

Numerička matematika

4. predavanje

Saša Singer

singer@math.hr

web.math.hr/~singer

PMF – Matematički odsjek, Zagreb

Sadržaj predavanja

- Rješavanje linearnih sustava:
 - Hilbertove matrice.
 - Teorija perturbacije linearnih sustava (nastavak).
 - Uloga reziduala i iterativno poboljšanje rješenja.
 - Struktura LR (LU) faktorizacije.
 - Matrice za koje ne treba pivotiranje.
 - Simetrične pozitivno definitne matrice.
 - Faktorizacija Choleskog.
 - Pivotiranje u faktorizaciji Choleskog.
- Aproksimacija i interpolacija:
 - Uvod u problem aproksimacije (norme, linearnost).

Informacije

Moja web stranica za Numeričku matematiku je

http://web.math.hr/~singer/num_mat/

Tamo su kompletna predavanja od prošle četiri godine, a stizat će i nova (kako nastaju). Prva 2 su još nesređena — onako kako ste ih vidjeli!

Skraćena verzija skripte — 1. dio (prvih 7 tjedana):

http://web.math.hr/~singer/num_mat/num_mat1.pdf

Skraćena verzija skripte — 2. dio (drugih 6 tjedana):

http://web.math.hr/~singer/num_mat/num_mat2.pdf

Informacije — demonstratori

Kolegij “Numerička matematika” ima čak tri demonstratora:

- Mario Berljafa — termin: petak, 10–12, u Pr3, poželjna najava mailom,
- Anastasia Kruchinina — termin: ponedjeljak, 17–19, poželjna najava mailom,
- Melkior Ornik — termin: utorak, 16–18, sastanak pred oglasnom pločom, nužna najava mailom.

Demosi lijepo mole da im se najavite mailom koji dan ranije!

- Njihove mail adrese nađete na oglasnoj ploči,
- ili se javite meni.

Hilbertove matrice

Hilbertova matrica

Primjer. Kod aproksimacije polinomima javljaju se linearni sustavi oblika

$$H_n x = b,$$

gdje je H_n Hilbertova matrica reda n , tj. $(H_n)_{ij} = \frac{1}{i+j-1}$, 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 $x^T = [1, 1, \dots, 1]$.

Što možemo očekivati od rješenja takvog sustava?

Pogled na **Frobeniusovu normu** matrice A kaže da ona **nije naročito velika**, tj.

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

Hilbertova matrica

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 — $n = 2, 5$

Za sustav s Hilbertovom matricom, u **extended** točnosti, umjesto svih **jedinica** u rješenju, dobivamo:

Red 2

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

Red 5

$$x(1) = 1.0000000000000000 \quad x(4) = 0.99999999999999990$$

$$x(2) = 0.9999999999999999 \quad x(5) = 1.00000000000000005$$

$$x(3) = 1.00000000000000007$$

Hilbertova matrica — $n = 10$

$$x(1) = 1.0000000000000003436$$

$$x(6) = 0.9999999294831902$$

$$x(2) = 0.9999999999710395$$

$$x(7) = 1.0000001151701616$$

$$x(3) = 1.0000000006068386$$

$$x(8) = 0.9999998890931838$$

$$x(4) = 0.9999999945453735$$

$$x(9) = 1.0000000580638087$$

$$x(5) = 1.0000000258066880$$

$$x(10) = 0.9999999872591526$$

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

Hilbertova matrica — $n = 15$

$$x(1) = 1.00000000005406387 \quad x(9) = 1.0952919444304200$$

$$x(2) = 0.9999999069805858 \quad x(10) = 0.8797820363884070$$

$$x(3) = 1.0000039790948573 \quad x(11) = 1.0994671444236333$$

$$x(4) = 0.9999257525660447 \quad x(12) = 0.9508102511158300$$

$$x(5) = 1.0007543452271621 \quad x(13) = 1.0106027108940050$$

$$x(6) = 0.9953234190795597 \quad x(14) = 1.0012346841153261$$

$$x(7) = 1.0188643674562383 \quad x(15) = 0.9992252029377023$$

$$x(8) = 0.9487142544341838$$

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

Hilbertova matrica — $n = 20$

$x(1) =$	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>

Perturbacije linearnih sustava (nastavak)

Još malo o perturbacijama linearnih sustava

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

• ako perturbiramo **samo** A ili **samo** b ,

• ako perturbiramo **i** A **i** b ,

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

Pretpostavimo da smo perturbirali **samo** A . Umjesto sustava $Ax = b$, tada rješavamo sustav

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

Također, možemo pretpostaviti da za **operatorsku normu perturbacije** vrijedi

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

Komentar. Ako je ε točnost računanja, tolika perturbacija je **napravljena** već pri **spremanju** elemenata matrice u računalo.

Perturbacija matrice A

Oduzimanjem $Ax = b$ od $(A + \Delta A)(x + \Delta x) = b$ dobivamo

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

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

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

Uzimanjem norme lijeve i desne strane, a zatim **ocjenjivanjem odozgo**, dobivamo

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

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

Perturbacija matrice A

Premještanjem na lijevu stranu svih pribrojnika koji sadrže Δx dobivamo

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

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

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

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

- približno **proporcionalna uvjetovanosti** matrice A .

Perturbacija vektora b

Pretpostavimo sad da, umjesto sustava $Ax = b$, rješavamo

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

Opet, pretpostavljamo da za **operatorsku normu** perturbacije vektora b vrijedi

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

Oduzimanjem $Ax = b$ od $A(x + \Delta x) = b + \Delta b$ izlazi

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

Množenjem slijeva s A^{-1} dobivamo

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

Perturbacija vektora b

Uzimanjem norme lijeve i desne strane, a zatim **ocjenjivanjem odozgo**, dobivamo

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

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

- ponovno, **proporcionalna uvjetovanosti** matrice A .

