode.

### Primer (presečišča premic)

*Sistem in njegova perturbacija*

$$x + y = 2 \rightarrow x + y = 1.9999$$

$$x - y = 0 \rightarrow x - y = 0.0002$$

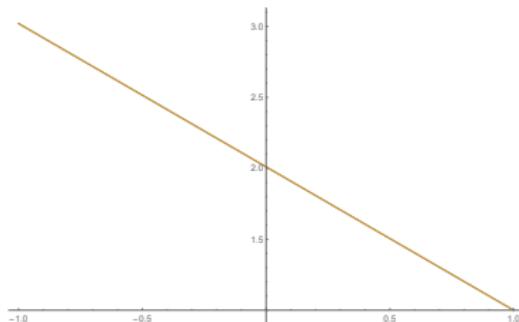
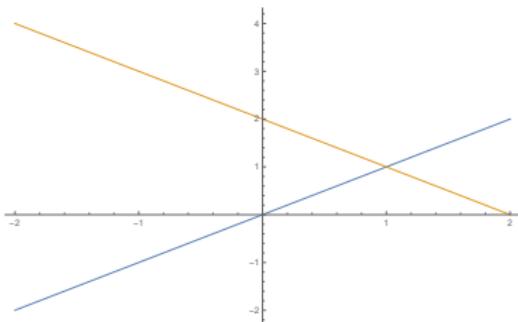
ima rešitvi  $x = y = 1$  oz.  $x = 1.00005$  in  $y = 0.99985$ . Problem je neobčutljiv, saj je šlo za spremembo za isti velikostni razred.

## Sistem in njegova perturbacija

$$x + 0.99y = 1.99 \rightarrow x + 0.99y = 1.9899$$

$$0.99x + 0.98y = 1.97 \rightarrow 0.99x + 0.98y = 1.9701$$

ima rešitvi  $x = y = 1$  oz.  $x = 2.97$  in  $y = -0.99$ . Problem je občutljiv, saj je majhna sprememba začetnih podatkov povzročila veliko spremembo rezultata.



# Na čem temeljijo numerične metode?

- ▶ Neskončne procese nadomestimo s končnimi (Taylorjeva vrsta) .
- ▶ Neskončno razsežne prostore nadomestimo s končno razsežnimi (funkcije nadomestimo s polinomi).
- ▶ Diferencialne enačbe nadomestimo z algebraičnimi (znebimo se vseh parcialnih odvodov iz enačb).
- ▶ Nelinearne probleme nadomestimo z linearnimi (linearna aproksimacija v točki).
- ▶ Matrike nadomestimo z enostavnejšimi (upoštevamo samo zgornjetrikotni del).

# Zakaj sploh potrebujemo numerično matematiko?

Znanost, ki temelji na matematičnih izračunih, je neposredno odvisna od NM.

Nekatere katastrofe so se zgodile zaradi slabega numeričnega računanja (<http://www-users.math.umn.edu/~arnold//disasters/>):

- ▶ Nesreča Misije Patriot, Zalivska vojna 1991, Savdska Arabija, 28 žrtev: **slaba analiza zaokrožitvenih napak.**

Čas zadetka iraške rakete, usmerjene na Savdsko Arabijo, je bil računan na vsako desetino sekunde v 24-bitnem sistemu. Ker velja

$$\frac{1}{10} = 2^{-4} + 2^{-5} + 2^{-8} + 2^{-9} + 2^{-12} + 2^{-13} + 2^{-16} + 2^{-17} + 2^{-20} + 2^{-21} + \underbrace{+ 2^{-24} + 2^{-25} + 2^{-28} + \dots}_{\text{zanemarimo}}$$

je vsako desetinko sekunde napaka  $9.5 \cdot 10^{-8}$  s. Po 100 urah računanja je bila napaka  $9.5 \cdot 10^{-8} \text{ s} \cdot 100 \cdot 60 \cdot 60 \cdot 10 = 0.34 \text{ s}$ . Ker je hitrost rakete 1.676 km/s, je bila pozicija rakete za več kot 500 m napačno predvidena in je ta ušla radarjem.

- ▶ *Eksplozija rakete Ariane 5, Francoska Gvajana, 1996: posledica prekoračitve obsega števil.*

[https://www.youtube.com/watch?v=PK\\_yguLapgA](https://www.youtube.com/watch?v=PK_yguLapgA)

<https://www.youtube.com/watch?v=W3YJeoYgozw>

Ob prenovi rakete so 'pozabili' nadgraditi uporabljen številski sistem, ki je horizontalno hitrost meril v 16-bitnem sistemu (1 bit porabimo za predznak). Največja hitrost v tem sistemu je

$$2^0 + 2^1 + \dots + 2^{13} + 2^{14} = \frac{2^{15} - 1}{2 - 1} = 32767.$$

Ker je prenovljena raketa po 37 sekundah presegla to hitrost, je prišlo do zaustavitve motorjev...

