

# Numerička matematika

## 3. predavanje

Saša Singer i Nela Bosner

PMF - Matematički odsjek, Zagreb

# Sadržaj predavanja

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

## Rješavanje linearnih sustava

### Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

# Gaussove eliminacije s pivotiranjem

**Pitanje:** Dozvolimo li **promjene poretka** jednadžbi — tzv. “**pivotiranje**” u **stupcu** kojeg poništavamo,

- ▶ **može** li se Gausovim eliminacijama s **pivotiranjem** riješiti **svaki** sustav kojemu je matrica **A** kvadratna i **regularna**?

**Odgovor:** Ako dozvolimo **pivotiranje** u svakom koraku,

- ▶ zamjenom “**ključne**” jednadžbe i **bilo koje** druge koja ima **ne-nula** element (u tom **stupcu**, **ispod** dijagonale),
- ▶ Gausovim eliminacijama **rješiv** je **svaki regularni** kvadratni linearni sustav.

**Objašnjenje:** Ako u **prvom** stupcu **ne postoji ne-nula** element, matrica je **singularna**. Isto vrijedi i za **svaki** sljedeći **korak** = stupac ispod dijag. (Dokaz: Laplaceov razvoj determinante!)

# Gaussove eliminacije — kako pivotiramo?

**Pitanje:** Kako vršiti **pivotiranje**, tj. **zamjene** jednažbi?

- ▶ Zamjenom “**ključne**” jednažbe i **bilo koje** druge koja ima **ne-nula** element (u tom **stupcu**, **ispod** dijagonale)?

**Odgovor:** Tu je **ključna** razlika između **egzaktog** i **približnog** računanja (kad imamo greške zaokruživanja).

- ▶ U **teoriji** — kod **egzaktog** računanja, **dovoljno** je naći **bilo koji ne-nula** element (u tom stupcu, ispod dijag.).
- ▶ U **praksi** — kad računamo **približno**, to **može** dovesti do potpuno **pogrešnog** rezultata.

**Jedna** jedina operacija može **upropastiti** rezultat!

- ▶ Postoji i **puno bolja** strategija za **pivotiranje**, kojom se to (barem dijelom) može **izbjeći**.

# Gaussove eliminacije — primjer

**Primjer.** Zadan je linearni sustav

$$0.0001 x_1 + x_2 = 1$$

$$x_1 + x_2 = 2.$$

Matrica sustava je regularna, pa postoji jedinstveno rješenje

$$x_1 = \frac{10000}{9999} = 1.000\dot{1}, \quad x_2 = \frac{9998}{9999} = 0.\dot{9}99\dot{8}.$$

Riješimo taj sustav “**računalom**” u bazi 10 — s 4 značajne znamenke **mantise** i 2 znamenke eksponenta (ovo nije bitno).

**Uočiti:** Broj  $0.0001 = 10^{-4}$  je “**mali**”, ali **nije nula**. Po teoriji,  
▶ možemo ga uzeti kao **prvi** (ili bilo koji) **ne-nula** element.

## Gaussove eliminacije — primjer (nastavak)

U takvom “računalu”, sustav se pamti **bez greške**, kao

$$1.000 \cdot 10^{-4} x_1 + 1.000 \cdot 10^0 x_2 = 1.000 \cdot 10^0$$

$$1.000 \cdot 10^0 x_1 + 1.000 \cdot 10^0 x_2 = 2.000 \cdot 10^0.$$

Množenjem prve jednadžbe s  $-10^4$  i dodavanjem drugoj, dobivamo **novu drugu** jednadžbu

$$(1.000 \cdot 10^0 - 1.000 \cdot 10^4) x_2 = 2.000 \cdot 10^0 - 1.000 \cdot 10^4.$$

**Oduzimanje** u računalu se vrši tako da manji eksponent postane jednak većem, a mantisa se denormalizira. Dobivamo

$$\begin{aligned} 1.000 \cdot 10^0 &= 0.100 \cdot 10^1 = 0.010 \cdot 10^2 = 0.001 \cdot 10^3 \\ &= 0.000|1 \cdot 10^4. \end{aligned}$$



## Gaussove eliminacije — primjer (nastavak)

Za zadnju **jedinicu nema mjesta** u mantisi, pa je mantisa postala **0**, tj. **prvi** broj “nema” utjecaja na rezultat. Slično se dogodi i s **desnom** stranom (i **2** je “zanemariv” prema  $10^4$ ).

Dakle, **nova druga** jednačba glasi

$$-1.000 \cdot 10^4 x_2 = -1.000 \cdot 10^4.$$

Rješenje ove jednačbe je očito  $x_2 = 1.000 \cdot 10^0$ . Uvrštavanjem u **prvu** jednačbu, dobivamo

$$\begin{aligned} 1.000 \cdot 10^{-4} x_1 &= 1.000 \cdot 10^0 - 1.000 \cdot 10^0 \cdot 1.000 \cdot 10^0 \\ &= 0.000 \cdot 10^0, \end{aligned}$$

pa je  $x_1 = 0$ , što **nije ni približno točan rezultat**.

# Gaussove eliminacije — primjer (nastavak)

Razlog za **ogromnu** relativnu grešku (100%):

- ▶ **prvu** jednadžbu množimo **velikim** brojem  $-10^4$  (po apsolutnoj vrijednosti) i **dodajemo drugoj**,
- ▶ što “**uništava**” **drugu** jednadžbu.

Drugim riječima, utjecaj **polazne druge** jednadžbe

- ▶ postaje **zanemariv** u **novoj drugoj** jednadžbi.

U **polaznoj drugoj** je moglo pisati “**bilo što**” (dovoljno **malo**)!

**Isto** bi nam se dogodilo za **bilo koju drugu** jednadžbu oblika

$$x_1 + \alpha x_2 = \beta,$$

gdje su  $|\alpha|, |\beta| < 5$ . (Za ovo “računalo” je  $u = 5 \cdot 10^{-4}$ .)

# Gaussove eliminacije s pivotiranjem — primjer

Promijenimo li poredak jednadžbi, dobivamo

$$1.000 \cdot 10^0 x_1 + 1.000 \cdot 10^0 x_2 = 2.000 \cdot 10^0$$

$$1.000 \cdot 10^{-4} x_1 + 1.000 \cdot 10^0 x_2 = 1.000 \cdot 10^0.$$

Množenjem prve jednadžbe s  $-10^{-4}$  i dodavanjem drugoj, dobivamo novu drugu jednadžbu

$$(1.000 \cdot 10^0 - 1.000 \cdot 10^{-4}) x_2 = 1.000 \cdot 10^0 - 2.000 \cdot 10^{-4}.$$

Ovdje nema oduzimanja — drugi broj s  $10^{-4}$  je “zanemariv” prema 1, na obje strane. Dakle, nova druga jednadžba sad glasi

$$1.000 \cdot 10^0 x_2 = 1.000 \cdot 10^0.$$

# Gaussove eliminacije s pivotiranjem — primjer

Ponovno dobivamo rješenje  $x_2 = 1.000 \cdot 10^0$ . Međutim, uvrštavanjem u **prvu** jednadžbu dobivamo

$$\begin{aligned} 1.000 \cdot 10^0 x_1 &= 2.000 \cdot 10^0 - 1.000 \cdot 10^0 \cdot 1.000 \cdot 10^0 \\ &= 1.000 \cdot 10^0, \end{aligned}$$

pa je  $x_1 = 1.000 \cdot 10^0$ , što je **točan** rezultat — **korektno zaokruženo** egzaktno rješenje na četiri decimalne znamenke!

**Razlog** za **vrlo malu** relativnu grešku:

- ▶ **prvu** jednadžbu sad množimo **malim** brojem  $-10^{-4}$  (po apsolutnoj vrijednosti) i **dodajemo drugoj**,
- ▶ što **nema utjecaja** na **drugu** jednadžbu — tj. ovdje **nema** “**uništavanja**” jednadžbi.

# Gaussove eliminacije s pivotiranjem — primjer

Kao i ranije, u **koraku** eliminacije,

- ▶ (bivša) **druga** jednadžba **nema utjecaja** na (bivšu) **prvu**.

Međutim, nakon **zamjene**

- ▶ **prva** jednadžba (bivša **druga**) ostaje **netaknuta** u prvom koraku eliminacije i uredno **utječe** na rješenje.

**Zaključak:** Sigurno **nije dovoljno** uzeti

- ▶ **prvi** (bilo koji) **ne-nula** element u **stupcu**

kao **ključni** element za eliminacije,

- ▶ jer možemo dobiti **potpuno pogrešan** rezultat.

# Gaussove eliminacije s pivotiranjem — primjer

**Primjer.** Usporedimo izračunata rješenja sustava

$$\varepsilon x_1 + x_2 = 1$$

$$x_1 + x_2 = 2,$$

za  $\varepsilon = 10^{-4}, \dots, 10^{-25}$ , Gaussovima eliminacijama **bez** zamjena i **sa zamjenom** poretka jednažbi, u aritmetici **računala**.

Računanjem u **najvećoj** dostupnoj preciznosti = tip **extended** ( $u \approx 5.42 \cdot 10^{-20}$ ), dobivamo tablicu na sljedećoj stranici.

Za  $x_1$  — **crvene** znamenke su **pogrešne**, **ljubičaste** su korektne kad ih **zaokružimo**, a **zelene** su **točne**. Za  $x_2$  — obje metode daju **iste** (i **točne**) vrijednosti, pa je naveden samo **jednom**.

U prvom stupcu pišu samo **eksponenti**  $p$ , pri čemu je  $\varepsilon = 10^p$ .

# Gaussove eliminacije s pivotiranjem — primjer

$p$	$x_1$ bez pivotiranja	$x_1$ s pivotiranjem	$x_2$
-4	1.00010001000100000	1.00010001000100010	0.99989998999899990
-5	1.00001000010000200	1.00001000010000100	0.99998999989999900
-6	1.000001000000999609	1.00000100000100000	0.99999899999900000
-7	1.00000009999978538	1.00000010000001000	0.99999989999990000
⋮	⋮	⋮	
-17	0.99746599868666408	1.00000000000000001	0.99999999999999999
-18	0.97578195523695399	1.00000000000000000	1.00000000000000000
-19	1.08420217248550443	1.00000000000000000	1.00000000000000000
-20	0.00000000000000000	1.00000000000000000	1.00000000000000000
⋮	isto	isto	isto

# Gaussove eliminacije s parcijalnim pivotiranjem

**Standardni** naziv: **pivotni** element = element koji se **prije**  $k$ -tog koraka eliminacije dovodi na **dijagonalno** mjesto  $a_{kk}^{(k)}$ .