Sada možemo **generalizirati** ove rezultate na slučaj

- kad **perturbiramo** istovremeno i A i b .

Perturbacija matrice A i vektora b

Teorem. Neka je $Ax = b$ i

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

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

Komentar: Uobičajeno se za E uzima A , jer je to **pogreška** koju napravimo spremanjem matrice A u računalo. Jednako tako, za f se 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

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

Ako od $(A + \Delta A)(x + \Delta x) = b + \Delta b$ oduzmemo $Ax = b$, dobivamo

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

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, ASNA2).

Komentar rezultata teorije perturbacija

Uočimo da sve ocjene vrijede

• samo za “dovoljno male” perturbacije matrice A .

Na primjer, 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.

Pitanje. Što kaže obratna analiza grešaka zaokruživanja, tj.

• koje su ocjene na perturbacije?

Rezultati obratne analize grešaka zaokruživanja

Obratna ocjena za LR faktorizaciju

Teorem. U aritmetici računala računamo LR 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{R} onda zadovoljavaju

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

gdje je γ_n standardna oznaka za mjeru grešaka zaokruživanja

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



Obratna ocjena za rješenje sustava

Teorem. 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{R} izračunati trokutasti faktori u LR faktorizaciji matrice A ,
- i neka je \hat{x} izračunato rješenje sustava $Ax = b$.

Onda postoji perturbacija ΔA matrice A za koju vrijedi

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

Za zaključak o relativnoj grešci, fali nam još

- neka veza između $|\hat{L}| |\hat{R}|$ 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

- početnim spremanjem elemenata matrice A u memoriju računala.

No, to nije realistično. Nad svakim elementom matrice A

- vrši se još najviše n aritmetičkih operacija.

Zato ne možemo očekivati nešto bolje od ocjene oblika

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

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

Relativne ocjene — idealni slučaj

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

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

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

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

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

pa, prebacivanjem članova dobivamo

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

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” $|\hat{L}| |\hat{R}| = |\hat{L}\hat{R}|$?

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

- Takve su tzv. **totalno nenegativne** ili **totalno pozitivne** matrice.

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

Što je bitno za stabilnost?

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

- ne ovisi o veličini multiplikatora,
- već o veličini elemenata koji se javljaju u matrici $|\hat{L}| |\hat{R}|$, relativno obzirom na elementu matrice A .

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

- može imati male elemente, iako su joj multiplikatori $m_{ij} = l_{ij}$ veliki,
- ali može imati i velike elemente, a da su joj multiplikatori reda veličine 1.

Analiza i procjena stabilnosti algoritma

Za lakšu analizu, ne gleda se po svim elementima, već se analizira omjer normi

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

Bitno: ovaj omjer ovisi o algoritmu kojim računamo LR faktorizaciju!

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

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

taj omjer jednak ε^{-1} .

Stabilnost parcijalnog pivotiranja

Kod **parcijalnog** pivotiranja znamo da vrijedi

$$|\ell_{ij}| \leq 1 \quad \text{za sve } i \geq j.$$

Kad uvrstimo $m_{ik} = \ell_{ik}$ u formule **transformacije**

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

indukcijom po koracima eliminacije, dobivamo da vrijedi

$$|r_{ij}| \leq 2^{i-1} \max_{k \leq i} |a_{kj}|.$$

Dakle, kod **parcijalnog** pivotiranja

• L je **malen**, a R je **ograđen relativno** obzirom na A .

Ocjena stabilnosti preko faktora rasta

Tradicionalno, **obratna** analiza greške izražava se preko **faktora rasta** (engl. growth factor)

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

U procesu **Gaussovih** eliminacija, očito vrijedi da je

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

što daje ogradu za **R**, **relativno** obzirom na **A**.

Može se naći i precizna veza između **omjera normi** i **faktora rasta**.

Obratna ocjena za sustav preko faktora rasta

Teorem (Wilkinson). Neka je A regularna kvadratna matrica reda n i neka je \hat{x} izračunato rješenje sustava $Ax = b$

- Gaussovima eliminacijama s parcijalnim pivotiranjem u aritmetici računala.

Tada vrijedi

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

U prethodnom teoremu, pretpostavka da koristimo parcijalno pivotiranje nije nužna.

Naime, isto vrijedi i za Gaussove eliminacije bez pivotiranja, samo s malo drugačijom konstantom.

Naravno, faktor rasta može biti puno veći!

Rezidual i iterativno poboljšanje rješenja

Rezidual približnog rješenja

Kad rješenje sustava $Ax = b$ računamo približno (računalom),

☛ umjesto pravog rješenja x , dobivamo približno rješenje \hat{x} .

Veličinu

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

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

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

Međutim, ako je (egzaktni) rezidual

- ☛ velik, onda sigurno nismo blizu pravom rješenju,
- ☛ ali rezidual može biti malen, a da izračunato rješenje sustava nije ni blizu pravom.

Izračunati rezidual

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

$$H_{20}x = b$$

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

Kad računamo u **extended** točnosti,

• **izračunati** rezidual $\hat{r} = b - A\hat{x}$ je **nula-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 rješenje može biti **katastrofalno**, ako je **uvjetovanost** matrice A **velika**.

Uloga reziduala — poboljšanje točnosti

Reziduali se mogu iskoristiti za poboljšavanje netočnog rješenja linearnog sustava.

To se obično provodi u tri koraka — može i iterativno.

- Izračuna se rezidual $r = b - A\hat{x}$, pri čemu je \hat{x} izračunato (ili približno) rješenje sustava.
- Riješi se sustav $Ad = r$, gdje je d korekcija.
- Korekcija se doda izračunatom rješenju

$$y = \hat{x} + d,$$

što bi trebalo dati bolje rješenje y .

Postupak se može ponoviti s y , umjesto \hat{x} .