- ▶ *Potop naftne ploščadi Sleipner A, Stavanger, Norveška, 1991, miljarda dolarjev škode: nenatančna obdelava obremenitev pri reševanju PDE-jev.*

<https://www.youtube.com/watch?v=eGdiPs4THW8>

# Ponovitev predstavljenih števil

Števila shranjujemo v obliki

$$x = \pm 0.d_1 d_2 d_3 \dots d_m \times \beta^e,$$

kjer je

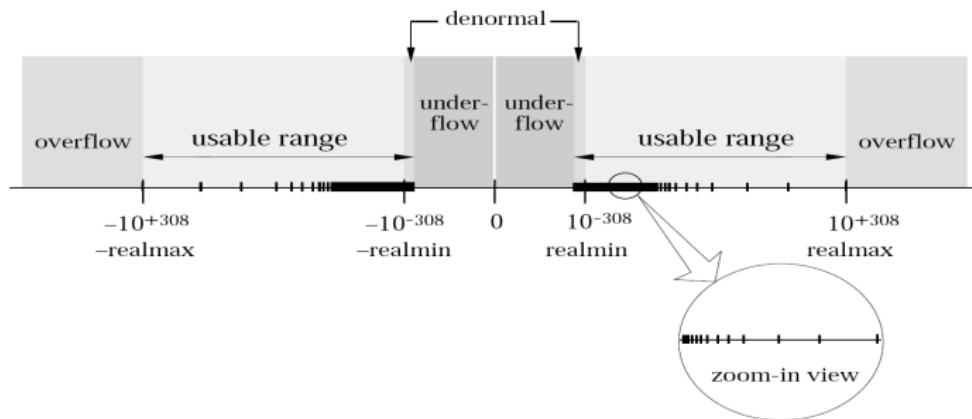
- ▶  $\beta$  naravno število (v računalništvu  $\beta = 2$ ),
- ▶  $d_1 d_2 d_3 \dots d_m$  mantisa,  $e$  eksponent.

## Primer (baza 10)

- ▶  $1000.12345$  zapišemo kot  $+(0.100012345)_{10} \times 10^4$ .
- ▶  $0.000812345$  zapišemo kot  $+(0.812345)_{10} \times 10^{-3}$ .

# Prekoračitev in podkoračitev

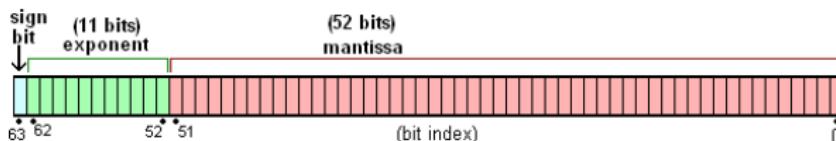
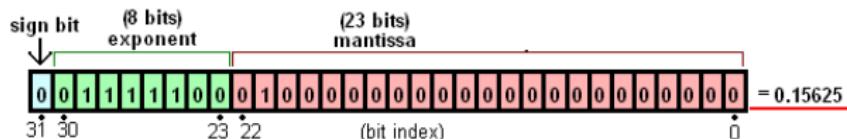
## Floating Point Number Line



- ▶ izračuni preblizu 0 lahko povzročijo **podkoračitev**
- ▶ preveliki izračuni lahko povzročijo **prekoračitev**
- ▶ prekoračitev je v splošnem hujši problem

# IEEE standard

- ▶ IEEE Enojna natančnost: števila so predstavljena z 32 biti.
  - ▶ IEEE Dvojna natančnost: števila so predstavljena z 64 biti.



## Kaj so zaokrožitvene napake?

- ▶ Večine realnih števil ne moremo predstaviti v strojni aritmetiki  $\Rightarrow$  zaokrožujemo in delamo zaokrožitvene napake.
- ▶ IEEE standard... zaokroži  $x$  do najbližjega predstavljivega števila  $\text{fl}(x)$ . Naj bosta  $x_- \leq x \leq x_+$  najbližji predstavljeni števili števila  $x$ . Potem je

$$\text{fl}(x) = \begin{cases} x_-, & \text{če je } x - x_- < x_+ - x, \\ x_+, & \text{če je } x - x_- \geq x_+ - x. \end{cases}$$

- ▶ Kako velika je napaka? Recimo, da je  $x$  bližje  $x_-$ :

$$x = (0.1b_2b_3 \dots b_m b_{m+1})_2 \times 2^e,$$

$$x_- = (0.1b_2b_3 \dots b_m)_2 \times 2^e,$$

$$x_+ = ((0.1b_2b_3 \dots b_m)_2 + 2^{-m}) \times 2^e,$$

$$x - x_- \leq \frac{x_+ - x_-}{2} = 2^{e-m-1},$$

$$\frac{x - x_-}{x} \leqslant \frac{2^{e-m-1}}{1/2 \times 2^e} \leqslant \underbrace{2^{-m}}_u \dots$$

osnovna zaokrožitvena napaka

Torej je

$$x_- = x_- - x + x \geqslant -ux + x = x(1 - u).$$

Podobno  $x_+ \leqslant x(1 + u)$ . Sledi

$$\boxed{\text{fl}(x) = x(1 + \delta)}, \quad \text{kjer je } |\delta| < u.$$

Analogna izpeljava velja v primeru, ko je  $x$  negativen.