U praksi se obično bira korištenjem **parcijalnog pivotiranja**.

- ▶ U  $k$ -tom koraku, **pivotni** element je **po apsolutnoj vrijednosti najveći** u “ostatku”  $k$ -tog **stupca** — na glavnoj dijagonali ili **ispod** nje.

Preciznije, ako je u  $k$ -tom koraku

$$|a_{rk}^{(k)}| = \max_{k \leq i \leq n} |a_{ik}^{(k)}|,$$

onda ćemo **prvo zamijeniti**  $r$ -ti i  $k$ -ti **redak**, a zatim početi korak eliminacije elemenata  $k$ -tog stupca.



# Gaussove eliminacije s parcijalnim pivotiranjem

**Motivacija:** Elementi “ostatka” linearnog sustava, koje treba izračunati u matrici  $A^{(k+1)}$  u  $k$ -tom koraku transformacije, 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  $i, j = k + 1, \dots, n$ , a multiplikatori  $m_{ik}$  su

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

Ako je multiplikator  $m_{ik}$  **velik**, u aritmetici računala može doći do **kraćenja** ili **gubitka** najmanje značajnih znamenki  $a_{ij}^{(k)}$ , tako da izračunati  $a_{ij}^{(k+1)}$  može imati **veliku** relativnu grešku, ili bitno **narasti** → **gubitak** informacija iz originalne jednačbe.

# Gaussove eliminacije s parcijalnim pivotiranjem

Sasvim općenito, ideja pivotiranja je **minimizirati** “korekcije” **elemenata** pri prijelazu s  $A^{(k)}$  na  $A^{(k+1)}$ . Dakle,

- ▶ multiplikatori  $m_{ik}$  trebaju biti **što manji**, po apsolutnoj vrijednosti.

Ekvivalentno, **pivotni** element treba biti **što veći**, jer ulazi u **nazivnik** multiplikatora.

Za multiplikatore kod **parcijalnog pivotiranja** vrijedi

$$|m_{ik}| \leq 1, \quad i = k + 1, \dots, n.$$

U praksi, parcijalno pivotiranje **funkcionira izvrsno**, ali matematičari su konstruirali primjere kad ono “**nije savršeno**” (v. kasnije).

# Gaussove eliminacije s potpunim pivotiranjem

Osim parcijalnog, može se provoditi i **potpuno pivotiranje**.

- ▶ U  $k$ -tom koraku, bira se **najveći** element u **cijelom "ostatku"** matrice  $A^{(k)}$ , a ne samo u  $k$ -tom stupcu.

Ako je u  $k$ -tom koraku

$$|a_{rs}^{(k)}| = \max_{k \leq i, j \leq n} |a_{ij}^{(k)}|,$$

onda ćemo **prvo zamijeniti**  $r$ -ti i  $k$ -ti **redak**,  $s$ -ti i  $k$ -ti **stupac**, a zatim početi korak eliminacije elemenata  $k$ -tog stupca.

**Opres:** zamjenom  $s$ -tog i  $k$ -tog **stupca zamijenili** smo ulogu nepoznanica (varijabli)  $x_s$  i  $x_k$ .

Ovo **nisu jedine** mogućnosti pivotiranja kod rješavanja linearnih sustava.

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

**GE s parcijalnim pivotiranjem — algoritam i složenost**

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

# Algoritam

## Gaussove eliminacije s parcijalnim pivotiranjem

```
/* Trokutasta redukcija */  
za k = 1 do n - 1 radi {  
  /* Nađi maks. |element| u ostatku stupca */  
  max_elt = |A[k, k]|;  
  ind_max = k;  
  za i = k + 1 do n radi {  
    ako je |A[i, k]| > max_elt onda {  
      max_elt = |A[i, k]|;  
      ind_max = i;  
    }  
  }  
}
```

## Algoritam (nastavak)

```
ako je max_elt > 0.0 onda {  
    /* Matrica ima ne-nula element u stupcu */  
    ako je ind_max <> k onda {  
        /* Zamijeni k-ti i ind_max-ti redak */  
        za j = k do n radi {  
            temp = A[ind_max, j];  
            A[ind_max, j] = A[k, j];  
            A[k, j] = temp;  
        }  
        temp = b[ind_max];  
        b[ind_max] = b[k];  
        b[k] = temp;  
    }  
}
```

## Algoritam (nastavak)

```
/* Korak Gaussovih eliminacija */  
za i = k + 1 do n radi {  
    /* Izračunaj multiplikator */  
    mult = A[i, k] / A[k, k];  
    /* Ažuriraj i-ti redak */  
    za j = k + 1 do n radi {  
        A[i, j] = A[i, j] - mult * A[k, j];  
    }  
    b[i] = b[i] - mult * b[k];  
}  
inače  
    /* Matrica je singularna, STOP */  
}
```

## Algoritam (nastavak)

```
/* Povratna supstitucija */  
ako je  $A[n, n] \neq 0.0$  onda {  
  /* Rješenje x */  
   $x[n] = b[n] / A[n, n];$   
  za  $i = n - 1$  do 1 radi {  
     $sum = b[i];$   
    za  $j = i + 1$  do  $n$  radi {  
       $sum = sum - A[i, j] * x[j];$   
    }  
     $x[i] = sum / A[i, i];$   
  }  
}  
inače  
  /* Matrica je singularna, STOP */
```



# Složenost algoritma

Prebrojimo sve **aritmetičke operacije** ovog algoritma.

U **prvom** koraku **trokutaste redukcije** obavlja se:

- ▶  $n - 1$  dijeljenje — računanje `mult`,
- ▶  $n(n - 1)$  množenje — **za svaki** od  $n - 1$  redaka imamo:
  - ▶  $n - 1$  množenje za računanje elemenata matrice  $A$ ;
  - ▶ **jedno** množenje za računanje elementa vektora  $b$ ,
- ▶  $n(n - 1)$  oduzimanje — u istoj naredbi gdje i prethodna množenja.

Na sličan način zaključujemo da se u  $k$ -tom koraku obavlja:

- ▶  $n - k$  dijeljenja,
- ▶  $(n - k + 1)(n - k)$  množenja i  $(n - k + 1)(n - k)$  oduzimanja.

## Složenost algoritma (nastavak)

Ukupan broj aritmetičkih operacija u  $k$ -tom koraku je

$$n - k + 2(n - k + 1)(n - k) = 2(n - k)^2 + 3(n - k).$$

Broj koraka  $k$  varira od 1 do  $n - 1$ , pa je **ukupan** broj operacija potrebnih za svođenje na **trokutastu formu** jednak

$$\begin{aligned} \sum_{k=1}^{n-1} [2(n - k)^2 + 3(n - k)] &= \sum_{k=1}^{n-1} (2k^2 + 3k) \\ &= \frac{1}{6}(4n^3 + 3n^2 - 7n). \end{aligned}$$

Druga suma se dobije iz prve zamjenom indeksa  $n - k \mapsto k$  (granice za sumu ostaju iste). Onda iskoristimo formule za sumu i sumu kvadrata prvih  $n - 1$  prirodnih brojeva.

## Složenost algoritma (nastavak)

Potpuno istim zaključivanjem dobivamo da u **povratnoj supstituciji** ima:

- ▶  $(n - 1) n/2$  množenja i  $(n - 1) n/2$  zbrajanja,
- ▶  $n$  dijeljenja,

što je, zajedno, tačno  $n^2$  operacija.

Dakle, **ukupan broj** operacija u **Gaussovima eliminacijama** je

$$OP(n) = \frac{1}{6}(4n^3 + 9n^2 - 7n),$$

što je približno  $2n^3/3$ , za malo veće  $n$ .

# Gaussove eliminacije — komentari

Par završnih komentara, nakon detaljnog opisa metode.

Gaussove eliminacije su metoda direktnog transformiranja linearnog sustava  $Ax = b$ , zajedno s desnom stranom  $b$ .

Možemo ih implementirati i tako da se desna strana  $b$  ne transformira istovremeno kad i matrica  $A$ .

- ▶ Tada se formiraju dvije matrice  $L$  i  $U$  takve da je  $A = LU$ , gdje je  $U$  gornja trokutasta matrica iz Gaussovih eliminacija, a  $L$  je donja trokutasta matrica.
- ▶ Tako implementirane Gaussove eliminacije zovemo LU faktorizacija matrice  $A$  — standard u praksi.
- ▶ Ovaj pristup je posebno zgodan kad imamo više desnih strana za isti  $A$ .

## Gaussove eliminacije — komentari (nastavak)

U praksi se koriste za “opće”, ali ne pretjerano velike matrice ( $n$  u tisućama), ili za sustave s tzv. “vrpčastom” strukturom.

**Složenost:** Polinomna i to kubna, tj.  $O(n^3)$ , što je sporo za još veće sustave. Za njih se koriste iterativne metode.

Mnogi sustavi imaju specijalna svojstva koja koristimo za brže i/ili točnije rješenje. Na primjer,

- ▶ za simetrične, pozitivno definitne matrice koristi se “simetrična” LU faktorizacija, tzv. faktorizacija Choleskog,
- ▶ za dijagonalno dominantne sustave ne treba pivotiranje,
- ▶ za vrpčaste, posebno, trodijagonalne matrice, algoritam se drastično skraćuje (v. kubična spline interpolacija).

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

### **LU faktorizacija**

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

# LU faktorizacija

U praksi se linearni sustavi najčešće rješavaju korištenjem **LU faktorizacije** — matricu  $A$  faktoriziramo kao produkt matrica

$$A = LU,$$

pri čemu je

- ▶  $L$  donja trokutasta matrica s jedinicama na dijagonali,
- ▶  $U$  gornja trokutasta matrica.

Nazivi: “LR” = (left, right), “LU” = (lower, upper).

