

Numerička matematika

2. predavanje

Saša Singer i Nela Bosner

PMF - Matematički odsjek, Zagreb

Sadržaj predavanja

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Greške — ponavljanje

Pri **numeričkom** rješavanju nekog problema javljaju se različiti tipovi **grešaka**:

- ▶ greške **modela** — svođenje **realnog** problema na neki “**matematički**” problem,
- ▶ greške u **ulaznim podacima** (mjerjenja i sl.),
- ▶ greške **numeričkih metoda** za rješavanje “**matematičkog**” problema,
- ▶ greške “**približnog**” **računanja** — obično su to
 - ▶ greške **zaokruživanja** u **aritmetici računala**.

Greške **modela** su “**izvan**” dosega **numeričke matematike**.

- ▶ Spadaju u fiziku, kemiju, biologiju, tehniku, ekonomiju, ...

Greške (nastavak)

Sljedeće tri kategorije (**podaci**, **metoda**, **računanje**) su vezane za “**matematički**” problem, i

- ▶ **spadaju** u domenu **numeričke matematike**!

O njima nešto “moramo reći”.

Skica **numeričkog** rješavanja nekog problema slič **algoritmu**:



Zamislite da pojam “**algoritam**” uključuje

- ▶ **metodu** i
- ▶ stvarno **računanje** rezultata na računalu!

Greške (nastavak)

Sve tri vrste grešaka — podaci, metoda, računanje,
▶ rezultiraju nekom greškom u konačnom rezultatu!
Ta greška nas “zanima”.

Uočite da greške u ulaznim podacima možemo gledati
▶ neovisno o metodi ili algoritmu za rješenje problema,
▶ i tako dolazimo do pojma uvjetovanosti problema.

Za razliku od toga, greške metode i računanja, naravno,
▶ ovise o metodi, odnosno, algoritmu za rješenje problema.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Greška metode

Gruba podjela **numeričkih metoda** — prema greškama:

Egzaktne metode

- ▶ daju **egzaktno** rješenje u **konačnom** broju “koraka”, odnosno, računskih operacija.

Primjer:

- ▶ Gaussove eliminacije ili LR faktorizacija za linearne sustave.

Greška takvih metoda je **nula**, uz **egzaktno** računanje.

Približne ili **neegzaktne** metode

- ▶ daju **približno** rješenje problema, u **konačnom** broju “koraka” (računskih operacija).

Greška metode — približne metode

Mogu biti **egzaktne** — na nekom limesu!

Primjeri:

- ▶ zamjena kompliciranog modela jednostavnijim,
- ▶ greške diskretizacije (numerička integracija),
- ▶ greške odbacivanja/rezanja, konačne iteracije (rješavanje nelinearnih jednažbi)

Analiza ovih grešaka spada u **TEORIJU APROKSIMACIJA**.

Pošteno, to je **standardni** predmet proučavanja **numeričke** matematike, u **širem** smislu,

- ▶ numerička analiza, funkcionalna analiza, itd.

Time se bavimo **veći** dio kolegija!

Greške u podacima

Ključno svojstvo **problema** je

- ▶ ovisnost **rješenja** o **greškama** ili **perturbacijama** ulaznih podataka.

To spada u **TEORIJU PERTURBACIJE**.

Da bi problem uopće **imao smisla**, očekujemo

- ▶ neku vrstu **neprekidnosti** rješenja,
- ▶ ili barem **ograničenu** osjetljivost rješenja na perturbacije.

Inače imamo “**loše**” postavljen (engl. “ill-posed”) problem!

Osjetljivost se obično mjeri tzv. **brojem uvjetovanosti** problema (engl. “condition number”). Može ih biti i **više**.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Kako mjeriti grešku?

Prije definicije broja uvjetovanosti, potrebno je odrediti kako ćemo mjeriti greške.

Kad x i $y = f(x)$ nisu brojevi, nego vektori ili matrice, grešku možemo mjeriti na više načina.

- ▶ Po svakoj od komponenata vektora/matrica,
 - ▶ što je “vrlo precizno”,
 - ▶ međutim, to je malo previše brojeva.
- ▶ Kao neku “ukupnu ili najveću” grešku,
 - ▶ što je samo jedan broj — pa se lakše nalazi,
 - ▶ iako može biti “neprecizno” (sažeta informacija).

Ovo se radi korištenjem vektorskih i/ili matičnih normi.

Prisjetite se: vektorski prostor na kojem je definirana norma zove se normirani prostor.

Vektorske norme

“**Vektorska**” norma na vektorskom prostoru V (nad poljem F , gdje je $F = \mathbb{R}$ ili $F = \mathbb{C}$) je

▶ svaka funkcija $\| \cdot \| : V \rightarrow \mathbb{R}$

koja zadovoljava sljedeća svojstva:

1. $\|x\| \geq 0$, $\forall x \in V$,

a jednakost vrijedi ako i samo ako je $x = 0$,

2. $\|\alpha x\| = |\alpha| \|x\|$, $\forall \alpha \in F$, $\forall x \in V$,

3. $\|x + y\| \leq \|x\| + \|y\|$, $\forall x, y \in V$

(nejednakost poznata pod imenom **nejednakost trokuta**).

Najpoznatije vektorske norme

Kad je vektorski prostor **konačnodimenzionalan**, $V = \mathbb{R}^n$ ili $V = \mathbb{C}^n$, najčešće se koriste sljedeće tri norme:

▶ **1-norma** ili l_1 norma $\|x\|_1 = \sum_{i=1}^n |x_i|$,

▶ **2-norma** ili l_2 norma ili **euklidska** norma

$$\|x\|_2 = (x^*x)^{1/2} = \sqrt{\sum_{i=1}^n |x_i|^2},$$

▶ **∞ -norma** ili l_∞ norma $\|x\|_\infty = \max_{i=1, \dots, n} |x_i|$.

Samo je **2-norma** izvedena iz **skalarnog produkta**.

Norme na prostoru funkcija

Vektorski prostor V **ne mora** biti konačnodimenzionalan.

Na primjer, norme definirane na vektorskom prostoru $C[a, b]$ **neprekidnih funkcija** f na segmentu $[a, b]$, definiraju se slično normama na \mathbb{R}^n (suma \mapsto integral):

▶ L_1 norma $\|f\|_1 = \int_a^b |f(t)| dt,$

▶ L_2 norma $\|f\|_2 = \left(\int_a^b |f(t)|^2 dt \right)^{1/2},$

▶ L_∞ norma $\|f\|_\infty = \max\{ |f(x)| \mid x \in [a, b] \}.$

Ekvivalentnost normi

Može se pokazati da vrijedi sljedeći teorem.

Teorem. Na svakom konačnodimenzionalnom vektorskom prostoru V sve su norme ekvivalentne, tj. za svake dvije norme $\|\cdot\|_a$ i $\|\cdot\|_b$, postoje konstante c i C , takve da za sve $v \in V$ vrijedi

$$c\|v\|_a \leq \|v\|_b \leq C\|v\|_a.$$



Na primjer,

$$\|x\|_\infty \leq \|x\|_2 \leq \sqrt{n}\|x\|_\infty,$$

za sve $x \in \mathbb{R}^n$.

Razlika između teorije i prakse — kad je n ogroman.

Matrične norme

Zamijenimo li u definiciji vektorske norme, čisto formalno, vektor x matricom A , dobivamo **matričnu normu**.

Matrična norma je svaka funkcija $\| \cdot \| : \mathbb{C}^{m \times n} \rightarrow \mathbb{R}$ koja zadovoljava sljedeća svojstva:

1. $\|A\| \geq 0$, $\forall A \in \mathbb{C}^{m \times n}$,
a jednakost vrijedi ako i samo ako je $A = 0$,
2. $\|\alpha A\| = |\alpha| \|A\|$, $\forall \alpha \in \mathbb{C}$, $\forall A \in \mathbb{C}^{m \times n}$,
3. $\|A + B\| \leq \|A\| + \|B\|$, $\forall A, B \in \mathbb{C}^{m \times n}$.

Tome se često dodaje i zahtjev **konzistentnosti**

4. $\|AB\| \leq \|A\| \|B\|$, kad god je produkt AB definiran.

Matrične norme (nastavak)

Matrične norme nastaju na dva načina.

- ▶ Matricu A promatramo kao **vektor** s $m \times n$ elemenata i za taj vektor koristimo odgovarajuću vektorsku normu.

