

# Numerične metode

## izročki predavanj

Aljaž Zalar

Fakulteta za računalništvo in informatiko  
Univerza v Ljubljani

Verzija 20.10.2022

# Literatura

## Osnovna vira:

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

## Tuji viri:

- ▶ K. Atkinson, W. Han: *Elementary Numerical Analysis*, 3rd edition, John Wiley & Sons, Inc., New Jersey, 2003.
- ▶ R.L. Burden, J.D. Faires, A.M. Burden: *Numerical Analysis*, 10th edition, Cengage Learning, Boston, 2016.
- ▶ G.H. Golub, C.F. Van Loan: *Matrix Computations*, 3rd edition, Johns Hopkins Univ. Press, Baltimore, 1996.
- ▶ D.R. Kincaid, E.W. Cheney: *Numerical Analysis, Mathematics of Scientific Computing*, 3rd edition, Brooks/Cole, Pacific Grove, 2002.
- ▶ L.N. Trefethen, D. Bau: *Numerical Linear Algebra*, SIAM, Philadelphia, 1997.

# Obveznosti

Potek predmeta:

- ▶ Predavanja: 3 ure na teden.
- ▶ Vaje: 2 uri na teden.

Ocena:

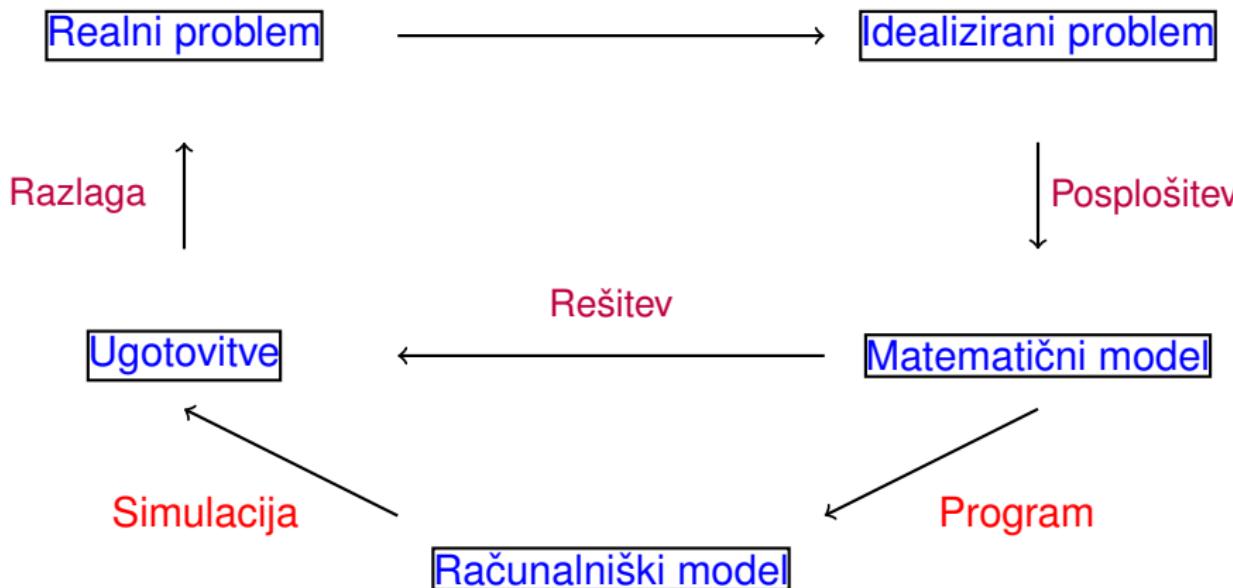
- ▶ 3 domače naloge.
- ▶ Pisni izpit.
- ▶ Ustni izpit.

Programska oprema:

- ▶ *Matlab*: Licenca dostopna za študente UL.
- ▶ *Octave*: Prosto dostopna alternativa Matlaba.

# Vloga numerične matematike

Poenostavitev



Numerična matematika ima ključno vlogo pri pretvorbi matematičnega modela v računalniškega, reševanju tega modela in razlagi rešitev s stališča napak.

# 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 Gauss-Seidlova iteracija
3. Reševanje (sistemov) nelinearnih enačb in optimizacija
  - ▶ Tangentna oz. Newtonova metoda
  - ▶ Metoda fiksne točke
  - ▶ Newtonova optimizacijska metoda
4. Aproksimacija in interpolacija
  - ▶ Lagrangeov in Newtonov interpolacijski polinom
  - ▶ Aproksimacija po metodi najmanjših kvadratov
  - ▶ QR razcep za predoločene sisteme

## 5. Numerično odvajanje in integriranje

- ▶ Trapezna metoda
- ▶ Simpsonova metoda
- ▶ Rombergova metoda

## 6. Numerično reševanje diferencialnih enačb

- ▶ Eulerjeva metoda
- ▶ Runge-Kutta metode

Prvo poglavje:

# Uvod v numerično računanje

- ▶ Numerično računanje
- ▶ Predstavljiva števila
- ▶ Zaokrožitvene napake
- ▶ Katastrofalno seštevanje/odštevanje
- ▶ Primeri (ne)stabilnega računanja

# 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:

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

# Numerično in simbolno računanje

## Primer

```
1 >> x=rand ; (x^2-1)/(x+1)-(x-1)  
2  
3 ans=1.387778780781446e-17
```

*Analitično bi rezultat moral biti 0, vendar zaradi numeričnih napak dobimo majhno napako.*

# 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    ⇒    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*

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

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

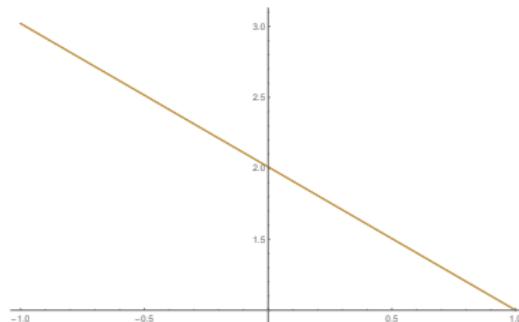
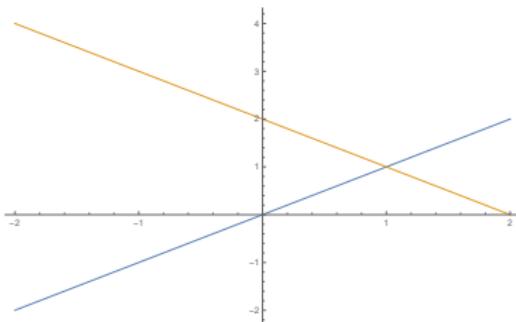
ima rešitvi  $x = y = 1$  oz.  $x = 1.00005$  in  $y = 0.99985$ . Problem je neobčutljiv, saj je šlo za spremembo za isti velikostni razred.

## 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?

- ▶ Matrike nadomestimo z enostavnejšimi (upoštevamo samo diagonalni ali zgornjetrikotni del).
- ▶ Nelinearne probleme nadomestimo z linearimi (linearna aproksimacija v točki).
- ▶ Neskončne procese nadomestimo s končnimi (uporabimo Taylorjev polinom) .
- ▶ Neskončno razsežne prostore nadomestimo s končno razsežnimi (funkcije nadomestimo s polinomi).
- ▶ Diferencialne enačbe nadomestimo z algebraicnimi (znebimo se vseh parcialnih odvodov iz enačb).

# 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 m/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

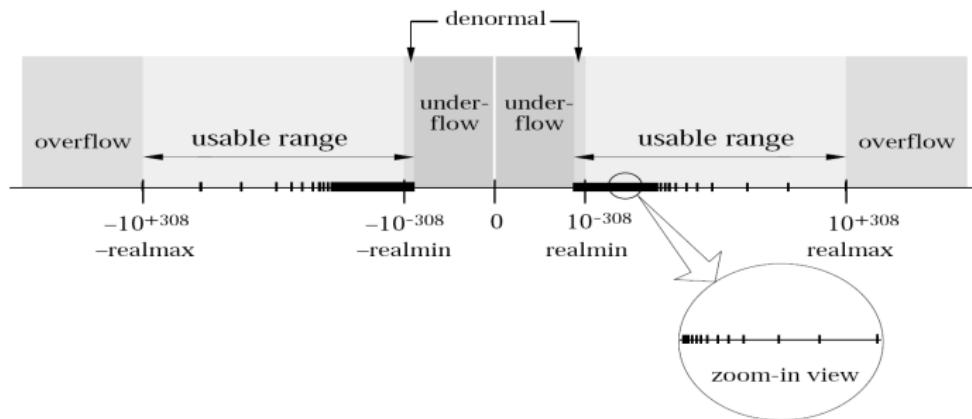
- ▶  $\beta$  naravno število (v računalništvu  $\beta = 2$ ),
- ▶  $d_1 d_2 d_3 \dots d_m$  mantisa,  $e$  eksponent.