Računanje reziduala — mora u većoj točnosti

Ovo ima smisla **samo** ako se **prvi** korak

- računanje reziduala $r = b - A\hat{x}$
- radi u **većoj** točnosti od **one** u kojoj je **izračunat** \hat{x} .

To je nužno zbog **kraćenja**, tako da

- **izračunati** \hat{r} ima **dovoljnu** relativnu točnost.

Preostala **dva** koraka standardno se rade

- u “**običnoj**” točnosti, kao za \hat{x} (to je **ideja!**).

Tipično se računanje reziduala radi u

- **dvostrukoj** točnosti — jedinična greška reda veličine u^2 , obzirom na **jednostruku**.

Na pr. **double**, prema **single**.

**Kad ne treba pivotirati
u LR faktorizaciji?**


Struktura LR faktorizacije

Ako matrica A koja ulazi u LR faktorizaciju ima nekakvu **strukturu**, pitanje je kad će se ta struktura **sačuvati**.

To je **posebno bitno** za

- sustave gdje je A takva da se **bitna** informacija o njoj može spremiti u **bitno manje** od n^2 elemenata.

Ako **ne pivotiramo**, onda se čuvaju, recimo, sljedeće forme:



Prva su **vrpčaste** matrice, a druga su “rupe **udesno i nadolje**”.

Kad ne moramo pivotirati?

Dakle, zgodno je znati kad **ne treba** pivotirati, a da

- imamo **garantiranu stabilnost** algoritma **eliminacija**, odnosno, **LR** faktorizacije.

Odgovor. Postoje tipovi matrica kod kojih **ne moramo** pivotirati. Na primjer, to su:

- strogo **dijagonalno dominantne** matrice po **stupcima**, tj. matrice za koje vrijedi

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

- **dijagonalno dominantne** matrice po **recima** ($i \leftrightarrow j$),
- **simetrične pozitivno definitne** matrice (v. malo kasnije).

Kad ne moramo pivotirati?

Za **dijagonalno dominantne** matrice po **stupcima**, treba samo pokazati da iza **prvog koraka** eliminacije **ostaju** dijagonalno dominantne po stupcima.

1. **Zaključak.** $a_{11} \neq 0$ i maksimalan po apsolutnoj vrijednosti u 1. stupcu, pa sigurno možemo napraviti 1. korak eliminacije.

Dobivamo matricu $A^{(2)}$ oblika

$$A^{(2)} = \begin{bmatrix} a_{11} & a_1 \\ 0 & S \end{bmatrix},$$

pri čemu je S **regularna** (dokaz korištenjem determinanti).

2. **Korak.** Moramo pokazati da je matrica S **dijagonalno dominantna** po stupcima.

Kad ne moramo pivotirati?

Za $j = 2, \dots, n$ vrijedi

$$\sum_{\substack{i=2 \\ i \neq j}}^n |a_{ij}^{(2)}| = \sum_{\substack{i=2 \\ i \neq j}}^n \left| a_{ij} - \frac{a_{i1} a_{1j}}{a_{11}} \right| \leq \sum_{\substack{i=2 \\ i \neq j}}^n |a_{ij}| + \left| \frac{a_{1j}}{a_{11}} \right| \sum_{\substack{i=2 \\ i \neq j}}^n |a_{i1}|$$

(dijagonalna dominantnost obje sume)

$$< (|a_{jj}| - |a_{1j}|) + \left| \frac{a_{1j}}{a_{11}} \right| (|a_{11}| - |a_{j1}|)$$

$$= |a_{jj}| - \left| \frac{a_{1j}}{a_{11}} a_{j1} \right| \quad (\text{koristimo } |a| - |b| \leq |a - b|)$$

$$\leq \left| a_{jj} - \frac{a_{1j}}{a_{11}} a_{j1} \right| = |a_{jj}^{(2)}|,$$

što pokazuje da je i $A^{(2)}$ dijagonalno dominantna po stupcima.

Dijagonalno dominantne matrice — preciznije

Za kompleksnu matricu $A \in \mathbb{C}^{n \times n}$ kažemo da je **dijagonalno dominantna** po **stupcima** ako vrijedi

$$|a_{jj}| \geq \sum_{\substack{i=1 \\ i \neq j}}^n |a_{ij}|, \quad j = 1, \dots, n.$$

Ako vrijedi **stroga** nejednakost ($>$), za **sve** $j = 1, \dots, n$, onda kažemo da je A **strogo** dijagonalno dominantna po **stupcima**.

Matrica A je (**strogo**) dijagonalno dominantna po **recima**, ako je A^* (**strogo**) dijagonalno dominantna po **stupcima** ($i \leftrightarrow j$).

U oba slučaja, **Gaussove eliminacije** i **LR faktorizacija** su

🔴 savršeno **stabilne** i **bez pivotiranja**.

GE i LR za dijagonalno dominantne matrice

Teorem (Wilkinson). Neka je A kompleksna regularna kvadratna matrica reda n .

- Ako je A dijagonalno dominantna po recima ili stupcima, tada A ima LR faktorizaciju bez pivotiranja i za faktor rasta vrijedi $\rho_n \leq 2$.
- Ako je A dijagonalno dominantna po stupcima, tada je $|l_{ij}| \leq 1$ za sve i, j , u LR faktorizaciji bez pivotiranja.

To znači da parcijalno pivotiranje ne radi nikakve zamjene redaka (najveći element je već na dijagonali). ■

Napomena. Regularnost samo osigurava da dijagonalni elementi ne smiju biti nula, jer dozvoljavamo \geq .

Dokaz. Sličan prethodnom (v. skripta ili Higham, ASNA2).

Simetrične pozitivno definitne matrice

Simetrične pozitivno definitne matrice

Za simetrične/hermitske pozitivno definitne matrice radi se “simetrizirana varijanta” LR faktorizacije

- jer je 2 puta brža nego obična LR faktorizacija,
- čuva strukturu matrice A — čak i kad računamo u aritmetici računala, množenjem faktora uvijek dobivamo simetričnu matricu.