Najpoznatija takva norma odgovara vektorskoj **2-normi** i zove se **euklidska**, **Frobeniusova**, **Hilbert–Schmidtova**, ili **Schurova** norma

$$\|A\|_F = (\operatorname{tr}(A^* A))^{1/2} = \sqrt{\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2}.$$

- ▶ **Operatorske norme:**

$$\|A\| = \max_{x \neq 0} \frac{\|Ax\|}{\|x\|} \quad \text{ili} \quad \|A\| = \max_{\|x\|=1} \|Ax\|.$$

Najpoznatije operatorske matrične norme

Uvrštavanjem odgovarajućih vektorskih normi, dobivamo

- ▶ matrična **1-norma**, “**maksimalna stupčana norma**”

$$\|A\|_1 = \max_{j=1,\dots,n} \sum_{i=1}^m |a_{ij}|,$$

- ▶ matrična **2-norma**, **spektralna norma**

$$\|A\|_2 = (\rho(A^*A))^{1/2} = \sigma_{\max}(A),$$

ρ je **spektralni radijus**, a σ **singularna vrijednost** matrice,

- ▶ matrična **∞ -norma**, “**maksimalna retčana norma**”

$$\|A\|_\infty = \max_{i=1,\dots,m} \sum_{j=1}^n |a_{ij}|.$$

Matrične norme (nastavak)

Svojstva:

- ▶ Za matrične norme, također, vrijedi **ekvivalentnost**.
- ▶ Matrična **2-norma** se **teško računa** u praksi — uobičajeno se **procjenjuje** korištenjem ostalih normi.
- ▶ Za svaku **operatorsku normu** vrijedi

$$\|Ay\| \leq \|A\| \|y\|,$$

za svaki vektor y . To se često koristi kod ocjena. Ova formula direktno izlazi iz definicije operatorske norme.

- ▶ **Unitarna** invarijantnost **spektralne** i **Frobeniusove** norme: za bilo koje **unitarne** matrice U (reda m) i V (reda n) vrijedi $\|UAV\|_2 = \|A\|_2$, $\|UAV\|_F = \|A\|_F$.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Uvjetovanost problema

Neformalno rečeno, **uvjetovanost problema** mjeri

- ▶ **osjetljivost** problema na **greške** u **podacima**.

Osnovno svojstvo **uvjetovanosti**:

- ▶ **Ne ovisi** o konkretnoj **numeričkoj metodi** za rješenje problema, već samo o **problemu**.

Svrha **uvjetovanosti** = daje odgovor na pitanje:

- ▶ Koju **točnost rezultata** možemo očekivati
- ▶ pri **točnom računanju**, bez grešaka zaokruživanja,
- ▶ s (malo) **pomaknutim** — **netočnim podacima**?

To je upravo ono što nam treba nakon obavljene “**obratne**” **analize** greške u natrag nekog algoritma.


Velika uvjetovanost \longleftrightarrow **nestabilan** problem.

Model problema

Matematički model **problema**, zovimo ga P :

- ▶ za zadani **ulaz** — podatak $x \in \mathcal{X}$,
- ▶ dobivamo **izlaz** — rezultat $y \in \mathcal{Y}$.

Slikica modela je



Problem P interpretiramo kao računanje vrijednosti **funkcije**

$$f: \mathcal{X} \rightarrow \mathcal{Y},$$

gdje su \mathcal{X} i \mathcal{Y} odgovarajući matematički **objekti**. Na primjer, **vektorski** prostori, a vrlo često su i **normirani** prostori (treba nam mjera za grešku). Najčešće, $\mathcal{X} = \mathbb{R}^m$, $\mathcal{Y} = \mathbb{R}^n$.

Uvjetovanost problema (nastavak)

Ideja **uvjetovanosti**:

greška u rezultatu \lesssim **uvjetovanost** · greška u podacima

Ovisi o **obje** vrijednosti: točnoj x i približnoj \hat{x} .


Za $m > 1$ ili $n > 1$, ovisi i o tome **kako** mjerimo greške.

Napomene:


- ▶ Obično nas **uvjetovanost** posebno zanima za **male** perturbacije (greške, smetnje) podataka.
- ▶ Ako je f dovoljno **glatka** funkcija, možemo koristiti **Taylorov** razvoj u okolini **točnog** ulaznog podatka x
- ▶ i dobiti procjenu **uvjetovanosti** preko **derivacija**!

Uvjetovanost — prigušivač i pojačalo grešaka

Mala uvjetovanost \longleftrightarrow funkcija f je “prigušivač” grešaka:



Velika uvjetovanost \longleftrightarrow funkcija f je “pojačalo” grešaka:



Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Vrste uvjetovanosti — kratki pregled

Prema **vrsti (tipu)** greške koju gledamo:

- ▶ **Apsolutna, relativna** — po x , odnosno, po $y = f(x)$.

Prema načinu **mjerenja** greške (u više dimenzija):

- ▶ Po pojedinim **komponentama** ili po **normi** cijelog vektora.

Po dozvoljenoj “**varijaciji**” argumenata x i \hat{x} :

- ▶ U “**fiksni**” točkama — tj. x i \hat{x} su zadani. Nema puno smisla kao informacija o funkciji f , jer su točke fiksne.
- ▶ **Lokalno** oko x — \hat{x} varira u nekoj zadanoj okolini oko x .
- ▶ **Lokalno** u točki x , za **male** perturbacije — na **limesu** kad $\hat{x} \rightarrow x$, tj. $\Delta x \rightarrow 0$, ako limes postoji. Ovisi samo o x .
- ▶ **Globalno** po x — (obično) kao **najgori** slučaj po **svim** x iz nekog skupa ili cijelog prostora. Ovisi samo o f .

Apsolutna greška i apsolutna uvjetovanost

Apsolutna, odnosno, **relativna** uvjetovanost problema mjeri koliko je problem **osjetljiv** na odgovarajuće promjene polaznih podataka.

- ▶ **Apsolutna greška**: $\|\Delta x\|$, $\|\Delta y\|$, (svaka norma u svom prostoru), gdje je

$$\Delta x = \hat{x} - x, \quad \Delta y = \hat{y} - y.$$

- ▶ **Apsolutna uvjetovanost**:

$$K_f^{\text{abs}}(x) := \lim_{\epsilon \rightarrow 0} \sup_{\|\Delta x\| \leq \epsilon} \frac{\|\Delta y\|}{\|\Delta x\|}.$$

Relativna greška i relativna uvjetovanost

U praksi se češće koristi **relativna** mjera za grešku (na primjer, zbog aritmetike računala).

- ▶ **Relativna greška** (po normi):

$$\delta_x := \frac{\|\Delta x\|}{\|x\|}, \quad \delta_y := \frac{\|\Delta y\|}{\|y\|}.$$

- ▶ **Relativna uvjetovanost** (po normi):

$$\kappa_f^{\text{rel}}(x) = \kappa_f(x) := \lim_{\varepsilon \rightarrow 0} \sup_{\|\Delta x\| \leq \varepsilon \|x\|} \frac{\delta_y}{\delta_x}.$$

Problem je **dobro uvjetovan** u relativnom smislu ako je

- ▶ $\kappa_f(x)$ što je moguće **manji**.

Landauov simbol — red veličine

Za zapis “reda veličine” vrijednosti neke funkcije u okolini neke točke koristimo tzv. Landauov simbol \mathcal{O} (“veliko O”).

Definicija. Neka su $g, h : \mathbb{R}^m \rightarrow \mathbb{R}^n$ funkcije, $\|\cdot\|_{\mathbb{R}^m}$ i $\|\cdot\|_{\mathbb{R}^n}$ norme i neka je $x_0 \in \mathbb{R}^m$.

Ako postoje konstante $\delta > 0$ i $C > 0$, takve da za sve x vrijedi

$$\|x - x_0\|_{\mathbb{R}^m} \leq \delta \quad \implies \quad \|g(x)\|_{\mathbb{R}^n} \leq C \|h(x)\|_{\mathbb{R}^n},$$

onda kažemo da je

“funkcija g reda veličine \mathcal{O} od h , kad x teži prema x_0 ”

i to pišemo ovako

$$g(x) = \mathcal{O}(h(x)) \quad (x \rightarrow x_0).$$

Landauov simbol (nastavak)

Napomena. Umjesto znaka “=”, **korektno** bi bilo pisati \in , tj.

$$g(x) \in \mathcal{O}(h(x)) \quad (x \rightarrow x_0).$$

Također, često se piše “veliko” \mathcal{O} , umjesto “pisanog” \mathcal{O} .

Primjer. Za $m = n = 1$ vrijedi:

$$\begin{aligned}\sin x &= \mathcal{O}(x), & \sin x &= x + \mathcal{O}(x^3) \quad (x \rightarrow 0), \\ x^2 + 3x &= \mathcal{O}(x) \quad (x \rightarrow 0), \\ x^2 - x - 6 &= \mathcal{O}(x - 3), \quad (x \rightarrow 3).\end{aligned}$$

Zadnje dvije relacije opisuju ponašanje polinoma u okolini **jednostruke** nultočke, a izlaze iz zapisa

$$x^2 + 3x = x(x + 3), \quad x^2 - x - 6 = (x - 3)(x + 2).$$

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Uvjetovanost i Taylorov teorem

Istražimo **uvjetovanost** problema **računanja vrijednosti** funkcije $f : \mathbb{R} \rightarrow \mathbb{R}$ u nekoj točki x .