## 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

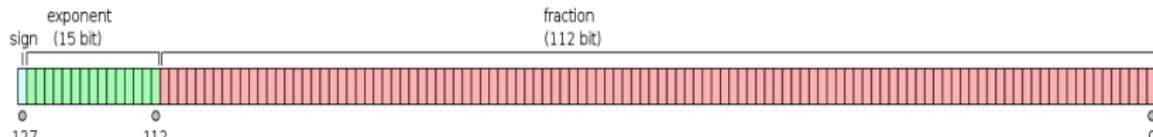
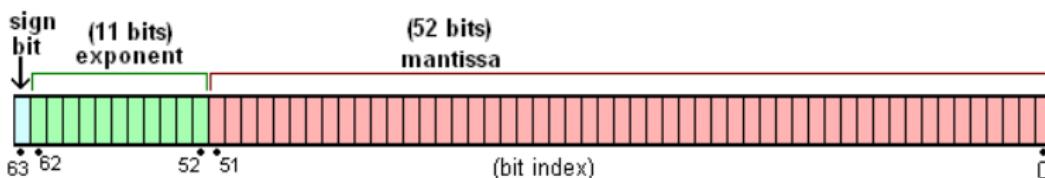
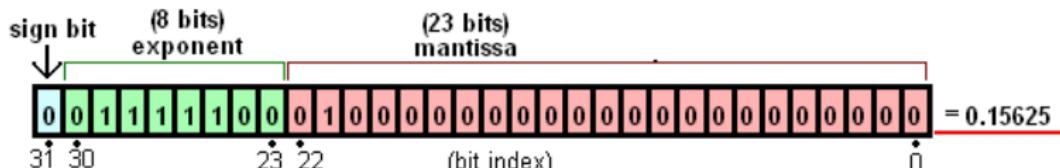
## Floating Point Number Line



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

## Različne natančnosti

- ▶ *IEEE Enojna natančnost*: števila so predstavljena z 32 biti.
  - ▶ *IEEE Dvojna natančnost*: števila so predstavljena z 64 biti.
  - ▶ *Multiprecision Computing Toolbox for MATLAB*: Omogoča računanje v višjih natančnostih. Dostopno na naslovu <https://www.advanpix.com/>



## 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

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

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

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

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

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

$$\text{fl}(x) = x(1 + \delta), |\delta| < 2^{-m}$$

**Absolutna napaka:**

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

**Relativna napaka:**

$$\frac{x - x_-}{x} \leq \frac{2^{e-m-1}}{1/2 \times 2^e} \leq \underbrace{2^{-m}}_u \dots \text{osnovna zaokrožitvena napaka}$$

Torej je

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

Podobno

$$x_+ \leq x(1 + u).$$

Sledi

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

## 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.

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

### Primer

```
1 >> a=rand; b=rand; c=rand; ((a+b)+c)-(a+(b+c))  
2  
3 ans=-2.220446049250313e-16
```

## Seštevamo od manjših k večjim številom

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

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  $\delta_3\delta_4$  (Zakaj to lahko naredimo?), 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

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

# 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:**  $\boxed{\bar{x} - x}$ .

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

- ▶ 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.

## Primer katastrofalnega odštevanja

Iščemo rešitve kvadratne enačbe

$$x^2 + 2ax + b = 0, \quad \text{kjer je } a > 0 \text{ in } a^2 > b.$$

Rešitev z manjšo absolutno vrednostjo je

$$x_2 = \frac{-2a + \sqrt{4a^2 - 4b}}{2} = -a + \sqrt{a^2 - b}.$$

1  $k_1 := a^2$

2  $k_2 := k_1 - b$

3  $k_3 := \sqrt{k_2}$

4  $k_4 := -a + k_3$

Če je  $a^2$  veliko večji od  $b$ , potem ima lahko korak 4 veliko napako. Možna rešitev:

$$x_2 = (-a + \sqrt{a^2 - b}) \cdot \frac{a + \sqrt{a^2 - b}}{a + \sqrt{a^2 - b}} = \frac{-b}{a + \sqrt{a^2 - b}}.$$

```
1  $k_1 := a^2$ 
2  $k_2 := k_1 - b$ 
3  $k_3 := \sqrt{k_2}$ 
4  $k_4 := a + k_3$ 
5  $k_5 := \frac{-b}{k_4}$ 
```

```
1 >> a = 10000; b=-1;
2 >> x = -a+sqrt(a^2 - b)
3 x = 5.000000055588316e-05
4
5 >> x^2 + 2 * a * x +b
6 ans = 1.361766321927860e-08
7
8 >> x = -b/(a+sqrt(a^2-b))
9 x = 4.99999987500000e-05
10
11 >> x^2 + 2 * a * x +b
12 ans = -9.011402890989895e-17
```

Koda primera: [klik](#)

## Računanje s stabilnejšo obliko

- ▶ Izračun vrednosti funkcije

$$f(x) = x(\sqrt{x+1} - \sqrt{x})$$

ni stabilen za velike  $x$ , ker je  $\sqrt{x+1} \approx \sqrt{x}$ . Tej težavi se lahko izognemo:

$$f(x) = f(x) \cdot \frac{\sqrt{x+1} + \sqrt{x}}{\sqrt{x+1} + \sqrt{x}} = \frac{x}{\sqrt{x+1} + \sqrt{x}}.$$

Koda primera: [klik](#)

- ▶ Vrsto

$$\frac{1}{1 \cdot 2} + \frac{1}{2 \cdot 3} + \dots + \frac{1}{n(n+1)},$$

ki se sešteje v  $\frac{n}{n+1}$  (dokaz: indukcija), je bolje numerično računati vzvratno kot

$$\frac{1}{n \cdot (n+1)} + \frac{1}{(n-1) \cdot n} + \dots + \frac{1}{1 \cdot 2}.$$

Koda primera: [klik](#)

- ▶ Vrednost integrala  $I_n = \int_0^1 x^n e^{-x} dx$  se lahko rekurzivno (integracija per partes) izračuna kot

$$I_n = -\frac{1}{e} + nI_{n-1}, \quad I_0 = 1 - \frac{1}{e}.$$

Če iz formule izrazimo  $I_{n-1}$ , dobimo

$$I_{n-1} = \frac{1}{n} I_n + \frac{1}{ne}.$$

Izkaže se, da je druga formula boljša, pri čemer za začetni približek  $I_N$  (pri velikem  $N$ ) lahko vzamemo karkoli. Zakaj?  
Koda primera: [klik](#)

## Seštevanje in odštevanje v splošnem nista relativno direktno stabilni operaciji

$x, y \in \mathbb{R}$ . Računamo približek  $\bar{p}$  za  $p = x + y$ .

$$\begin{aligned}\bar{p} &= \text{fl}(\text{fl}(x) + \text{fl}(y)) = \text{fl}(x(1 + \delta_1) + y(1 + \delta_2)) \\ &= (x(1 + \delta_1) + y(1 + \delta_2))(1 + \delta_3) \\ &= x(1 + \delta_1)(1 + \delta_3) + y(1 + \delta_2)(1 + \delta_3) \\ &= x + y + x(\delta_1 + \delta_3 + \delta_1\delta_3) + y(\delta_2 + \delta_3 + \delta_2\delta_3)\end{aligned}$$

kjer je  $|\delta_i| \leq u$ ,  $i = 1, 2, 3$ . Relativna napaka je

$$\boxed{\frac{|\bar{p} - p|}{|p|} \leq \frac{|x(\delta_1 + \delta_3 + \delta_1\delta_3) + y(\delta_2 + \delta_3 + \delta_2\delta_3)|}{|x + y|}}.$$

Torej:

Če je  $x + y$  blizu 0, potem je  $\frac{|\bar{p} - p|}{|p|}$  veliko.