Matrica  $L$  je regularna, jer je  $\det L = 1$ . Onda je regularnost matrice  $A$  ekvivalentna regularnosti matrice  $U$ , jer vrijedi

$$\det A = \det L \cdot \det U = \det U.$$

# LU faktorizacija — rješenje sustava

Ako znamo LU faktorizaciju od  $A$ , onda linearni sustav  $Ax = b$  postaje

$$LUx = b.$$

Uz oznaku  $y = Ux$ , sustav  $LUx = b$  svodi se na dva sustava

$$Ly = b, \quad Ux = y.$$

Lako pamćenje: matrice u sustavima idu slijeva  $\mapsto$  udesno.

Prednost LU faktorizacije:

- ▶ za zadani  $b$ , rješavaju se dva jednostavna sustava,
- ▶ desna strana  $b$  ne transformira se istovremeno s matricom  $A$ , pa promjena desne strane košta samo  $O(n^2)$  operacija.



# LU faktorizacija — rješenje sustava (nastavak)

Oba sustava se lako rješavaju:

- ▶ prvi  $Ly = b$  — supstitucijom unaprijed

$$y_1 = b_1,$$

$$y_i = b_i - \sum_{j=1}^{i-1} \ell_{ij} y_j, \quad i = 2, \dots, n,$$

- ▶ drugi  $Ux = y$  — povratnom supstitucijom (unatrag)

$$x_n = \frac{y_n}{u_{nn}},$$

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

# LU faktorizacija — nalaženje

Kako izračunati elemente  $\ell_{ij}$  i  $u_{ij}$  matrica  $L$  i  $U$ ?

- ▶ Iskoristimo **poznatu strukturu** matrica  $L$  i  $U$
- ▶ i činjenicu da je  $A = L \cdot U$ .

Dobivamo:

$$a_{ij} = \sum_{k=1}^{\min\{i,j\}} \ell_{ik} u_{kj}, \quad \text{uz } \ell_{ii} = 1.$$

Iz ovih  $n^2$  jednažbi računamo, **redom**, one elemente matrica  $L$  i  $U$  koje **možemo** izračunati iz već **poznatih** elemenata.

- ▶ Za  $i = 1$ , zbog  $\ell_{11} = 1$ , dobivamo **prvi** redak matrice  $U$ .
- ▶ Zatim, za  $j = 1$ , dobivamo **prvi** stupac matrice  $L$ , jer znamo  $u_{11}$ .
- ▶ I tako **redom**,  $i = 2, j = 2, \dots, i = n$  (**bez**  $j = n$ ).

## LU faktorizacija — nalaženje (nastavak)

Tako dobivamo **rekurzivne** relacije za elemente matrica  $L$  i  $U$

$$u_{1j} = a_{1j}, \quad j = 1, \dots, n,$$

$$l_{j1} = \frac{a_{j1}}{u_{11}}, \quad j = 2, \dots, n,$$

za  $i = 2, \dots, n$ :

$$u_{ij} = a_{ij} - \sum_{k=1}^{i-1} l_{ik} u_{kj}, \quad j = i, \dots, n,$$

$$l_{ji} = \frac{1}{u_{ii}} \left( a_{ji} - \sum_{k=1}^{i-1} l_{jk} u_{ki} \right), \quad j = i+1, \dots, n.$$

U **zadnjem** koraku, za  $i = n$ , računamo **samo**  $u_{nn}$  (nema  $l$ -ova).

## LU faktorizacija — nalaženje (nastavak)

**Napomena.** Ako je  $u_{ij} \neq 0$ , za  $i = 1, \dots, n - 1$  (bez  $n$ ), onda iz prethodnih relacija možemo

- ▶ izračunati **sve netrivialne** elemente matrica  $L$  i  $U$ .

Drugim riječima,

- ▶ imamo **egzistenciju** i **jedinstvenost** matrica  $L$  i  $U$ .


Primijetite da  $u_{nn} \neq 0$  treba samo za **povratnu** supstituciju.

**Pitanje:** Kojim se **redom** računaju elementi od  $L$  i  $U$ ?

- ▶ Može **točno** prema prethodnim relacijama (v. slikice), ali
- ▶ **neke** elemente smijemo računati i **kasnije** — za efikasno korištenje tzv. **cache** memorije (granice i poredak petlji).


# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :



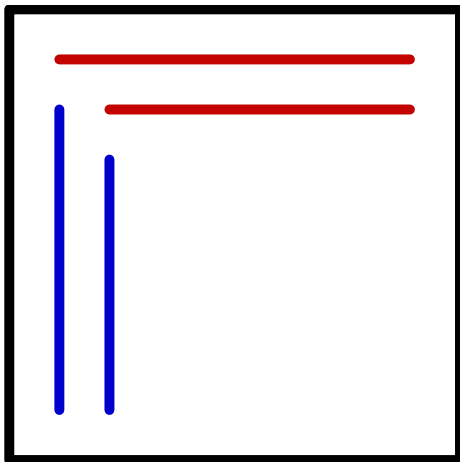
# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :



# LU faktorizacija — poredak nalaženja


Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :






# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :



# LU faktorizacija — poredak nalaženja


Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :






# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — **plavo** za  $L$  i **crveno** za  $U$ :




# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :



# LU faktorizacija — poredak nalaženja

Poredak računanja elemenata — plavo za  $L$  i crveno za  $U$ :



# LU faktorizacija — spremanje elemenata

Uobičajeno se LU faktorizacija matrice  $A$  izvodi tako da se njezina “radna kopija” = neko polje u memoriji računala,

- ▶ koje, na početku, sadrži matricu  $A$ ,
- ▶ postupno uništava i prepisuje elementima matrica  $L$  i  $U$

na sljedeći način:

- ▶ elementi matrice  $U$  spremaju se u gornjem trokutu i na dijagonali,
- ▶ elementi matrice  $L$  spremaju se u donjem trokutu, s tim da se dijagonala matrice  $L$  ne sprema (znamo da su 1).

Redosljed spremanja — kao na prošlim slikama, ili drugačije (ovisno o granicama i poretku petlji).

## Digresija — “Matlab” oznake za podmatrice

Ostaje još vidjeti uz koje **uvjete** na matricu  $A$  vrijedi  $u_{ij} \neq 0$ , za  $i = 1, \dots, n - 1$ .

Za iskaz teorema, korisno je uvesti tzv. **Matlab** oznake za one **podmatrice** matrice  $A$ , koje se dobivaju na **presjeku** redaka i stupaca, s indeksima u zadanim **rasponima** (oblika “od : do”).

- ▶  $A(i : j, k : \ell)$  = podmatrica od  $A$  na **presjeku** redaka, od  $i$ -tog do  $j$ -tog, i stupaca, od  $k$ -tog do  $\ell$ -tog.  
Tip ove podmatrice je  $(j - i + 1) \times (\ell - k + 1)$ .
- ▶ Ako za raspon napišemo **samo** “ : ”, podrazumijevaju se **svi** dozvoljeni indeksi, od prvog do zadnjeg iz  $A$ .

Definiramo još i **apsolutnu** vrijednost matrice  $A$ , u oznaci  $|A|$ . To je **matrica** istog tipa kao i  $A$ , čiji elementi su **apsolutne** vrijednosti elemenata od  $A$ , tj.  $(|A|)_{ij} = |a_{ij}|$ , za sve  $i, j$ .

## Digresija — Blok–matrice i operacije

Za skraćeni zapis, matricu  $A$  možemo podijeliti na **blokove** ili **podmatrice** — vodoravnim i okomitim “crtama”, kao na slici

$$A = \left[ \begin{array}{c|c|c|c} A_{11} & A_{12} & \cdots & A_{1q} \\ \hline A_{21} & A_{22} & \cdots & A_{2q} \\ \hline \vdots & \vdots & \cdots & \vdots \\ \hline A_{p1} & A_{p2} & \cdots & A_{pq} \end{array} \right],$$

gdje su  $A_{ij}$ , općenito, **pravokutne** matrice.

Kad imamo dvije matrice  $A$  i  $B$ , podijeljene u blokove, onda se matrice operacije  $+$  i  $\cdot$  “**po blokovima**” rade **isto** kao i **po elementima**, uz **uvjet** da su operacije **korektno definirane** za pripadne blokove, tj. da ti blokovi imaju odgovarajući **tip**.

## Digresija — Blok–matrice i operacije (nastavak)

**Primjer.** Neka su  $A$  i  $B$  kvadratne matrice reda  $n$ , s **istom** podjelom na blokove, tj. blokovi  $A_{ij}$  i  $B_{ij}$  su **istog tipa**,

$$A = \begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix}, \quad B = \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix}.$$

Ako u produktu  $C = A \cdot B$  napravimo **istu** podjelu na blokove, onda za blokove  $C_{ij}$  vrijedi **ista** formula kao i “po elementima”

$$C_{ij} = \sum_{k=1}^2 A_{ik} \cdot B_{kj}, \quad i, j = 1, 2.$$

**Napomena.** Ovo koristimo u dokazu teorema. Dodatno, kad je blok  $A_{11}$  reda  $n - 1$ , onda blok  $A_{12}$  pišemo kao **vektor** ( $v$ ), blok  $A_{21}$  kao **transponirani vektor** ( $w^T$ ), a “blok”  $A_{22}$  je **skalar**  $a_{nn}$ .

# Egzistencija i jedinstvenost LU faktorizacije

**Teorem.** Postoji **jedinstvena** LU faktorizacija matrice  $A$  **ako i samo ako** su vodeće glavne podmatrice  $A_k := A(1 : k, 1 : k)$  **regularne**, za  $k = 1, \dots, n - 1$ .

Ako je  $A_k$  **singularna** za neki  $k$ , faktorizacija **može postojati**, ali onda sigurno **nije jedinstvena** (v. primjere na kraju dokaza).

**Dokaz.** Za **prvi smjer**, pretpostavimo da su sve podmatrice  $A_k$  **regularne**, za  $k = 1, \dots, n - 1$ . Konstrukcija LU faktorizacije za  $A = A_n$  napreduje induktivno po dimenziji  $k$ .

**Baza indukcije:** Za  $k = 1$ , **uvijek** postoji jedinstvena LU faktorizacija

$$A_1 = [1] [a_{11}].$$



# Egzistencija i jedinstvenost LU faktorizacije

**Korak indukcije:** Pretpostavimo da je  $k > 1$  i da podmatrica  $A_{k-1}$  ima jedinstvenu LU faktorizaciju  $A_{k-1} = L_{k-1} U_{k-1}$ .