Promatramo ponašanje funkcije f za **male** perturbacije Δx u okolini točke x . Neka je Δy pripadna perturbacija funkcijske vrijednosti $y = f(x)$, tj.

$$f(x + \Delta x) = y + \Delta y.$$

Neka je f još **dva puta neprekidno derivabilna** oko x . Korištenjem **Taylorovog** polinoma stupnja **1** dobivamo da je

$$\begin{aligned}\Delta y &= f(x + \Delta x) - f(x) \\ &= f'(x) \Delta x + \frac{f''(x + \vartheta \Delta x)}{2!} (\Delta x)^2, \quad \vartheta \in (0, 1).\end{aligned}$$

Apsolutna uvjetovanost i Taylorov teorem

Druga derivacija f'' je neprekidna oko $x \implies f''$ je ograničena oko x , tj. vrijedi

$$f''(x + \vartheta \Delta x) = \mathcal{O}(1),$$

za sve dovoljno male Δx i sve $\vartheta \in [0, 1]$.

Za male perturbacije Δx , apsolutni oblik relacije za grešku je

$$\Delta y = f'(x) \Delta x + \mathcal{O}((\Delta x)^2),$$

odnosno

$$\frac{|\Delta y|}{|\Delta x|} \leq |f'(x)| + \mathcal{O}(|\Delta x|).$$

Odavde slijedi da je apsolutna uvjetovanost funkcije f

$$\kappa_f^{\text{abs}}(x) = |f'(x)|,$$

i za male perturbacije Δx tada vrijedi

$$|\Delta y| \approx |f'(x)| |\Delta x|.$$

Relativna uvjetovanost i Taylorov teorem

Ako je $x \neq 0$ i $y \neq 0$, dijeljenjem s y izlazi **relativna** forma

$$\frac{\Delta y}{y} = \frac{xf'(x)}{f(x)} \cdot \frac{\Delta x}{x} + O\left(\frac{(\Delta x)^2}{y}\right).$$

Ovdje koristimo da su x , $1/x$ i $1/y$ ograničene, pa za sve dovoljno **male** relativne perturbacije $\Delta x/x$ vrijedi

$$\frac{(\Delta x)^2}{y} = \frac{x^2}{y} \left(\frac{\Delta x}{x}\right)^2 = O\left(\left(\frac{\Delta x}{x}\right)^2\right).$$

Zbog toga je

$$\frac{\frac{|\Delta y|}{|y|}}{\frac{|\Delta x|}{|x|}} = \left| \frac{xf'(x)}{f(x)} \right| + O\left(\frac{|\Delta x|}{|x|}\right).$$

Onda **relativnu** uvjetovanost funkcije f možemo definirati

$$\kappa_f^{\text{rel}}(x) = \kappa_f(x) = \left| \frac{xf'(x)}{f(x)} \right|.$$

Uvjetovanost — posebni slučajevi oko nule

Ako je $x = 0$ i $y \neq 0$, onda relativna greška u x **nema** smisla (nije ograničena). Zato gledamo **apsolutnu** grešku u x i **relativnu** u y . Pripadni tzv. “**miješani**” broj uvjetovanosti je

$$\kappa_f(x) := \left| \frac{f'(x)}{f(x)} \right|.$$

Analogno, za $x \neq 0$ i $y = 0$, pripadni broj uvjetovanosti je

$$\kappa_f(x) := |xf'(x)|.$$

Ako je $x = y = 0$, onda gledamo samo apsolutne greške, pa je

$$\kappa_f(x) := |f'(x)|.$$

Uvjetovanost — primjer

Primjer. **Relativna** uvjetovanost funkcije

$$f(x) = \ln x$$

jednaka je

$$\kappa_f(x) = \left| \frac{xf'(x)}{f(x)} \right| = \left| \frac{1}{\ln x} \right|,$$

što je **veliko** za $x \approx 1$, kada je $\ln x \approx 0$.

Pitanje: **Apsolutna** uvjetovanost?

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Što u više dimenzija?

Kad je $f : \mathbb{R}^m \rightarrow \mathbb{R}^n$, problem postaje **složeniji**. Uz oznake

$$x = (x_1, x_2, \dots, x_m)^T \in \mathbb{R}^m, \quad y = (y_1, y_2, \dots, y_n)^T \in \mathbb{R}^n,$$

preslikavanje f možemo komponentno zapisati kao

$$y_k = f_k(x_1, x_2, \dots, x_m), \quad k = 1, 2, \dots, n.$$

Ponovno, pretpostavljamo da **svaka funkcija** f_k ima

- ▶ neprekidne parcijalne derivacije po **svim komponentnim** varijablama x_ℓ u točki x , do barem **drugog** reda.

Najdetaljniju analizu dobivamo gledajući promjene

- ▶ **svake komponentne** funkcije f_k po **svakoj** varijabli x_ℓ .

Finija analiza — svaki izlaz po svakom ulazu

Promjena koju uzrokuje mala relativna perturbacija varijable x_ℓ u funkciji f_k ista je kao za funkciju jedne varijable.

Relativna uvjetovanost tog problema je

$$\gamma_{k\ell}(x) := \kappa_{f_k, x_\ell}(x) := \left| \frac{x_\ell}{f_k(x)} \cdot \frac{\partial f_k}{\partial x_\ell} \right|.$$

Ako to napravimo za sve varijable x_ℓ i za svaku funkciju f_k , dobivamo matricu brojeva uvjetovanosti

$$\Gamma(x) = [\gamma_{k\ell}(x)] \in \mathbb{R}_+^{n \times m}.$$

Da bismo iz matrice $\Gamma(x)$ dobili jedan broj, koristimo neku normu i definiramo

$$(\text{cond}f)(x) := \|\Gamma(x)\|.$$

Primjer — uvjetovanost aritmetičkih operacija

Zadatak. Osnovne aritmetičke operacije $\circ = +, -, *, /$, na realnim brojevima gledamo kao računanje vrijednosti funkcije $f_{\circ} : \mathbb{R}^2 \rightarrow \mathbb{R}$, gdje je

$$f_{\circ}(x_1, x_2) = x_1 \circ x_2.$$

Izračunajte pripadne matrice $\Gamma_{\circ}(x_1, x_2)$ za svaku operaciju \circ i nađite pripadnu relativnu uvjetovanost u ∞ -normi.

Rješenje.

$$\|\Gamma_{\pm}(x_1, x_2)\|_{\infty} = \frac{|x_1| + |x_2|}{|x_1 \pm x_2|},$$

$$\|\Gamma_{*}(x_1, x_2)\|_{\infty} = \|\Gamma_{/}(x_1, x_2)\|_{\infty} = 2.$$

To odgovara ranijim rezultatima za (vrlo) male relativne greške u polaznim podacima, tj. na limesu kad $\varepsilon \rightarrow 0!$

Grublja analiza — po normi

Grublju analizu — s manje parametara, dobivamo po ugledu na jednodimenzionalnu, promatranjem

- ▶ apsolutnih i relativnih perturbacija vektora u smislu norme, pri čemu je $\|\cdot\|$ bilo koja vektorska norma.

Relativnu perturbaciju vektora $x \in \mathbb{R}^m$ “po normi” definiramo kao

$$\frac{\|\Delta x\|}{\|x\|}, \quad \Delta x = (\Delta x_1, \Delta x_2, \dots, \Delta x_m)^T,$$

Pretpostavljamo da su komponente Δx_ℓ vektora perturbacije Δx male u odnosu na pripadne komponente x_ℓ vektora x . Tada je i $\|\Delta x\|/\|x\|$ malo (obrat ne vrijedi).

Isto napravimo i za vektor $y \in \mathbb{R}^n$, tj. gledamo $\|\Delta y\|/\|y\|$.

Taylorov razvoj komponentnih funkcija

Sada možemo pokušati povezati **relativnu perturbaciju** od y s **relativnom perturbacijom** od x .

Za **male perturbacije** Δx , iz početka **Taylorovog** razvoja funkcije f_k dobivamo

$$\Delta y_k = f_k(x + \Delta x) - f_k(x) \approx \sum_{\ell=1}^m \frac{\partial f_k}{\partial x_\ell} \Delta x_\ell.$$

Ovu relaciju možemo zapisati u vektorsko-matričnom obliku

$$\Delta y \approx \frac{\partial f}{\partial x} \cdot \Delta x,$$

gdje je $\frac{\partial f}{\partial x} = J_f(x)$ **Jacobijeva matrica** funkcije f u točki x .

Jacobijeva matrica preslikavanja

Jacobijeva matrica $J_f(x)$ sadrži **parcijalne derivacije** svih komponentnih funkcija po svim varijablama:

$$[J_f(x)]_{k\ell} = \frac{\partial f_k}{\partial x_\ell}, \quad k = 1, \dots, n, \quad \ell = 1, \dots, m,$$

ili

$$J_f(x) = \frac{\partial f}{\partial x} = \begin{bmatrix} \frac{\partial f_1}{\partial x_1} & \frac{\partial f_1}{\partial x_2} & \cdots & \frac{\partial f_1}{\partial x_m} \\ \frac{\partial f_2}{\partial x_1} & \frac{\partial f_2}{\partial x_2} & \cdots & \frac{\partial f_2}{\partial x_m} \\ \cdots & \cdots & \cdots & \cdots \\ \frac{\partial f_n}{\partial x_1} & \frac{\partial f_n}{\partial x_2} & \cdots & \frac{\partial f_n}{\partial x_m} \end{bmatrix} \in \mathbb{R}^{n \times m}.$$

Apsolutne perturbacije po normi

Iz približne jednakosti za **male** perturbacije

$$\Delta y \approx \frac{\partial f}{\partial x} \cdot \Delta x,$$

uzimanjem bilo koje **operatorske** ili **konzistentne** norme izlazi

$$\|\Delta y\| \approx \left\| \frac{\partial f}{\partial x} \cdot \Delta x \right\| \lesssim \left\| \frac{\partial f}{\partial x} \right\| \cdot \|\Delta x\|.$$

Za **operatorske** norme, prethodna nejednakost **oštra**, tj. **postoji** perturbacija Δx za koju se ona **dostiže**.