## Množenje (in deljenje) je relativno direktno stabilna operacija

$x, y \in \mathbb{R}$ . Računamo približek  $\bar{p}$  za  $p = x \cdot y$ .

$$\begin{aligned}\bar{p} &= \text{fl}(\text{fl}(x) \cdot \text{fl}(y)) = \text{fl}(x(1 + \delta_1) \cdot y(1 + \delta_2)) \\ &= x(1 + \delta_1) \cdot y(1 + \delta_2)(1 + \delta_3) \\ &= xy(1 + \delta_1 + \delta_2 + \delta_3 + \text{produkti več } \delta),\end{aligned}$$

kjer je  $|\delta_i| \leq u$ ,  $i = 1, 2, 3$ . Relativna napaka je

$$\boxed{\frac{|\bar{p} - p|}{|p|} \leqslant \frac{|xy||\delta_1 + \delta_2 + \delta_3 + \mathcal{O}(u^2)|}{|xy|} = |\delta_1 + \delta_2 + \delta_3 + \mathcal{O}(u^2)|}.$$

Torej:

Relativna napaka  $\frac{|\bar{p} - p|}{|p|}$  ni odvisna od velikosti produkta  $xy$ .

## Večina numeričnih metod ni relativno direktno stabilnih

Vse numerične metode, kjer sta vključeni

operaciji  $+$   $-$

in kot rezultat lahko dobimo npr. vrednost 0 ali nekje po poti kot vmesno vrednost skoraj singularno matriko, **niso relativno direktno stabilne**, tj. v rezultatu je lahko veliko relativna napaka.

Zato moramo vedno premisliti:

1. V katerih primerih so zgodil velika napaka?
2. Kako nestabilne primere preoblikovati v stabilne?

Primeri takih operacij:

- ▶ Računanje vrednosti polinoma.
- ▶ Računanje skalarnega produkta.
- ▶ Reševanje linearnega sistema.
- ▶ :

## Drugo poglavje:

# Linearni sistemi

$$Ax = b$$

- ▶ Direktne metode za reševanje
  - ▶ LU razcep
  - ▶ Pivotna rast  $\rho(A)$
- ▶ Iterativne metode za reševanje
  - ▶ Jacobi, Gauss-Seidel, SOR, SSOR, konjugirani gradienti

# Direktne metode

$$Ax = b$$

- ▶ Gaussova-eliminacija
- ▶  $LU$  razcep
- ▶ Pivotiranje
- ▶ Pivotna rast

## Reševanje kvadratnih linearnih sistemov

Linearni sistem  $n$  enačb z  $n$  neznankami  $x_1, \dots, x_n$  je oblike

$$a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1,$$

$$a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n = b_2,$$

 $\vdots$  $\vdots$ 

$$a_{n1}x_1 + a_{n2}x_2 + \dots + a_{nn}x_n = b_n,$$

kjer so  $a_{ij}, b_j$  realna števila.

V matrični obliki ga zapišemo kot

$$\underbrace{\begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \dots & \dots & \vdots \\ a_{n1} & a_{n2} & \dots & a_{nn} \end{bmatrix}}_A \underbrace{\begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix}}_x = \underbrace{\begin{bmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{bmatrix}}_b.$$

## Geometrijski pomen sistema $Ax = b$

Naj bodo  $a_{(1)}, a_{(2)}, \dots, a_{(n)}$  stolpci matrike A, tj.,

$$a_{(i)} := \begin{bmatrix} a_{1i} \\ a_{2i} \\ \vdots \\ a_{ni} \end{bmatrix} \in \mathbb{R}^n$$

Linearna kombinacija vektorjev  $a_{(1)}, a_{(2)}, \dots, a_{(n)}$  je vsak vektor oblike

$$x_1 \begin{bmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{n1} \end{bmatrix} + x_2 \begin{bmatrix} a_{12} \\ a_{22} \\ \vdots \\ a_{n2} \end{bmatrix} + \cdots + x_n \begin{bmatrix} a_{1n} \\ a_{2n} \\ \vdots \\ a_{nn} \end{bmatrix}, \quad (1)$$

kjer so  $x_i \in \mathbb{R}$  realna števila.

Zanima nas, ali obstaja linearna kombinacija (1), ki je enaka vektorju  $b$ .

# Sistem $Ax = b$ z vidika numerične matematike

- ▶ Kako **drago** je reševanje sistema  $Ax = b$ ?  
cena=število osnovnih računskih operacij (+, -, :, :).
- ▶ Kateri **problemi** in **napake** se pojavijo med reševanjem  $Ax = b$ ?  
Ali obstajajo slabe matrike? Kako take matrike identificirati?
- ▶ Za katere matrike se da **enostavno** in **poceni** rešiti tak sistem?

# Ponovitev Gaussove eliminacije (GE)

Cilj je pretvoriti sistem v zgornjetrikotnega, nato pa ga rešiti z obratno substitucijo.

## Primer

Rešujemo  $Ax = b$ , kjer sta

$$A = \begin{bmatrix} -3 & 2 & -1 \\ 6 & -6 & 7 \\ 3 & -4 & 4 \end{bmatrix}, \quad b = \begin{bmatrix} -1 \\ -7 \\ -6 \end{bmatrix}.$$

Tvorimo *razširjen sistem*

$$\tilde{A} = [ A \mid b ] = \left[ \begin{array}{ccc|c} -3 & 2 & -1 & -1 \\ 6 & -6 & 7 & -7 \\ 3 & -4 & 4 & -6 \end{array} \right]$$

Prištejemo 2-kratnik prve vrstice drugi in 1-kratnik prve vrstice tretji.

$$\tilde{A}_{(1)} = \left[ \begin{array}{ccc|c} -3 & 2 & -1 & -1 \\ 0 & -2 & 5 & -9 \\ 0 & -2 & 3 & -7 \end{array} \right]$$

## Primer

*Odštejemo 1-kratnik druge vrstice od tretje*

$$\tilde{A}_{(2)} = \left[ \begin{array}{ccc|c} -3 & 2 & -1 & -1 \\ 0 & -2 & 5 & -9 \\ 0 & 0 & -2 & 2 \end{array} \right]$$

*Rešimo z obratno substitucijo*

$$x_3 = \frac{2}{-2} = -1,$$

$$x_2 = \frac{1}{-2} (-9 - 5x_3) = 2,$$

$$x_1 = \frac{1}{-3} (-1 - 2x_2 + x_3) = 2.$$

V nadaljevanju bomo:

1. Prešteli število potrebnih računskih operacij za Gaussovo eliminacijo (GE).
2. GE bomo zapisali s pomočjo matričnih množenj.
3. Ukvarjali se bomo s stabilnostjo GE.

# Algoritem GE in cena GE

```
1 -  $n \times n$  matrika  $A = [a_{ij}]_{ij}$  in  $n \times 1$  vektor  $b = [b_i]_i$ 
2 - preoblikujemo  $[A|b]$  v zgornjetrikotno z GE
3
4 for  $k = 1 \dots n - 1$ 
5   for  $i = k + 1 \dots n$ 
6      $xmult = a_{ik} / a_{kk}$ 
7      $a_{ik} = 0$ 
8     for  $j = k + 1 \dots n$ 
9        $a_{ij} = a_{ij} - (xmult)a_{kj}$ 
10    end
11     $b_i = b_i - (xmult)b_k$ 
12  end
13 end
```

## Izrek

Število računskih operacij ( $+, -, \cdot, :)$  za prevedbo matrike  $A$  in razširjene matrike  $[A|b]$  v zgornjetrikotno obliko je

$$\frac{2}{3}n^3 + \mathcal{O}(n^2).$$

# Obratna substitucija in število operacij

```
1 -zgornjetrikotna  $n \times n$  matrika  $U = [u_{ij}]_{i,j}$ , vektor  
2  $c = [c_i]_i$   
3 -resimo sistem  $Ux = c$   
4  
5  $x_n = c_n / u_{nn}$   
6 for  $i = n - 1 \dots 1$   
7      $s = c_i$   
8     for  $j = i + 1 \dots n$   
9          $s = s - u_{ij}x_j$   
10     end  
11      $x_i = s / u_{ii}$   
12 end
```

## Izrek

Število računskih operacij  $(+, -, \cdot, :)$  za rešitev sistema  $Ux = c$  je

$$n^2.$$

## Motivacija za zapis GE v matrični obliki

Videli smo, da je cena pretvorba matrike  $A$  oz. sistema  $[A|b]$  v zgornjetrikotno obliko bistveno dražja kot pa obratna substitucija.