“Simetrizirana LR” faktorizacija zove se faktorizacija Choleskog.

Prisjećanje. Matrica je hermitska ako je

$$A = A^*.$$

Ako je $A \in \mathbb{R}^{n \times n}$, onda je hermitska matrica isto što i simetrična, tj. $*$ = T .

Simetrične pozitivno definitne matrice

Pozitivna definitnost matrice se ne vidi odmah. Uobičajeno se unaprijed, iz prirode problema zna da je neka matrica pozitivno definitna.

Matrica $A \in \mathbb{F}^{n \times n}$ je pozitivno definitna ako je

$$x^* Ax > 0, \quad \text{za svaki } x \in \mathbb{F}^n, \quad x \neq 0.$$

Ekvivalentni uvjeti za pozitivnu definitnost:

☛ sve svojstvene vrijednosti od A su pozitivne, tj. vrijedi

$$\lambda_k(A) > 0, \quad \text{za } k = 1, \dots, n,$$

gdje λ_k označava k -tu najveću svojstvenu vrijednost;

Simetrične pozitivno definitne matrice

Ekvivalentni uvjeti (nastavak):

☛ sve vodeće glavne minore od A su pozitivne, tj. vrijedi

$$\det(A_k) > 0, \quad \text{za } k = 1, \dots, n,$$

gdje je $A_k = A(1 : k, 1 : k)$ vodeća glavna podmatrica od A reda k .

Posljedica. Sve vodeće glavne podmatrice A_k su regularne, za $k = 1, \dots, n$.

Digresija. Katkad se puno lakše vidi da neka matrica nije pozitivno definitna. Pokažite da nisu pozitivno definitne matrice koje

☛ na dijagonali imaju negativan element ili nulu.

Pozitivna definitnost i simetrija

Za **kompleksne** matrice $A \in \mathbb{C}^{n \times n}$, može se pokazati da vrijedi

● A je **pozitivno definitna** $\implies A$ je **hermitska** ($A = A^*$).

Za **realne** matrice $A \in \mathbb{R}^{n \times n}$ to **ne mora** vrijediti, tj.

● **pozitivno definitna** matrica **ne mora** biti **simetrična**
(može biti i $A \neq A^T$).

Međutim, u **numerici** se vrlo često koristi “**stroža**” varijanta pojma — koja, po **definiciji**, uključuje i **simetriju**:

● **Realna** matrica $A \in \mathbb{R}^{n \times n}$ **pozitivno definitna** ako je **simetrična** i za svaki $x \in \mathbb{R}^n$, $x \neq 0$, vrijedi $x^T A x > 0$.

Da ne bude zabune, u nastavku, koristimo “**strožu**” definiciju! U tom slučaju, originalni pojam (**bez** simetrije) katkad se zove samo “**pozitivnost**” matrice A .

LR Faktorizacija za sim. poz. def. matrice

Iz ekvivalentnog uvjeta odmah izlazi da se za

- hermitsku/simetričnu pozitivno definitnu matricu uvijek može napraviti
- LR faktorizacija bez pivotiranja (v. Teorem o LR)!

Simetrizacija — faktorizacija Choleskog

Tvrdnja. Za hermitsku/simetričnu pozitivno definitnu matricu A , LR faktorizaciju možemo napisati u obliku

$$A = LDL^*.$$

Ta faktorizacija se obično zove LDL^* faktorizacija.

Kako se dobije ova faktorizacija?

U LR faktorizaciji matrice A , faktor R se rastavi na

$$R = DM^*,$$

gdje je

- D dijagonalna,
- a M^* gornja trokutasta s jedinicama na dijagonali.

Faktorizacija Choleskog

Da se dobije takva faktorizacija,

- dijagonalni elementi R stave se na dijagonalu od D ,
- svaki redak u R podijeli se s dijagonalnim elementom u tom retku da se dobije M^* .

Dakle,

$$A = LDM^*, \quad M \text{ donjetrokutasta, regularna.}$$

Zbog hermitičnosti/simetrije vrijedi

$$A = A^* = (LDM^*)^* = MDL^*,$$

pa je $LDM^* = MDL^* \dots$

Faktorizacija Choleskog

(nastavak) ...

$$LDM^* = MDL^*.$$

Množenjem s lijeva s L^{-1} i zdesna s L^{-*} dobivamo

$$DM^*L^{-*} = L^{-1}MD.$$

Na lijevoj strani imamo produkt **gornjetrokutastih** matrica, a na desnoj strani **donjetrokutastih**, pa su ti produkti **dijagonalne matrice**.

Te dijagonalne matrice su **jednake** D (jer i M i L imaju na dijagonali **jedinice**), pa je

$$L^{-1}MD = D \implies MD = LD \implies M = L.$$

Faktorizacija Choleskog

Nadalje, D ima **pozitivne elemente**, jer bi inače postojao vektor x takav da je

$$(Ax, x) = (LDL^*x, x) = (DL^*x, L^*x) := (Dy, y) \leq 0.$$

Dakle, D možemo **rastaviti** na

$$D = \Delta \cdot \Delta$$

gdje je Δ **dijagonalna** i $\Delta_{ii} = \sqrt{D_{ii}}$.

Tada LDL^* faktorizaciju možemo napisati u obliku:

$$A = LDL^* = (L\Delta)(\Delta L^*) = (L\Delta)(\Delta^*L^*) = (L\Delta)(L\Delta)^*.$$

Faktorizacija Choleskog

Uz oznaku $R := (L\Delta)^*$ dobivamo faktorizaciju Choleskog

$$A = R^*R.$$

Digresija. Mnogi slovom L označavaju $L := L\Delta$, pa se u literaturi faktorizacija Choleskog može naći napisana kao

$$A = LL^*.$$

Oprez: taj L nema jedinice na dijagonali!