Tražimo LU faktorizaciju podmatrice  $A_k$ , gdje je

$$A_k = \begin{bmatrix} A_{k-1} & b \\ c^T & a_{kk} \end{bmatrix} = \begin{bmatrix} L_{k-1} & 0 \\ \ell^T & 1 \end{bmatrix} \begin{bmatrix} U_{k-1} & u \\ 0 & u_{kk} \end{bmatrix} := L_k U_k.$$

Množenjem dobivamo da moraju vrijediti sljedeće jednadžbe

$$L_{k-1}u = b, \quad U_{k-1}^T \ell = c, \quad a_{kk} = \ell^T u + u_{kk}.$$

Matrice  $L_{k-1}$  i  $U_{k-1}$  su regularne, pa postoje **jedinstvena rješenja** prva dva sustava — vektori  $u$ ,  $\ell$ . Iz zadnje jednadžbe dobivamo da je onda i  $u_{kk}$  **jedinstven**. Dakle, vrijedi i za  $A_k$ .

# Egzistencija i jedinstvenost LU faktorizacije

**Obrat.** Pretpostavimo da matrica  $A$  ima jedinstvenu LU faktorizaciju  $A = LU$  i označimo

$$L_k := L(1 : k, 1 : k), \quad U_k := U(1 : k, 1 : k), \quad k = 1, \dots, n.$$

Onda je, raspisom kao na prethodnoj stranici, za  $k = n$

$$A = \begin{bmatrix} A_{n-1} & b \\ c^T & a_{nn} \end{bmatrix} = \begin{bmatrix} L_{n-1} & 0 \\ \ell^T & 1 \end{bmatrix} \begin{bmatrix} U_{n-1} & u \\ 0 & u_{nn} \end{bmatrix} := LU.$$

Množenjem dobivamo da onda vrijede sljedeće četiri jednačbe

$$\begin{aligned} A_{n-1} &= L_{n-1} U_{n-1}, & L_{n-1} u &= b, & a_{nn} &= \ell^T u + u_{nn}. \\ U_{n-1}^T \ell &= c, & & & & \end{aligned}$$

Sad iskoristimo **jedinstvenost** matrica  $L$  i  $U$  u faktorizaciji.

# Egzistencija i jedinstvenost LU faktorizacije

To znači da **vektor**  $\ell$  mora biti **jedinstveno** rješenje sustava

$$U_{n-1}^T \ell = c,$$

pa matrica  $U_{n-1}$  mora biti **regularna**, tj. vrijedi

$$\det U_{n-1} = u_{11} u_{22} \cdots u_{n-1,n-1} \neq 0.$$

Iz strukture matrica  $L$  i  $U$  (rastavom unatrag) vidimo da je  $A_k = L_k U_k$ , za **sve**  $k = 1, \dots, n-1$ , pa je  $\det A_k = \det U_k$ . Iz regularnosti  $U_{n-1}$  onda slijedi

$$\det A_k = \det U_k = u_{11} u_{22} \cdots u_{kk} \neq 0, \quad k = 1, \dots, n-1.$$

Dakle, **sve** podmatrice  $A_k$  su **regularne**, za  $k = 1, \dots, n-1$ .  
Samo **zadnja** matrica  $A_n = A$  može biti **singularna** ( $u_{nn} = 0$ ).

# Egzistencija i jedinstvenost LU faktorizacije

Primjer singularne matrice  $A$  za koju postoji LU faktorizacija, ali nije jedinstvena:

$$A = \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix} = \begin{bmatrix} 1 & 0 \\ l_{21} & 1 \end{bmatrix} \begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix}.$$

Ovdje je  $A_1 = U_1 = 0$ , sustav za  $l_{21}$  je  $0 \cdot l_{21} = 0$  (u skladu s prethodnim dokazom), pa element  $l_{21}$  može biti bilo što.

S druge strane, matrica

$$A = \begin{bmatrix} 0 & 1 \\ 1 & 1 \end{bmatrix}$$

nema LU faktorizaciju, iako je regularna (fali pivotiranje). Sustav za  $l_{21}$  ovdje glasi  $0 \cdot l_{21} = 1$  i nema rješenja.



## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

**Gaussove eliminacije i LU faktorizacija**

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

# Veza Gaussovih eliminacija i LU faktorizacije

Može se pokazati da je

- ▶ matrica  $U$  dobivena LU faktorizacijom **jednaka**
- ▶ matrici  $U$  dobivenoj **Gausovim** eliminacijama.

Neka je, kao ranije,

- ▶  $A^{(k)}$  matrica na **početku**  $k$ -tog koraka **Gausovih** eliminacija,
- ▶ a  $A^{(k+1)}$  matrica dobivena na **kraju** tog koraka.

Onda se  $A^{(k+1)}$  može **matrično** napisati kao produkt

$$A^{(k+1)} = M_k A^{(k)},$$

pri čemu matrica “transformacije”  $M_k$  ima sljedeći oblik . . .

# Veza Gaussovih eliminacija i LU faktorizacije

$$M_k = \left[ \begin{array}{c|cccc} I_{k-1} & & & & \\ \hline & 1 & & & \\ & -m_{k+1,k} & 1 & & \\ & -m_{k+2,k} & & \ddots & \\ & \vdots & & & \ddots & \\ & -m_{n,k} & & & & 1 \end{array} \right].$$

Matrica  $I_{k-1}$  je **jedinična** matrica reda  $k-1$ , a  $m_{ik}$  su odgovarajući **multiplikatori** u  $k$ -tom koraku eliminacija.

Na **kraju** eliminacija, nakon  $n-1$  koraka, dobijemo **gornju trokutastu** matricu

$$\tilde{U} := A^{(n)} = M_{n-1} M_{n-2} \cdots M_1 A.$$

# Veza Gaussovih eliminacija i LU faktorizacije

Sve matrice  $M_k$  su **regularne**, jer su  $M_k$  **donje trokutaste** s 1 na dijagonali, pa postoje njihovi **inverzi**. Onda se  $A$  može napisati kao

$$A = M_1^{-1} M_2^{-1} \cdots M_{n-1}^{-1} \tilde{U} := \tilde{L}\tilde{U},$$

gdje  $M_k^{-1}$  ima **istu strukturu** kao  $M_k$ , jedino što se u  $k$ -tom stupcu ispod dijagonale nalaze multiplikatori  $m_{ik}$ , pa je zbog toga

$$\tilde{L} = \begin{bmatrix} 1 & & & & \\ m_{21} & 1 & & & \\ \vdots & m_{32} & \ddots & & \\ \vdots & \vdots & & \ddots & \\ m_{n1} & m_{n2} & \cdots & m_{n,n-1} & 1 \end{bmatrix}.$$

Iz **jedinstvenosti** LU faktorizacije slijedi da je  $\tilde{U} = U$ . Usput, slijedi i  $\tilde{L} = L$ , pa imamo vezu matrice  $L$  s multiplikatorima.



# Parcijalno pivotiranje u LU faktorizaciji

Veza LU faktorizacije i Gaussovih eliminacija upućuje nas da pivotiranje vršimo na isti način kao kod Gaussovih eliminacija.

Ako koristimo parcijalno pivotiranje, onda se LU faktorizacija tako dobivene matrice — permutiranih redaka, zapisuje kao

$$PA = LU,$$

pri čemu je  $P$  matrica permutacije.

Matrica permutacije  $P$  u svakom retku i stupcu

- ▶ ima točno jednu jedinicu, a ostalo su nule.

$P$  je uvijek regularna matrica, čak ortogonalna — pokažite to!  
Zato  $P$  ima inverz i vrijedi  $P^{-1} = P^T$ .

## Parcijalno pivotiranje u LU faktORIZACIJI

Ako znamo “permutiranu” faktORIZACIJU  $PA = LU$ , kako ćemo riješiti linearni sustav  $Ax = b$ ?

Najjednostavnije je lijevu i desnu stranu (slijeva) pomnožiti s  $P$ , pa dobivamo

$$PAx = LUx = Pb.$$

Dakle, u prvom koraku rješavamo sustav  $Ly = Pb$ .

**Oprez:** kad permutiramo, istovremeno zamjenjujemo retke

- ▶ u obje “radne matrice” u polju — to su  $(L - I)$  u strogom donjem trokutu i  $U$  u gornjem trokutu,

tj. permutiramo dosadašnje multiplikatore i jednadžbe.

Kako realiziramo permutacije u algoritmu?

# Parcijalno pivotiranje u LU faktorizaciji

## Realizacija permutacija:

- ▶ Fizički zamjenjujemo retke u radnoj matrici  $A$ , u kojoj formiramo  $L$  i  $U$ ,
  - ▶  $L - I$  u strogo donjem trokutu od  $A$ ,
  - ▶  $U$  u gornjem trokutu od  $A$ .
- ▶ Moramo pamtiti permutaciju  $P$ , zbog naknadne permutacije desne strane — vektora  $b$ .
- ▶ Matrica  $P$  se pamti kao vektor  $p$ , koji na mjestu  $i$  ima
  - ▶ indeks stupca  $j$ , gdje se nalazi jedinica u  $i$ -tom retku od  $P$ , tj.

$$p[i] = j \iff P_{ij} = 1.$$

Za velike matrice — može i bez zamjena redaka, dovoljan je vektor  $p$ .

# Parcijalno pivotiranje u LU faktORIZACIJI

**Primjer.** Ako u LU faktORIZACIJI sustava s 3 jednađbe

- ▶ **prvo** zamijenimo **prvi** i **treći** redak,
- ▶ pa onda **trenutni drugi** i **treći** redak,

onda će se matrica  $P$ , odnosno, vektor  $p$  mijenjati ovako:

$$P: \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{bmatrix} \rightarrow \begin{bmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{bmatrix} \rightarrow \begin{bmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix},$$

$$p: \begin{bmatrix} 1 \\ 2 \\ 3 \end{bmatrix} \rightarrow \begin{bmatrix} 3 \\ 2 \\ 1 \end{bmatrix} \rightarrow \begin{bmatrix} 3 \\ 1 \\ 2 \end{bmatrix}.$$

# Potpuno pivotiranje u LU faktORIZACIJI

Ako koristimo **potpuno pivotiranje**, dobivamo **LU** faktORIZACIJU matrice koja ima permutirane **retke** i **stupce** obzirom na **A**, tj.

$$PAQ = LU,$$

gdje su **P** i **Q** matrice permutacije (**P** za **retke**, **Q** za **stupce**).

**Rješenje** sustava  $Ax = b$  dobivamo kao i prije — iz  $PAx = Pb$ .

**Q** je ortogonalna, pa je  $PA = LUQ^T$ . Uz pokratu  $Q^T x = z$ , imamo

$$PAx = LU(Q^T x) = LUz = Pb.$$

Dakle, jedina **razlika** obzirom na **parcijalno pivotiranje** je:

- ▶ na **kraju** treba “**izokretati**” rješenje **z**, da se dobije **x**, tj.  $x = Qz$ .

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

**Rezultati obratne analize grešaka zaokruživanja**

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

# Obratna ocjena za LU faktorizaciju

**Teorem** (v. Higham, ASNA3). U aritmetici računala računamo LU faktorizaciju zadane matrice  $A$ , reda  $n$ . Pretpostavimo da je algoritam uspješno završio,

- ▶ bez pojave prevelikih ili premalih brojeva koji nisu prikazivi,
- ▶ i bez pokušaja dijeljenja s nulom.

Izračunati trokutasti faktori  $\hat{L}$  i  $\hat{U}$  onda zadovoljavaju

$$\hat{L}\hat{U} = A + \Delta A, \quad |\Delta A| \leq \gamma_n |\hat{L}| |\hat{U}|,$$

gdje je  $\gamma_n$  standardna oznaka za mjeru grešaka zaokruživanja

$$\gamma_n := \frac{nu}{1 - nu}.$$



# Obratna ocjena za rješenje sustava

**Teorem** (v. Higham, ASNA3). U aritmetici računala računamo rješenje linearnog sustava  $Ax = b$ , s matricom  $A$ , reda  $n$ .

Uz iste pretpostavke kao u prošlom teoremu, neka su

- ▶  $\hat{L}$  i  $\hat{U}$  izračunati trokutasti faktori u LU faktorizaciji matrice  $A$ ,
- ▶ i neka je  $\hat{x}$  izračunato rješenje sustava  $Ax = b$ .

Onda postoji perturbacija  $\Delta A$  matrice  $A$ , za koju vrijedi

$$(A + \Delta A)\hat{x} = b, \quad |\Delta A| \leq \gamma_{3n} |\hat{L}| |\hat{U}|.$$

Za zaključak o relativnoj grešci, fali nam još

- ▶ neka veza između matrica  $|\hat{L}| |\hat{U}|$  i  $|A|$ .



# Put do relativnih ocjena

U **idealnom** slučaju, **željeli** bismo da je

$$|\Delta A| \leq u |A|.$$

To bi odgovaralo **grešci zaokruživanja** koju napravimo samo

- ▶ početnim **spremanjem** elemenata matrice  $A$  u memoriju računala.

No, to **nije realistično**. Nad **svakim** elementom matrice  $A$

- ▶ vrši se još **najviše**  $n$  aritmetičkih operacija (za  $A = LU$ ).

Zato **ne možemo** očekivati nešto **bolje** od ocjene oblika

$$|\Delta A| \leq c_n u |A|,$$

gdje je  $c_n$  “konstanta” **reda veličine**  $n$ , odnosno,  $c_n u \approx c \gamma_n$ .

## Relativne ocjene — idealni slučaj

Na primjer, takvu ocjenu **dobivamo** pod uvjetom da  $\hat{L}$  i  $\hat{U}$  zadovoljavaju da je

$$|\hat{L}| |\hat{U}| = |\hat{L}\hat{U}|.$$

To je **idealni** slučaj — i, naravno, **ne vrijedi** uvijek.

Ako to **vrijedi**, onda iz **prvog** teorema izlazi

$$|\hat{L}| |\hat{U}| = |\hat{L}\hat{U}| = |A + \Delta A| \leq |A| + |\Delta A| \leq |A| + \gamma_n |\hat{L}| |\hat{U}|,$$

pa, prebacivanjem članova dobivamo

$$|\hat{L}| |\hat{U}| \leq \frac{1}{1 - \gamma_n} |A|.$$

## Relativne ocjene — idealni slučaj (nastavak)

Ako tu relaciju uvrstimo u **drugi** teorem, onda izlazi

$$(A + \Delta A) \hat{x} = b, \quad |\Delta A| \leq \frac{\gamma_{3n}}{1 - \gamma_n} |A|,$$

tj. **izračunato** rješenje  $\hat{x}$  ima

- ▶ **malu** obratnu **relativnu** grešku po **komponentama**.

Za koje matrice **vrijedi** “idealno”  $|\hat{L}| |\hat{U}| = |\hat{L}\hat{U}|$ ?

Na primjer, ako **LU** faktorizacija daje **nenegativne** elemente u faktorima  $L$  i  $U$ , tj. vrijedi  $L, U \geq 0$  (po elementima).

- ▶ Takve su tzv. **totalno nenegativne** ili **totalno pozitivne** matrice — i zato se kod njih **ne pivotira** u GE ili LU.

Javljaju se, na primjer, kod **splajn interpolacije** (v. kasnije).

# Što je bitno za stabilnost?

Iz prethodna dva teorema slijedi da stabilnost LU faktorizacije i rješenja linearnog sustava

- ▶ ne ovisi o veličini multiplikatora,
- ▶ već o veličini elemenata koji se javljaju u matrici  $|\hat{L}| |\hat{U}|$ , relativno obzirom na odgovarajuće elemente matrice  $A$  (toliko kraćenje može nastati računanjem  $\hat{L}\hat{U} \approx A$ ).

Naime, ta matrica  $|\hat{L}| |\hat{U}|$

- ▶ može imati male elemente, iako su joj multiplikatori  $m_{ij} = \ell_{ij}$  veliki — pripadni elementi u  $\hat{U}$  su jako mali,
- ▶ ali može imati i velike elemente, a da su joj multiplikatori reda veličine 1 — pripadni elementi u  $\hat{U}$  su veliki.

# Analiza i procjena stabilnosti algoritma

Za **lakšu** (ali **grublju**) analizu, ne gleda se po **svim** elementima, već se analizira omjer **normi**

$$\frac{\| |\hat{L}| |\hat{U}| \|}{\|A\|}.$$

**Bitno:** Ovaj omjer **ovisi** o **algoritmu** kojim računamo **LU** faktorizaciju matrice **A**!

Kod **LU** faktorizacije **bez pivotiranja**, ovaj omjer **normi** može biti **proizvoljno velik**. Na primjer, pokažite da je za matricu

$$\begin{bmatrix} \varepsilon & 1 \\ 1 & 1 \end{bmatrix}$$

taj omjer jednak  $\varepsilon^{-1}$ .

Dakle, kod **parcijalnog** pivotiranja

- ▶ **L** je **malen**, i želimo naći kako je **U** **ograden relativno** obzirom na **A**.

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

### **Pivotni rast**

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

Rezidual

# Parcijalno vs. potpuno pivotiranje

Možemo li, i na temelju čega, reći da je **potpuno** pivotiranje “**bolje**” od **parcijalnog**?

- ▶ Tradicionalno, to se čini na temelju tzv. **pivotnog rasta**.

**Pivotni rast** ili “**faktor rasta**”, u oznaci  $\rho_n$ , je **omjer**

- ▶ **najvećeg** (po apsolutnoj vrijednosti) elementa u **svim** koracima eliminacije — **ovisi** o pivotiranju,
- ▶ i (apsolutno) **najvećeg** elementa u **originalnoj** matrici  $A$ ,

$$\rho_n(A) = \frac{\max_{i,j,k} |a_{ij}^{(k)}|}{\max_{i,j} |a_{ij}|}.$$

Intuitivno je jasno da **nije dobro** da elementi **jako narastu** po apsolutnoj vrijednosti, jer to može dovesti do **gubitka točnosti**. To je analogno “**uništavanju**” polaznih jednadžbi!

## Pivotni rast — parcijalno pivotiranje

Koliki je **pivotni rast**  $\rho_n^{(p)}$  kod **parcijalnog** pivotiranja? Znamo da vrijedi

$$|\ell_{ij}| = \begin{cases} 0, & i < j \\ 1, & i = j \\ |m_{ij}|, & i > j \end{cases} \leq 1 \quad \text{za sve } i \geq j.$$

**Transformacije elemenata** u  $k$ -tom koraku eliminacija su

$$a_{ij}^{(k+1)} = a_{ij}^{(k)} - m_{ik} a_{kj}^{(k)}.$$

Kad to uvrstimo  $|m_{ik}| \leq 1$  u formule **transformacije** elemenata dobivamo

$$|a_{ij}^{(k+1)}| \leq |a_{ij}^{(k)}| + 1 \cdot |a_{kj}^{(k)}| \leq 2 \max_{\ell \leq i} |a_{\ell j}^{(k)}|.$$



# Pivotni rast — parcijalno pivotiranje

Indukcijom po koracima eliminacije, dobivamo da vrijedi

$$|a_{ij}^{(k+1)}| \leq 2^k \max_{\ell \leq i} |(PA)_{\ell j}| \leq 2^k \max_{i,j} |a_{ij}|,$$

Nakon svih  $n - 1$  koraka algoritma, ova ocjena daje **pivotni rast**

$$\rho_n^{(p)}$$

$$\rho_n^{(p)} \leq 2^{n-1}.$$

Za za matricu  $U$  možemo zaključiti

$$|u_{ij}| \leq 2^{i-1} \max_{\ell \leq i} |(PA)_{\ell j}| \leq 2^{i-1} \max_{i,j} |a_{ij}| \leq \rho_n^{(p)} \max_{i,j} |a_{ij}|,$$

jer element  $u_{ij}$  nastaje nakon  $i - 1$  koraka eliminacije.

## Pivotni rast — parcijalno pivotiranje (nastavak)

Već je J. H. Wilkinson primijetio da se taj pivotni rast može dostići za sve matrice oblika

$$\begin{bmatrix} 1 & & & & 1 \\ -1 & 1 & & & 1 \\ -1 & -1 & \ddots & & 1 \\ -1 & -1 & \ddots & 1 & 1 \\ -1 & -1 & -1 & -1 & 1 \end{bmatrix}.$$

Eksponencijalno rastu elementi zadnjeg stupca (s faktorom 2).

Ovo je samo “umjetno” konstruirani primjer, a u praksi je takvih matrica izrazito malo, pa se parcijalno pivotiranje ponaša mnogo bolje od očekivanog. Obično je  $\rho_n^{(p)}(A) \ll 2^{n-1}$ .

# Pivotni rast — potpuno pivotiranje

Za pivotni rast  $\rho_n^{(c)}$  kod **potpunog** pivotiranja, J. H. Wilkinson je 1961. godine dokazao da vrijedi sljedeća **ocjena odozgo**

$$\rho_n^{(c)} \leq n^{1/2} \left( 2 \cdot 3^{1/2} \dots n^{1/(n-1)} \right)^{1/2} \approx c n^{1/2} n^{(\ln n)/4}$$

i da se ta ocjena **ne može** dostići.

Dugo se mislilo da vrijedi

$$\rho_n^{(c)} \leq n.$$

Međutim, **nađeni** su kontraprimjeri matrica kad to **ne vrijedi**.

- ▶ 1991. g. — matrica reda **13** za koju je  $\rho_{13}^{(c)} = 13.0205$ ,
- ▶ 1992. g. — matrica reda **25** za koju je  $\rho_{25}^{(c)} = 32.986341$ .

Točno ponašanje  $\rho_n^{(c)}$  je **otvoren** problem!

# Ocjena stabilnosti preko faktora rasta

Tradicionalno, **obratna** analiza greške izražava se preko **pivotnog rasta** ili **faktora rasta** (engl. growth factor)  $\rho_n$ . U procesu **Gaussovih** eliminacija, očito vrijedi da je

$$|u_{ij}| = |a_{ij}^{(i)}| \leq \rho_n \max_{i,j} |a_{ij}|.$$

što daje ogradu za  $U$ , **relativno** obzirom na  $A$ . Naravno, faktor rasta  $\rho_n$  ovisi o **algoritmu** kojim računamo matricu  $U$ .

Može se naći i precizna ocjena odzgo za **omjer normi**

$$\frac{\|\hat{L}\|\|\hat{U}\|}{\|A\|}$$

preko **faktora rasta**, i obratno (ovisi o algoritmu i izabranoj normi).

# Obratna ocjena za sustav preko faktora rasta

**Teorem** (Wilkinson, v. Higham, ASNA3).

Neka je  $A$  **regularna** kvadratna matrica reda  $n$  i neka je  $\hat{x}$  **izračunato rješenje** sustava  $Ax = b$

- ▶ **Gausovim eliminacijama** s **parcijalnim** pivotiranjem u aritmetici **računala**.

Tada vrijedi

$$(A + \Delta A)\hat{x} = b, \quad \|\Delta A\|_{\infty} \leq n^2 \gamma_{3n} \rho_n^{(p)} \|A\|_{\infty}.$$

**Slično** vrijedi i za **Gaussove** eliminacije **bez** pivotiranja, samo s malo drugačijim oblikom **faktora** ispred  $\|A\|_{\infty}$ .

Naravno, u tom slučaju **faktor rasta**  $\rho_n$  može biti **puno veći**!

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

**Perturbacije linearnih sustava i uvjetovanost matrice**

Hilbertove matrice

Rezidual

# Teorija perturbacije linearnih sustava

Teorija perturbacije linearnih sustava bavi se **ocjenom** (po **elementima** i/ili po **normi**) koliko se **najviše** promijeni rješenje sustava  $x$ , ako se **malo** promijene elementi od  $A$  i/ili  $b$ .

**Problem.** Neka je

$$Ax = b,$$

gdje je  $A \in \mathcal{F}^{n \times n}$  regularna matrica, a  $b$  zadani vektor.

Zanima nas koliko će se **najviše** promijeniti rješenje  $x$  ovog problema, ako **perturbiramo**  $A$ , odnosno,  $b$ . Za ovaj problem

- ▶ **ulazni podaci** su elementi od  $A$  i  $b$  — njih  $n^2 + n$ ,
- ▶ a **rezultat** je vektor  $x \in \mathcal{F}^n$ .

U **općem** obliku problema, ulaznih podataka je **puno**.

# Koliko je dobro uvjetovan linearni sustav?

Zato, pojednostavnimo problem i pretpostavimo da je

- ▶  $A$  “fiksna” matrica (ne varira),
- ▶ a dozvoljene su perturbacije samo vektora  $b$  (on varira).

Pripadna funkcija problema je onda  $f_A : \mathcal{F}^n \rightarrow \mathcal{F}^n$ , uz

$$x = f_A(b) := A^{-1}b.$$

Iskoristimo ranije rezultate — samo, umjesto  $x, y$ , pišemo  $b, x$ .

U grubljoj analizi gledamo relativne perturbacije “po normi”, a relativna uvjetovanost problema je

$$\kappa_{f_A}(b) := \frac{\|b\|}{\|f_A(b)\|} \cdot \left\| \frac{\partial f_A}{\partial b} \right\|.$$



# Koliko je dobro uvjetovan linearni sustav?

Funkcija problema  $f_A(b) = A^{-1}b$  je **linearna**, pa je **Jacobijeva matrica** te funkcije

$$\frac{\partial x}{\partial b} = \frac{\partial f_A}{\partial b} = J_{f_A}(b) = A^{-1}.$$

Onda je

$$\kappa_{f_A}(b) = \frac{\|b\| \cdot \|A^{-1}\|}{\|A^{-1}b\|} = \frac{\|Ax\| \cdot \|A^{-1}\|}{\|x\|}.$$

Nađimo **najgoru** moguću relativnu uvjetovanost sustava, po **svim** vektorima  $b$  — u bilo kojoj **operatorskoj** normi  $\|\cdot\|$ :

$$\max_{\substack{b \in \mathcal{F}^n \\ b \neq 0}} \kappa_{f_A}(b) = \max_{\substack{x \in \mathcal{F}^n \\ x \neq 0}} \frac{\|Ax\|}{\|x\|} \cdot \|A^{-1}\| = \|A\| \cdot \|A^{-1}\|.$$

# Uvjetovanost matrice

Dobili smo broj koji ovisi **samo** o matrici  $A$ .

**Definicija.** Broj uvjetovanosti ili **uvjetovanost** matrice  $A$  je

$$\kappa(A) := \|A\| \cdot \|A^{-1}\|.$$

U ovoj definiciji, norma može biti **bilo koja** matrična norma, a najčešće se koriste **operatorske** norme.

**Oznaka** norme = uvjetovanost dobije **indeks** norme. Na pr.

$$\kappa_2(A) := \|A\|_2 \cdot \|A^{-1}\|_2.$$

**Napomena.** Kao mjera uvjetovanosti **linearnog sustava**, uvjetovanost matrice je **dostižna** u **operatorskim** normama, tj.

- ▶ **postoji** desna strana  $b$  za koju je

$$\kappa_{f_A}(b) = \kappa(A).$$

# Osnovna svojstva uvjetovanosti matrice

Za regularne matrice, u bilo kojoj **operatorskoj** normi vrijedi

$$1 = \|I\| = \|A \cdot A^{-1}\| \leq \|A\| \cdot \|A^{-1}\| = \kappa(A).$$

Zato kažemo da je **A loše** uvjetovana ako je  $\kappa(A) \gg 1$ .

Posebno, u **unitarno** invarijantnoj **2-normi** vrijedi

$$1 \leq \|A\|_2 \cdot \|A^{-1}\|_2 = \kappa_2(A),$$

a jednakost se **dostiže** za **unitarne** matrice **A** i za  $\alpha A$ .

Dodatno, za bilo koje dvije **unitarne** matrice **U** i **V** vrijedi

$$\kappa_2(UAV) = \kappa_2(A),$$

jer su inverzi  $U^{-1} = U^*$  i  $V^{-1} = V^*$ , opet, **unitarne** matrice.

# Još malo o perturbacijama linearnih sustava

Ocjenu koliko se **najviše** promijenilo rješenje sustava  $Ax = b$ ,

- ▶ ako **perturbiramo samo  $b$**  ili **samo  $A$** ,
- ▶ ako **perturbiramo i  $A$  i  $b$** ,

možemo dobiti **direktno** — po **normi** i po **elementima**.

U nastavku, gledamo samo **relativne** perturbacije po **normi**.

Razumna **pretpostavka**: perturbacije  $\Delta b$  vektora  $b$ , odnosno,  $\Delta A$  matrice  $A$ , su relativno, po normi, **odozgo** ograđene nekim brojem  $\varepsilon$ , tj. vrijedi

$$\|\Delta b\| \leq \varepsilon \|b\|, \quad \|\Delta A\| \leq \varepsilon \|A\|.$$

**Komentar**. Obratna analiza algoritma za rješavanje sustava daje nam procjenu za  $\varepsilon$ , kao npr. **Wilkinsonov teorem** za Gussove eliminacije sa parcijalnim pivotiranjem.

## Perturbacija vektora $b$

Za početak, pretpostavimo da smo perturbirali **samo** vektor  $b$  i da za **vektorsku** normu **perturbacije** vektora  $b$  vrijedi

$$\|\Delta b\| \leq \varepsilon \|b\|.$$

Umjesto sustava  $Ax = b$ , onda rješavamo sustav

$$A(x + \Delta x) = b + \Delta b.$$

Od ovog sustava **oduzmemo**  $Ax = b$ , pa ostaje

$$A \Delta x = \Delta b.$$

**Množenjem** slijeva s  $A^{-1}$  dobivamo

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

Uzmemo normu obje strane i desnu stranu **ocijenimo** odozgo.

## Perturbacija vektora $b$ (nastavak)

Korištenjem pretpostavke  $\|\Delta b\| \leq \varepsilon \|b\|$ , dobivamo

$$\begin{aligned}\|\Delta x\| &\leq \|A^{-1}\| \|\Delta b\| \leq \varepsilon \|A^{-1}\| \|b\| = \varepsilon \|A^{-1}\| \|Ax\| \\ &\leq \varepsilon \|A^{-1}\| \|A\| \|x\| = \varepsilon \kappa(A) \|x\|,\end{aligned}$$

pri čemu je  $\kappa(A) = \|A\| \|A^{-1}\|$  **uvjetovanost** matrice  $A$ .

To pokazuje da je **pogreška** u rješenju (relativno, po normi)

- ▶ **proporcionalna uvjetovanosti** matrice  $A$ .

Korektno bi bilo dodati “**u najgorem slučaju** po  $b$ ”, jer imamo ocjenu **odozgo**, ali se ona može dostići.

Ovaj rezultat **odgovara ranijem** za **relativnu** uvjetovanost po normi — na temelju kojeg smo **definirali** uvjetovanost matrice.

# Perturbacija matrice $A$

Pretpostavimo da smo perturbirali **samo** matricu  $A$  (Wilkinson), i da za **operatorsku** normu **perturbacije** vrijedi

$$\|\Delta A\| \leq \varepsilon \|A\|.$$

Umjesto sustava  $Ax = b$ , onda rješavamo sustav

$$(A + \Delta A)(x + \Delta x) = b.$$

Od ovog sustava **oduzmemo**  $Ax = b$ , pa ostaje

$$A \Delta x + \Delta A(x + \Delta x) = 0.$$

**Množenjem** slijeva s  $A^{-1}$  i sređivanjem dobivamo

$$\Delta x = -A^{-1} \Delta A(x + \Delta x).$$

Uzmemo normu obje strane i desnu stranu **ocijenimo** odozgo.

# Perturbacija matrice $A$ (nastavak)

Korištenjem pretpostavke  $\|\Delta A\| \leq \varepsilon \|A\|$ , dobivamo

$$\begin{aligned}\|\Delta x\| &\leq \|A^{-1}\| \|\Delta A\| \|x + \Delta x\| \leq \varepsilon \|A^{-1}\| \|A\| \|x + \Delta x\| \\ &\leq \varepsilon \kappa(A) (\|x\| + \|\Delta x\|).\end{aligned}$$

Na lijevu stranu **prebacimo** sve članove koji sadrže  $\Delta x$ . Izlazi

$$(1 - \varepsilon \kappa(A)) \|\Delta x\| \leq \varepsilon \kappa(A) \|x\|.$$

**Ako** je  $\varepsilon \kappa(A) < 1$ , a to znači da je i  $\|\Delta A\| \|A^{-1}\| < 1$ , **onda** je

$$\|\Delta x\| \leq \frac{\varepsilon \kappa(A)}{1 - \varepsilon \kappa(A)} \|x\|,$$

pa je **pogreška** u rješenju (relativno, po normi)

- ▶ približno **proporcionalna uvjetovanosti** matrice  $A$ .



## Perturbacija matrice $A$ i vektora $b$

Kad **perturbiramo**  $A$  i  $b$  — **zbrojimo** ranije ocjene. Poopćenje:

**Teorem** (v. Higham, ASNA3). Neka je  $Ax = b$  i neka je

$$(A + \Delta A)(x + \Delta x) = b + \Delta b,$$

gdje je

$$\|\Delta A\| \leq \varepsilon \|E\|, \quad \|\Delta b\| \leq \varepsilon \|f\|,$$

pri čemu je  $E$  **neka** matrica, a  $f$  **neki** vektor. Također, neka je

$$\varepsilon \|A^{-1}\| \|E\| < 1.$$

Tada, za  $x \neq 0$ , vrijedi ocjena

$$\frac{\|\Delta x\|}{\|x\|} \leq \frac{\varepsilon}{1 - \varepsilon \|A^{-1}\| \|E\|} \left( \frac{\|A^{-1}\| \|f\|}{\|x\|} + \|A^{-1}\| \|E\| \right).$$

## Perturbacija matrice $A$ i vektora $b$ (nastavak)

**Komentar.** Uobičajeno se za  $E$  uzima  $A$ , jer je to **pogreška** koju napravimo spremanjem matrice  $A$  u računalo. Jednako tako, za  $f$  se obično uzima  $b$ . U tom slučaju je

$$\begin{aligned}\frac{\|\Delta x\|}{\|x\|} &\leq \frac{\varepsilon}{1 - \varepsilon \|A^{-1}\| \|A\|} \left( \frac{\|A^{-1}\| \|b\|}{\|x\|} + \|A^{-1}\| \|A\| \right) \\ &= \frac{\varepsilon}{1 - \varepsilon \kappa(A)} \left( \frac{\|A^{-1}\| \|Ax\|}{\|x\|} + \kappa(A) \right) \\ &\leq \frac{\varepsilon}{1 - \varepsilon \kappa(A)} \left( \frac{\|A^{-1}\| \|A\| \|x\|}{\|x\|} + \kappa(A) \right) \\ &= \frac{2\varepsilon \kappa(A)}{1 - \varepsilon \kappa(A)}.\end{aligned}$$

## Perturbacija matrice $A$ i vektora $b$ (nastavak)

**Dokaz** (skica). Provodi se na sličan način kao za pojedinačne perturbacije vektora  $b$ , odnosno, matrice  $A$ .

Od  $(A + \Delta A)(x + \Delta x) = b + \Delta b$  oduzmemo  $Ax = b$ , pa ostaje

$$A \Delta x = \Delta b - \Delta A x - \Delta A \Delta x.$$

Množenjem s  $A^{-1}$  slijeva, a zatim korištenjem svojstava operatorskih normi, s malo truda, izlazi traženo. ■

Malo kompliciranije, mogu se dobiti i ocjene za perturbacije po elementima. Na primjer, uz pretpostavke da je

$$|\Delta A| \leq \varepsilon |E|, \quad |\Delta b| \leq \varepsilon |f|,$$

gdje je  $E$  neka matrica, a  $f$  neki vektor (v. Higham, ASNA3).  
**Nejednakost** za matrice  $\Leftrightarrow$  vrijedi po elementima, za svaki.

# Komentar rezultata teorije perturbacija

Uočimo da sve ocjene vrijede

- ▶ samo za “dovoljno male” perturbacije matrice  $A$ .

U općem teoremu, za relativne perturbacije po normi, mora biti

$$\varepsilon \|A^{-1}\| \|E\| < 1, \quad \text{odnosno,} \quad \varepsilon \kappa(A) < 1.$$

Druga relacija se dobiva za  $E = A$ .

U protivnom, ocjena ne vrijedi (nazivnik nula ili krivi znak),

- ▶ tj. relativna greška (po normi) može biti po volji velika.

## Primjer — loša uvjetovanost

**Primjer.** Na prvom predavanju imali smo primjer sustava

$$\begin{aligned}2x_1 + 6x_2 &= 8 \\2x_1 + 6.0001x_2 &= 8.0001,\end{aligned}$$

s rješenjem  $x_1 = 1$ ,  $x_2 = 1$ , i **malo perturbiranog** sustava

$$\begin{aligned}2x_1 + 6x_2 &= 8 \\2x_1 + 5.99999x_2 &= 8.00002.\end{aligned}$$

s rješenjem  $x_1 = 10$ ,  $x_2 = -2$ .

Ovdje je  $\|\Delta A\|_2 < 10^{-4} \|A\|_2$  i  $\|\Delta b\|_2 < 10^{-4} \|b\|_2$ . Krivac za **veliku** perturbaciju u rješenju je **loša uvjetovanost** matrice  $A$

$$\kappa_2(A) \approx 4.00006 \cdot 10^5.$$

Zato je  $\|\Delta A\|_2 \|A^{-1}\|_2 > 1$ , pa ranija ocjena **ne vrijedi**.

## Primjer — uvjetovanost i izračunato rješenje

**Pitanje:** Ako je **uvjetovanost** matrice **mala**, mora li onda rješenje izračunato računalom biti **dobro**?

**Primjer.** Sjetimo se sustava  $Ax = b$ , gdje je

$$A = \begin{bmatrix} 0.0001 & 1 \\ 1 & 1 \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 2 \end{bmatrix}.$$

Na tom sustavu smo pokazali korisnost **zamjene** jednadžbi.

Za vježbu izračunajte da je

$$\kappa_2(A) = \frac{300000001 + 10001\sqrt{499980001}}{199980000} \approx 2.61839.$$

Dakle, ovo je **dobro** uvjetovan sustav.

## Primjer (nastavak)

Međutim, u Gaussovima eliminacijama **bez pivotiranja**,

- ▶ u prethodnom sustavu je nešto “**pošlo po zlu**”! Što?

Na **bitnom mjestu** u računu došlo je do “**underflow-a**”, tj.

- ▶ **mali** broj je pretvoren u **nulu**,

i više **ne možemo** govoriti o **malim relativnim** perturbacijama!

Za **razliku** od toga, s **parcijalnim** pivotiranjem

- ▶ **nije** bilo nikakvih problema — dobivamo **malu** grešku.

Dakle, ponašanje izračunatog rješenja **bitno** ovisi o **algoritmu**!

- ▶ **Gdje** se ta “razlika” **vidi**?

## Završni komentar — perturbacije i algoritmi

Uočite još da pivotiranje **ne mijenja** uvjetovanost matrice  $A$  (bar u 2-normi), jer je

$$\kappa_2(PAQ) = \kappa_2(A).$$

Ključna **razlika** između algoritama s **raznim** matricama  $P$  i  $Q$ :

- ▶ **različite**  $PAQ$  imaju **različite** faktore  $L, U$  u  $PAQ = LU$ .
- ▶ Zato **obratna** analiza grešaka zaokruživanja daje bitno **različite ocjene** na perturbacije za **razne** algoritme! (**Pivotni rast!**)

**Zadatak.** Izračunajte  $\kappa_2(A)$  i LU faktorizacije matrica  $PAQ$ , za **sve** moguće zamjene redaka  $P$  i zamjene stupaca  $Q$ , gdje je

$$A = \begin{bmatrix} \varepsilon & 1 \\ 1 & 1 \end{bmatrix}, \quad |\varepsilon| < 1.$$



## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

**Hilbertove matrice**

Rezidual

# Hilbertova matrica

**Primjer.** Kod aproksimacije polinomima (v. kasnije) javljaju se linearni sustavi oblika

$$H_n x = b,$$

gdje je  $H_n$  Hilbertova matrica reda  $n$ ,  $(H_n)_{ij} = \frac{1}{i+j-1}$ , ili

$$H_n = \begin{bmatrix} 1 & \frac{1}{2} & \cdots & \frac{1}{n} \\ \frac{1}{2} & \frac{1}{3} & \cdots & \frac{1}{n+1} \\ \vdots & \vdots & & \vdots \\ \frac{1}{n} & \frac{1}{n+1} & \cdots & \frac{1}{2n-1} \end{bmatrix}.$$

# Hilbertova matrica

Da bismo ispitali **točnost** rješenja, stavimo **desnu** stranu

$$b(i) := \sum_{j=1}^n H_n(i, j) = \sum_{j=1}^n \frac{1}{i+j-1}, \quad i = 1, \dots, n,$$

tako da je egzaktno **rješenje** sustava vektor  $x = [1, 1, \dots, 1]^T$ .

Što možemo očekivati kod **računanja** rješenja takvog sustava?

Pogled na **Frobeniusovu normu** matrice  $H_n$  kaže da ona **nije naročito velika**,

$$\|H_n\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n \left| \frac{1}{i+j-1} \right|^2} \leq \sqrt{\sum_{i=1}^n \sum_{j=1}^n 1} = n.$$

# Hilbertova matrica — uvjetovanost

Međutim ... ne treba gledati samo normu matrice!!!

Uvjetovanost Hilbertovih matrica je vrlo visoka:

$n$	$\kappa_2(H_n)$	$n$	$\kappa_2(H_n)$	$n$	$\kappa_2(H_n)$
2	$1.928 \cdot 10^1$	9	$4.932 \cdot 10^{11}$	15	$6.117 \cdot 10^{20}$
3	$5.241 \cdot 10^2$	10	$1.603 \cdot 10^{13}$	16	$2.022 \cdot 10^{22}$
4	$1.551 \cdot 10^4$	11	$5.231 \cdot 10^{14}$	17	$6.697 \cdot 10^{23}$
5	$4.766 \cdot 10^5$	12	$1.713 \cdot 10^{16}$	18	$2.221 \cdot 10^{25}$
6	$1.495 \cdot 10^7$	13	$5.628 \cdot 10^{17}$	19	$7.376 \cdot 10^{26}$
7	$4.754 \cdot 10^8$	14	$1.853 \cdot 10^{19}$	20	$2.452 \cdot 10^{28}$
8	$1.526 \cdot 10^{10}$				

# Hilbertova matrica — rješenje za $n = 2, 5$

Za sustav  $H_n x = b$  s Hilbertovom matricom, za razne  $n$ ,

► GE s parcijalnim pivotiranjem, u *extended* točnosti, dobivamo ove rezultate (umjesto svih jedinica u rješenju):

Red  $n = 2$

$$x(1) = 1.0000000000000000 \quad x(2) = 1.0000000000000000$$

Red  $n = 5$

$$\begin{aligned} x(1) &= 1.0000000000000000 & x(4) &= 0.9999999999999990 \\ x(2) &= 0.9999999999999999 & x(5) &= 1.0000000000000005 \\ x(3) &= 1.0000000000000007 \end{aligned}$$

Uvjetovanost:  $\approx 4.766 \cdot 10^5$ .

# Hilbertova matrica — rješenje za $n = 10$

$$x(1) = 1.0000000000003436$$

$$x(2) = 0.9999999999710395$$

$$x(3) = 1.0000000006068386$$

$$x(4) = 0.9999999945453735$$

$$x(5) = 1.0000000258066880$$

$$x(6) = 0.9999999294831902$$

$$x(7) = 1.0000001151701616$$

$$x(8) = 0.9999998890931838$$

$$x(9) = 1.0000000580638087$$

$$x(10) = 0.9999999872591526$$

Uvjetovanost:  $\approx 1.603 \cdot 10^{13}$ .

# Hilbertova matrica — rješenje za $n = 15$

$$x(1) = 1.0000000005406387$$

$$x(2) = 0.9999999069805858$$

$$x(3) = 1.0000039790948573$$

$$x(4) = 0.9999257525660447$$

$$x(5) = 1.0007543452271621$$

$$x(6) = 0.9953234190795597$$

$$x(7) = 1.0188643674562383$$

$$x(8) = 0.9487142544341838$$

$$x(9) = 1.0952919444304200$$

$$x(10) = 0.8797820363884070$$

$$x(11) = 1.0994671444236333$$

$$x(12) = 0.9508102511158300$$

$$x(13) = 1.0106027108940050$$

$$x(14) = 1.0012346841153261$$

$$x(15) = 0.9992252029377023$$

Uvjetovanost:  $\approx 6.117 \cdot 10^{20}$ .

# Hilbertova matrica — rješenje za $n = 20$

$x(1) =$	1.0000000486333029	$x(11) =$	231.3608002738048500
$x(2) =$	0.9999865995557111	$x(12) =$	-60.5143391625873562
$x(3) =$	1.0008720556363132	$x(13) =$	-57.6674972682886125
$x(4) =$	0.9760210562677670	$x(14) =$	5.1760567992057506
$x(5) =$	1.3512820600312678	$x(15) =$	8.7242780841976215
$x(6) =$	-2.0883247796748707	$x(16) =$	210.1722288687690970
$x(7) =$	18.4001541798146106	$x(17) =$	-413.9544667202651170
$x(8) =$	-63.8982130462650081	$x(18) =$	349.7671855031355400
$x(9) =$	161.8392478869777220	$x(19) =$	-142.9134532513063250
$x(10) =$	-254.7902985140752950	$x(20) =$	25.0584794423327874

Uvjetovanost  $\approx 2.452 \cdot 10^{28}$ .



# Uvjetovanost Hilbertovih matrica

Može se pokazati da za **uvjetovanost** Hilbertove matrice  $H_n$  vrijedi formula

$$\kappa_2(H_n) \approx \frac{(\sqrt{2} + 1)^{4n+4}}{2^{15/4} \sqrt{\pi n}}, \quad \text{za } n \rightarrow \infty.$$

Dakle, iako Hilbertove matrice imaju “**idealna**” svojstva,

- ▶ **simetrične**, **pozitivno definitne** (čak **totalno pozitivne** = determinanta **svake** kvadratne podmatrice je **pozitivna**), njihova uvjetovanost **katastrofalno brzo raste!**

“**Krivci**” za to su elementi **inverza**  $H_n^{-1}$ .

# Inverz Hilbertove matrice

Recimo,  $H_5^{-1}$  izgleda ovako:

$$H_5^{-1} = \begin{bmatrix} 25 & -300 & 1050 & -1400 & 630 \\ -300 & 4800 & -18900 & 26880 & -12600 \\ 1050 & -18900 & 79380 & -117600 & 56700 \\ -1400 & 26880 & -117600 & 179200 & -88200 \\ 630 & -12600 & 56700 & -88200 & 44100 \end{bmatrix}.$$

A kako tek izgledaju elementi  $H_{20}^{-1}$ ?

# Inverz Hilbertove matrice

Elementi inverza  $H_n^{-1}$  Hilbertove matrice mogu se eksplicitno izračunati u terminima binomnih koeficijenata

$$(H_n^{-1})_{ij} = (-1)^{i+j} (i+j-1) \cdot \binom{n+i-1}{n-j} \binom{n+j-1}{n-i} \binom{i+j-2}{i-1}^2.$$

Lako se vidi da ovi elementi vrlo brzo rastu za malo veće  $n$ .

Pogledajte

<http://mathworld.wolfram.com/HilbertMatrix.html>

## Rješavanje linearnih sustava

Gaussove eliminacije s pivotiranjem

GE s parcijalnim pivotiranjem — algoritam i složenost

LU faktorizacija

Gaussove eliminacije i LU faktorizacija

Rezultati obratne analize grešaka zaokruživanja

Pivotni rast

Perturbacije linearnih sustava i uvjetovanost matrice

Hilbertove matrice

**Rezidual**

# Rezidual približnog rješenja

- Kad rješenje sustava  $Ax = b$  računamo približno (računalom),
- ▶ umjesto pravog rješenja  $x$ , dobivamo približno rješenje  $\hat{x}$ .

Vektor

$$r = r(\hat{x}) = b - A\hat{x},$$

zovemo **rezidual** izračunatog rješenja  $\hat{x}$ .

**Napomena.** Egzaktni rezidual pravog rješenja  $x$  je  $r(x) = 0!$

Međutim, ako je (egzaktni) rezidual  $r = r(\hat{x})$

- ▶ **velik**, onda sigurno **nismo blizu** pravom rješenju,
- ▶ ali rezidual može biti **malen**, a da izračunato rješenje  $\hat{x}$  sustava nije **ni blizu** pravom rješenju  $x$ .

# Izračunati rezidual

**Primjer.** Gledamo **izračunato** rješenje  $\hat{x}$  linearnog sustava

$$H_{20}x = b$$

s desnom stranom  $b$ , takvom da je  $x = [1, 1, \dots, 1]^T$ .

Kad računamo u **extended** točnosti,

▶ **izračunati** rezidual  $\hat{r} = b - A\hat{x}$  je **nul-vektor** (kraćenje), a komponente rješenja  $\hat{x}$  su bile u **stotinama**.

Ovo ponašanje je u **skladu** s **teorijom perturbacija**, koja

- ▶ **garantira mali** rezidual  $r$ , za iole razumne perturbacije,
- ▶ a **izračunato rješenje**  $\hat{x}$  može biti **katastrofalno**, ako je **uvjetovanost** matrice  $A$  **velika**.

# Odnos reziduala i greške

Neka je  $\|\cdot\|$  oznaka za neku **vektorsku** i **operatorsku normu** induciranu danom vektorskom normom. Tada vrijedi

$$\begin{aligned}\frac{\|x - \hat{x}\|}{\|x\|} &= \frac{\|A^{-1}A(x - \hat{x})\|}{\|x\|} \stackrel{\text{konzistentnost}}{\leq} \|A^{-1}\| \frac{\|Ax - A\hat{x}\|}{\|x\|} \\ &= \|A^{-1}\| \frac{\|b - A\hat{x}\|}{\|x\|} \frac{\|A\|}{\|A\|} = \|A^{-1}\| \|A\| \frac{\|r(\hat{x})\|}{\|A\| \|x\|} \\ &\stackrel{\text{konzistentnost}}{\leq} \|A^{-1}\| \|A\| \frac{\|r(\hat{x})\|}{\|Ax\|} = \|A^{-1}\| \|A\| \frac{\|r(\hat{x})\|}{\|b\|}\end{aligned}$$

Možemo zaključiti

$$\frac{\|x - \hat{x}\|}{\|x\|} \leq \kappa(A) \frac{\|r(\hat{x})\|}{\|b\|}.$$