Oдавde vidimo da **normu Jacobijeve** matrice možemo uzeti kao **apsolutnu** uvjetovanost “**po normi**”.

Uočite: Za $m = n = 1$ dobivamo **isto** kao i ranije!

Relativne perturbacije po normi

Kao i ranije, ako je $x \neq 0$ i $y \neq 0$, dijeljenjem s $\|y\|$ dobivamo da za **relativne perturbacije po normi** vrijedi

$$\frac{\|\Delta y\|}{\|y\|} \approx \frac{\|x\|}{\|f(x)\|} \cdot \left\| \frac{\partial f}{\partial x} \right\| \cdot \frac{\|\Delta x\|}{\|x\|}.$$

To opravdava definiciju **relativne** uvjetovanosti “**po normi**” u obliku

$$\kappa_f(x) := \frac{\|x\|}{\|f(x)\|} \cdot \left\| \frac{\partial f}{\partial x} \right\|.$$

Ova uvjetovanost je **mnogo grublja** nego $\|\Gamma(x)\|$, jer **norma** pokušava “**uništiti**” detalje o komponentama vektora.

Ako su komponente **bitno različitih** redova veličina, samo **najveće** po apsolutnoj vrijednosti igraju **neku ulogu**.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Problem — računanje integrala (Gautschi)

Ispitajmo **uvjetovanost** problema računanja integrala

$$I_n = \int_0^1 \frac{t^n}{t+5} dt,$$

za **zadani** nenegativni cijeli broj $n \in \mathbb{N} \cup \{0\} = \mathbb{N}_0$.

U **ovom** obliku, problem je napisan kao preslikavanje iz \mathbb{N}_0 u \mathbb{R} i **ne** “paše” ranijem pojmu **problema**.

- ▶ Domena ovdje **nije** \mathbb{R} , nego \mathbb{N}_0 (diskretan skup), pa nema smisla govoriti o neprekidnosti, derivabilnosti i sl.

Zato prvo **transformiramo** problem.

Rekurzija za integral

Nadimo **vezu** između I_k i I_{k-1} , s tim da I_0 **znamo** izračunati

$$I_0 = \int_0^1 \frac{1}{t+5} dt = \ln(t+5) \Big|_0^1 = \ln \frac{6}{5}.$$

Za početak, očito vrijedi da je

$$\frac{t}{t+5} = 1 - \frac{5}{t+5}.$$

Množenjem obje strane s t^{k-1} dobivamo

$$\frac{t^k}{t+5} = t^{k-1} - 5 \frac{t^{k-1}}{t+5}.$$

Rekurzija za integral (nastavak)

Na kraju, **integracijom** na segmentu $[0, 1]$ izlazi

$$I_k = \int_0^1 t^{k-1} dt - 5I_{k-1} = \frac{1}{k} - 5I_{k-1}, \quad k = 1, 2, \dots, n.$$

Dakle, I_k je **rješenje** (linearne, nehomogene) **diferencijske** **jednadžbe prvog** reda

$$y_k = -5y_{k-1} + \frac{1}{k}, \quad k = 1, 2, \dots,$$

uz **početni** uvjet $y_0 = I_0$.

Ovo gore je **dvočlana rekurzivna relacija** za y_k (pogledajte priču o rekurzivnim relacijama u **Diskretnoj matematici**).

Rekurzija unaprijed — zapis funkcijama

Varijacija **početnog** uvjeta definira niz funkcija f_k , $y_k = f_k(y_0)$.

Zanima nas **relativna uvjetovanost** funkcije f_n u točki $y_0 = l_0$, u ovisnosti o $n \in \mathbb{N}_0$. Razlog:

- ▶ l_0 nije **egzaktno** prikaziv u računalu,
- ▶ umjesto l_0 , spremi se aproksimacija \hat{l}_0 ,
- ▶ konačni rezultat — neka aproksimacija $\hat{l}_n = f_n(\hat{l}_0)$.

Indukcijom ili supstitucijom unatrag lako se dokaže da vrijedi

$$y_n = f_n(y_0) = (-5)^n y_0 + p_n, \quad p_n = \sum_{k=1}^n \frac{(-5)^{n-k}}{k},$$

gdje je p_n ovisi samo o **nehomogenim** članovima rekurzije, ali **ne** i o početnom uvjetu y_0 .

Rekurzija unaprijed — relativna uvjetovanost

Relativna uvjetovanost funkcije f_n u točki y_0 je

$$\kappa_{f_n}(y_0) = \left| \frac{y_0 f'_n(y_0)}{y_n} \right| = \left| \frac{y_0 (-5)^n}{y_n} \right|.$$

Iz definicije integrala slijedi: I_n monotonno padaju po n , čak

$$\lim_{n \rightarrow \infty} I_n = 0.$$

Zbrajanjima dobivamo sve manje i manje brojeve! U $y_0 = l_0$ je

$$\kappa_{f_n}(l_0) = \frac{l_0 \cdot 5^n}{I_n} > \frac{l_0 \cdot 5^n}{l_0} = 5^n.$$

Zaključak: f_n je vrlo loše uvjetovana u $y_0 = l_0$, i to tim gore kad n raste.


Rekurzija unaprijed — rezultati

Pitanje: Kako se **loša** uvjetovanost **vidi**, kad stvarno računamo $f_n(l_0)$ u aritmetici računala?

Algoritam **unaprijed**, za zadani n (pseudokôd):

```
k = 0;
y = ln( 6.0 / 5.0 );    /* y_0 */
ispisi k, y;
za k = 1 do n radi {
    y = -5.0 * y + 1.0 / k;    /* y_k */
    ispisi k, y;
}
```

Točne vrijednosti integrala I_n



egzaktne/točne vrijednosti integrala I_n


Rekurzija unaprijed — numerički rezultati

Izračunate vrijednosti u tipu `extended` ($u \approx 5.42 \cdot 10^{-20}$).

Crvene znamenke su pogrešne!

n	\hat{I}_n	I_n	rel. greška
0	1.82321556793954626E-1	1.82321556793954626E-1	2.2E-19
1	8.83922160302268688E-2	8.83922160302268689E-2	-2.0E-18
2	5.80389198488656562E-2	5.80389198488656553E-2	1.5E-17
..
22	7.38035060732479776E-3	7.29738306511145509E-3	1.1E-02
23	6.57650783294122857E-3	6.99134554400794192E-3	-5.9E-02
24	8.78412750196052383E-3	6.70993894662695705E-3	3.1E-01
25	-3.92063750980261915E-3	6.45030526686521474E-3	-1.6E+00
..
39	-6.32992112791892692E+7	4.18374034921478077E-3	-1.5E+10
40	3.16496056420946346E+8	4.08129825392609613E-3	7.8E+10

Rekurzija unaprijed za I_n — relativne greške



(\log_{10}) relativne greške izračunate vrijednosti
integrala I_n rekurzijom unaprijed

Rekurzija unaprijed — komentar rezultata

Izračunata vrijednost \hat{l}_0 ima

- ▶ vrlo **malu** relativnu grešku — samo **nekoliko** u .

Međutim, ta mala greška “**eksplodira**” vrlo **brzo**,

- ▶ jer se **pojačava** s faktorom **5** u **svakoj** iteraciji.

Isto vrijedi i za **sve** greške zaokruživanja iza toga, samo je **ukupni** faktor pojačanja malo manji (kasnije su nastale).

Stvarni problem i **bitna** razlika od primjera “**sin** 24π ”:

- ▶ Ovdje **nema velikih omjera** brojeva u algoritmu.

Brojevi l_n relativno **sporo** padaju — omjer l_0/l_{40} je ispod **50**. Po tome, očekivali bismo gubitak točnosti od oko **2** decimale,

- ▶ a stvarno imamo **užasno** i još “**nevidljivo**” kraćenje.

Rekurzija unatrag — zapis funkcijama

Može li se loša uvjetovanost **izbjeći**?

- ▶ **Može** — **okretanjem rekurzije**, unaprijed \mapsto **unatrag!**

Treba uzeti neki $\nu > n$ i “**silazno**” računati

$$y_{k-1} = \frac{1}{5} \left(\frac{1}{k} - y_k \right), \quad k = \nu, \nu - 1, \dots, n + 1.$$

Ovo, u principu, smijemo koristiti i za $n = 0$, tj. računati y_0 .

Problem: Kako izračunati **početnu** vrijednost y_ν ?