Kad znamo da postoji, **Faktorizacija Choleskog** se može i **direktno** izvesti, znajući da je $A = R^*R$.

Algoritam

Ograničimo se na **realni** slučaj. Tada je

$$a_{ij} = \sum_{k=1}^i r_{ki} r_{kj}, \quad i \leq j,$$

pa dobivamo sljedeću **rekurziju** za elemente:

za $j = 1, \dots, n$:

$$r_{ij} = \left(a_{ij} - \sum_{k=1}^{i-1} r_{ki} r_{kj} \right) / r_{ii}, \quad i = 1, \dots, j-1,$$

$$r_{jj} = \left(a_{jj} - \sum_{k=1}^{j-1} r_{kj}^2 \right)^{1/2}.$$

Za $j = 1$ računamo samo r_{11} .

Algoritam

Greške zaokruživanja \Rightarrow moguć negativan izraz pod korijenom.

Faktorizacija Choleskog

```
za j = 1 do n radi {  
    /* Nađi j-ti stupac od R */  
    /* Supstitucija unaprijed iznad dijagonale */  
    za i = 1 do j - 1 radi {  
        sum = A[i, j];  
        za k = 1 do i - 1 radi {  
            sum = sum - R[k, i] * R[k, j];  
        };  
        R[i, j] = sum / R[i, i];  
    };  
};
```

Algoritam

```
    /* Dijagonalni element */
sum = A[j, j];
za k = 1 do j - 1 radi {
    sum = sum - R[k, j]**2;
};
ako je sum > 0.0 onda {
    R[j, j] = sqrt(sum)
};
inače
    /* Matrica nije pozitivno definitna, STOP */
};
```

Komentar na algoritam

Uočimo da:

- se po prethodnoj rekurziji matrica R generira **stupac po stupac**, dok se u LR faktorizaciji R generirala **redak po redak**, a L **stupac po stupac**;
- ovo je tzv. *jik* varijanta algoritma, a naziv dolazi od **poretka petlji**, uz prirodno imenovanje indeksa;
- ovo **nije** jedina varijanta za realizaciju algoritma.

Složenost algoritma (broj aritmetičkih operacija) je približno jednaka

$$OP(n) \sim \frac{1}{3} n^3,$$

što je približno **polovina** složenosti LR faktorizacije.

Rješenje linearnog sustava

Kad imamo faktorizaciju Choleskog $A = R^T R$, onda se rješenje linearnog sustava $Ax = b$ svodi na dva rješavanja trokutastih sustava

$$R^T y = b, \quad Rx = y,$$

koje lako rješavamo:

● sustav $R^T y = b$ — supstitucijom unaprijed

$$y_1 = b_1 / r_{11}$$

$$y_i = \left(b_i - \sum_{j=1}^{i-1} r_{ji} y_j \right) / r_{ii}, \quad i = 2, \dots, n,$$

Rješenje linearnog sustava

- sustav $Rx = y$ — supstitucijom unatrag

$$x_n = y_n / r_{nn}$$

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

Za **razliku** od LR faktorizacije, ovdje u obje supstitucije imamo dijeljenja.

Zbog toga se često koristi LDL^T oblik faktorizacije:

- u algoritmu **nema** računanja **drugih korijena**;
- rješavaju se **tri** linearna sustava:

$$Lz = b, \quad Dy = z, \quad L^T x = y.$$

- L ima **jediničnu** dijagonalu, pa štedimo n **dijeljenja**.

Može li LDL^T za simetrične matrice?

Može li se LDL^T faktorizacija napraviti za bilo koju simetričnu matricu A (uz dozvolu da matrica D ima i negativne elemente)?

To ne vrijedi! Kontraprimjer:

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

Pomaže li simetrična permutacija redaka/stupaca? Ne!

Poopćenje na indefinitne matrice dobivamo tako da

• dozvolimo dijagonalne blokove reda 2 u matrici D .

Pivotiranje u faktorizaciji Choleskog

I kod faktorizacije Choleskog možemo koristiti pivotiranje.

- Da bismo očuvali simetriju radne matrice, pivotiranje mora biti “simetrično”, tj. radimo istovremene zamjene redaka i stupaca u A

$$A \rightarrow P^T A P,$$

gdje je P matrica permutacije.

- “Simetrična zamjena” \Rightarrow dijagonalni element zamjenjuje mjesto s dijagonalnim!
- Standardni izbor pivotnog elementa u k -tom koraku je

$$a_{rr}^{(k)} = \max_{k \leq i \leq n} a_{ii}^{(k)},$$

što odgovara potpunom pivotiranju u Gaussovima eliminacijama.

Pivotiranje u faktorizaciji Choleskog

Ovim postupkom dobivamo faktorizaciju Choleskog

$$P^T A P = R^T R,$$

a za elemente matrice R vrijedi

$$r_{kk}^2 \geq \sum_{i=k}^j r_{ij}^2, \quad j = k + 1, \dots, n, \quad k = 1, \dots, n.$$

Posebno, to znači da R ima nerastuću dijagonalu

$$r_{11} \geq \dots \geq r_{nn} > 0.$$

Napomena. Usporedite kasnije s rezultatom za QR faktorizaciju s pivotiranjem stupaca.

Aproksimacija i interpolacija

Općenito o problemu aproksimacije

Što je problem **aproksimacije**?

Poznate su **neke** informacije o funkciji f , definiranoj na nekom podskupu $X \subseteq \mathbb{R}$.

Na osnovu tih **informacija**, želimo funkciju f

- **zamijeniti** nekom **drugom** funkcijom φ na skupu X , ili na još **većem** skupu,
- tako da su funkcije f i φ **bliske** u nekom **smislu**.