## Kako računamo s predstavljenimi števili?

Za **predstavljeni** števili  $x, y$  in katerokoli od osnovnih operacij  $\odot \in \{+, -, \cdot, :\}$  število  $x \odot y$  ni nujno predstavljivo. Po zgornjem pa velja

$$\text{fl}(x \odot y) = (x \odot y)(1 + \delta), \quad \text{kjer je } |\delta| \leq u.$$

Seštevanje numerično **ni asociativna operacija**, tj.

$$(a + b) + c \neq a + (b + c) :$$

$$\begin{aligned} (a + b) + c &= \text{fl}(\text{fl}(a + b) + c) = \text{fl}((a + b)(1 + \delta_1) + c) \\ &= [(a + b)(1 + \delta_1) + c](1 + \delta_2) \\ &= [(a + b + c) + (a + b)\delta_1](1 + \delta_2) \\ &= (a + b + c) \left[ 1 + \frac{a + b}{a + b + c} \delta_1(1 + \delta_2) + \delta_2 \right] \end{aligned}$$

Podobno

$$a + (b + c) = (a + b + c) \left[ 1 + \frac{b + c}{a + b + c} \delta_3(1 + \delta_4) + \delta_4 \right].$$

Če pozabimo na člena  $\delta_1\delta_2$  in  $\delta_3\delta_4$ , dobimo

$$(a + b) + c = (a + b + c)(1 + \epsilon_3) \quad \text{kjer je} \quad \epsilon_3 \approx \frac{a + b}{a + b + c} \delta_1 + \delta_2,$$

$$a + (b + c) = (a + b + c)(1 + \epsilon_4) \quad \text{kjer je} \quad \epsilon_4 \approx \frac{b + c}{a + b + c} \delta_3 + \delta_4.$$

**Sklep:** Ko seštevamo števila, je za čim manjšo napako najbolje začeti z najmanjšim in prištevati večje.

# Napake pri numeričnem računanju

- ▶ **Neodstranljiva napaka**  $D_n \dots$  nenatančni začetni podatki.
- ▶ **Napaka metode**  $D_m \dots$  npr. neskončni proces aproksimiramo s končnim.
- ▶ **Zaokrožitvena napaka**  $D_z \dots$  računanje s približki in zaokroževanje.

Celotna napaka  $D$  je

$$D = D_n + D_m + D_z .$$

Primer ( $\sin \frac{\pi}{10}$  računamo v desetiškem sistemu z  $m = 4$ )

- ▶  $D_n: f(\frac{\pi}{10}) = 0.3142 \cdot 10^0$ . Ocenimo:  $|D_n| \approx \sin'(\frac{\pi}{10})|x - f(x)| \leq \frac{1}{2} \cdot 10^{-4}$ .
- ▶  $D_m: \sin x \approx x - x^3/6$ . Ocenimo:  $|D_m| \leq |x^5/120| = 2.6 \cdot 10^{-5}$ .
- ▶  $D_z: f(x - f(f(x \cdot x) \cdot x)/6))$ . Ocenimo:  $|D_z| \leq 3.0 \cdot 10^{-5}$ .

# Stabilnost meri kakovost metode

Stabilnost metode preverimo z **analizo zaokrožitvenih napak**.

Vrste napak ( $x$  naj bo točna vrednost,  $\bar{x}$  pa približek zanjo):

- ▶ Prva delitev:

- ▶ **Absolutna napaka** :  $|\bar{x} - x|$ .

- ▶ **Relativna napaka** :  $\frac{|\bar{x} - x|}{x}$ .

- ▶ Druga delitev:

- ▶ **Direktna napaka**: Numerična napaka rezultata.

- ▶ **Obratna napaka**: Koliko je potrebno spremeniti začetne podatke, da dobimo izračunan rezultat.

Velja

$$|\text{direktna napaka}| \approx \text{občutljivost} \times |\text{obratna napaka}|.$$

Izračunana vrednost je blizu pravi, če rešujemo neobčutljiv problem z obratno stabilno metode.

# Odštevanje in seštevanje sta lahko 'katastrofalni'

odštevanje dveh približno enakih števil

seštevanje dveh približno nasprotnih števil

$$a = x.\overbrace{xxxx\;xxxx\;xxx}{}^{\text{izguba}} 1 \overbrace{ssss\;\dots}{}^{\text{izguba}}$$

$$b = x.\overbrace{xxxx\;xxxx\;xxx}{}^{\text{izguba}} 0 \overbrace{tttt\;\dots}{}^{\text{izguba}}$$

Potem

$$\begin{array}{r} \overbrace{x.\overbrace{xxx\;xxxx\;xxx}{}^{\text{končna natančnost}} 1} \\ - \overbrace{x.\overbrace{xxx\;xxxx\;xxx}{}^{\text{izguba}}} 0 \\ \hline = 0.000\;0000\;0001 & \overbrace{\quad\quad\quad\quad\quad}^{\text{????\;????}} \\ = 1.\underbrace{\quad\quad\quad\quad\quad}_{\text{izguba natančnosti}} \cdot \beta^{-m} \end{array}$$

S ponavljanjem se napake seštevajo.