Nova rekurzija definira niz funkcija $g_{n,\nu}$, koje vežu y_n i y_ν , uz $\nu > n$, tj.

$$y_n = g_{n,\nu}(y_\nu).$$

Rekurzija unatrag — relativna uvjetovanost

Relativna uvjetovanost za $g_{n,\nu}$ je

$$\kappa_{g_{n,\nu}}(y_\nu) = \left| \frac{y_\nu (-1/5)^{\nu-n}}{y_n} \right|, \quad \nu > n.$$

Za $y_\nu = l_\nu$ dobivamo da je $y_n = l_n$, a iz monotonosti l_n slijedi

$$\kappa_{g_{n,\nu}}(l_\nu) = \frac{l_\nu}{l_n} \cdot \left(\frac{1}{5}\right)^{\nu-n} < \left(\frac{1}{5}\right)^{\nu-n}, \quad \nu > n,$$

što je ispod 1, tj. relativne greške se prigušuju.

- ▶ Prigušenje grešaka ide s faktorom 1/5 po svakoj iteraciji!
- ▶ To vrijedi i za greške zaokruživanja napravljene u ranijim iteracijama (u aritmetici računala).

Rekurzija unatrag — početna vrijednost

Ako je \hat{l}_ν neka aproksimacija za l_ν , onda za **relativne perturbacije** vrijedi

$$\left| \frac{\hat{l}_n - l_n}{l_n} \right| = \kappa_{g_{n,\nu}}(l_\nu) \cdot \left| \frac{\hat{l}_\nu - l_\nu}{l_\nu} \right| < \left(\frac{1}{5} \right)^{\nu-n} \cdot \left| \frac{\hat{l}_\nu - l_\nu}{l_\nu} \right|.$$

Zbog **linearnosti** funkcije $g_{n,\nu}$, ova relacija vrijedi za **bilo kakve perturbacije**, a ne samo za **male**.

- ▶ **Početna** vrijednost \hat{l}_ν uopće **ne mora biti blizu** prave l_ν .
- ▶ Možemo uzeti $\hat{l}_\nu = 0$, čime smo napravili **relativnu** grešku od **100%** (tj. **1**) u **početnoj** vrijednosti ...

Rekurzija unatrag — točnost i start ν

- ▶ ... a još uvijek dobivamo \hat{l}_n s **relativnom** greškom

$$\left| \frac{\hat{l}_n - l_n}{l_n} \right| < \left(\frac{1}{5} \right)^{\nu - n}, \quad \nu > n.$$

- ▶ Povoljnim izborom ν , ocjenu na desnoj strani možemo napraviti **po volji malom** — ispod **tražene točnosti** ε .
- ▶ Dovoljno je uzeti $\hat{l}_\nu = 0$ i

$$\nu \geq n + \frac{\log(1/\varepsilon)}{\log 5},$$

a zatim računamo vrijednosti

$$\hat{l}_{k-1} = \frac{1}{5} \left(\frac{1}{k} - \hat{l}_k \right), \quad k = \nu, \nu - 1, \dots, n + 1.$$

Rekurzija unatrag — rezultati

Pitanje: Kako se **dobra** uvjetovanost **vidi**, kad stvarno računamo $g_{n,\nu}(l_\nu)$ u aritmetici računala?

Promatramo rezultate za $\varepsilon = 10^{-19}$!


- ▶ **Početna** vrijednost je $\hat{l}_\nu = 0$.
- ▶ Za ovaj ε dobijemo

$$\nu \geq n + \frac{\log(1/\varepsilon)}{\log 5} \approx n + 28.$$

Dakle, “**silazno**” računamo **28** vrijednosti.

Usput, to su vrijednosti za l_n iz ranije tablice i **sve** prikazane znamenke su **točne** (ima ih **18**). Dakle, “ništa se **ne vidi**”. Greška je samo **nekoliko u**, jer je $\varepsilon \approx 2u$ i imamo **3** operacije.

Rekurzija unatrag za I_{40} — ovisno o startu ν



(\log_{10}) relativne greške izračunate vrijednosti integrala I_{40} obratnom rekurzijom za $I_{40+\nu} = 0$

Rekurzivno računanje — završne napomene

Rekurzije prvog i (posebno) drugog reda se vrlo često koriste u praksi

- ▶ ne samo za računanje vrijednosti **integrala**,
- ▶ već za računanje raznih **specijalnih** funkcija (poput **Besselovih**) i **ortogonalnih** polinoma (v. kasnije).

Zato **oprez** ...

- ▶ treba znati nešto o **stabilnosti** rekurzije, **prije računanja!**

“Trik” **okretanja** rekurzije poznat je kao **Millerov algoritam**. Prvi puta je iskorišten baš za računanje **Besselovih** funkcija.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Kvadratna jednadžba

Uzmimo da treba riješiti (realnu) kvadratnu jednadžbu

$$ax^2 + bx + c = 0,$$

gdje su a , b i c zadani, i vrijedi $a \neq 0$.

Matematički gledano, problem je lagan: imamo 2 rješenja

$$x_{1,2} = \frac{-b \pm \sqrt{b^2 - 4ac}}{2a}.$$

Numerički gledano, problem je mnogo izazovniji:

- ▶ ni uspješno računanje po ovoj formuli,
- ▶ ni točnost izračunatih korijena,

ne možemo uzeti “zdravo za gotovo”.

Kvadratna jednadžba — standardni oblik

Za početak, jer znamo da je $a \neq 0$, onda jednadžbu možemo **podijeliti** s a , tako da dobijemo tzv. “**normalizirani**” oblik

$$x^2 + px + q = 0, \quad p = \frac{b}{a}, \quad q = \frac{c}{a}.$$

Po standardnim formulama, rješenja ove jednadžbe su

$$x_{1,2} = \frac{-p \pm \sqrt{p^2 - 4q}}{2}.$$

Međutim, u praksi, stvarno **računanje** se radi po formuli

$$x_{1,2} = -\frac{p}{2} \pm \sqrt{\left(\frac{p}{2}\right)^2 - q},$$

s tim da na početku izračunamo i **zapamtimo** $p/2$ ili $-p/2$.
Ovim postupkom **štedimo jedno množenje** (ono s 4).

Kvadratna jednadžba — problem

Primjer. Rješavamo kvadratnu jednadžbu $x^2 - 56x + 1 = 0$.

U dekadskoj aritmetici s $p = 5$ značajnih znamenki dobijemo

$$x_1 = 28 - \sqrt{783} = 28 - 27.982 = 0.018000,$$

$$x_2 = 28 + \sqrt{783} = 28 + 27.982 = 55.982.$$

Točna rješenja su

$$x_1 = 0.0178628\dots \quad \text{i} \quad x_2 = 55.982137\dots$$

Apsolutno **manji** od ova dva korijena — x_1 , ima **samo dvije** točne znamenke (**kraćenje**), relativna greška je $7.7 \cdot 10^{-3}$!

Apsolutno veći korijen x_2 je “savršeno” **točan**.

Kvadratna jednadžba — popravak

Prvo izračunamo **većeg** po apsolutnoj vrijednosti, po formuli

$$x_2 = \frac{-(b + \text{sign}(b)\sqrt{b^2 - 4ac})}{2a} = -\frac{p}{2} - \text{sign}(p)\sqrt{\left(\frac{p}{2}\right)^2 - q},$$

a **manjeg** po apsolutnoj vrijednosti, izračunamo iz

$$x_1 \cdot x_2 = \frac{c}{a} = q$$

(**Vièteova** formula), tj. formula za x_1 je

$$x_1 = \frac{c}{x_2 a} = \frac{q}{x_2}.$$

Opasnog **kraćenja** za x_1 više **nema!**

Kvadratna jednadžba (nastavak)

Ovo je bila samo **jedna**, od (barem) **tri** “opasne” točke za računanje. Preostale **dvije** su:

- ▶ “**kvadriranje**” pod korijenom — mogućnost za **overflow**. Rješenje — “**skaliranje**”.
- ▶ **oduzimanje** u diskriminanti s velikim **kraćenjem** — **nema** jednostavnog rješenja. Naime, “krivac” **nije** aritmetika.
 - ▶ To je samo odraz tzv. **nestabilnosti** problema. Tad imamo **dva bliska korijena**, koji su **vrlo osjetljivi** na male **promjene** (**perturbacije**) koeficijenata jednadžbe.
 - ▶ Na primjer, pomak **c** = pomak grafa “**gore–dolje**”. **Mali** pomak rezultira **velikom** promjenom korijena!

Neki primjeri izbjegavanja kraćenja

Primjer. Treba izračunati

$$y = \sqrt{x + \delta} - \sqrt{x},$$

gdje su x i δ zadani **ulazni** podaci, s tim da je $x > 0$,

▶ a $|\delta|$ **vrlo mali** broj.

U ovoj formuli, očito, dolazi do **velike greške** zbog **kraćenja** — zaokruživanje korijena **prije** oduzimanja.

Ako formulu “**deracionaliziramo**” u oblik

$$y = \frac{\delta}{\sqrt{x + \delta} + \sqrt{x}},$$

problema više **nema!**

Neki primjeri izbjegavanja kraćenja

Primjer. Treba izračunati

$$y = \cos(x + \delta) - \cos x,$$

gdje su x i δ zadani **ulazni** podaci, s tim da je $|\cos x|$ razumno velik,

▶ a $|\delta|$ **vrlo mali** broj.