Če bomo v nekem postoku reševali sisteme  $Ax = b$  pri **fiksni matriki  $A$ , vektor  $b$  pa se bo spremenjal**, bi bilo iz računskega vidika bistveno učinkoviteje preoblikovanje matrike  $A$  v zgornjetrikotno obliko narediti samo enkrat.

Ključno v tem procesu je ugotoviti, **kako moramo preblikovati vektor  $b$** , ne da bi delali GE na razširjenem sistemu.

# LU razcep matrike $A$

```
1 -Vhod:  $A = [a_{ij}]_{i,j}$   $n \times n$  matrika.  
2 -Izhod: Spodnja trikotna matrika  $L$  in zgornja  
3 trikotna matrika  $U$ , da je  $A = LU$   
4 - $\ell_{ik}$  v spodnjem algoritmu so elementi pod  
5 diagonalo v  $L$ , na diagonali so same 1  
6 -preostali elementi  $a_{ij}$  v zgornjem trikotniku so  
7 elementi matrike  $U$   
8  
8 for  $k = 1, \dots, n - 1$   
9   for  $i = k + 1, \dots, n$   
10     $\ell_{ik} = a_{ik}/a_{kk}$   
11    for  $j = k + 1, \dots, n$   
12       $a_{ij} = a_{ij} - \ell_{ik}a_{kj}$   
13    end  
14  end  
15 end
```

## Izrek

Število računskih operacij ( $+, -, \cdot, :)$  za izračun LU razcepa matrike  $A$  je  $\frac{2}{3}n^3 + \mathcal{O}(n^2)$ .

## Prema substitucija in število operacij

```
1 -Vhod: spodnja trikotna  $n \times n$  matrika  $L = [\ell_{ij}]_{i,j}$  in
2     vektor  $b = [b_i]_i$ 
3 -Izhod: resitev  $y$  sistema  $Ly = b$ 
4
5
6
7
8
9
10
11
```

$y_1 = b_1 / \ell_{11}$   
**for**  $i = 2 \dots n$   
     $s = b_i$   
    **for**  $j = 1 \dots i - 1$   
         $s = s - \ell_{ij}y_j$   
    **end**  
     $y_i = s / \ell_{ii}$   
**end**

### Izrek

Število računskih operacij  $(+, -, \cdot, :)$  za rešitev sistem  $Ly = b$  je

$$n^2.$$

## Reševanje sistema $Ax = b$ prek LU razcepa:

1. Izračunamo  $A = LU$ . Cena:  $\frac{2}{3}n^3 + \mathcal{O}(n^2)$ .
2. Rešimo  $Ly = b$  s premo substitucijo, tj. od  $y_1$  proti  $y_n$ .  
Cena:  $n^2 - n$ .
3. Rešimo  $Ux = y$  z obratno substitucijo, t. od  $x_n$  proti  $x_1$ .  
Cena:  $n^2$ .

Cena preme substitucije je za  $n$  operacij manjša kot cena obratne substitucije, saj imamo ne diagonali  $L$  same enice in prihranimo v vsaki spremenljivki eno deljenje.

# Reševanje sistema $Ax = b$ prek LU razcepa

## Primer

$$A = \begin{pmatrix} 2 & 1 & 3 & -4 \\ -4 & -1 & -4 & 7 \\ 2 & 3 & 5 & -3 \\ -2 & -2 & -7 & 9 \end{pmatrix}, \quad b = \begin{pmatrix} 8 \\ -14 \\ 7 \\ -16 \end{pmatrix}.$$

1.  $L = \begin{pmatrix} 1 & 0 & 0 & 0 \\ -2 & 1 & 0 & 0 \\ 1 & 2 & 1 & 0 \\ -1 & -1 & 1 & 1 \end{pmatrix}, U = \begin{pmatrix} 2 & 1 & 3 & -4 \\ 0 & 1 & 2 & -1 \\ 0 & 0 & -2 & 3 \\ 0 & 0 & 0 & 1 \end{pmatrix}.$

2. Rešimo  $Ly = b$  in dobimo  $y = (8 \ 2 \ -5 \ -1)^T$ .

3. Rešimo  $Ux = y$  in dobimo  $x = (1 \ -1 \ 1 \ -1)^T$ .

LU razcep brez pivotiranja: [koda](#)

Prema substitucija: [koda](#)

Obratna substitucija: [koda](#)

Primer: [koda](#)

# Obstoj LU razcepa matrike

V nadaljevanju se bomo ukvarjali z **obstojem** in **stabilnostjo LU razcepa**.

Problematična sta npr. matriki

$$A = \begin{bmatrix} 0 & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix}, \quad B = \begin{bmatrix} 10^{-17} & 2 & 3 \\ 4 & 5 & 6 \\ 7 & 8 & 9 \end{bmatrix},$$

saj je  $10^{-17}$  pod strojnim  $\epsilon$ . Da pa se natančno povedati, kdaj LU razcep obstaja.

Podmatriki matrike  $A \in \mathbb{R}^{n \times n}$ , zožene na prvih  $k$  vrstic in stolpcev, pravimo  **$k$ -ta glavna vodilna podmatrika**.

## Izrek (Obstoj LU razcepa)

Za  $n \times n$  matriko  $A$  sta naslednji trditvi ekvivalentni:

1. LU razcep matrike  $A$  obstaja in je enoličen.
2.  $k$ -ta glavna vodilna podmatrika matrike  $A$  je obrniljiva za vsak  $k = 1, \dots, n$ .

## LU razcep z delnim pivotiranjem

Pri **delnem pivotiranju** pred eliminacijo v  $j$ -tem stolpcu primerjamo elemente

$$a_{jj}, a_{j+1,j}, \dots, a_{nj},$$

nato pa **zamenjamo  $j$ -to vrstico s tisto, ki vsebuje element z največjo absolutno vrednostjo.**

Menjava  $j$ -te in  $k$ -te vrstice pa je **množenje z leve s permutacijsko matriko**  $P_{jk}$ , ki se od identitete razlikuje le v  $j$ -ti in  $k$ -ti vrstici, ki sta zamenjeni:

$$P_{jk} = I_n - E_{jj} - E_{kk} + E_{jk} + E_{kj}.$$

Tu so  $E_{ij}$  standardne koordinatne matrike (1 v  $i$ -ti vrstici in  $j$ -tem stolpcu in 0 drugje).

# LU razcep z delnim pivotiranjem - algoritem

```
1 -Vhod:  $A = [a_{ij}]_{i,j}$   $n \times n$  matrika
2 -Izhod: permutacijska matrika  $P$ , spodnja in
   zgornja trikotna matrika  $L$  in  $U$ , da je
    $PA = LU$ 
3
4  $P$  in  $L$  identični  $n \times n$  matriki
5 for  $k = 1, \dots, n-1$ 
6     poisci  $q$ -to in  $k$ -to vrstico, ki zadostca
          $|a_{qk}| = \max_{k \leq p \leq n} |a_{pk}|$ 
7      $q$ -to in  $k$ -to vrstico v matrikah  $A, P$  in strogem
         spodnjem trikotniku  $L$ 
8     for  $i = k+1, \dots, n$ 
9          $\ell_{ik} = a_{ik}/a_{kk}$ 
10        for  $j = k+1, \dots, n$ 
11             $a_{ij} = a_{ij} - \ell_{ik} a_{kj}$ 
12        end
13    end
14 end
```

# LU razcep z delnim pivotiranjem

Izrek (O računski zahtevnosti LU razcep z delnim pivotiranjem)

Število računskih operacij ( $+, -, \cdot, :)$  za izračun LU razcepa z delnim pivotiranjem je  $\frac{2}{3}n^3 + \mathcal{O}(n^2)$ .