Skup X je najčešće:

- **interval** oblika $[a, b]$ (koji može biti i **neograničen**), ili
- **diskretni skup** točaka.

Pitanje: Zašto uopće želimo **zamjenu** $f \mapsto \varphi$?

Oblici problema aproksimacije

Problem aproksimacije javlja se u dva bitno različita oblika.

Prvi oblik: Znamo funkciju f (analitički ili slično),

- ali je njezina forma prekomplikirana za računanje.

U tom slučaju,

- izaberemo neke informacije o f i

- po nekom kriteriju odredimo aproksimacijsku funkciju φ .

Prednosti ovog oblika problema aproksimacije:

- Možemo birati informacije o f koje ćemo koristiti.

- Jednako tako, možemo ocijeniti grešku dobivene aproksimacije φ , obzirom na prave vrijednosti funkcije f .

Oblici problema aproksimacije (nastavak)

Drugi oblik: Ne znamo funkciju f ,

- već samo neke informacije o njoj,
- na primjer, vrijednosti na nekom (diskretnom) skupu točaka.

Zamjenska funkcija φ određuje se iz raspoloživih informacija.

- Osim samih podataka (poznate vrijednosti),
- ove informacije mogu uključivati i očekivani oblik ponašanja tih podataka (tj. funkcije φ).

Mane ovog oblika problema aproksimacije:

- Ne može se napraviti ocjena pogreške,
- bez dodatnih informacija o nepoznatoj funkciji f .

Prvi oblik problema — primjene

Prvi oblik se obično koristi u teoriji

- za razvoj numeričkih metoda na bazi aproksimacije.

Na primjer, za numeričko

- integriranje funkcija (integriramo aproksimaciju),
- rješavanje diferencijalnih jednažbi.

Praktični primjer:

- programska biblioteka za računanje raznih elemenatnih funkcija (`exp`, `sin`, `cos`, `sqrt` i sl),

Traži se maksimalna brzina i puna točnost, na razini osnovne greške zaokruživanja.

Realizacija standardno ide racionalnim aproksimacijama.

Drugi oblik problema — primjene

Drugi oblik problema se vrlo često javlja u praksi.

Na primjer,

- kod mjerenja nekih veličina (rezultat je “tablica”),
- osim izmjerenih podataka, pokušavamo aproksimirati i podatke koji se nalaze “između” izmjerenih točaka.

To je ključna svrha ovakve aproksimacije!

Napomena. Kod mjerenja se javljaju i greške mjerenja.

- Zato postoje posebne tehnike — vrste aproksimacija, za “ublažavanje” tako nastalih grešaka.

Na primjer, metoda najmanjih kvadrata.

Izbor aproksimacijske funkcije φ

Aproksimacijska funkcija φ bira se:

- prema **prirodi modela** — izbor dolazi iz **problema**,
- ali tako da bude relativno **jednostavna** za **računanje**.

Obično se **prvo fiksira** (izabere) neki **skup** funkcija \mathcal{F} .

- **Onda** se traži “**najbolja**” aproksimacija φ iz tog skupa \mathcal{F} .

Skup \mathcal{F} može biti **vektorski prostor**, ali ne mora.

Za **praktično** računanje, funkcija φ obično ovisi

- o nekom **konačnom** broju **parametara** a_k , $k = 0, \dots, m$,
- koje treba **odrediti** po nekom **kriteriju** aproksimacije.

Ideja: **Sve moguće** vrijednosti ovih $m + 1$ parametara određuju skup **svih** “**dozvoljenih**” funkcija \mathcal{F} .

Parametrizacija aproksimacijske funkcije φ

Kad funkciju φ zapišemo u obliku

$$\varphi(x) = \varphi(x; a_0, a_1, \dots, a_m),$$

kao funkciju koja ovisi o parametrima a_k , onda kažemo da smo

- da smo izabrali opći oblik aproksimacijske funkcije φ (u odnosu na skup \mathcal{F}).

Prema obliku ovisnosti o parametrima, aproksimacijske funkcije možemo grubo podijeliti na:

- linearne aproksimacijske funkcije,
- nelinearne aproksimacijske funkcije.

Koje su bitne razlike između ove dvije grupe?

Linearne aproksimacijske funkcije

Opći oblik **linearne** aproksimacijske funkcije je

$$\varphi(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_m\varphi_m(x),$$

gdje su $\varphi_0, \dots, \varphi_m$ **poznate** funkcije koje **znamo** računati.

Linearnost u **ovisnosti** o parametrima znači:

- traženi parametri su **koeficijenti** u **linearnoj kombinaciji poznatih** funkcija.

Velika **prednost**: **Određivanje** parametara a_k obično vodi na “**linearne**” probleme (koji su **lakše** rješivi od **nelinearnih**):

- sustave linearnih** jednadžbi, ili
- linearne** probleme **optimizacije**.

Linearne aproksimacijske funkcije (nastavak)

Standardni model za linearni oblik aproksimacije:

- skup “dozvoljenih” funkcija \mathcal{F} je vektorski prostor, a
- funkcije $\varphi_0, \dots, \varphi_m$ su neka baza u tom prostoru.

Unaprijed se bira (fiksira):

- vektorski prostor \mathcal{F} , odgovarajuće dimenzije $m + 1$,
- baza $\varphi_0, \dots, \varphi_m$ u \mathcal{F} .

Napomena. Kod približnog numeričkog računanja,

- “dobar” izbor baze je ključan za stabilnost postupka
- i točnost izračunatih vrijednosti parametara aproksimacijske funkcije φ .

Primjer 1 — polinomi

Nekoliko primjera najčešće korištenih vektorskih prostora \mathcal{F} .

Polinomi. Uzimamo $\mathcal{F} = \mathcal{P}_m$, gdje je \mathcal{P}_m vektorski prostor polinoma stupnja $\leq m$.