Opet, dolazi do **velike greške** zbog **kraćenja**.

Ako formulu napišmo u “**produktnom**” obliku

$$y = -2 \sin \frac{\delta}{2} \sin \left(x + \frac{\delta}{2} \right),$$

problema više **nema!**

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Svojsvene vrijednosti i nultočke polinoma

U linearnoj algebri, **svojsvene vrijednosti** zadane matrice A se računaju “**na ruke**” kao

- ▶ **nultočke karakterističnog polinoma** te matrice

$$k_A(\lambda) = \det(\lambda I - A) = 0.$$

Prvo, računanjem determinante, nađemo “standardni” oblik karakterističnog polinoma, preko **koeficijenata**

$$k_A(\lambda) = \lambda^n + c_{n-1}\lambda^{n-1} + \dots + c_1\lambda + c_0,$$

a onda tražimo **nultočke** $\lambda_1, \dots, \lambda_n$ tog polinoma.

Oprez: **Nultočke** polinoma mogu biti **vrlo osjetljive** na male perturbacije u **koeficijentima** polinoma.

Primjer — Wilkinsonov polinom

Primjer. Uzmimo tzv. **Wilkinsonov** polinom stupnja $n = 20$,

$$P_{20}(\lambda) = (\lambda - 1) \cdot (\lambda - 2) \cdots (\lambda - 19) \cdot (\lambda - 20).$$

Iz ovog “**multiplikativnog**” oblika odmah čitamo da su **nultočke** tog polinoma, redom, prirodni brojevi

$$\lambda_i = i, \quad i = 1, \dots, 20.$$

Ovaj oblik polinoma — kao **produkt linearnih faktora**, je

- ▶ idealno **stabilan** na male perturbacije “**polaznih**” podataka,
- ▶ jer su ti podaci upravo **nultočke** polinoma!

Wilkinsonov polinom — razvijen po potencijama

Kad polinom P_{20} “razvijemo” po potencijama od λ , tj. zapišemo preko **koeficijenata** c_j , dobivamo

$$P_{20}(\lambda) = \lambda^{20} + c_{19}\lambda^{19} + \cdots + c_1\lambda + c_0,$$

s koeficijentima:

$$c_{19} = -(1 + 2 + \cdots + 19 + 20) = -210,$$

$$\vdots$$

$$c_0 = (-1) \cdot (-2) \cdots (-19) \cdot (-20) = 20!$$

Baš to je oblik kojeg bismo, na primjer, izračunali iz pripadne matrice. Poanta:

- ▶ Ovdje se **nultočke** baš i “**ne vide**” odmah ...

Treba ih **izračunati!**

Egzaktni koeficijenti Wilkinsonovog polinoma

Točne vrijednosti koeficijenata c_j su

$c_0 =$	2432 90200 81766 40000	$c_{10} =$	1 30753 50105 40395
$c_1 =$	-8752 94803 67616 00000	$c_{11} =$	-13558 51828 99530
$c_2 =$	13803 75975 36407 04000	$c_{12} =$	1131 02769 95381
$c_3 =$	-12870 93124 51509 88800	$c_{13} =$	-75 61111 84500
$c_4 =$	8037 81182 26450 51776	$c_{14} =$	4 01717 71630
$c_5 =$	-3599 97951 79476 07200	$c_{15} =$	-16722 80820
$c_6 =$	1206 64780 37803 73360	$c_{16} =$	533 27946
$c_7 =$	-311 33364 31613 90640	$c_{17} =$	-12 56850
$c_8 =$	63 03081 20992 94896	$c_{18} =$	20615
$c_9 =$	-10 14229 98655 11450	$c_{19} =$	-210

Koeficijenti su “jedva” prikazivi u tipu `extended`, a sigurno nisu egzaktno prikazivi u manjim tipovima, poput `double`.

Mala perturbacija koeficijenta c_{19}

U polinomu P_{20} napravimo

▶ jednu jedinu perturbaciju veličine 2^{-23} u koeficijentu c_{19} , tako da dobijemo polinom

$$\tilde{P}_{20}(\lambda) = P_{20}(\lambda) - 2^{-23}\lambda^{19}.$$

Pripadna relativna perturbacija koeficijenta c_{19} je

▶ reda veličine 2^{-30} , odnosno, ispod 10^{-9} .

Reklo bi se — zaista mala perturbacija!

Kako izgledaju nultočke tog perturbiranog polinoma \tilde{P}_{20} , tj.

▶ jesu li se i nultočke “malo” promijenile?

Nažalost, ne!

Nestabilnost nultočka Wilkinsonovog polinoma

Egzaktne nultočke polinoma \tilde{P}_{20} , na 9 decimala, su

1.00000 0000	6.00000 6944	10.09526 6145 \pm 0.64350 0904 <i>i</i>
2.00000 0000	6.99969 7234	11.79363 3881 \pm 1.65232 9728 <i>i</i>
3.00000 0000	8.00726 7603	13.99235 8137 \pm 2.51883 0070 <i>i</i>
4.00000 0000	8.91725 0249	16.73073 7466 \pm 2.81262 4894 <i>i</i>
4.99999 9928	20.84690 8101	19.50243 9400 \pm 1.94033 0347 <i>i</i>

Od 20 realnih nultočka polinoma P_{20} , dobili smo

- ▶ samo 10 realnih — prvih 9 i zadnja,
- ▶ i 5 parova konjugirano kompleksnih, s vrlo “nezanemarivim” imaginarnim dijelovima.

Ni govora o “maloj” perturbaciji!

Svojstvene vrijednosti matrica — pouka

Zato se, u praksi, **svojstvene vrijednosti** matrice A

- ▶ **nikad** (ili gotovo nikad) **ne** računaju kao
- ▶ **nultočke karakterističnog polinoma** k_A .

Za taj problem postoji gomila **raznih** numeričkih metoda, ovisno o vrsti matrice i raznim drugim stvarima.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Primjer: računanje sume u aritmetici računala

Primjer. Računamo sumu (zbroj) $s_n = x_1 + x_2 + \dots + x_n$, uz pretpostavku da su svi brojevi x_i prikazivi u računalu, tj. vrijedi $x_i = fl(x_i)$, za $i = 1, \dots, n$.

Algoritam. Zbrajamo unaprijed — redom po indeksima:

```
s = x_1;  
za i = 2 do n radi  
    s = s + x_i;
```

Oznake. Razlikujemo egzaktne i izračunate parcijalne sume:

- ▶ **Egzaktne** parcijalne sume su $s_i = s_{i-1} + x_i = x_1 + \dots + x_i$,
 - ▶ **Izračunate** parcijalne sume su $\hat{s}_i = fl(\hat{s}_{i-1} + x_i)$,
- za $i = 2, \dots, n$. Za početnu sumu vrijedi $s_1 = \hat{s}_1 = x_1$.

Greške zaokruživanja u aritmetici računala

Prema IEEE standardu, za svaki **izračunati** rezultat vrijedi

$$\hat{s}_i = fl(\hat{s}_{i-1} + x_i) = (1 + \varepsilon_{i-1})(\hat{s}_{i-1} + x_i), \quad i = 2, \dots, n,$$

s tim da je $|\varepsilon_{i-1}| \leq u$, uz pretpostavku da su svi \hat{s}_j **unutar** prikazivog raspona (nadalje smatramo da je tako).

Jedino **razumno** je izraziti **završni** rezultat \hat{s}_n u terminima

- ▶ **polaznih** vrijednosti x_1, \dots, x_n .

Kad to napravimo i sredimo po x_i , dobivamo

$$\begin{aligned} \hat{s}_n = & (1 + \varepsilon_1) \cdots (1 + \varepsilon_{n-1}) x_1 + (1 + \varepsilon_1) \cdots (1 + \varepsilon_{n-1}) x_2 \\ & + (1 + \varepsilon_2) \cdots (1 + \varepsilon_{n-1}) x_3 + \cdots \\ & + (1 + \varepsilon_{n-2})(1 + \varepsilon_{n-1}) x_{n-1} + (1 + \varepsilon_{n-1}) x_n. \end{aligned}$$

Zapis izračunate sume

Izračunatu sumu \hat{s}_n možemo napisati u obliku

$$\hat{s}_n = (1 + \eta_1) x_1 + (1 + \eta_2) x_2 + \cdots + (1 + \eta_n) x_n,$$

gdje je

$$\eta_1 = \eta_2 = (1 + \varepsilon_1) \cdots (1 + \varepsilon_{n-1}) - 1$$

$$\eta_3 = (1 + \varepsilon_2) \cdots (1 + \varepsilon_{n-1}) - 1$$

\vdots

$$\eta_{n-1} = (1 + \varepsilon_{n-2}) (1 + \varepsilon_{n-1}) - 1$$

$$\eta_n = (1 + \varepsilon_{n-1}) - 1 = \varepsilon_{n-1}.$$

Iz $|\varepsilon_i| \leq u$ dobivamo ocjene (v. “velika” skripta, str. 135–136)

$$|\eta_i| \leq (1 + u)^{n+1-i} - 1 \leq \gamma_{n+1-i} := \frac{(n+1-i)u}{1 - (n+1-i)u},$$

za $i = 2, \dots, n$, i $|\eta_1| = |\eta_2| \leq \gamma_{n-1}$ (uz uvjet $(n-1)u < 1$).

Što ćemo s tim — interpretacija unatrag

Pogled unatrag u domenu — obratna greška, stabilnost unatrag (engl. backward error, backward stability), iz relacije

$$\hat{s}_n = (1 + \eta_1) x_1 + (1 + \eta_2) x_2 + \cdots + (1 + \eta_n) x_n.$$

Izračunati rezultat \hat{s}_n je egzaktna suma

- ▶ malo “perturbiranih” polaznih podataka x_1, \dots, x_n ,
- ▶ s obratnim ili polaznim relativnim greškama η_1, \dots, η_n .

To kaže da je algoritam zbrajanja stabilan “unatrag”.

Pogled unaprijed = teorija perturbacije za greške η_1, \dots, η_n .
Prava greška izračunate sume je

$$\hat{s}_n - s_n = \eta_1 x_1 + \eta_2 x_2 + \cdots + \eta_n x_n.$$

Ocjena relativne greške unaprijed

Odavde slijedi

$$\begin{aligned} |\hat{s}_n - s_n| &\leq (|x_1| + \dots + |x_n|) \cdot \max_{i=1, \dots, n} |\eta_i| \\ &\leq (|x_1| + \dots + |x_n|) \cdot \gamma_{n-1}. \end{aligned}$$

Za **relativnu** grešku izračunate sume dobivamo ocjenu

$$\frac{|\hat{s}_n - s_n|}{|s_n|} \leq \frac{|x_1| + \dots + |x_n|}{|x_1 + \dots + x_n|} \cdot \gamma_{n-1} = \kappa_{s_n} \cdot \gamma_{n-1},$$

gdje je uvjetovanost

$$\kappa_{s_n} = \frac{|x_1| + \dots + |x_n|}{|x_1 + \dots + x_n|}.$$

Zbrajanje brojeva **istog** predznaka $\implies \kappa_{s_n} = 1$.

Poredak zbrajanja za iste predznake

Zbog prijelaza $|\eta_i| \leq \max_{i=1, \dots, n} |\eta_i|$, prethodna ocjena vrijedi

- ▶ za bilo koji algoritam — neovisno o poretku sumanada!

Prave obratne greške η_i , naravno, ne znamo. Međutim, znamo da za ocjene tih grešaka vrijedi:

$$|\eta_1| = |\eta_2| \leq \gamma_{n-1}, \quad |\eta_i| \leq \gamma_{n+1-i}, \quad i = 2, \dots, n,$$

tj. najveća je ocjena za prva dva sumanda x_1, x_2 , i ocjena pada kako indeksi rastu (sumandi kasnije ulaze u zbrajanja).

Kad zbrajamo brojeve istog predznaka (tj. nema kraćenja), najmanju ocjenu greške dobivamo tako da

- ▶ sumande x_i poredamo uzlazno po apsolutnoj vrijednosti!
Razlog: veće (ocjene) greške množe se sa manjim sumandima.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Općenito o linearnim sustavima — teorija

Neka je $\mathcal{F} = \mathbb{R}$ polje **realnih** brojeva (može i $\mathcal{F} = \mathbb{C}$).

Zadani su:

- ▶ (pravokutna) matrica $A \in \mathcal{F}^{m \times n}$ i vektor $b \in \mathcal{F}^m$.

Tražimo **rješenje** linearnog sustava

$$Ax = b.$$

Teorem **Kronecker–Capelli** kaže da linearni sustav $Ax = b$

- ▶ **ima rješenje** $x \in \mathcal{F}^n$ — **ako i samo ako** je rang matrice A , u oznaci r , **jednak** rang u proširene matrice $\hat{A} = [A \mid b]$,
- ▶ rješenje sustava je **jedinstveno** ako je $r = n$.

Znamo čak i malo više!

Linearni sustavi — teorija (nastavak)

Opće rješenje sustava $Ax = b$ (ako postoji) ima oblik

$$x = x_p + \mathcal{N}(A),$$

gdje je

- ▶ x_p jedno **partikularno** rješenje polaznog sustava $Ax = b$,
- ▶ $\mathcal{N}(A)$ je **nul-potprostor** od A , ili **opće** rješenje pripadnog **homogenog** sustava $Ax = 0$.

Iz teorema o **rangu i defektu** za matricu A

$$r + \dim \mathcal{N}(A) = n,$$

slijedi tvrdnja o **jedinstvenosti** rješenja:

- ▶ $\dim \mathcal{N}(A) = 0 \iff r = n$.

Linearni sustavi — od teorije prema praksi

U praksi se najčešće rješavaju linearni sustavi $Ax = b$ kod kojih je matrica A kvadratna i regularna.

- ▶ A kvadratna — znači da je $m = n$ (A je reda n).
- ▶ A regularna — znači, na primjer, $\det A \neq 0$.

Iz teorema Kronecker–Capelli onda izlazi da

- ▶ rješenje x takvog sustava postoji i jedinstveno je.

⇒ ima smisla promatrati algoritme za računanje rješenja.

Nema smisla računati nešto što (možda) ne postoji, ili nije jedinstveno (koje od beskonačno mnogo rješenja računamo).

Oprez: To što unaprijed znamo da je A regularna

- ▶ ne znači da to vrijedi i numerički!

Kako naći rješenje? — Inverz matrice

Teorija (1). Možemo naći **inverz** matrice A , tj. matricu A^{-1}

- ▶ i **slijeva** pomnožiti sustav $Ax = b$ matricom A^{-1} .

Dobivamo

$$x = A^{-1}b.$$

Samo je **pitanje**: Kako ćemo **izračunati** inverz A^{-1} ?

Zaključak: **Lakši** problem sveli smo na **teži** — u prijevodu, **pali smo s konja na magarca**.

Zašto? Jednostavno, zato što je

- ▶ j -ti stupac inverza, upravo, rješenje sustava $Ax = e_j$.

Dakle, za n stupaca od A^{-1} treba **riješiti** n linearnih sustava. A krenuli smo od **jednog** (sustava)! **Ne tako!**

Kako naći rješenje? — Cramerovo pravilo

Teorija (2). Iz linearne algebre znate za Cramerovo pravilo:

- ▶ j -ta komponenta rješenja sustava je

$$x_j = \frac{\det A_j}{\det A}, \quad j = 1, \dots, n,$$

- ▶ pri čemu je matrica A_j jednaka matrici A ,
- ▶ osim što je j -ti stupac u A_j zamijenjen desnom stranom b .

Treba još “samo” izračunati determinante — i to $n + 1$ njih.
A kako ćemo to?

“Klasični” odgovor: pa ... recimo, Laplaceovim razvojem.

Jao, jao ... Bilo kako, samo ne tako!

Kako naći rješenje? — Zaboravite Cramera

Zašto? Laplaceovim razvojem dobijemo (kao u definiciji \det)

- ▶ “samo” $n!$ pribrojnika u **svakoj** determinanti,
- ▶ a **svaki** pribrojnik je produkt od n faktora.

Prava “sitnica”. I tako to, još $n + 1$ puta ...

Zaključak: Ako determinante računamo na ovaj način,

- ▶ složenost Cramerovog pravila za rješavanje linearnog sustava je eksponencijalna u n (dokažite to!)
- ▶ i **nikad** se ne koristi kao metoda numeričkog rješavanja.

Zaboravite determinante i Cramera — finale

Komentar: Determinante možemo računati i puuuno brže,

- ▶ tako da matricu svedemo na trokutasti oblik,
- ▶ postupkom sličnim Gausovim eliminacijama.

Naime, determinanta trokutaste matrice (gornje ili donje) je

- ▶ produkt dijagonalnih elemenata,

pa se lako računa!

No, isti postupak eliminacija koristimo i za

- ▶ rješavanje “cijelog” linearnog sustava $Ax = b$,
- ▶ i to samo jednom, a ne $n + 1$ puta.

Dakle, Cramerovo pravilo se ne isplati ni kad ovako računamo determinante.

Kako naći rješenje? — Gaussove eliminacije!

Najjednostavnija metoda za rješavanje linearnih sustava su

- ▶ Gaussove eliminacije, odnosno,
- ▶ slične metode svođenja na trokutastu formu.

Ideja: Sustav $Ax = b$ se ekvivalentnim transformacijama svodi na sustav oblika

$$Ux = y,$$

gdje je

- ▶ U trokutasta matrica (recimo, gornja),

iz kojeg se lako, tzv. povratnom supstitucijom, nalazi rješenje.

Oznaka U — “upper” (gornja) = gornja trokutasta matrica.

Ekvivalentne transformacije sustava

Ekvivalentne transformacije sustava su

- ▶ one koje **ne mijenjaju rješenje** sustava.

Standardne ekvivalentne transformacije su (v. LA):

- ▶ **zamjena poretka** jednadžbi (**nužno!**),
- ▶ **množenje** jednadžbe **brojem** različitim od **nule**,
 - ▶ ova transformacija “**skaliranja**” se obično **ne** koristi, ili se **vrlo pažljivo** koristi — za povećanje **stabilnosti**,
- ▶ **množenje jedne** jednadžbe nekim **brojem** i **dodavanje drugoj** jednadžbi (**ključno!**),

= dodavanje **linearne kombinacije** preostalih jednadžbi, s tim da uzmemo samo **jednu** preostalu jednadžbu.

Uvodna priča o greškama (nastavak)

Analiza pojedinih vrsta grešaka

Mjerenje grešaka — norme

Uvjetovanost problema

Vrste uvjetovanosti

Uvjetovanost jednodimenzionalnog problema

Uvjetovanost višedimenzionalnog problema

Primjer uvjetovanosti problema

Primjeri izbjegavanja kraćenja

Primjer osjetljivosti problema na greške u podacima

Primjer računanja u aritmetici računala

Rješavanje linearnih sustava

Gaussove eliminacije

Gaussove eliminacije — algoritam

Označimo $A^{(1)} := A$, $b^{(1)} := b$ na početku **prvog** koraka.

U skraćenoj notaciji, **bez** pisanja nepoznanica x_j , linearni sustav $Ax = b$ možemo zapisati **proširenom** matricom, kao

$$\left[\begin{array}{cccc|c} a_{11}^{(1)} & a_{12}^{(1)} & \cdots & a_{1n}^{(1)} & b_1^{(1)} \\ a_{21}^{(1)} & a_{22}^{(1)} & \cdots & a_{2n}^{(1)} & b_2^{(1)} \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ a_{n1}^{(1)} & a_{n2}^{(1)} & \cdots & a_{nn}^{(1)} & b_n^{(1)} \end{array} \right].$$

Svođenje na **trokutastu** formu radimo u $n - 1$ **koraka**.

Gaussove eliminacije — algoritam (nastavak)

1. korak.

- ▶ U prvom stupcu matrice $A^{(1)}$ poništimo sve elemente, osim prvog, tj. sve elemente strogo ispod dijagonale.

Kako se to radi?

Ako je element $a_{11}^{(1)} \neq 0$, onda redom, možemo

- ▶ od i -te jednačbe oduzeti
- ▶ prvu jednačbu pomnoženu s

$$m_{i1} = \frac{a_{i1}^{(1)}}{a_{11}^{(1)}}, \quad i = 2, \dots, n.$$

Pritom se prva (tzv. “ključna”) jednačba ne mijenja.

Gaussove eliminacije — algoritam (nastavak)

Prva jednađba — kao **redak** proširene matrice $[A^{(1)} \mid b^{(1)}]$, je

$$a_{i1}^{(1)} \quad a_{i2}^{(1)} \quad \cdots \quad a_{in}^{(1)} \quad \Big| \quad b_i^{(1)} \quad .$$

Polazna i -ta jednađba — pisana na isti nađin, za $i = 2, \dots, n$,

$$a_{i1}^{(1)} \quad a_{i2}^{(1)} \quad \cdots \quad a_{in}^{(1)} \quad \Big| \quad b_i^{(1)} \quad .$$

Nova i -ta jednađba — pisana na isti nađin, za $i = 2, \dots, n$,

$$a_{i1}^{(2)} \quad a_{i2}^{(2)} \quad \cdots \quad a_{in}^{(2)} \quad \Big| \quad b_i^{(2)} \quad .$$

Relacije za **nove** elemente su

$$a_{ij}^{(2)} = a_{ij}^{(1)} - m_{i1} a_{1j}^{(1)}, \quad b_i^{(2)} = b_i^{(1)} - m_{i1} b_1^{(1)},$$

za $j = 1, \dots, n$, $i = 2, \dots, n$. **Prvi** redak ($i = 1$) ostaje **isti**.

Gaussove eliminacije — algoritam (nastavak)

Iz ovih relacija za **nove** elemente (prepisane još jednom)

$$a_{ij}^{(2)} = a_{ij}^{(1)} - m_{i1}a_{1j}^{(1)}, \quad b_i^{(2)} = b_i^{(1)} - m_{i1}b_1^{(1)},$$

vidimo da su **multiplikatori**

$$m_{i1} = \frac{a_{i1}^{(1)}}{a_{11}^{(1)}}, \quad i = 2, \dots, n.$$

odabrani upravo tako da je $a_{i1}^{(2)} = 0$, za $i = 2, \dots, n$.

Dakle, nakon **prvog** koraka dobivamo proširenu matricu $[A^{(2)} \mid b^{(2)}]$ u kojoj

- ▶ **prvi stupac** ima **nule** (strogo) **ispod** dijagonale, tj. **gornju** trokutastu formu.

Gaussove eliminacije — algoritam (nastavak)

Time smo dobili **ekvivalentni** linearni sustav $A^{(2)}x = b^{(2)}$ s **proširenom** matricom

$$\left[\begin{array}{cccc|c} a_{11}^{(1)} & a_{12}^{(1)} & \cdots & a_{1n}^{(1)} & b_1^{(1)} \\ 0 & a_{22}^{(2)} & \cdots & a_{2n}^{(2)} & b_2^{(2)} \\ \vdots & \vdots & \cdots & \vdots & \vdots \\ 0 & a_{n2}^{(2)} & \cdots & a_{nn}^{(2)} & b_n^{(2)} \end{array} \right].$$

Postupak **poništanja** možemo nastaviti s **drugim** stupcem matrice $A^{(2)}$ — na isti način.

Ako je $a_{22}^{(2)} \neq 0$, biramo faktore m_{i2} tako da **poništimo** sve elemente **drugog** stupca **ispod** dijagonale. I tako redom.

Gaussove eliminacije — algoritam (nastavak)

Općenito, k -ti korak izgleda ovako, za $k = 1, \dots, n - 1$:

- ▶ iz proširene matrice $[A^{(k)} \mid b^{(k)}]$ dobivamo novu proširenu matricu $[A^{(k+1)} \mid b^{(k+1)}]$,
- ▶ tako da **poništimo** sve elemente strogo **ispod** dijagonale u k -tom **stupcu** matrice $A^{(k)}$, koristeći “ključni” k -ti redak.

Relacije za **nove** elemente koje treba **izračunati** u matrici $A^{(k+1)}$ i vektoru $b^{(k+1)}$ su

$$a_{ij}^{(k+1)} = a_{ij}^{(k)} - m_{ik} a_{kj}^{(k)}, \quad b_i^{(k+1)} = b_i^{(k)} - m_{ik} b_k^{(k)},$$

za $i, j = k + 1, \dots, n$. Iz $a_{ik}^{(k+1)} = 0$, **multiplikatori** m_{ik} su

$$m_{ik} = \frac{a_{ik}^{(k)}}{a_{kk}^{(k)}}, \quad i = k + 1, \dots, n.$$

Gaussove eliminacije — algoritam (nastavak)

Prvih k redaka u $[A^{(k+1)} \mid b^{(k+1)}]$ ostaju isti kao u $[A^{(k)} \mid b^{(k)}]$.

Konačno, ako su svi $a_{ii}^{(i)} \neq 0$, za $i = 1, \dots, n-1$ (ne treba n), završni linearni sustav $[A^{(n)} \mid b^{(n)}]$, ekvivalentan polaznom, je

$$\left[\begin{array}{cccc|c} a_{11}^{(1)} & a_{12}^{(1)} & \cdots & a_{1n}^{(1)} & b_1^{(1)} \\ & a_{22}^{(2)} & \cdots & a_{2n}^{(2)} & b_2^{(2)} \\ & & \ddots & \vdots & \vdots \\ & & & a_{nn}^{(n)} & b_n^{(n)} \end{array} \right].$$

Dobili smo gornju trokutastu matricu $U = A^{(n)}$ (nule u strogo donjem trokutu matrice U ne pišemo).

Gaussove eliminacije — algoritam (nastavak)

Uz pretpostavku da je $a_{nn}^{(n)} \neq 0$, ovaj se linearni sustav lako rješava tzv. **povratnom supstitucijom** (supstitucijom unatrag)

$$x_n = \frac{b_n^{(n)}}{a_{nn}^{(n)}},$$

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

Pitanje: Ako je A kvadratna i **regularna** matrica,

- ▶ moraju li **svi** elementi $a_{ii}^{(i)}$ biti **različiti** od **nule**?

To je **nužno** (i **dovoljno**) da algoritam “**prođe**” u **ovom** obliku.

Gaussove eliminacije — primjedba na algoritam

Odgovor: Ne!

Primjer. Linearni sustav $Ax = b$, s proširenom matricom

$$[A | b] = \left[\begin{array}{cc|c} 0 & 1 & 1 \\ 1 & 0 & 1 \end{array} \right],$$

je **regularan** ($\det A = -1$), sustav ima **jedinstveno** rješenje $x_1 = x_2 = 1$,

- ▶ a ipak ga **ne možemo** riješiti Gausovim eliminacijama,
- ▶ ako **ne mijenjamo poredak** jednažbi.

Zaključak: Moramo dozvoliti **promjenu poretka** jednažbi.