Dodatno delo pri LU razcepu z delnim pivotiranjem je  $\mathcal{O}(n^2)$  primerjanj in menjav.

Reševanje  $Ax = b$  prek LU razcepa z delnim pivotiranjem:

1. Izračunamo  $PA = LU$ . Cena:  $\frac{2}{3}n^3 + \mathcal{O}(n^2)$ .
2. Rešimo  $Ly = Pb$  s premo substitucijo. Cena:  $n^2 - n$ .
3. Rešimo  $Ux = y$  z obratno substitucijo. Cena:  $n^2$ .

Izrek (Obstoj LU razcepa z delnim pivotiranjem)

Za  $n \times n$  matriko  $A$  sta naslednji trditvi ekvivalentni:

1. LU razcep matrike  $A$  z delnim pivotiranjem obstaja.
2. Matrika  $A$  je obrnljiva.

# $Ax = b$ prek LU razcepa z delnim pivotiranjem

Primer.

$$A = \begin{pmatrix} 2 & 1 & 3 & -4 \\ -4 & -1 & -4 & 7 \\ 2 & 3 & 5 & -3 \\ -2 & -2 & -7 & 9 \end{pmatrix}, \quad b = \begin{pmatrix} 8 \\ -14 \\ 7 \\ -16 \end{pmatrix}.$$

1.  $L = \begin{pmatrix} 1 & 0 & 0 & 0 \\ -\frac{1}{2} & 1 & 0 & 0 \\ \frac{1}{2} & -\frac{3}{5} & 1 & 0 \\ -\frac{1}{2} & \frac{1}{5} & -\frac{1}{8} & 1 \end{pmatrix}, U = \begin{pmatrix} -4 & -1 & -4 & 7 \\ 0 & \frac{5}{2} & 3 & \frac{1}{2} \\ 0 & 0 & -\frac{16}{5} & \frac{58}{10} \\ 0 & 0 & 0 & \frac{1}{8} \end{pmatrix},$

$$P = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 \end{pmatrix}.$$

2. Rešimo  $Ly = Pb$  in dobimo  $y = (-14 \quad 0 \quad -9 \quad -\frac{1}{8})^T$ .

3. Rešimo  $Ux = y$  in dobimo  $x = (1 \quad -1 \quad 1 \quad -1)^T$ .

LU razcep z delnim pivotiranjem: [koda](#)

Primer: [koda](#)

## LU s kompletним pivotiranjem

Pri kompletнем pivotiranju pred eliminacijo v  $j$ -tem stolpcu poiščemo element z največjo absolutno vrednostjo v podmatriki  $A(j : n, j : n)$  in nato izvedemo ustrezeni menjavi vrstic in stolpcev.

Dodatno delo pri LU razcepu s kompletnim pivotiranjem je  $\mathcal{O}(n^3)$  primerjanj in menjav. Torej je skupna cena precej dražja od LU razcepa z delnim pivotiranjem. Ker bomo videli, da je LU razcep z delnim pivotiranjem statistično numerično stabilen, se v praksi kompletno pivotiranje redko uporablja.

## Stabilnost LU razcepa matrike A

Sistem  $Ax = b$  smo rešili prek LU razcepa in dobili približek  $\hat{x}$ . Računali smo v treh korakih:

1. Izračun LU razcepa:  $A + E = \widehat{L}\widehat{U}$ .
2. Prema substituciji:  $\widehat{L}\widehat{y} = b$ .
3. Obratna substitucija:  $\widehat{U}\widehat{x} = \widehat{y}$ .

Izkaže se, da je (teoretično) nestabilen samo prvi korak.

Spomnimo se, da z  $u$  označujemo osnovno zaokrožitveno napako  $2^{-m}$  kjer je  $m$  dolžina mantise. Z  $|A| = [|a_{ij}|]_{i,j}$  označimo matriko absolutnih vrednosti vhodov matrike  $A = [a_{ij}]_{i,j}$

**Izrek ( Ocena absolutne napake pri izračunu LU razcepa )**

Naj bo  $A \in \mathbb{R}^{n \times n}$  obrnljiva matrika, pri kateri se izvede LU razcep brez pivotiranja. Za izračunani matriki  $\widehat{L}$ ,  $\widehat{U}$  velja  $A = \widehat{L}\widehat{U} + E$ , kjer je

$$|E| \leq 3(n-1)u \left( |A| + |\widehat{L}| |\widehat{U}| \right) + \mathcal{O}(u^2).$$

## Stabilnost LU razcepa matrike A

Označimo z  $\|X\|_\infty$  največjo vsoto absolutnih vrednosti neke vrstice matrike X.

Izrek ( Ocena relativne napake pri izračunu LU razcepa )

Pri LU razcepu z delnim pivotiranjem velja ocena relativne napake:

$$\frac{\|E\|_\infty}{\|A\|_\infty} \leq 3(n-1)u + 3(n-1)nu \cdot \frac{\|\hat{U}\|_\infty}{\|A\|_\infty} + \mathcal{O}(u^2).$$

# Pivotna rast

Pivotna rast matrike  $A$  je definirana kot

$$\rho(A) := \frac{\max_{i,j} |\hat{u}_{i,j}|}{\max_{i,j} |a_{i,j}|}.$$

Velja

$$\|\hat{U}\|_\infty \leq n\rho(A)\|A\|_\infty.$$

Trditev

Pri delnem pivotiranju je pivotna rast omejena z  $2^{n-1}$ .

Dokaz. Velja namreč  $|\ell_{ij}| \leq 1$ ,  $a_{ij}$  pa na vsakem od največ  $n - 1$  korakov izračunamo kot

$$a_{ij} = a_{ij} - \ell_{ik} a_{kj}.$$

Torej se absolutna vrednost največjega elementa v matriki kvečjemu podvoji.

# Pivotna rast pri delnem pivotiranju

Žal pa za vsak  $n$  obstajajo matrike s pivotno rastjo  $2^{n-1}$ , tako da LU razcep z delnim pivotiranjem **teoretično ni stabilen**.

## Primer

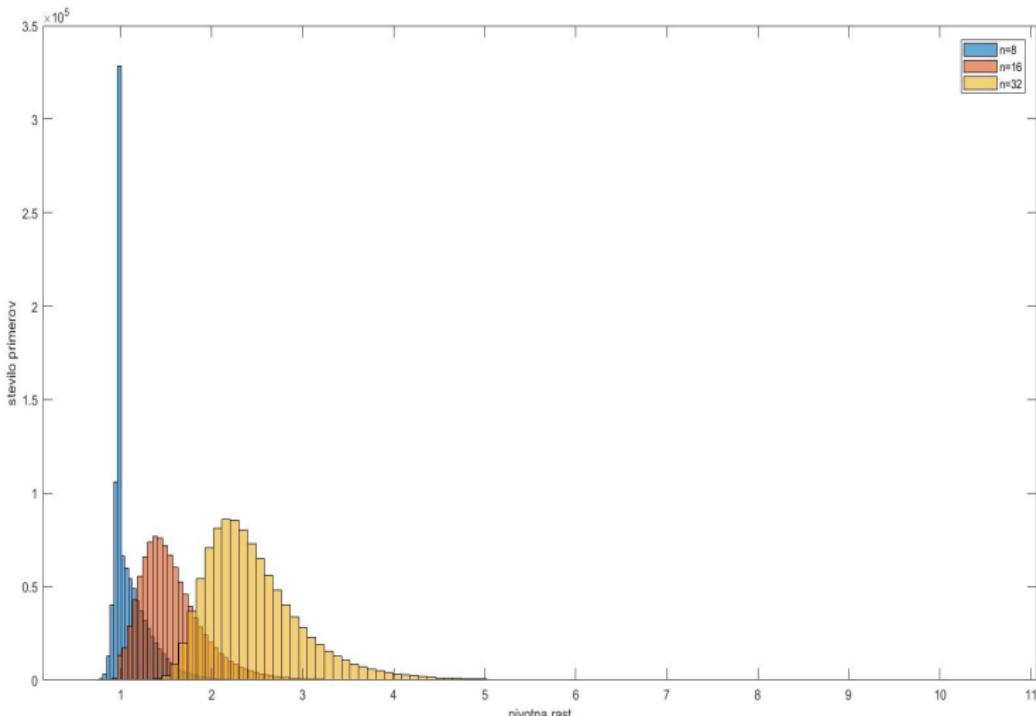
### Matrika

$$A_n = \begin{pmatrix} 1 & 0 & \cdots & 0 & 1 \\ -1 & 1 & \ddots & \vdots & 1 \\ \vdots & \ddots & \ddots & 0 & \vdots \\ \vdots & & \ddots & \ddots & \vdots \\ -1 & \cdots & \cdots & -1 & 1 \end{pmatrix}$$