Standardni izbor baze je $\varphi_k(x) = x^k$, za $k = 0, \dots, m$, tj.

$$\varphi(x) = a_0 + a_1x + \dots + a_mx^m.$$

Nije nužno da φ zapisujemo u bazi $\{1, x, \dots, x^m\}$. Upravo suprotno, vrlo često je neka druga baza **bitno bolja**.

- Na primjer, $\{1, (x - x_0), (x - x_0)(x - x_1), \dots\}$, gdje su x_0, x_1, \dots **zadane** točke (v. kod interpolacije).
- **Ortogonalni** polinomi, obzirom na **pogodno** izabrani skalarni produkt (v. kod najmanjih kvadrata).

Primjer 2 — trigonometrijski polinomi

Trigonometrijski “polinomi”. Za funkcije φ_k uzima se prvih $m + 1$ funkcija iz skupa

$$\{ 1, \cos x, \sin x, \cos 2x, \sin 2x, \dots \}.$$

Koriste se za aproksimaciju **periodičkih** funkcija na intervalu **perioda** — ovdje, recimo, $[0, 2\pi]$.

● **Primjena** je, na primjer, u **obradi i modeliranju signala**.

Varijacije u izboru **baze**:

● Koristi se **dodatni faktor** u argumentu **sinusa i kosinusa** ($x \mapsto \lambda x$) — koji služi za **kontrolu perioda**.

● Ponekad se biraju **samo parne** ili **samo neparne** funkcije iz ovog skupa.

Primjer 3 — polinomni splajnovi

Polinomni splajnovi. To su funkcije koje su “po dijelovima” **polinomi**. Ako su zadane točke $x_0 < \dots < x_n$, onda se **splajn** funkcija na svakom **podintervalu**

- svodi na **polinom** određenog fiksnog (**niskog**) stupnja,

$$\varphi \Big|_{[x_{k-1}, x_k]} = p_k, \quad k = 1, 2, \dots, n,$$

a p_k su **polinomi** najčešće stupnjeva 1, 2, 3 ili 5.

U točkama x_i obično se zahtijeva da funkcija φ zadovoljava još

- i “**uvjete ljepljenja**” vrijednosti **funkcije** i nekih njezinih **derivacija**, ili nekih **aproksimacija** za te **derivacije**.

Splajnovi se često koriste zbog dobrih **ocjena greške** aproksimacije i **kontrole oblika** aproksimacijske funkcije.

Nelinearne aproksimacijske funkcije

Nelinearne aproksimacijske funkcije φ

$$\varphi(x) = \varphi(x; a_0, a_1, \dots, a_m),$$

imaju nelinearnu ovisnosti o parametrima aproksimacijske funkcije a_0, \dots, a_m .

Pripadni skup ‘dozvoljenih’ funkcija \mathcal{F} najčešće

● nije vektorski prostor.

Određivanje parametara a_k , općenito, vodi na “nelinearne” probleme:

- sustave nelinearnih jednažbi, ili
- nelinearne probleme optimizacije.

Primjer 4 — eksponencijalne funkcije

Par **primjera** najčešće korištenih oblika **nelinearnih** aproksimacijskih funkcija.

Eksponencijalne aproksimacije. Imaju oblik **linearne kombinacije eksponencijalnih** funkcija s **parametrima** u eksponentu:

$$\varphi(x) = c_0 e^{b_0 x} + c_1 e^{b_1 x} + \dots + c_r e^{b_r x},$$

Broj **nezavisnih** parametara je $m + 1 = 2r + 2$.

Opisuju, na primjer,

- procese **rasta** i **odumiranja** u raznim **populacijama**,
- s primjenom u **biologiji**, **ekonomiji** i **medicini**.

Primjer 5 — racionalne funkcije

Racionalne funkcije. Imaju opći oblik

$$\varphi(x) = \frac{b_0 + b_1x + \cdots + b_r x^r}{c_0 + c_1x + \cdots + c_s x^s},$$

i $m + 1 = r + s + 1$ nezavisnih parametara, a ne $r + s + 2$, kako formalno piše.

Objašnjenje. Razlomci se mogu proširivati,

- ako su b_i, c_i parametri, onda su to i tb_i, tc_i , za $t \neq 0$;
- uvijek možemo fiksirati jedan od koeficijenata b_i ili c_i , a koji je to — obično slijedi iz prirode modela.

Ovako definirane racionalne funkcije imaju mnogo bolja svojstva aproksimacije nego polinomi, a pripadna teorija je relativno nova.

Kriteriji aproksimacije — interpolacija

Interpolacija je zahtjev da se funkcije f i φ podudaraju na nekom konačnom skupu točaka.

- Te točke nazivamo **čvorovi interpolacije**.
- Zahtjevu se može, ali i ne mora, **dodati** zahtjev da se u čvorovima, **osim funkcijskih vrijednosti, poklapaju i vrijednosti nekih derivacija**.

U **najjednostavnijem** obliku interpolacije, kad se podudaraju samo funkcijske vrijednosti, od podataka o funkciji f

- koristi se **samo informacija** o njenoj vrijednosti na skupu od $n + 1$ točaka,
- tj. podaci (x_k, f_k) , gdje je $f_k := f(x_k)$, za $k = 0, \dots, n$.

Kriteriji aproksimacije — interpolacija

- Parametri a_0, \dots, a_n (mora ih biti **točno onoliko koliko i podataka**, tj. $m = n$) određuju se iz uvjeta

$$\varphi(x_k; a_0, a_1, \dots, a_n) = f_k, \quad k = 0, \dots, n,$$

što je, općenito, **nelinearni** sustav jednažbi.

- **Linearnost** funkcije φ povlači da parametre a_k dobivamo iz sustava **linearnih jednažbi**
 - koji ima **točno $n + 1$** jednažbi za $n + 1$ nepoznanica. Matrica tog sustava je **kvadratna**.

Kriteriji aproksimacije — minimizacija pogreške

Minimizacija pogreške je drugi kriterij određivanja parametara aproksimacije. Funkcija φ bira se tako da se **minimizira** neka odabrana norma pogreške

$$e(x) = f(x) - \varphi(x)$$

u nekom odabranom prostoru funkcija \mathcal{F} za φ , na nekoj domeni X .

Ove aproksimacije, često zvane i **najbolje aproksimacije po normi**, dijele se na

- **diskretne** — ako se norma pogreške e minimizira na **diskretnom** skupu podataka X ;
- **kontinuirane** — ako se norma pogreške e minimizira na **kontinuiranom** skupu podataka X .

Kriteriji aproksimacije — minimizacija pogreške

Standardno se kao **norme pogreške** koriste

- 2-norma i
- ∞ -norma.

Za 2-normu

- pripadna se aproksimacija zove **srednjekvadratna**,
- a **metoda** za njeno nalaženje zove se **metoda najmanjih kvadrata**.

Funkcija φ , odnosno njeni **parametri**, se traže tako da bude

$$\min_{\varphi \in \mathcal{F}} \|e(x)\|_2.$$

Kriteriji aproksimacije — minimizacija pogreške

- U diskretnom slučaju je $X = \{x_0, \dots, x_n\}$, pa raspisom prethodne relacije dobivamo

$$\sqrt{\sum_{k=0}^n (f(x_k) - \varphi(x_k))^2} \rightarrow \min,$$

- a u kontinuiranom slučaju

$$\sqrt{\int_a^b (f(x) - \varphi(x))^2 dx} \rightarrow \min.$$

Preciznije, **minimizira** se samo ono pod korijenom.

Kriteriji aproksimacije — minimizacija pogreške

U slučaju ∞ -norme pripadna se aproksimacija zove **minimaks aproksimacija**, a parametri se biraju tako da se nađe

$$\min_{\varphi \in \mathcal{F}} \|e(x)\|_{\infty}.$$

📍 U **diskretnom** slučaju traži se

$$\max_{k=0, \dots, n} |f(x_k) - \varphi(x_k)| \rightarrow \min,$$

📍 a u **kontinuiranom** slučaju

$$\max_{x \in [a, b]} |f(x) - \varphi(x)| \rightarrow \min.$$

Kriteriji aproksimacije — minimizacija pogreške

Ovaj je tip aproksimacija **poželjniji** od srednjkvadratnih,

- jer se traži da **maksimalna greška** bude **minimalna**,
- ali ih je općenito **mного teže izračunati** (na primjer, dobivamo problem minimizacije **nederivabilne** funkcije!).

Za znatiželjne: U praksi norme, pored funkcije mogu uključivati i **neke njene derivacije**. Primjer takve norme

$$\|f\| = \sqrt{\int_a^b [(f(x))^2 + (f'(x))^2] dx},$$

na prostoru $C^1[a, b]$ svih funkcija koje imaju **neprekidnu prvu derivaciju** na $[a, b]$.

Ključni problemi kod aproksimacije

Matematički problemi koje treba riješiti:

- egzistencija i jedinstvenost rješenja problema aproksimacije, što ovisi o tome
 - koje funkcije f aproksimiramo kojim funkcijama φ (dva prostora)
 - i kako mjerimo grešku e (norma);
- analiza kvalitete dobivene aproksimacije — vrijednost “najmanje” pogreške i ponašanje funkcije greške e (jer norma je ipak samo broj),
- konstrukcija algoritama za računanje najbolje aproksimacije.

Veza aproksimacije i interpolacije — diskretno

U diskretnom slučaju,

- problem interpolacije na konačnom skupu točaka X (točke iz X su čvorovi interpolacije),

možemo smatrati specijalnim, ali posebno važnim slučajem

- aproksimacije po normi na skupu X , uz neku od
- standardnih normi na konačnodimenzionalnim prostorima (ovisi o tome odakle bирамо φ).

Posebnost: uz minimizaciju norme pogreške $\|e\| \rightarrow \min$, dodatno tražimo da je

- minimum norme pogreške jednak nuli, tj. $\min \|e\| = 0$, što je onda ekvivalentno odgovarajućim uvjetima interpolacije.

Veza aproksimacije i interpolacije — primjer

Primjer. Neka je $X = \{x_0, \dots, x_n\}$ i tražimo aproksimacijsku funkciju φ

• u prostoru \mathcal{P}_n svih polinoma stupnja najviše baš n .

Kao kriterij aproksimacije uzmimo neku p -normu ($1 \leq p \leq \infty$)

• vektora e grešaka funkcijskih vrijednosti na skupu X .

Za $1 \leq p < \infty$, zahtjev je

$$\|e\|_p = \|f - \varphi\|_p = \left(\sum_{k=0}^n |f(x_k) - \varphi(x_k)|^p \right)^{1/p} \rightarrow \min.$$

Za $p = \infty$, tražimo

$$\|e\|_\infty = \|f - \varphi\|_\infty = \max_{k=0, \dots, n} |f(x_k) - \varphi(x_k)| \rightarrow \min.$$

Veza aproksimacije i interpolacije — primjer

Očito je $\|e\|_p = 0$ ekvivalentno uvjetima interpolacije

$$f(x_k) = \varphi(x_k), \quad k = 0, \dots, n.$$

Međutim, nije jasno može li se to postići, tj.

- postoji li takva aproksimacijska funkcija $\varphi \in \mathcal{P}_n$
 - za koju je minimum norme greške jednak nuli,
- tako da je φ i interpolacijska funkcija.

U nastavku, pokazat ćemo da je odgovor potvrđan za ovaj primjer. Razlog:

- Prostor \mathcal{P}_n , u kojem tražimo aproksimaciju, ima taman dovoljno veliku dimenziju.