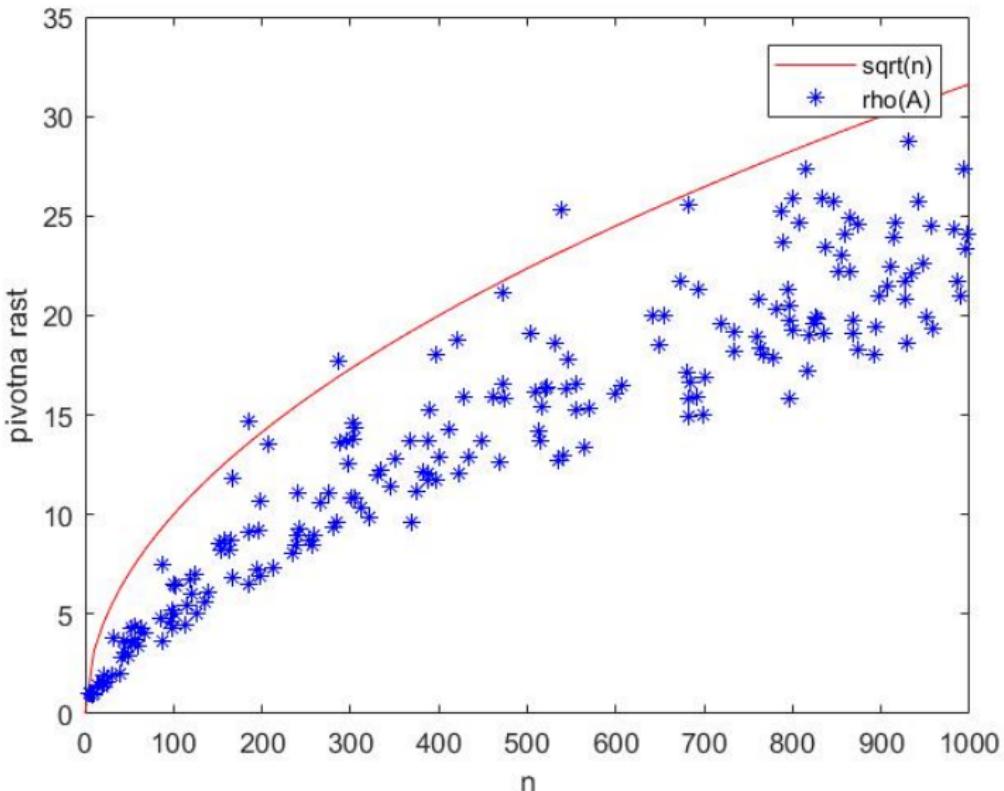
ima pivotno rast  $2^{n-1}$ .

Statistično pa velja, da je pričakovana vrednost pivotne rasti  $\mathcal{O}(n^{2/3})$ , tako da LU razcep z delnim pivotiranjem **v praksi je obratno stabilen**.

**Verjetnostne porazdelitve** slučajne spremenljivke  $p$ , generirane z milijon naključnimi matrikami velikosti  $n \times n$  (tj. vsak vhod naključen element iz enakomerne zvezne porazdelitve na intervalu  $[0, 1]$ ):



Pivotna rast 200 naključnih matrik velikosti  $n \times n$  (tj. vsak vhod naključen element iz enakomerne zvezne porazdelitve na intervalu  $[0, 1]$ ):



# Iterativne metode

$$Ax = b$$

- ▶ Jacobijeva iteracija
- ▶ Gauss-Seidlova iteracija
- ▶ SOR iteracija
  
- ▶ Veliko bolj specialnih metod (ki jih ne bomo obravnavali):  
Pospešitev Čebiševa, SSOR, Metode podprostorov  
Krilova, Metoda konjugiranih gradientov, Hitra Fourierova  
transformacija, Ciklična redukcija, Večmrežna metoda.

## Iterativne metode za reševanje $Ax = b$

Doslej smo iskali **točno rešitev**  $x^*$  sistema

$$Ax = b. \quad (2)$$

Odslej nas bodo zanimali samo **približki**  $\hat{x}$  točnih rešitev  $x^*$ .

Naprej si bomo izbrali  $\epsilon > 0$  in iskali  $\hat{x}$ , ki zadošča pogoju

$$\|\hat{x} - x^*\| \leq \epsilon.$$

Prednosti iterativnih metod pred direktnimi:

- ▶ Če je matrika  $A$  velika in ima veliko ničel, je bolje uporabiti iterativne metode.
- ▶ Ko je rezultat znotraj vnaprej predpisane natančnosti, lahko končamo računanje. Pri direktnih metodah tega vpliva nimamo.

Recimo, da ugibamo, kaj bi lahko bila prava rešitev sistema (2)

$$x^{(0)} \approx x$$

## Kako izboljšati $x^{(0)}$ ?

Idealno bi prišteli pravi razliko:

$$x^{(1)} = x^{(0)} + (x^* - x^{(0)}),$$

kar lahko drugače zapišemo kot

$$\begin{aligned}x^{(1)} &= x^{(0)} + (x^* - x^{(0)}) \\&= x^{(0)} + (A^{-1}b - x^{(0)}) \\&= x^{(0)} + A^{-1} \underbrace{(b - Ax^{(0)})}_{r^{(0)}}.\end{aligned}$$

Toda ta metoda ni smiselna, saj bi morali izračunati  $A^{-1}$ .

*Kaj pa, če bi znali aproksimirati  $A^{-1}$ ?*

Recimo, da je približek

$$Q^{-1} \approx A^{-1}$$

poceni za izračunati. Potem izračunamo

$$x^{(1)} = x^{(0)} + Q^{-1}r^{(0)}.$$

Nadaljujemo z  $k = 2, 3, \dots$

$$x^{(k)} = x^{(k-1)} + \underbrace{Q^{-1}(b - Ax^{(k-1)})}_{r^{(k-1)}}. \quad (3)$$

# Algoritem iterativnih metod

```
1 A je dana  $n \times n$  matrika, ki jo aproksimiramo z  
matriko  $Q$ , in  $n \times 1$  vektor  $b$ .  
2 Izberi zacetni priblizek  $x = x^{(0)}$ , toleranco  
dovoljene relativne napake  $tol$  in maksimalno  
stevilo  $k_{max}$  korakov iteracije.  
3  
4  $x^{(nov)} = \infty$   
5 for  $k = 1$  to  $k_{max}$   
6    $r = b - Ax$   
7   if  $\frac{\|x^{(nov)} - x\|}{\|x\|} \leq tol$ , stop  
8   else  
9      $x = x^{(nov)}$   
10     $x^{(nov)} = x + Q^{-1}r$   
11 end  
12  $x = x^{(nov)}$ 
```

## Jacobijeva iteracija

Aproksimiramo  $A = [a_{ij}]_{i,j}$  z diagonalno matriko

$$D = \begin{pmatrix} a_{11} & 0 & \cdots & 0 \\ 0 & a_{22} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ 0 & \cdots & 0 & a_{nn} \end{pmatrix}.$$

Če pišemo

$$A = S + D + Z, \quad (4)$$

kjer je  $S$  strogo spodnjetrikotna matrika in  $Z$  strogo zgornjetrikotna matrika, potem (3) postane

$$\begin{aligned} x^{(k)} &= x^{(k-1)} + D^{-1}(b - Sx^{(k-1)} - Dx^{(k-1)} - Zx^{(k-1)}) \\ &= x^{(k-1)} + D^{-1}b - D^{-1}Sx^{(k-1)} - x^{(k-1)} - D^{-1}Zx^{(k-1)} \\ &= D^{-1}(b - Sx^{(k-1)} - Zx^{(k-1)}). \end{aligned} \quad (5)$$

## Pišimo

$$x^{(j)} = \begin{pmatrix} x_1^{(j)} & x_2^{(j)} & \cdots & x_n^{(j)} \end{pmatrix}^T$$

Po komponentah (5) pomeni

$$x_i^{(k)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1, j \neq i}^n a_{ij} x_j^{(k-1)} \right). \quad (6)$$

Torej vsak preskok (iz  $k - 1$  na  $k$ ) potrebuje  $O(n)$  operacij za vsak element novega vektorja.

**Računska zahtevnost:** Če je v vsaki vrstici vsi razen največ  $m$  koeficientov  $a_{ij}$  neničelnih, potem za vsak korak iteracije potrebujemo  $O(mn)$  operacij.

Koda algorima: [klik](#)

Primer 1: [klik](#)

Primer 2: [klik](#)

## Gauss-Seidlova iteracija

Naj bo  $A = [a_{ij}]_{i,j} = S + D + Z$  kot v (4). A aproksimiramo s spodnjekotriktotno matriko

$$S + D = \begin{pmatrix} a_{11} & 0 & \cdots & 0 \\ a_{21} & a_{22} & \ddots & \vdots \\ \vdots & \ddots & \ddots & 0 \\ a_{n1} & \cdots & a_{n,n-1} & a_{nn} \end{pmatrix}.$$

Potem (3) postane

$$\begin{aligned} x^{(k)} &= x^{(k-1)} + (D + S)^{-1}(b - (S + D)x^{(k-1)} - Zx^{(k-1)}) \\ &= x^{(k-1)} + (D + S)^{-1}b - x^{(k-1)} - (D + S)^{-1}Zx^{(k-1)} \quad (7) \\ &= (D + S)^{-1}(b - Zx^{(k-1)}), \end{aligned}$$

Pomnožimo (7) z leve z  $D + S$  in dobimo

$$(D + S)x^{(k)} = b - Zx^{(k-1)}. \quad (8)$$

Odštejemo  $Sx^{(k)}$  od obeh strani (8) in dobimo

$$Dx^{(k)} = b - Zx^{(k-1)} - Sx^{(k)}$$

OZ.

$$x^{(k)} = D^{-1}(b - Zx^{(k-1)} - Sx^{(k)}). \quad (9)$$

Po komponentah (9) pomeni

$$x_i^{(k)} = \frac{1}{a_{ii}} \left( b_i - \sum_{j=1, j < i}^n a_{ij} x_j^{(k)} - \sum_{j=1, j > i}^n a_{ij} x_j^{(k-1)} \right). \quad (10)$$

**Računska zahtevnost:** Če je v vsaki vrstici vsi razen največ  $m$  koeficientov  $a_{ij}$  neničelnih, potem za vsak korak iteracije potrebujemo  $O(mn)$  operacij.

Koda algorima: [klik](#)

Primer 1: [klik](#)

Primer 2: [klik](#)

Razlika v primerjavi z Jacobijevo metodo je ta, da so popravki shranjeni v obstoječem vektorju in ne potrebujemo še enega dodatnega vektorja. Tako pridobimo precej prihranka v spominu.

## SOR iteracija

Ideja ekstrapolirana Gauss-Seidlove iteracija ali **SOR( $w$ )**, kjer je  $w \in \mathbb{R}$  **relaksacijski parameter**, je pospešiti GS–iteracijo tako, da nov približek računamo kot uteženo povprečje

$$x_i^{(k)} = (1 - w)x_i^{(k-1)} + wx_i^{(k)},$$

pri čemer  $x_i^{(k)}$  na desni strani enačbe izračunamo iz predpisa za GS–iteracijo:

$$x_i^{(k)} = (1 - w)x_i^{(k-1)} + \frac{w}{a_{ii}} \left( b_j - \sum_{j < i}^n a_{ij}x_j^{(k)} - \sum_{j > i} a_{ij}x_j^{(k-1)} \right).$$

Koda algorima: [klik](#)

Primer 1: [klik](#)

Primer 2: [klik](#)

# Konvergenčni kriteriji

Matrika je **krepko vrstično diagonalno dominantna (kVDD)**, če za vsak  $i$  velja

$$|a_{ii}| > \sum_{j=1, j \neq i}^n |a_{ij}|.$$

Diagonalno dominantne matrike velikokrat nastopajo pri reševanju parcialnih diferencialnih enačb z metodo diskretizacije.

Nekaj konvergenčnih rezultatov:

1. Jacobijeva in GS iteracija za kVDD matrike vedno konvergirata, ne glede na izbiro začetnega približka  $x^{(0)}$ . GS je hitrejša.
2. V primeru enakosti v kVDD pogojih za konvergenco Jacobija in GS potrebujemo dodatno lastnost matrike  $A$  - **nerazcepnost**.
3. Potreben pogoj za konvergenco  $SOR(w)$  je  $0 < w < 2$ . Za pozitivno definitno matriko  $A$  je pogoj tudi zadosten.
4. Primerjavo hitrosti konvergence metod lahko naredimo za matrike  $A$ , katerih graf sosednosti je dvodelen. Hkrati lahko za take s formulo določimo optimalen  $w$  v  $SOR(w)$ .

# Reševanje nelinearnih enačb in optimizacija

$$* f(x) = 0$$

$$* f_i(x_1, x_2, \dots, x_n) = 0, \quad i=1, \dots, n$$

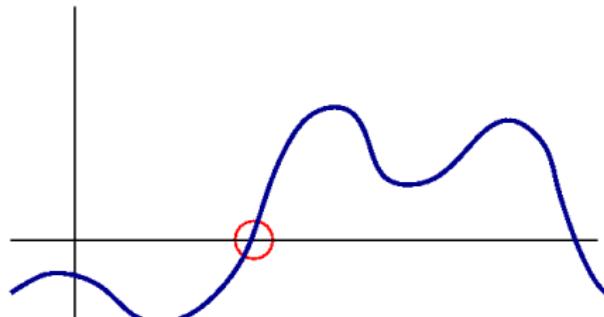
$$* \min\{f(x) : x \in K \subseteq \mathbb{R}^n\}$$

- ▶ Ena enačba v eni spremenljivki: Bisekcija, tangentna metoda, sekantna metoda, regula falsi, navadna iteracija
- ▶ Sistem  $n$  enačb v  $n$  spremenljivkah: Newtonova metoda, Broydenova metoda
- ▶ Optimizacija: Gradientni spust

# Motivacija

**Problem:** Naj bo dana funkcija  $f(x)$ . Poišči  $x$ , ki zadošča

$$f(x) = 0.$$

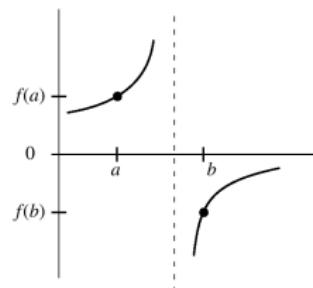
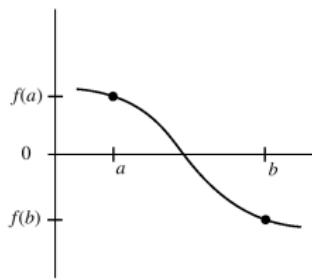


- ▶ Nelinearni sistemi niso tako enostavno rešljivi kot sistemi linearnih enačb.
- ▶ Ničel polinoma stopnje 5 ne moremo zapisati analitično.
- ▶ Kako reševati take probleme? Z **iterativnim postopkom**, pri čemer se rešitvam čim bolj približamo.

# Osnovna strategija reševanja

## 1. Skiciraj funkcijo.

- ▶ Postavimo začetno domnevo, kaj je lahko ničla.
- ▶ Ničla  $x$  gotovo obstaja na intervalu  $[a, b]$ , če imata  $f(a)$  in  $f(b)$  različna predznaka in je funkcija  $f$  zvezna na  $[a, b]$ .
- ▶ Toda: Spremembra predznaka funkcije ne pomeni vedno, da je na tem intervalu ničle, kajti lahko imamo na intervalu singularnost:



## 2. Začnemo z začetno domnevo in uporabimo nek iteracijski algoritem.

# Konvergenčni kriteriji za $x$

Zaustavitevni kriterij je odvisen od narave problema, ki ga rešujemo:

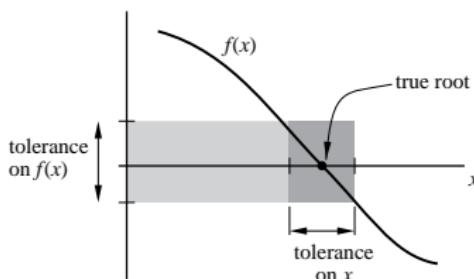
- ▶ Lahko nas zanima, kdaj velja

$$|x_k - x_{k-1}| < \text{toleranca}.$$

- ▶ Lahko pa nas zanima, kdaj velja

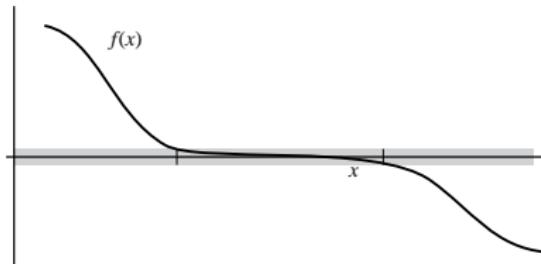
$$|f(x_k)| < \text{toleranca}.$$

- ▶ Še najbolje pa je zahtevati izpolnjenost **obeh pogojev** hkrati.

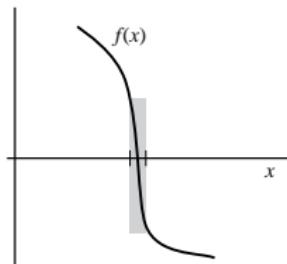


# Primerjava obeh konvergenčnih kriterijev

Če je  $f'(x)$  majhen v okolici ničle, je lažje zadostiti toleranci na funkcionalno vrednost.



Če je  $f'(x)$  velik v bližini ničle, je možno zadostiti toleranci na dolžino intervala, četudi je  $|f(x)|$  še vedno velik.



## Povezava med obema kriterijama

Vprašanje: Kako sta kriterija na  $x$  in  $f(x)$  povezana med sabo?

Ko  $x_a$  in  $x_b$  konvergirata proti  $x^*$ , gre razmerje

$$\frac{f(x_b) - f(x_a)}{x_b - x_a} \quad \text{proti} \quad f'(x^*)$$

Zato lahko pričakujemo, da velja

$$|f(x_b) - f(x_a)| \approx |f'(x^*)| |x_b - x_a|,$$

ko  $x_a$  in  $x_b$  konvergirata proti  $x^*$ .

Zaključek:  $|f'(x^*)|$  določa povezavo med kriterijema.

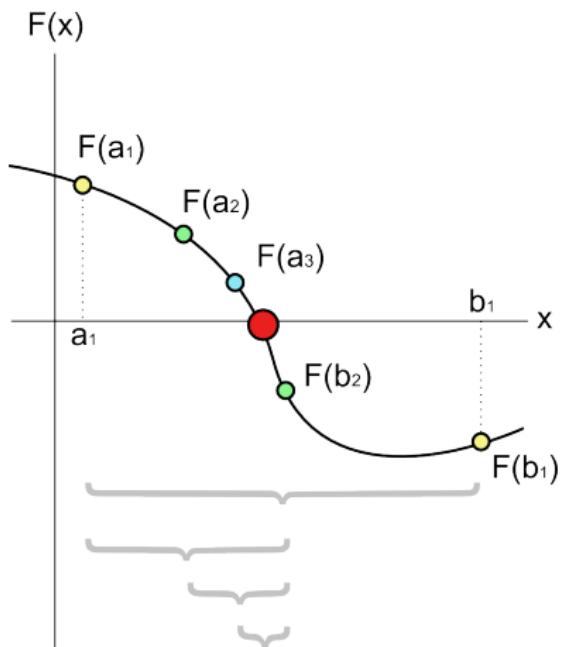
# Bisekcija

Razpolovišče začetnega intervala  $[a, b]$  je točka

$$x_m = \frac{1}{2}(a + b).$$

## Postopek:

1. Poišči razpolovišče.
2. Izmed dveh možnih intervalov izberi tistega, kjer ima funkcija različno predznačeni krajišči.
3. Nadaljujemo s prvim korakom.
4. Ustavimo se, ko je interval krajši od naprej predpisane tolerance.



# Algoritem za bisekcijo

```
1 zacetni podatki: f, a, b, tol
2 for k = 1,2, ...
3      $x_m = a + (b - a)/2$ 
4     if sign(f( $x_m$ )) = sign(f(a))
5         a =  $x_m$ 
6     else
7         b =  $x_m$ 
8     end
9     if |b-a| < tol, stop
10    end
```

Algoritem: klik

Primer 1: klik

Primer 2: klik

## Hitrost konvergencije in računska zahtevnost

Naj bo  $\delta_n$  velikost intervala po  $n$ -tem koraku bisekcije. Potem velja

$$\delta_0 = b - a, \quad \delta_1 = \frac{1}{2} \delta_0, \quad \delta_2 = \frac{1}{2} \delta_1 = \frac{1}{4} \delta_0, \quad \dots, \quad \delta_n = \left(\frac{1}{2}\right)^n \delta_0$$

$$\Rightarrow \quad \frac{\delta_n}{\delta_0} = \left(\frac{1}{2}\right)^n = 2^{-n} \quad \text{ali} \quad n = \log_2 \left(\frac{\delta_n}{\delta_0}\right)$$

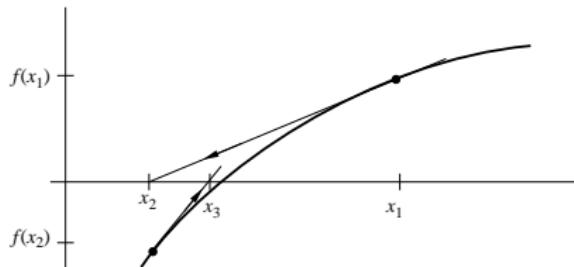
$n$	$\frac{\delta_n}{\delta_0}$	število izračunov funkcijskih vrednosti
5	$3.1 \times 10^{-2}$	7
10	$9.8 \times 10^{-4}$	12
20	$9.5 \times 10^{-7}$	22
30	$9.3 \times 10^{-10}$	32
40	$9.1 \times 10^{-13}$	42
50	$8.9 \times 10^{-16}$	52

# Tangentna metoda

Iteracija:

$$x_{k+1} = x_k - \frac{f(x_k)}{f'(x_k)}. \quad (11)$$

Izpeljava:



Pri trenutnem približku  $x_k$  uporabimo funkcijsko vrednost  $f(x_k)$  in odvod  $f'(x_k)$ , da izračunamo naslednji približek. Enačba tangente na krivuljo v točki  $(x_k, f(x_k))$  je

$$y = f(x_k) + (x - x_k) f'(x_k).$$

Ker je cilj najti  $x$ , tako da je  $f(x) = 0$ , dobimo

$$0 = f(x_k) + (x_{k+1} - x_k) f'(x_k)$$

in izrazimo  $x_{k+1}$ .

```

1 zacetni podatki: funkcija f, priblizek x1
2 for k = 2,3, ...
3 xk = xk-1 - f(xk-1)/f'(xk-1)
4 if xk znotraj tolerance, stop
5 end

```

Algoritem: klik

Primer 1: klik

Primer 2: klik

Lastnosti tangentne metode:

- ▶ Konvergira precej hitreje kot bisekcija - **red konvergence je vsaj 2**, tj. na vsakem koraku se število točnih decimalk podvoji.
- ▶ Zahteva analitično formulo za  $f'(x)$  - če tega ne poznamo, lahko uporabimo sekantno metodo (sledi).
- ▶ **Ni nujno, da konvergira**, saj približki pobegnejo:

