

Numerička matematika

Tomislav Došlić



Građevinski fakultet
Sveučilište u Zagrebu

Sadržaj

1	Uvod	1
1.1	Apsolutne i relativne pogreške	1
1.2	Osnovni izvori pogrešaka	1
2	Približno rješavanje jednadžbi	3
2.1	Izoliranje rješenja	3
2.2	Metoda raspolavljanja (bisekcije)	5
2.3	Metoda sekante (regula falsi)	6
2.4	Newtonova metoda (metoda tangente)	7
2.5	Metoda iteracije (metoda fiksne točke)	8
3	Aproksimacija i interpolacija	10
3.1	Problem aproksimacije funkcija	10
3.2	Osnovni tipovi aproksimacijskih funkcija	10
3.3	Kriteriji optimalnosti	12
3.4	Polinomijalna interpolacija	14
3.4.1	Rješivost problema interpolacije	14
3.4.2	Lagrangeov oblik interpolacijskog polinoma	15
3.4.3	Newtonov oblik interpolacijskog polinoma	16
3.4.4	Problemi s polinomijalnom interpolacijom	17
3.4.5	Splineovi	18
3.4.6	Zaključak	21
4	Numeričko integriranje	22
4.1	Uvod	22
4.2	Newton-Cotesove kvadrature formule	24
4.3	Trapezna formula	25
4.4	Simpsonova formula	27
4.5	Newton-Cotesove formule viših redova	27
4.6	Poopćena trapezna formula	28
4.7	Poopćena Simpsonova formula	29
4.8	Gaussove kvadrature formule	30
4.9	Mogući problemi	31
4.10	Kubaturne formule i višestruki integrali	32
5	Obične diferencijalne jednadžbe	34
5.1	Eulerova metoda	35
5.2	Poboljšana Eulerova metoda	36
5.3	Metode Runge-Kutta	37
6	Matrice i linearni sustavi	39
6.1	Izvori problema	39
6.2	Tipovi matrica	39
6.3	Tipovi problema	40

6.4	Tipovi metoda	41
6.5	Gaussove eliminacije	41
6.5.1	Modifikacije Gausovih eliminacija - pivotiranje	42
6.5.2	Gauss-Jordanove eliminacije	43
6.6	Simetrične matrice	43
6.7	Analiza pogreške izravnih metoda	44
6.8	Jacobijeva metoda	45
6.9	Gauss-Seidelova metoda	46
6.10	Ocjena pogreške iteracijskih metoda	47
6.11	OR metode	48
6.12	Problem svojstvenih vrijednosti	48
6.12.1	Karakteristični polinom	50
6.12.2	Krylovljeva metoda	50
6.12.3	Metoda neodređenih koeficijenata	51
6.12.4	Lokalizacija nul-točaka	52

Predgovor

Ovaj nastavni materijal namijenjen je studentima druge godine svih smjerova diplomskog studija koji su se tijekom svog obrazovanja već upoznali s mnogim matematičkim modelima kojima opisujemo mehaničke probleme. Ti modeli opisuju odnose veličine koja nas zanima (recimo progiba grede) i vanjskih i unutarnjih parametara o kojima ta veličina ovisi (kao što su svojstva materijala, raspodjela vanjskih opterećenja i sl.). U idealnom slučaju, rješenje takvog modela trebala bi biti formula koja bi na kompaktan način prikazala ovisnost promatrane veličine o parametrima modela. Iz iskustva znamo da je to više iznimka nego pravilo - rješenja koja se daju iskazati elegantnim matematičkim formulama dobivaju se samo za vrlo specijalne slučajeve. U pravilu je riječ o područjima visoke simetrije (segment, kvadrat, pravokutnik, krug) i o modelima koji zanemarivanjem nekih parametara značajno pojednostavnjuju fizikalnu situaciju (mali progibi, konstantni parametri i sl.). Kad god imamo područje nepravilne geometrije i/ili model koji ne zanemaruje nezgodna svojstva parametara, moramo rješenje modela tražiti numeričkim metodama.

Numerička matematika, tj. grana matematike koja se bavi razvojem i proučavanjem metoda za približno rješavanje problema, doživjela je proteklih desetljeća iznimno brz razvoj. To je, u sinergiji s istim takvim razvojem računala, operacijskih sustava i programskih jezika, dovelo do toga da se danas mogu uspješno modelirati složeni nelinearni problemi iz hidrodinamike i mehanike deformabilnih krutih tijela. Razvijeni su i standardni programski alati za pojedina područja koji omogućuju rutinsko modeliranje netrivialnih problema i osobama koje nisu specijalisti. Takvi alati, osim nesumnjivih i očitih prednosti, nose i potencijalne opasnosti, kao što je njihova primjena na probleme za koje nisu predviđeni. Kako bi se izbjegle negativne posljedice i poboljšao učinak standardnih programskih paketa, bilo bi dobro i poželjno da njihovi korisnici imaju određeno razumijevanje matematičkih ideja i pojmova na kojima se oni temelje. S tim je ciljem i koncipiran kolegij Numerička matematika i napisan ovaj nastavni materijal.

Ni skripta ni kolegij nisu zamišljeni kao iscrpan prikaz numeričke matematike i njenih metoda. Namjera im je informirati i zainteresirati studente i čitatelje. Oni koji budu o tome željeli znati više mogu potražiti dodatne informacije u literaturi navedenoj na kraju skripte. Također, mnogi pojmovi koje ovdje koristimo obrađeni su i izloženi u nastavnim materijalima za kolegije Matematika 1 i Matematika 2.

Za nastanak ove skripte u velikoj su mjeri zaslužni slušači prve generacije kojoj je kolegij predavan, Marina Alagušić, Luka Božić, Andrea Klarendić, Janko Koščak, Dejan Stjepanović i Gregor Turkalj. Zahvalan sam im što su s velikim strpljenjem i upornošću utipkali ne uvijek čitljiv i uredan tekst mojih bilješki. Posebno zahvaljujem Janku Koščaku koji je izradio slike.

Zahvaljujem i asistentici Ani Martinčić i docentu Nikoli Sandriću koji su pozorno pročitali prvu verziju teksta i ukazali mi na mnoge pogreške.

Posebno zahvaljujem recenzentima koji su mi ukazali na mnoge propuste i sugerirali brojna poboljšanja.

Odgovornost za sve preostale činjenične, pravopisne i stilske nedostatke je isključivo moja. Bit ću zahvalan svim čitateljima koji mi na njih ukažu.

U Zagrebu, 15. XII 2016.

Tomislav Došlić

1 Uvod

1.1 Apsolutne i relativne pogreške

Neka je $A \in \mathbb{R}$ točna vrijednost nekog broja. Njegova **približna vrijednost** je broj $a \in \mathbb{R}$, koji se malo razlikuje od A . Ako znamo da je $a < A$, kažemo da je a **donja aproksimacija** od A ; ako znamo da je $a > A$, onda je a **gornja aproksimacija** od A .

Pogreška Δa približnog broja a je razlika točne i približne vrijednosti: $\Delta a = A - a$. U većini slučajeva predznak pogreške nije poznat. Zato se često radi s njenom apsolutnom vrijednošću. **Apsolutna pogreška** Δ približnog broja a je $\Delta = |A - a|$.

Točna vrijednost veličine Δ u pravilu nije poznata pa se umjesto točne vrijednosti apsolutne pogreške moramo zadovoljiti njenim ocjenama ili ogradama: $\Delta = |A - a| \leq \Delta_a$. Imamo li takvu ogradu, znamo u kojem se intervalu oko a nalazi točna vrijednost A : $a - \Delta_a \leq A \leq a + \Delta_a$. Često skraćeno pišemo $A = a \pm \Delta_a$.

Apsolutna pogreška (ili njena ograda) ne daje potpun opis točnosti rezultata; ista apsolutna pogreška od 1 cm znači puno više, ako je točna vrijednost $A = 1$ m, nego ako je $A = 1$ km. Stoga uvodimo pojam **relativne pogreške**, $\delta = \frac{\Delta}{|A|}$. U pravilu radimo s ocjenama (ogradama) oblika $\delta \leq \delta_a$.

$\frac{\Delta}{|A|} \leq \delta_a \Rightarrow \Delta \leq |A| \delta_a$, pa možemo uzeti $\Delta_a = |A| \delta_a$, odnosno, zbog $A \approx a$, $\Delta_a = |a| \delta_a$. Odatle možemo dobiti interval oko a u kojem leži A . Uzmimo, zbog određenosti, da je $A > 0$, $a > 0$ i $\delta_a < 1$. Tada možemo pisati $a(1 - \delta_a) \leq A \leq a(1 + \delta_a)$, ili skraćeno, $A = a(1 \pm \delta_a)$.

1.2 Osnovni izvori pogrešaka

1. Pogreške modela - dolaze od idealizacija i aproksimacija u formulaciji matematičkog modela. Primjer - linearizacija.
2. Rezidualne pogreške - dolaze od zamjena beskonačnih procesa konačnima. Primjer - računanje e^x .
3. Ulazne (početne) pogreške - dolaze od netočnih vrijednosti parametara modela. Primjer - fizikalne konstante, $g \approx 9.81$.
4. Pogreške zaokruživanja - dolazi od problema s predstavljanjem brojeva u danom brojevnom sustavu. Primjer - $\frac{1}{3} = 0.333$ unosi pogrešku $\Delta \approx 3 \times 10^{-4}$.
5. Pogreške operacija - netočni ulazi daju netočne rezultate.

Na neke izvore i tipove pogrešaka ne možemo utjecati, a neke možemo smanjiti ili izbjeći pažljivim pristupom. Često se događa da smanjenje pogreške jednog tipa vodi do povećanja pogreške drugog tipa. Treba balansirati cijenu (u vremenu i opremi) i kvalitetu rezultata.

Primjer 1.1:

Koliko je $(\sqrt{2})^2$? Koliko je star fosil dinosaura?

Prvo pitanje ima trivijalan odgovor, $(\sqrt{2})^2 = 2$. No što se zbiva pokušamo li ga izračunati zaokružujući rezultate na dvije decimale? Dobivamo $(\sqrt{2})^2 = 1.99$.

Drugo pitanje je vezano uz priču o čuvaru muzeja koji je na pitanje koliko je star fosil dinosaura odgovorio "Sedamdeset milijuna i trideset pet godina". Kad su ga pitali kako to tako točno zna, rekao je da su mu prvog radnog dana rekli da je fosil star sedamdeset milijuna godina, a on

radi u muzeju već trideset pet godina. Ova priča ilustrira ako ne opasnosti, a onda apsurdnost uporabe prevelike točnosti u računanju s podacima koji sami nisu dovoljno točni.

2 Približno rješavanje jednadžbi


Mnogi inženjerski problemi svode se na rješavanje jednadžbi oblika $f(x) = 0$. Samo u najjednostavnijim slučajevima moguće je naći rješenja takve jednadžbe u obliku formule. (To je moguće ako je $f(x)$ polinom stupnja najviše 4, no i u tom slučaju su formule nespretne i nepraktične. Za ostale funkcije $f(x)$ je rješenje pomoću formule moguće samo za specijalne kombinacije koeficijenata. Npr., $\sin x - \frac{1}{2} = 0$ ima rješenje $x = \frac{\pi}{6} + 2k\pi$, $x = \frac{5\pi}{6} + 2k\pi$, no $\sin x - \frac{1}{3} = 0$?) Za neke važnije jednadžbe su rješenja tabelirana i proglašena standardnim funkcijama (npr. $e^x - c = 0$, $\tan x - c = 0$ itd.).

U mnogim slučajevima ni koeficijenti nisu točno, već samo približno poznati, pa nema ni smisla govoriti o točnom ili egzaktnom rješenju. Stoga je važno biti u stanju naći približno rješenje jednadžbi.


2.1 Izoliranje rješenja

Promatramo jednadžbu $f(x) = 0$, gdje je funkcija f definirana i neprekidna na nekom intervalu $\langle a, b \rangle$ (koji može biti i beskonačan). Ponekad ćemo zahtijevati od f i određenu glatkost, tj. neprekidnost od f , f' i f'' .

Svaka vrijednost ξ za koju je $f(\xi) = 0$ je **korijen** ili **rješenje** jednadžbe $f(x) = 0$. Kažemo još da je ξ **nul-točka** funkcije f . Pretpostavljamo da f ima samo **izolirane** nul-točke, tj. da oko svake nul-točke postoji okolina na kojoj je $f(x) \neq 0$.



Slika 1: Primjeri funkcija s izoliranim (lijevo) i neizoliranim (desno) nul-točkama.



Slika 2: Primjeri intervala s više nultočaka i s jednom nul-točkom funkcije.

Približno rješavanje jednadžbe $f(x) = 0$ uključuje dva koraka:

1. Izoliranje korijena, tj. određivanje intervala $[a, b]$ koji sadrže jedan i samo jedan korijen.
2. Nalaženje korijena u tim intervalima uz zadanu točnost.


Teorem 1. *Ako neprekidna funkcija $f(x)$ na krajevima intervala $[a, b]$ ima vrijednosti suprotnih predznaka, $f(a)f(b) < 0$, onda u tom intervalu postoji barem jedna njena nul-točka.* $\square$

Nul-točka će biti **jedinstvena**, ako $f'(x)$ postoji i ne mijenja predznak na $\langle a, b \rangle$. Teorem 1 je specijalni slučaj tzv. teorema o međuvrijednostima koji kaže da neprekidna funkcija koja na krajevima nekog segmenta poprima određene (različite) vrijednosti negdje unutar tog segmenta poprima svaku međuvrijednost.

Danas je postupak izolacije rješenja bitno olakšan postojanjem softwera za crtanje grafova funkcija. Potrebno je pritom paziti na moguće lažne korijene.


Primjer 2.1:

$f(x) = \frac{1}{x}$ na $[-1000, 1000]$. Loš software (ili loš matematičar) nacrtat će ovakav graf.



Slika 3: Kako loš software crta graf funkcije $f(x) = \frac{1}{x}$.

Kvaliteta približnog rješenja - što je dobar kriterij? Jednom kad smo našli približno rješenje $\bar{x}$, zanima nas koliko je ono dobro, tj. koliko je ono blizu pravom rješenju ξ . Prva ideja, provjera koliko je $f(\bar{x})$ daleko od nule, nije dobra.



Slika 4: Što je dobra mjera kvalitete aproksimacije?

Teorem 2. *Neka je ξ točno, a $\bar{x}$ približno rješenje jednadžbe $f(x) = 0$ u intervalu $[a, b]$. Ako je u tom intervalu $|f'(x)| \geq m_1 > 0$, onda je*

$$|\bar{x} - \xi| \leq \frac{|f(\bar{x})|}{m_1}.$$

$\square$

Primjenom teorema srednje vrijednosti dobivamo

$$f(\bar{x}) - f(\xi) = f'(c)(\bar{x} - \xi),$$

gdje je c neka vrijednost između $\bar{x}$ i ξ , pa i između a i b . Odatle, zbog $f(\xi) = 0$ i $|f'(c)| \geq m_1$, slijedi

$$|f(\bar{x}) - f(\xi)| = |f(\bar{x})| \geq m_1 |\bar{x} - \xi|,$$

pa onda i tvrdnja teorema.

2.2 Metoda raspolavljanja (bisekcije)

Neka je funkcija $f(x)$ neprekidna na $[a, b]$ i neka je $f(a)f(b) < 0$. Dakle u $[a, b]$ postoji rješenje jednadžbe $f(x) = 0$.

Promatrajmo $f\left(\frac{a+b}{2}\right)$. Ako je $f\left(\frac{a+b}{2}\right) = 0$, našli smo rješenje. Ako nije, tada za točno jedan od intervala $\left[a, \frac{a+b}{2}\right]$ i $\left[\frac{a+b}{2}, b\right]$, funkcija ima različite predznake u rubovima. Nazovimo taj interval $[a_1, b_1]$ i ponovimo postupak. Nakon određenog broja koraka doći ćemo ili do točne vrijednosti rješenja ξ ili do tako malog intervala $[a_n, b_n]$ koji ju sadrži da nam je ta točnost dovoljna. Ako ne naiđemo na točno rješenje, dobivamo (beskonačan) niz ugniježđenih intervala $[a_1, b_1], [a_2, b_2], \dots, [a_n, b_n], \dots$ takvih da je


$$f(a_n)f(b_n) < 0 \quad \text{i} \quad b_n - a_n = \frac{1}{2^n}(b - a).$$

Lijevi rubovi intervala, $a_1, a_2, \dots, a_n, \dots$ čine monotono neopadajući niz i svi su manji od b ; dakle niz (a_n) je monoton i ograničen, pa i konvergentan. Slično niz (b_n) je monoton (nerastući), ograničen odozdo s a , pa je i on konvergentan.

Kako je $a_n \leq \xi \leq b_n$, iz $b_n - a_n = \frac{1}{2^n}(b - a) \rightarrow 0$ slijedi da je

$$\xi = \lim_{n \rightarrow \infty} a_n = \lim_{n \rightarrow \infty} b_n.$$


Očito je $0 \leq \xi - a_n \leq \frac{1}{2^n}(b - a)$ pa imamo i ocjenu pogreške. Metoda raspolavljanja je gruba,



Slika 5: Metoda raspolavljanja.

robustna i laka za implementaciju na računalu. Ne zahtijeva glatkost funkcije (tj. radi i za funkcije koje nisu derivabilne) i neosjetljiva je na strмину. Loša strana je polagana konvergencija. Koliko koraka treba za točnost od 10^{-3} za $b - a = 1$?

2.3 Metoda sekante (regula falsi)




Slika 6: Metoda sekante.

Zamijenimo komad grafa funkcije između a i b za koje je $f(a)f(b) < 0$ sekantom i pogledajmo gdje ta sekanta siječe os x . U situaciji kao na slici to vodi na niz aproksimacija $a = x_0 < x_1 < x_2 < \dots < x_n < x_{n+1} < \dots < \xi < b$, čiji je opći član definiran formulom

$$x_{n+1} = x_n - \frac{f(x_n)}{f(b) - f(x_n)}(b - x_n).$$

Uz pretpostavku da na $[a, b]$ postoji samo jedno rješenje, gornji niz aproksimacija (x_n) konvergira (monoton je i ograničen) prema rješenju ξ .

Vidimo da rub b ostaje fiksni u ovim iteracijama. Moguće su i situacije u kojima rub a ostaje fiksni. Ako postoji $f''(x)$, onda je pravilo da ostaje fiksni onaj rub u kojem je $f(x)$ istog predznaka kao i $f''(x)$. Sve aproksimacije su s iste strane korijena ξ , i to s one strane na kojoj je predznak od $f(x)$ suprotan predznaku od $f''(x)$.



Slika 7: Metoda sekante.

Za ocjenu pogreške imamo $|x_n - \xi| \leq \frac{f(x_n)}{m_1}$, gdje je $m_1 \leq |f'(x)|$ za $a \leq x \leq b$. Ako znamo ograde $m_1 \leq |f'(x)| \leq M_1$ na $[a, b]$, možemo dati i ocjenu pogreške oblika

$$|\xi - x_n| \leq \frac{M_1 - m_1}{m_1} |x_n - x_{n-1}|.$$


To nam daje kriterij zaustavljanja. Ova se ocjena dobije primjenom teorema srednje vrijednosti na formulu za x_n i korištenjem činjenice da derivacija ne mijenja predznak na promatranom intervalu.

2.4 Newtonova metoda (metoda tangente)

Neka je korijen ξ izoliran u $[a, b]$ i neka su $f'(x)$ i $f''(x)$ neprekidne i ne mijenjaju predznak na $[a, b]$. Znamo da od svih pravaca kroz neku točku na krivulji tu krivulju najbolje lokalno aproksimiramo tangentom. Povucimo tangentu kroz točku na desnom kraju intervala $[a, b]$ (u slučaju na slici kroz $(b, f(b))$) i pogledajmo gdje ona siječe os x . Nazovimo tu točku x_1 i povucimo tangentu kroz $(x_1, f(x_1))$. Ona siječe os x u x_2 . Nastavljajući taj postupak dobivamo niz

$$x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)},$$

koji izgleda kao da konvergira prema ξ . Sa slike vidimo da bi $x_0 = a$ odnijelo x_1 izvan intervala



Slika 8: Metoda tangente.


$[a, b]$. Pravilo je uzeti x_0 za koji je $f(x_0)f''(x_0) > 0$.

Teorem 3. Neka je $f(a)f(b) < 0$ i neka su $f'(x)$, $f''(x)$ neprekidne, različite od 0 i ne mijenjaju predznak na $[a, b]$. Tada, polazeći od x_0 za koji je $f(x_0)f''(x_0) > 0$, niz $x_{n+1} = x_n - \frac{f(x_n)}{f'(x_n)}$ konvergira prema rješenju ξ jednadžbe $f(x) = 0$. $\square$

Newtonova metoda je neprikladna za računanje nul-točaka u čijoj je okolini funkcija f malog nagiba.

Ako je $m_1 \leq |f'(x)|$ i $|f''(x)| \leq M_2$ na $[a, b]$, imamo ocjenu

$$|\xi - x_n| \leq \frac{M_2}{2m_1} |x_n - x_{n-1}|^2.$$



Slika 9: Modificirana metoda tangente.

Kažemo da je konvergencija Newtonove metode **kvadratična**. Gornja se ocjena dobiva polazeći od Taylorove formule

$$f(x_n) = f(x_{n-1}) + f'(x_{n-1})(x_n - x_{n-1}) + \frac{1}{2}f''(\xi_{n-1})(x_n - x_{n-1})^2$$

koja vrijedi za neki $\xi_{n-1} \in (x_n, x_{n-1})$. Kako prva dva člana na desnoj strani daju 0, po definiciji od x_n , ostaje nam

$$|f(x_n)| \leq \frac{1}{2}M_2(x_n - x_{n-1})^2.$$

Ocjena sada slijedi uvrštavanjem gornje nejednakosti za $|f(x_n)|$ u desnu stranu Teorema 3.

Newtonovu se metodu može modificirati tako da se izbjegne računanje derivacije u svakom koraku i da se jednom izračunata derivacija koristi u nekoliko uzastopnih koraka kao na slici. To rezultira sporijom konvergencijom.

2.5 Metoda iteracije (metoda fiksne točke)


Metoda se još zove i metoda sukcesivnih aproksimacija. Promatramo jednadžbu $f(x) = 0$ i zapišemo ju u obliku $x = \varphi(x)$, gdje je φ neprekidna funkcija. Uzmimo neku početnu aproksimaciju x_0 . Kad bi to bilo rješenje, vrijedilo bi $x_0 = \varphi(x_0)$. Kako nije, označimo $\varphi(x_0)$ s x_1 i ponovimo postupak:

$$x_1 = \varphi(x_0), x_2 = \varphi(x_1), \dots, x_{n+1} = \varphi(x_n).$$

Ako taj niz konvergira, onda je

$$\underbrace{\lim_{n \rightarrow \infty} x_{n+1}}_{\xi = \varphi(\xi)} = \lim_{n \rightarrow \infty} \varphi(x_n) = \varphi(\underbrace{\lim_{n \rightarrow \infty} x_n}_{\xi}),$$

tj. onda on konvergira prema rješenju jednadžbe $f(x) = 0$.



Slika 10: Različiti načini konvergencije metode iteracija: “stubište” (lijevo) i “spirala” (desno).

Teorem 4. Neka je funkcija $\varphi(x)$ definirana i derivabilna na $[a, b]$ i neka su joj sve vrijednosti u $[a, b]$. Ako postoji $0 < q < 1$ za koji je $|\varphi'(x)| \leq q < 1$ za sve $x \in [a, b]$, onda za svaki $x_0 \in [a, b]$ niz

$$x_n = \varphi(x_{n-1})$$

konvergira prema (jedinom) rješenju ξ jednadžbe $x = \varphi(x)$ u $[a, b]$. □

Funkcija φ koja zadovoljava uvjete Teorema 4 je **kontrakcija**. Za ocjenu pogreške imamo izraze

$$|\xi - x_n| \leq \frac{q^n}{1 - q} |x_1 - x_0|;$$

$$|\xi - x_n| \leq \frac{q}{1 - q} |x_n - x_{n-1}|.$$

Dokaz bi slijedio iz teorema srednje vrijednosti.

3 Aproksimacija i interpolacija

3.1 Problem aproksimacije funkcija

Promatramo funkciju $f : I \rightarrow \mathbb{R}$. Ponekad je potrebno umjesto funkcije f promatrati neku drugu funkciju φ koja joj je u izvjesnom smislu bliska. Ako aproksimacijska funkcija φ osim o x ovisi još i o parametrima $a_0, a_1, \dots, a_n$, tj.


$$\varphi(x) = \varphi(x, a_0, a_1, \dots, a_n),$$

onda se problem aproksimacije funkcije f funkcijom φ svodi na određivanje parametara $a_0, \dots, a_n$ prema nekom zadanom kriteriju. U ovisnosti o odabranom kriteriju imamo razne vrste aproksimacija.

Tipična situacija u kojoj imamo gornji problem je kad su vrijednosti nepoznate funkcije f poznate (ili dostupne) samo na diskretnom skupu $x_0, x_1, \dots, x_n$, a trebaju nam (približne) vrijednosti te funkcije u točkama koje nisu iz tog skupa.

Primjer 3.1:

U sljedećoj su tablici dana očitavanja temperature zraka na nekom mjestu u pune sate određenog dana.



Slika 11: Tablični i grafički prikaz podataka o temperaturi.

Što iz te tablice možemo zaključiti o temperaturi zraka na tom mjestu u 9 sati i 45 minuta? A u 16 sati i 15 minuta?


Druga tipična situacija je kad je funkcija f komplicirana i/ili skupa za računanje. Recimo vrijednost funkcije u točki x_0 zahtijeva 2 tjedna računa.

Kvaliteta (i smislenost) aproksimacije ovise o izboru oblika funkcije φ . Izbor neodgovarajuće funkcije daje, u pravilu, besmislen ili, u najboljem slučaju, jako loš rezultat.

3.2 Osnovni tipovi aproksimacijskih funkcija

Osnovna podjela je na **linearne** i **nelinearne** aproksimacijske funkcije. Opći oblik linearne aproksimacijske funkcije je

$$\varphi(x) = a_0\varphi_0(x) + a_1\varphi_1(x) + \dots + a_n\varphi_n(x)$$



Slika 12: Kakva je funkcija pogodna za aproksimaciju ovih podataka?

pri čemu funkcije $\varphi_0, \varphi_1, \dots, \varphi_n$ zadovoljavaju određene uvjete. Linearnost se odnosi na parametre $a_0, \dots, a_n$, oni u formulu ulaze linearno.


Za $\varphi_k(x) = x^k$ imamo $\varphi(x) = a_0 + a_1x + \dots + a_nx^n$, dakle aproksimaciju (algebarskim) polinomima.

Za $\{\varphi_k(x)\} = \{1, \cos x, \sin x, \cos 2x, \sin 2x, \dots\}$ imamo aproksimaciju trigonometrijskim polinomima.

Uzmemo li

$$\varphi_k(x) = (x - x_k)_+^m = \begin{cases} (x - x_k)^m & , \quad x \geq x_k \\ 0 & , \quad x < x_k \end{cases} ,$$

imamo aproksimaciju splineovima. Funkcije $(x - x_k)_+^m$ zovu se **prikraćene potencije** (truncated powers).



Slika 13: Prikraćena potencija.

Od nelinearnih aproksimacijskih funkcija često se koriste **eksponencijalna**

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


(gdje je $n + 1 = 2r + 2$, tj. $n = 2r + 1$), i **racionalna aproksimacija**

$$\varphi(x) = \varphi(x; b_0, \dots, b_r, c_0, \dots, c_s) = \frac{b_0 + b_1 x + \dots + b_r x^r}{c_0 + c_1 x + \dots + c_s x^s}$$

za koju je $n = r + s + 2$.

Izbor tipa aproksimacijske funkcije ovisi o poznavanju prirode problema koji generira podatke i o iskustvu.

Primjer 3.2:




Slika 14: Kakve su funkcije pogodne za aproksimaciju ovih podataka?

3.3 Kriteriji optimalnosti

Postoje različiti načini mjerenja “bliskosti” dviju funkcija. U nekim slučajevima nam je bitno podudaranje vrijednosti na nekom skupu točaka, kao na slici lijevo. U nekim drugim slučajevima su bolje druge mjere. Na slici u sredini su dvije funkcije koje možemo smatrati bliskima ako je kriterij površina ispod grafa funkcije, ali ne i ako je kriterij maksimalno odstupanje u točki. Slika desno prikazuje dvije funkcije kod kojih je razlika vrijednosti svugdje mala, no nigdje se ne podudaraju. Izbor kriterija ovisi o prirodi problema i formalizira se izborom norme ili udaljenosti u odgovarajućem funkcijskom prostoru.

Primjer 3.3:



Slika 15: Različiti kriteriji kvalitete aproksimacije.

Kvaliteta aproksimacije se mjeri malošću razlike funkcije i aproksimacije u odabranoj normi u funkcijskom prostoru kojem pripadaju.


Ako od aproksimacijske funkcije zahtijevamo podudaranje sa zadanim vrijednostima na konačnom (dakle diskretnom) skupu točaka, onda je kriterij za izbor parametara zadovoljavanje sustava jednadžbi

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

Takva aproksimacija se zove **interpolacija** funkcije f . Funkciju φ zovemo **interpolacijskom funkcijom**, a točke x_k , $k = 0, \dots, n$, u kojima se njene vrijednosti podudaraju sa zadanim, zovemo **čvorovima interpolacije**.

Kriterij kod interpolacije je poništavanje razlike funkcije i njene aproksimacije na zadanom diskretnom (štoviše, konačnom) skupu. Aproksimacija koja je dobra po tom kriteriju ne mora biti dobra ako gledamo odstupanja u drugim točkama ili razliku površina ispod grafova funkcije i njene aproksimacije.

Primjer 3.4:



Slika 16: Interpolacija – funkcija i aproksimacija se podudaraju u zadanim točkama.

Odstupanje u čvorovima je 0, no što ako nas zanima $|f(x) - \varphi(x)|$ na $[a, b]$? Što ako nas zanima $\int_a^b f(x)dx$? U tom slučaju je bolje uzeti druge mjere bliskosti:

$$\max_{x \in [a, b]} |f(x) - \varphi(x)|, \quad \text{ili} \quad \int_a^b (f(x) - \varphi(x))^2 dx.$$

Te mjere daju tzv. min-max aproksimaciju i srednje-kvadratnu aproksimaciju, redom. Te se mjere mogu definirati i na diskretnim skupovima.

Popularna je metoda aproksimacije zvana diskretna metoda najmanjih kvadrata, u kojoj se minimizira suma kvadrata odstupanja u zadanim točkama.

Primjer 3.5:

Odabрати parametre $a_0, \dots, a_n$ tako da zbroj kvadrata odstupanja aproksimacijske funkcije $\varphi(x; a_0, \dots, a_n)$ od vrijednosti funkcije f na zadanom skupu točaka bude najmanji mogući.

Imamo, dakle, problem minimizacije

$$\sum_{k=0}^n (f(x_k) - \varphi(x_k; a_0, \dots, a_n))^2 \rightarrow \min.$$

Koliko su ovakvi problemi rješivi? Pokazuje se da se svaka funkcija koja je neprekidna na $[a, b]$ može po volji dobro aproksimirati polinomom.

Teorem 5. (Weierstrass) Ako je funkcija $f \in C[a, b]$, onda $(\forall \varepsilon > 0)(\exists n \in \mathbb{N})$ i polinom $P_n(x)$ stupnja n takav da je $\forall x \in [a, b]$,

$$|f(x) - P_n(x)| \leq \varepsilon.$$

□

3.4.2 Lagrangeov oblik interpolacijskog polinoma

Uvedemo li oznaku

$$\omega(x) = \prod_{k=0}^n (x - x_k) = (x - x_0) \cdots (x - x_n),$$


imamo

$$L_k(x) = \frac{\omega(x)}{(x - x_k)\omega'(x_k)}.$$

Zašto? Polinomi $L_k(x)$ imaju svojstvo

$$L_k(x_j) = \delta_{kj} = \begin{cases} 1 & , \quad j = k, \\ 0 & , \quad j \neq k. \end{cases}$$

Zovemo ih **bazni polinomi**.



Slika 18: Bazni polinomi za Lagrangeovu interpolaciju.

Znamo li maksimum apsolutne vrijednosti $(n + 1)$ -ve derivacije od f ,

$$M_{n+1} = \max_{x \in [a, b]} |f^{(n+1)}(x)|,$$

možemo dati i ocjenu pogreške:

$$|f(x) - P_n(x)| \leq \frac{M_{n+1}}{(n + 1)!} |\omega(x)|.$$

Ocjena se dobiva promatranjem pomoćne funkcije

$$u(x) = f(x) - P_n(x) - k\omega(x),$$

gdje je k konstanta koja se bira tako da $u(x)$ ima, osim $n + 1$ nultočaka u točkama interpolacije, još jednu nultočku $\bar{x}$ u intervalu na kojem interpoliramo. Tvrdnja slijedi višekratnom primjenom Rolleovog teorema. Detalje izvoda zainteresirani čitatelj može naći na str. 548–549 knjige Demidovicha i Marona navedene u popisu literature. Problem je da za tabelirane vrijednosti x_k i f_k ne znamo što bi mogla biti dobra gornja granica za $|f^{(n+1)}(x)|$.

Zadatak 3.1:

Oredimo Lagrangeov interpolacijski polinom za podatke iz tablice

x_k	-1	0	2	3
$f(x_k)$	-1	2	10	35

Rješenje 3.1:

Ovdje je $x_0 = -1$, $x_1 = 0$, $x_2 = 2$ i $x_3 = 3$.

$$\begin{aligned}
L_0(x) &= \frac{(x-0)(x-2)(x-3)}{(-1-0)(-1-2)(-1-3)} = -\frac{1}{12}x(x-2)(x-3) \\
L_1(x) &= \frac{(x+1)(x-2)(x-3)}{(0-(-1))(0-2)(0-3)} = \frac{1}{6}(x+1)(x-2)(x-3), \quad \text{itd.}
\end{aligned} \tag{3.1}$$

Konačno, $P_3(x) = \frac{5}{3}x^3 - \frac{4}{3}x^2 + 2$. □

Ako su čvorovi ekvidistantni, $x_k - x_{k-1} = h$, ocjenu grješke možemo dati u obliku

$$|f(x) - P_n(x)| < \frac{M_{n+1}}{(n+1)!} h^{n+1}.$$

Lagrangeov oblik je konceptualno jednostavan, ali nije pogodan za numeriku. Posebno, dodavanje novog čvora znači računanje svega ispočetka.

3.4.3 Newtonov oblik interpolacijskog polinoma

Promatramo funkciju f zadanu svojim vrijednostima u čvorovima x_k , $k = 0, \dots, n$. **Podijeljena razlika** (reda 1, prva) funkcije f u točkama x_0 i x_1 je kvocijent

$$f[x_0, x_1] = \frac{f(x_1) - f(x_0)}{x_1 - x_0}.$$

Podijeljene razlike višeg reda definiraju se rekursivno:

$$f[x_0, \dots, x_r] = \frac{f[x_1, \dots, x_r] - f[x_0, \dots, x_{r-1}]}{x_r - x_0}.$$

Počnemo s $f[x_k] = f_k$, $k = 0, \dots, n$. Podijeljene razlike imaju svojstvo linearnosti, tj.

$$(\alpha f + \beta g)[x_0, \dots, x_r] = \alpha f[x_0, \dots, x_r] + \beta g[x_0, \dots, x_r].$$

Dalje, iz definicije podijeljene razlike vidimo da je

$$f[x_0, x_1] = \frac{f(x_0)}{x_0 - x_1} + \frac{f(x_1)}{x_1 - x_0}.$$

Odatle se indukcijom može pokazati da vrijedi

$$f[x_0, \dots, x_r] = \sum_{i=0}^r \frac{f(x_i)}{\omega'(x_i)},$$

gdje je $\omega(x) = (x - x_0) \cdots (x - x_r)$.

Pomoću podijeljenih razlika možemo dati alternativni zapis interpolacijskog polinoma za vrijednosti $f(x_k)$ u čvorovima x_k :

$$\begin{aligned}
P_n(x) &= f[x_0] + (x - x_0)f[x_0, x_1] + (x - x_0)(x - x_1)f[x_0, x_1, x_2] + \dots \\
&\quad + (x - x_0)(x - x_1) \cdots (x - x_{n-1})f[x_0, \dots, x_n].
\end{aligned}$$

To je Newtonov oblik interpolacijskog polinoma. Za njegovo računanje nam treba tablica podijeljenih razlika:

$$\begin{array}{ccccccc}
x_0 & \underline{f[x_0]} & & & & & \\
x_1 & f[x_1] & \cdots & \underline{f[x_0, x_1]} & & & \\
& & & f[x_1, x_2] & \cdots & \underline{f[x_0, x_1, x_2]} & \\
x_2 & f[x_2] & \cdots & & & f[x_0, x_1, x_2, x_3] & \\
& & & f[x_1, x_2, x_3] & \cdots & & \cdots \\
& & & & & \vdots & \underline{f[x_0, x_1, \dots, x_n]} \\
x_3 & f[x_3] & \cdots & & & \vdots & \cdots \\
& \vdots & & \vdots & & \vdots & \\
& \vdots & & \vdots & & \vdots & \\
& \vdots & & \vdots & f[x_{n-2}, x_{n-1}, x_n] & & \\
& \vdots & & \vdots & & & \\
x_n & f[x_n] & \cdots & f[x_{n-1}, x_n] & \cdots & &
\end{array}$$

Za računanje interpolacijskog polinoma nam trebaju samo podvučene podijeljene razlike iz gornje stranice trokuta.

Računamo podijeljene razlike po uzlaznim dijagonalama. Na taj način kod dodavanja nove točke možemo koristiti već izračunate koeficijente:

$$P_{n+1}(x) = P_n(x) + (x - x_0)(x - x_1) \cdots (x - x_n) f[x_0, x_1, \dots, x_{n+1}].$$

Ako su f_k vrijednosti funkcije kojoj znamo $(n + 1)$ -vu derivaciju, možemo dati ocjenu pogreške:

$$R_n(x, f) = f(x) - P_n(x) = \omega(x) f[x_0, x_1, \dots, x_n, x]$$

za neki x . Odatle slijedi ocjena

$$|R_n(x, f)| \leq \frac{M_{n+1}}{(n+1)!} \max_x |\omega(x)|,$$

gdje je M_{n+1} maksimum apsolutne vrijednosti $(n + 1)$ -ve derivacije od f na intervalu interpolacije. Što dobijemo kad pustimo $x_k \rightarrow x_0$ za sve k ? Taylorov polinom! Iz podijeljenih razlika se za ekvidistantne čvorove dobiju konačne razlike. Pomoću konačnih razlika organiziranih u trokutastu tablicu može se izvesti više interpolacijskih formula, npr. Gaussova, Besselova, Stirlingova, druga Newtonova itd.


Mogu se gledati i interpolacijski problemi u kojima su u pojedinim čvorovima zadane ne samo vrijednosti funkcije već i njenih derivacija. Polinomijalna interpolacija u takvom slučaju zove se Hermiteova interpolacija.

3.4.4 Problemi s polinomijalnom interpolacijom

Interpolacijski polinomi visokog stupnja ($n > 3$) daju jako velika odstupanja između točaka; veliko je $|f(x) - P_n(x)|$. Velike su oscilacije pogotovo blizu rubova intervala. Vrlo su strmi, što ih čini beskorisnima za procjenu derivacije od f . Osjetljivi su na “outliere”, tj. slučajnu kontaminaciju podataka.

Ekstrapolacija je aproksimacija vrijednosti nepoznate funkcije izvan intervala u kojem su nam neke njene vrijednosti poznate. Polinomijalna ekstrapolacija u pravilu ne daje dobre rezultate.

Primjer 3.6:



Slika 19: Primjeri skupova podataka koji se loše interpoliraju polinomima.

Rješenje - nepolinomijalna ili po dijelovima polinomijalna interpolacija. To nas vodi do **splineova**.

3.4.5 Splineovi



Slika 20: Spline.

Ime dolazi od elastične drvene ili metalne letvice (engl. *spline*) koja je nekad korištena za crtanje glatkih krivulja koje prolaze kroz zadane točke. Prolazimo od pretpostavke da letvica zauzima oblik u kojem se njena potencijalna energija minimizira. Potencijalna energija dolazi od elastičnosti i proporcionalna je integralu po splineu kvadrata njegove zakrivljenosti. Ako je oblik splinea opisan krivuljom $\Gamma = f(x)$, onda je potencijalna energija proporcionalna integralu:

$$\int_{\Gamma} \kappa(s)^2 ds = \int_a^b \frac{f''(x)^2}{(\sqrt{1 + f'(x)^2})^5} dx = E[f],$$

gdje je $\kappa(s)$ zakrivljenost krivulje Γ . Oblik koji spline zauzima je funkcija f koja minimizira funkciju E uz nametnuta ograničenja.

Za male vrijednosti od $f'(x)$ možemo zanemariti član $f'(x)^2$, pa u nazivniku dobijemo 1. Dakle minimiziramo integral (funkcional)

$$E[f] = \int_a^b f''(x)^2 dx.$$


Matematička teorija splineova i njihova primjena počinju se razvijati krajem prve polovice dvadesetog stoljeća (Collatz, Courant, Schoenberg). Mi ćemo promatrati **polinomske splineove**, tj. splineove koji su na svakom segmentu $[x_{i-1}, x_i]$ polinomi zadanog stupnja i koji se u čvorovima sastaju tako da se čuva zadana glatkost. Razliku između stupnja polinoma i zadane

glatkosti u čvorovima zvat ćemo **defekt** splinea. Prisjetimo se da je funkcija klase $C^k[a, b]$ ako su joj sve derivacije do reda uključivo k neprekidne na nekom otvorenom skupu koji sadrži segment $[a, b]$.

Funkcija $S_m^k(x)$ je **polinomski spline stupnja m i defekta k** ($1 \leq k \leq m$) s čvorovima $a = x_0 < x_1 < \dots < x_n = b$, ako vrijedi

- (i) $S_m^k(x)$ je polinom stupnja (najviše) m na svim $[x_{i-1}, x_i]$
- (ii) $S_m^k(x) \in C^{m-k}[a, b]$.

Obično se gledaju polinomski splineovi defekta 1. To znači da im je m -ta derivacija možda prekidna u čvorovima. Najjednostavniji slučaj su splineovi stupnja 0 i 1, prikazani na slici 21,



Slika 21: Splineovi stupnja 0 (lijevo) i 1 (desno).

dok se u praksi najčešće pojavljuju kubični i B-splineovi.

Kubični interpolacijski spline za funkciju f na čvorovima $a = x_0 < x_1 < \dots < x_n = b$ je funkcija $S_3(x)$ koja zadovoljava sljedeće uvjete

- (i) $S_3(x)$ je polinom stupnja najviše 3 na svim $[x_{i-1}, x_i]$, $i = 1, \dots, n$;
- (ii) $S_3(x) \in C^2[a, b]$;
- (iii) $S_3(x_i) = f(x_i)$, $i = 0, \dots, n$.

Uvjet (iii) ga čini interpolacijskim splineom.

Kubični spline interpolira funkciju f u čvorovima, neprekidan je zajedno sa svojom 1. i 2. derivacijom i na svakom je podintervalu polinom stupnja ne većeg od 3. Uvjet neprekidnosti 2. derivacije je vrlo bitan u mehaničkim primjenama (ubrzanje, tj. sila, ne smije imati skokove) i u računalnoj grafici.

Kubični spline se konstruira iz zadanih vrijednosti u čvorovima i uvjeta neprekidnosti derivacija. Kad se oni svi uzmu u obzir, ostaju dva slobodna parametra koje se fiksira dodatnim uvjetima. To su obično uvjeti tipa

- (i) $S_3'(a) = S_3'(b)$, $S_3''(a) = S_3''(b)$ - periodički spline
- (ii) $S_3'(a) = a$, $S_3'(b) = b$


$$(iii) S_3''(a) = A, \quad S_3''(b) = B.$$

U uvjetima tipa (iii) često se stavlja $S_3''(a) = f''(a)$, $S_3''(b) = f''(b)$, ako su vrijednosti druge derivacije na krajevima poznate. U mehaničkim modelima je često $A = B = 0$ pa se kubični spline s takvim uvjetima zove **prirodni kubični spline**.

Kako se splineovi matematički prikazuju? Koristi se baza **pikraćenih** potencija

$$(x - t)_+^k = \begin{cases} (x - t)^k, & x \geq t \\ 0, & x < t \end{cases}$$


Ovdje je t parametar kojim reguliramo područje na kojem je pikraćena potencija različita od nule. Uočimo da se za fiksni n i $k \leq n$ bazne funkcije stupnja $n - k$ mogu prikazati pomoću k -te derivacije od $(x - t)_+^n$ kao $((x - t)_+^n)^{(k)} = n(n - 1) \cdots (n - k + 1)(x - t)_+^{n-k}$. Štoviše, uzimanje cijele desne strane ovog izraza kao bazne funkcije umjesto $(x - t)_+^{n-k}$ rezultira bazom u kojoj se kao koeficijenti pojavljuju manji brojevi. Bazni skup tako modificiranih pikraćenih potencija za $n = 3$ prikazan je na sljedećoj slici.



Slika 22: Baza pikraćenih potencija.

Interpolacija kubičnim splineovima je globalna - spline svuda ovisi o vrijednosti u svakom čvoru. Alternativni način je prikaz pomoću B-splineova. **B-spline** je po dijelovima polinom stupnja m koji je različit od 0 samo na $m + 1$ podintervalu (lokalnost).

Primjer 3.7:



Slika 23: B-splineovi stupnja 1 (lijevo) i 2 (desno).

Na slici su prikazani B-splineovi stupnja 1 (lijevo) i 2 (desno). Vidimo da se svaki linearni B-spline sastoji od dva linearna komada, a svaki kvadratični B-spline od tri luka parabole. Kod

linearnog B-splinea se čuva samo neprekidnost u čvorovima, dok se kod kvadratičnog čuva i glatkost, tj. komadi su spojeni tako da prva derivacija nema prekida. $S(x) = \sum_i a_i \cdot B_i(x)$ je prikaz splinea $S(x)$ u bazi B-splineova. Prikaz preko B-splineova je kompaktan, numerički stabilan, lako se računa (lako za računalo). Mana im je da su komplicirani za manipulaciju - korisnici se moraju osloniti na standardne programske pakete.

Osim u interpolaciji, splineovi se koriste i u drugim tipovima aproksimacija - srednje kvadratnoj, metodi konačnih elemenata itd. Poopćavaju se na dvije i više dimenzija.

3.4.6 Zaključak

Polinomijalnom interpolacijom se služimo u tri standardne situacije:

1. Izvodi formula - numeričko integriranje, deriviranje, približno rješavanje jednadžbi.
2. Lokalna zamjena/manipulacija podacima - treba imati neku ideju o tome kako se funkcija (ili tabelirani podatci) lokalno ponaša - treba formulirati model. Polinomi nekog stupnja su obično dobar model ako u blizini nema singulariteta i/ili kontaminacija.
3. Globalna zamjena/manipulacija podacima - polinomi su rijetko kad dobar globalni model. Splineovi su bolji, no čak i njima je teško interpolirati mnoge situacije koje se često javljaju. U globalnom je slučaju bolje ići na druge tipove aproksimacija (npr. metoda najmanjih kvadrata i sl.).

4 Numeričko integriranje

4.1 Uvod

Za funkciju f neprekidnu na $[a, b]$ za koju znamo primitivnu funkciju F , određeni integral $\int_a^b f(x)dx$ računamo po Newton-Leibnizovoj formuli:

$$\int_a^b f(x)dx = F(b) - F(a).$$

(Za primitivnu funkciju $F(x)$ vrijedi $F'(x) = f(x)$).

U mnogim slučajevima primitivnu funkciju nije moguće izraziti preko elementarnih funkcija; u nekim drugim slučajevima, čak i kad primitivna funkcija može biti izražena preko elementarnih funkcija, formule mogu biti prekomplikirane i/ili nepraktične. Osim toga, u praksi je $f(x)$ često zadana tablično pa se i ne može govoriti o primitivnoj funkciji. Stoga je bitno razviti metode za približno računanje određenih integrala.

Kako je računanje određenog integrala, ustvari, računanje površine nekog lika, numerička integracija se često zove i **numerička (mehanička) kvadratura**. Formule za približno računanje određenih integrala zovu se i **kvadraturene formule**. Kad je riječ o računanju dvostrukih integrala, imamo mehaničku kubaturu i **kubaturene formule**.

Problem numeričke kvadrature je problem računanja određenog integrala na temelju niza (konačnog) vrijednosti integranda. Standardni pristup je zamjena integranda $f(x)$ na segmentu $[a, b]$ interpolacijskom ili aproksimacijskom funkcijom $\varphi(x)$ tako da bude približno zadovoljena jednakost

$$\int_a^b f(x)dx \approx \int_a^b \varphi(x)dx.$$

Pri tome se funkcija $\varphi(x)$ odabire tako da se $\int_a^b \varphi(x)dx$ može izravno i točno izračunati. Ako je $f(x)$ zadana analitički, dobro bi bilo znati procijeniti pogrješku.

Pretpostavimo da za funkciju $f(x)$ znamo vrijednosti u $n + 1$ točki $x_0, x_1, \dots, x_n \in [a, b]$. Koristeći vrijednosti $y_i = f(x_i)$ možemo konstruirati Lagrangeov interpolacijski polinom

$$P_n(x) = \sum_{i=0}^n L_i(x)y_i,$$

gdje je

$$L_i(x) = \frac{\omega(x)}{(x - x_i)\omega'(x_i)}.$$

Odatle,

$$\int_a^b f(x)dx = \int_a^b P_n(x)dx + R_n[f],$$

gdje je $R_n[f]$ pogrješka. Približna formula je

$$\int_a^b f(x)dx \approx \sum_{i=0}^n A_i y_i,$$

gdje je

$$A_i = \int_a^b L_i(x) dx, \quad i = 0, 1, \dots, n.$$

Ako su granice a, b među interpolacijskim čvorovima, ove su kvadrature formule **zatvorenog tipa**; inače su **otvorenog tipa**.

Kako računamo A_i ? Uočimo sljedeće:

- (i) A_i su neovisni o funkciji f , ovise samo o čvorovima interpolacije.
- (ii) Gornja formula mora biti **točna** za polinome stupnja najviše n (jer je interpolacijski polinom jedinstven). Odatle slijedi da formula mora biti točna za sve x^k , $k = 0, \dots, n$, tj. $R_n[x^k] = 0$ za $k = 0, \dots, n$.

Uvrštavajući $f(x) = x^k$, $k = 0, \dots, n$, u kvadraturnu formulu, dobivamo sustav od $n + 1$ jednadžbi za nepoznate koeficijente od A_i :

$$\begin{aligned} \sum_{i=0}^n A_i &= I_0 \\ \sum_{i=0}^n A_i x_i &= I_1 \\ &\vdots \\ \sum_{i=0}^n A_i x_i^n &= I_n, \end{aligned}$$

gdje su desne strane točni integrali,

$$I_k = \int_a^b x^k dx = \frac{b^{k+1} - a^{k+1}}{k+1}.$$

Gornji sustav uvijek ima rješenje (za čvorove x_i koji su svi različiti), jer je determinanta matrice tog sustava Vandermondeova determinanta:

$$\begin{vmatrix} 1 & 1 & \cdots & 1 \\ x_0 & x_1 & \cdots & x_n \\ x_0^2 & x_1^2 & \cdots & x_n^2 \\ \vdots & \vdots & & \vdots \\ x_0^n & x_1^n & \cdots & x_n^n \end{vmatrix} = \prod_{0 \leq i < j \leq n} (x_j - x_i) \neq 0.$$

Uočimo da se ne mora eksplicitno računati sam interpolacijski polinom $P_n(x)$.

Primjer 4.1:

Nađimo kvadraturnu formulu oblika

$$\int_0^1 f(x) dx \approx A_0 f\left(\frac{1}{4}\right) + A_1 f\left(\frac{1}{2}\right) + A_2 f\left(\frac{3}{4}\right).$$

Rješenje 4.1:

Uvrstimo x^0 , x^1 i x^2 u formulu gore i uvrštavajući $\int_0^1 x^k dx = \frac{1}{k+1}$, dobivamo sustav jednažbi

$$\begin{aligned}A_0 + A_1 + A_2 &= 1 \\ \frac{1}{4}A_0 + \frac{1}{2}A_1 + \frac{3}{4}A_2 &= \frac{1}{2} \\ \frac{1}{16}A_0 + \frac{1}{4}A_1 + \frac{9}{16}A_2 &= \frac{1}{3}.\end{aligned}$$

Rješenje je $A_0 = \frac{2}{3}$, $A_1 = -\frac{1}{3}$ i $A_2 = \frac{2}{3}$. Dakle je

$$\int_0^1 f(x)dx \approx \frac{2}{3}f\left(\frac{1}{4}\right) - \frac{1}{3}f\left(\frac{1}{2}\right) + \frac{2}{3}f\left(\frac{3}{4}\right) = \frac{1}{3}\left(2f\left(\frac{1}{4}\right) - f\left(\frac{1}{2}\right) + 2f\left(\frac{3}{4}\right)\right).$$

Dobivena formula je otvorenog tipa i točna je za sve polinome stupnja najviše 2. Što se događa uvrstimo li u nju $f(x) = x^3$?

$$\int_0^1 x^3 dx = \frac{1}{3}\left(\frac{2}{64} - \frac{1}{8} + \frac{54}{64}\right) = \frac{1}{3}\left(\frac{48}{64}\right) = \frac{1}{4} \quad !$$

Vidimo da je formula točna i za polinome 3. stupnja! Kasnije ćemo vidjeti da se neočekivano povišenje točnosti javlja i za neke druge kvadraturene formule s neparnim brojem točaka. $\square$

4.2 Newton-Cotesove kvadraturene formule

Formule kakve smo izveli u prijašnjem primjeru pripadaju formulama Newton-Cotesovog tipa. Primjenjuju se kad je funkcija zadana u fiksnim čvorovima koje ne možemo birati po volji.

Promatrajmo $\int_a^b f(x)dx$. Podijelimo $[a, b]$ na n podintervala ekvidistantnim točkama $x_0 = a, x_1, \dots, x_n = b$. Vrijedi $x_i - x_{i-1} = h$, tj. $x_i = x_0 + ih$, $i = 0, \dots, n$. Tada je $h = \frac{b-a}{n}$. Označimo $y_i = f(x_i)$, $i = 0, \dots, n$. Zamjenjujući $f(x)$ Lagrangeovim interpolacijskim polinomom dobivamo

$$\int_{x_0}^{x_n} f(x)dx \approx \sum_{i=0}^n A_i y_i.$$

Uvodeći oznaku $q = \frac{x-x_0}{h}$ možemo prijeći na novu varijablu integracije. Primijetimo da za $x = x_i$ imamo $q = i$. Dalje, $q^{[n+1]} = q(q-1)\cdots(q-n)$, je **padajuća potencija** od q . Lagrangeovi interpolacijski polinom u varijabli q sada ima oblik

$$P_n(x) = \sum_{i=0}^n \frac{(-1)^{n-i}}{i!(n-i)!} \frac{q^{[n+1]}}{q-i} y_i$$

Uvrštavajući to u kvadraturnu formulu dobivamo

$$A_i = \int_{x_0}^{x_n} \frac{(-1)^{n-i}}{i!(n-i)!} \frac{q^{[n+1]}}{q-i} dx.$$

Prijedemo na integraciju po q : $q = \frac{x-x_0}{h}$, $dq = \frac{dx}{h}$, $dx = h dq$

$$A_i = \int_0^n h \frac{(-1)^{n-i}}{i!(n-i)!} \frac{q^{[n+1]}}{q-i} dq = h \frac{(-1)^{n-i}}{i!(n-i)!} \int_0^n \frac{q^{[n+1]}}{q-i} dq, \quad i = 0, 1, \dots, n.$$

Iz $h = \frac{b-a}{n}$ stavimo $A_i = (b-a)H_i$, gdje su

$$H_i = \frac{1}{n} \frac{(-1)^{n-i}}{i!(n-i)!} \int_0^n \frac{q^{[n+1]}}{q-i} dq, \quad i = 0, 1, \dots, n,$$

Cotesovi koeficijenti. Dakle je

$$\int_a^b f(x) dx \approx (b-a) \sum_{i=0}^n H_i y_i,$$

gdje je $h = \frac{b-a}{n}$, $y_i = f(x_0 + ih)$,


$$H_i = \frac{1}{n} \frac{(-1)^{n-i}}{i!(n-i)!} \int_0^n \frac{q^{[n+1]}}{q-i} dq, \quad i = 0, 1, \dots, n.$$

Za Cotesove koeficijente vrijedi

$$\sum_{i=0}^n H_i = 1, \quad H_i = H_{n-i}.$$

Iz općenitog računa koji smo proveli sada možemo za različite n dobiti odgovarajuće kvadrature formule jednostavnim uvrštavanjem n i računanjem Cotesovih koeficijenata. Najjednostavniji je slučaj $n = 1$.

4.3 Trapezna formula



Slika 24: Trapezna formula.

Uvrštavajući $n = 1$ u formulu za H_i , $i = 0, 1$, dobivamo

$$H_0 = - \int_0^1 \frac{q(q-1)}{q} dq = \frac{1}{2}$$

$$H_1 = \int_0^1 q dq = \frac{1}{2}.$$

Dakle je

$$\int_{x_0}^{x_1} f(x) dx \approx \frac{h}{2} (y_0 + y_1) - \text{trapezna formula.}$$

Što možemo reći o ostatku (pogrješci) ove formule? Očito taj ostatak ovisi i o funkciji f i o odabranom koraku h . U računu koji slijedi naglasit ćemo ovisnost o h i pisati $R(h)$; kad budemo govorili o ocjeni pogrješke, naglašavat ćemo ovisnost o f i pisati $R[f]$.

$$R(h) = \int_{x_0}^{x_1} f(x)dx - \frac{h}{2}(y_0 + y_1).$$

Ako je $f(x)$ dovoljno glatka, možemo izvesti ocjenu za $R(h)$.

$$R(h) = \int_{x_0}^{x_1} f(x)dx - \frac{h}{2} \left(f(x_0) + f(x_0 + h) \right).$$

Deriviramo ovo po h , dvaput:

$$\begin{aligned} R'(h) &= f(x_0 + h) - \frac{1}{2} \left[f(x_0) + f(x_0 + h) \right] - \frac{h}{2} f'(x_0 + h) \\ &= \frac{1}{2} \left[f(x_0 + h) - f(x_0) \right] - \frac{h}{2} f'(x_0 + h) \\ R''(h) &= \frac{1}{2} f'(x_0 + h) - \frac{1}{2} f'(x_0 + h) - \frac{h}{2} f''(x_0 + h) = -\frac{h}{2} f''(x_0 + h). \end{aligned}$$

Znamo da je $R(0) = 0$, $R'(0) = 0$. Integrirajući gornju relaciju i primjenjujući (dvaput) integralni teorem srednje vrijednosti, dobivamo

$$\begin{aligned} R'(h) &= R'(0) + \int_0^h R''(t)dt = -\frac{1}{2} \int_0^h t f''(x_0 + t)dt \\ &= -\frac{1}{2} f''(\xi_h) \int_0^h t dt = -\frac{h^2}{4} f''(\xi_h), \quad \text{za neki } \xi_h \in \langle x_0, x_0 + h \rangle \\ R(h) &= R(0) + \int_0^h R'(t)dt = -\frac{1}{4} \int_0^h t^2 f''(\xi_t)dt. \end{aligned}$$

Odatle,


$$R(h) = -\frac{h^3}{12} f''(\xi),$$

za neki $\xi \in \langle x_0, x_0 + h \rangle$. Ako je f konveksna na $[x_0, x_1]$ imamo preveliku, ako je konkavna, imamo premalu vrijednost integrala. Znamo li $M_2 = \max_{x \in [x_0, x_1]} |f''(x)|$, možemo ocijeniti pogrješku formulom

$$|R[f]| \leq \frac{M_2}{12} h^3.$$

4.4 Simpsonova formula

Simpsonovu kvadraturnu formulu dobivamo računajući Cotesove koeficijente za $n = 2$. Uvr-



Slika 25: Simpsonova formula.

stavajući $n = 2$ u formulu za H_i , $i = 0, 1, 2$, dobivamo

$$\begin{aligned} H_0 &= \frac{1}{2} \frac{1}{2} \int_0^2 (q-1)(q-2) dq = \frac{1}{6} \\ H_1 &= -\frac{1}{2} \frac{1}{1} \int_0^2 q(q-2) dq = \frac{2}{3} \\ H_2 &= \frac{1}{2} \frac{1}{2} \int_0^2 q(q-1) dq = \frac{1}{6} \quad - \text{ mogli smo i iz simetrije.} \end{aligned}$$

Odatle, zbog $x_2 - x_0 = 2h$, imamo

$$\boxed{\int_{x_0}^{x_2} f(x) dx \approx \frac{h}{3} \left(f(x_0) + 4f(x_1) + f(x_2) \right)} \quad - \text{ Simpsonova formula}$$

Računom sličnim onom koji smo proveli kod trapezne formule može se pokazati da je

$$\boxed{|R_2[f]| \leq \frac{h^5}{90} M_4,}$$

gdje je $M_4 = \max_{x \in (x_0, x_2)} |f^{(4)}(x)|$. Vidimo da je Simpsonova formula točna i za polinome stupnja 3 - slično primjeru iz uvoda. Ponovo imamo bonus, što Simpsonovu formulu čini vrlo pogodnom za praktičnu primjenu - uz malo točaka daje (dosta) visoku točnost.

4.5 Newton-Cotesove formule viših redova

Za $n = 3$ računanjem Cotesovih koeficijenata dobivamo tzv. **Newtonovu kvadraturnu formulu** (poznatu još i kao formula 3/8):

$$\boxed{\int_{x_0}^{x_3} f(x) dx \approx \frac{3h}{8} \left(f(x_0) + 3f(x_1) + 3f(x_2) + f(x_3) \right)}$$

Za ocjenu pogreške dobivamo $|R_3[f]| \leq \frac{3h^5}{80} M_4$. Vidimo da je ona istog reda kao i za Simpsonovu formulu.


Newton-Cotesove formule postaju nepraktične za $n \sim 8$ i više. Ostatci su reda veličine $O(h^{2\lfloor n/2 \rfloor + 3})$, gdje je $\lfloor n/2 \rfloor$ najveće cijelo u $\frac{n}{2}$. Vidimo da kvaliteta raste skokovito za 2 pri prijelazu s parnog na neparni broj točaka i ostaje ista pri prijelazu s neparnog na sljedeći parni broj točaka.

n	$\hat{H}_0$	$\hat{H}_1$	$\hat{H}_2$	$\hat{H}_3$	$\hat{H}_4$	$\hat{H}_5$	$\hat{H}_6$	$\hat{H}_7$	D_n
1	1	1							2
2	1	4	1						6
3	1	3	3	1					8
4	7	32	12	32	7				90
5	19	75	50	50	75	19			288
6	41	216	27	272	27	216	41		840
7	751	3577	1323	2989	2989	1323	3577	751	17280

Newton-Cotesove koeficijente H_i za zadani n dobivamo iz gornje tablice kao kvocijente brojnika $\hat{H}_i$ i nazivnika D_n , $H_i = \frac{\hat{H}_i}{D_n}$ za $i = 0, 1, \dots, n$.

Problemi s Newton-Cotesovim formulama visokog reda rješavaju se tako da se područje integracije podijeli na podintervale na kojima se onda primjenjuju N-C formule nižeg reda. To vodi do tzv. poopcjenih kvadrature formula.

4.6 Poopcjena trapezna formula



Slika 26: Poopcjena trapezna formula.

Podijelimo područje integracije $[a, b]$ na n podintervala točkama $a = x_0, x_1, \dots, x_n = b$, gdje je $x_i = x_0 + ih$, $h = \frac{b-a}{n}$ i na svakom intervalu $[x_{i-1}, x_i]$ primijenimo trapeznu formulu.

$$\int_a^b f(x)dx \approx \frac{h}{2}(y_0 + y_1) + \frac{h}{2}(y_1 + y_2) + \frac{h}{2}(y_2 + y_3) + \dots + \frac{h}{2}(y_{n-1} + y_n)$$


$$\int_a^b f(x)dx \approx \frac{h}{2} \left[f(x_0) + 2f(x_1) + \dots + 2f(x_{n-1}) + f(x_n) \right]$$

Za ostatak se može izvesti formula koja vodi na ocjenu grješke

$$|R_{n+1}[f]| \leq \frac{b-a}{12} M_2 h^2,$$

gdje je M_2 definiran kao za jednostavnu trapeznu formulu. Vidimo da je pogreška drugog reda u h , što je lako objasniti činjenicom da se u njoj zbraja n pogrešaka jednostavne trapezne formule, a $n = \frac{b-a}{h}$.

4.7 Poopćena Simpsonova formula



Slika 27: Poopćena Simpsonova formula.

Ako je broj podintervala paran, možemo na dva po dva podintervala zamijeniti graf funkcije interpolacijskom parabolom, tj. integrirati pomoću Simpsonove formule

$$h = \frac{b-a}{n} = \frac{b-a}{2m}$$

$$\begin{aligned} \int_a^b f(x)dx &\approx \frac{h}{3}(y_0 + 4y_1 + y_2) + \frac{h}{3}(y_2 + 4y_3 + y_4) + \dots + \frac{h}{3}(y_{2m-2} + 4y_{2m-1} + y_{2m}) = \\ &= \frac{h}{3} \left[y_0 + y_{2m} + 4 \underbrace{(y_1 + y_3 + \dots + y_{2m-1})}_{\sigma_1} + 2 \underbrace{(y_2 + y_4 + \dots + y_{2m-2})}_{\sigma_2} \right] \end{aligned}$$

$$\boxed{\int_a^b f(x)dx \approx \frac{h}{3} \left(y_0 + y_{2m} + 4\sigma_1 + 2\sigma_2 \right)}$$

Za ostatak se dobiva

$$-\frac{mh^5}{90}f^{(4)}(\xi) = -\frac{b-a}{180}h^4f^{(4)}(\xi) \quad \text{za } \xi \in \langle a, b \rangle,$$

odakle slijedi ocjena pogreške

$$|R_{2m+1}[f]| \leq \frac{b-a}{180}M_4h^4,$$

gdje je $M_4 = \max_{x \in (a,b)} |f^{(4)}(x)|$.

4.8 Gaussove kvadraturene formule

Promatramo funkciju $f : [-1, 1] \rightarrow \mathbb{R}$. Želimo odabrati točke $t_1, t_2, \dots, t_n$ i koeficijente $A_1, A_2, \dots, A_n$ tako da formula

$$\int_{-1}^1 f(t) dt = \sum_{i=1}^n A_i f(t_i)$$

bude točna za polinome što je moguće višeg stupnja N . Koji je najviši mogući stupanj N za koji se možemo nadati točnosti? Imamo $2n$ slobodnih parametara, u najboljem slučaju možemo dobiti formulu točnu za polinome do stupnja $2n-1$. Uvrštavajući funkcije $f(t) = 1, t, t^2, \dots, t^{2n-1}$ u gornju formulu i računajući egzaktno integrale $\int_{-1}^1 t^k dt$ dobivamo sustav od $2n$ jednažbi s $2n$ nepoznanica

$$\begin{aligned} \sum_{i=1}^n A_i &= 2 \\ \sum_{i=1}^n A_i t_i &= 0 \\ &\vdots \\ \sum_{i=1}^n A_i t_i^{2n-2} &= \frac{2}{2n-1} \\ \sum_{i=1}^n A_i t_i^{2n-1} &= 0 \end{aligned}$$

Ovaj sustav je **nelinearan** jer se nepoznanice A_i i t_i u njemu javljaju s potencijama i međusobno se množe. Može se pokazati da se uzimanjem t_i kao nul-točaka Legendreovih polinoma taj sustav može svesti na linearan sustav za A_i , čija je matrica regularna (ima Vandermondeovu determinantu).

Legendreovi polinomi su polinomi ortogonalni na $[-1, 1]$ koji zadovoljavaju rekurzivne relacije

$$P_0(x) = 1, \quad P_1(x) = x, \quad nP_n(x) = (2n-1)xP_{n-1}(x) - (n-1)P_{n-2}(x).$$

Ortogonalni su, ali nisu ortonormirani:

$$\int_{-1}^1 P_m(x) P_n(x) dx = \frac{2}{2n+1} \delta_{mn}.$$

Prvih nekoliko je

$$\begin{aligned} P_0(x) &= 1 \\ P_1(x) &= x \\ P_2(x) &= \frac{1}{2}(3x^2 - 1) \\ P_3(x) &= \frac{1}{2}(5x^3 - 3x) \\ P_4(x) &= \frac{1}{8}(35x^4 - 30x^2 + 3). \end{aligned}$$

Osim toga, $P_n(1) = 1$, $P_n(-1) = (-1)^n$ i $\int_{-1}^1 P_n(x)Q_k(x)dx = 0$, za sve polinome $Q_k(x)$ stupnja manjeg od n .

Primjer 4.2:

Gaussova kvadratura formula za $n = 3$. Odaberimo t_i kao nultočke Legendreovog polinoma $P_3(t) = \frac{1}{2}t(5t^2 - 3)$. Dakle je $t_1 = -\sqrt{\frac{3}{5}}$, $t_2 = 0$, $t_3 = \sqrt{\frac{3}{5}}$. Koeficijenti A_i se određuju iz (linearnog) sustava

$$\left. \begin{aligned} A_1 + A_2 + A_3 &= 2 \\ -\sqrt{\frac{3}{5}}A_1 + \sqrt{\frac{3}{5}}A_2 &= 0 \\ \frac{3}{5}A_1 + \frac{3}{5}A_2 &= \frac{2}{3} \end{aligned} \right\} \quad A_1 = A_3 = \frac{5}{9}, \quad A_2 = \frac{8}{9}.$$

Dakle imamo

$$\int_{-1}^1 f(t)dt \approx \frac{1}{9} \left[5f\left(-\sqrt{\frac{3}{5}}\right) + 8f(0) + 5f\left(\sqrt{\frac{3}{5}}\right) \right]$$

Može se pokazati da je ostatak dan formulom

$$R_3[f] = \frac{1}{15750} f^{(6)}(\xi), \text{ za neki } \xi \in [-1, 1],$$

odakle slijedi ocjena pogreške

$$|R_3[f]| \leq \frac{M_6}{15750},$$

gdje je $M_6 = \max_{x \in (-1,1)} |f^{(6)}(x)|$. □

Vidimo da je točnost formule bolja od točnosti Simpsonove koja koristi isti broj točaka.

Općenito, za $\int_a^b f(x)dx$ prvo transformiramo interval integracije na $[-1, 1]$ supstitucijom $x = \frac{b+a}{2} + \frac{b-a}{2}t$ i onda primjenjujemo Gaussove formule

$$\int_a^b f(x)dx \approx \frac{b-a}{2} \sum_{i=1}^n A_i f(x_i),$$

gdje je $x_i = \frac{b+a}{2} + \frac{b-a}{2}t_i$, a t_i su nul-točke Legendreovog polinoma $P_n(t)$. Ocjena pogreške je oblika


$$|R_n[f]| \leq \frac{(b-a)^{2n+1}}{2n+1} \frac{(n!)^4}{((2n)!)^3} M_{2n},$$

gdje je $M_{2n} = \max_{x \in (a,b)} |f^{(2n)}(x)|$.


Postoje i drugi tipovi Gaussovih kvadrature formula. U svima se pojavljuju nul-točke ortogonalnih polinoma (Čebiševljevih, Laguerreovih, Hermiteovih). Obično su tabelirane, zajedno s pripadajućim koeficijentima A_i .

4.9 Mogući problemi

Prije računanja integrala treba nastojati upoznati ponašanje funkcije na području integracije. U primjeru na slici bi kvadratura formula s ekvidistantnim čvorovima $x_0, \dots, x_n$ dala $\int_a^b f(x)dx <$



Slika 28: Patološki primjer za ekvidistantne čvorove.



Slika 29: Brzooscilirajuća funkcija.


0, dok je, očito, prava vrijednost pozitivna. Notorno teško za integrirati su brzo-oscilirajuće funkcije, čak i kad ne mijenjaju predznak, jer se gubi sva informacija o ponašanju između čvorova. U takvim je situacijama potrebno integrirati posebno pozitivni i posebno negativni dio (ako je moguće). Ako je moguće treba uzeti više točaka. Najbolje je koristiti posebne metode prilagođene za brzo varirajuće funkcije.

Poglavlje zaključujemo kratkim sažetkom postupka kojeg se dobro držati kad se javi potreba za numeričkim integriranjem neke funkcije:

- Saznati što je više moguće o ponašanju funkcije.
- Nacrtati graf (ako je moguće).
- Odabrati metodu primjerenu ponašanju funkcije i zahtijevanoj točnosti. Rabiti specijalno prilagođene metode ako je funkcija lošeg ponašanja.
- Odabrati čvorove primjereno ponašanju funkcije.
- Usporediti rezultate različitih metoda - nominalno točnija ne mora nužno biti bolja.

4.10 Kubaturne formule i višestruki integrali

Kod računanja višedimenzionalnih integrala broj točaka (pa onda i broj računskih operacija) vrlo brzo rastu - dolazi do tzv. kombinatorne eksplozije. Za niske dimenzije (2 i 3) kubaturne formule Newton-Cotesovog i Gaussovog tipa još daju prihvatljive rezultate. Za više dimenzije je uglavnom zgodnije koristiti tzv. Monte Carlo metode. Ideja Monte Carlo metode je ilustrirana



Slika 30: Metoda Monte Carlo za dvostruke integrale.

na slici 30. Želimo li izračunati površinu lika D , uzmemo neki pravokutnik koji sadrži D i generiramo slučajne točke koje su uniformno raspodijeljene u tom pravokutniku. Imamo li dovoljno mnogo točaka, razumno je očekivati da će omjer broja onih koje su u D i njihovog ukupnog broja biti dobra aproksimacija omjera površine lika D i površine pravokutnika.

Kubaturne formule se javljaju, npr. kod računanja elemenata matrice krutosti za 2-D i 3-D konačne elemente.

5 Obične diferencijalne jednačbe

Promatramo Cauchyjev problem za obične diferencijalne jednačbe (ODJ) 1. reda

$$\left. \begin{aligned} y' &= f(x, y) \\ y(x_0) &= y_0 \end{aligned} \right\}$$

Većina metoda koje rade za ovaj problem izravno se poopćava i na sustave ODJ.

Primjer 5.1:

$$\begin{aligned} y_1' &= y_1 + y_2, & y_1(0) &= 0 \\ y_2' &= -y_1 + y_2, & y_2(0) &= 1 \end{aligned}$$

□

ODJ višeg reda mogu se svesti na sustav ODJ 1. reda.

Primjer 5.2:

Promatramo ODJ 4. reda

$$y^{(4)} + (x+1)y' + y + x + 1 = 0$$

Uvodimo nove varijable z , u i v kao $y' = z$, $z' = u$, $u' = v$.

Dobivamo sustav

$$\underbrace{\begin{bmatrix} y \\ z \\ u \\ v \end{bmatrix}'}_{\vec{\omega}'} = \begin{bmatrix} z \\ u \\ v \\ -(x+1)z - y - x - 1 \end{bmatrix}$$

$$\vec{\omega}' = \underbrace{A(x)\vec{\omega} + \vec{f}_0(x)}_{\vec{f}(x, \vec{\omega})}$$

gdje je

$$A(x) = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ -1 & -(x+1) & 0 & 0 \end{bmatrix}, \quad \vec{f}_0(x) = \begin{bmatrix} 0 \\ 0 \\ 0 \\ -(x+1) \end{bmatrix}.$$

□


Ako je polazna jednačba n -tog reda, dobije se sustav n -tog reda. Ako je jednačba linearna, sustav je linearan.

Pri numeričkom rješavanju ODJ javljaju se problemi stabilnosti i krutosti.


Primjer 5.3:

$$y' = 4y - 5e^{-x}, \quad y(0) = 1$$

Opće rješenje pripadne homogene jednačbe $y' = 4y$ je $y_H = Ce^{4x}$. Oblik funkcije smetnje sugerira partikularno rješenje $y_P = e^{-x}$, a početni uvjet daje $C = 0$. Rješenje našeg problema je, dakle, $y = e^{-x}$.



Slika 31: Nestabilnost rješenja u ovisnosti o koraku h .



Slika 32: Eulerova metoda.

Pogledajmo što se zbiva rješavamo li našu jednadžbu numerički. Pokazuje se da i najmanje pogreške u ulaznim podacima uzrokuju odstupanje od točnog rješenja i komad e^{4x} postaje dominantan. Rješenje je **nestabilno**, mala perturbacija na ulazu dovodi do velikih odstupanja u rezultatu. Nestabilnost je uzrokovana velikim (> 1) korijenom karakteristične jednadžbe ($\lambda - 4 = 0$). Čak i za jednadžbe koje imaju stabilna rješenja može doći do nestabilnosti zbog svojstava numeričke metode. Drugi problem je **krutost**. Javlja se pogotovo kod sustava ODJ kad se razne funkcije (nepoznanice) različito ponašaju - jedna se brzo mijenja, druga sporo. Korak diskretizacije koji je dobar za onu koja se sporo mijenja je besmislen za onu drugu, korak dobar za onu koja se brzo mijenja vodi do ogromnog utroška računalnih resursa.

5.1 Eulerova metoda

Promatramo Cauchyjev problem

$$\left. \begin{array}{l} y' = f(x, y) \\ y(x_0) = y_0 \end{array} \right\}$$


Najjednostavnija ideja je iz poznate vrijednosti y_0 za $x = x_0$ dobiti vrijednost u $x_0 + h$ kao

$$y(x_0 + h) \approx y_0 + h \underbrace{f(x_0, y_0)}_{y'(x_0)}$$

Općenito, za $y(x_i) = y_i$ vrijednosti u x_{i+1} dobivamo kao

$$y_{i+1} = y_i + hf(x_i, y_i) - \text{Eulerova metoda.}$$

U gornjoj formuli i u ostatku ovog odjeljka y_i označava približnu vrijednost (nepoznatog) točnog rješenja $y(x)$ u čvoru x_i .




Slika 33: Odnos pogreške metode i pogreške zaokruživanja.

Eulerova metoda je vrlo jednostavna no nije jako dobra u praksi jer brzo akumulira pogreške. Pogreška se može smanjiti smanjenjem koraka h , no to vodi do rasta pogreške zaokruživanja. Ukupna pogreška sastoji se od pogreške metode, koja raste s korakom h , i pogreške zaokruživanja koja pada s korakom h . Nije moguće proizvoljno smanjiti i jednu i drugu. Njihov odnos je prikazan na gornjoj slici.

Eulerova metoda odgovara integraciji metodom pravokutnika.

5.2 Poboljšana Eulerova metoda



Slika 34: Poboljšana Eulerova metoda.

Modifikacija Eulerove metode u kojoj se nagib pod kojim se kreće iz x_i korigira koristeći informaciju o (procijenjenom) nagibu u x_{i+1} , zove se poboljšana Eulerova metoda.

$$y_{i+1}^* = y_i + hf(x_i, y_i)$$

$$y_{i+1} = y_i + \frac{1}{2}h \left[f(x_i, y_i) + f(x_{i+1}, y_{i+1}^*) \right]$$

Korigirani nagib je aritmetička sredina nagiba u (x_i, y_i) (tj. vrijednosti $y'(x_i) = f(x_i, y_i)$) i procijenjenog nagiba u (x_{i+1}, y_{i+1}) . Zašto moramo procjenjivati nagib u (x_{i+1}, y_{i+1}) ? Zašto ne uzeti točno $f(x_{i+1}, y_{i+1})$? Zato što ne znamo y_{i+1} . Procijenimo ga linearnom aproksimacijom iz (x_i, y_i) .

Što ako zanemarimo da ne znamo y_{i+1} ? Dobivamo formulu

$$y_{i+1} = y_i + \frac{1}{2}h \left[f(x_i, y_i) + f(x_{i+1}, y_{i+1}) \right].$$

To je **implicitna Adamsova formula 2. reda**. Ponekad se Adamsova formula može eksplicitno riješiti po y_{i+1} , recimo kad je $f(x, y)$ linearno u y . Može se i iterativno rješavati.

5.3 Metode Runge-Kutta

Eulerova metoda temelji se na linearnoj ekstrapolaciji funkcije $y(x)$. Pokušajmo uvidjeti što možemo dobiti kvadratnom ekstrapolacijom. Uzmimo $x_0 = 0$, pretpostavimo da je $y(x) = \alpha + \beta x + \gamma x^2$ u okolini 0 i odredimo nepoznate koeficijente α , β i γ tako da jednadžba bude zadovoljena u okolini 0,

$$y'(x) = \beta + 2\gamma x = f(x, \alpha + \beta x + \gamma x^2).$$

Aproksimirajmo (zamijenimo) sada desnu stranu njenim Taylorovim polinomom u okolini točke $(0, \alpha)$.

$$\beta + 2\gamma x = f(0, \alpha) + x \frac{\partial f}{\partial x}(0, \alpha) + (\beta x + \gamma x^2) \frac{\partial f}{\partial y}(0, \alpha)$$

Zbog $y(0) = y_0$ mora biti $\alpha = y_0$. Izjednačavajući koeficijente uz potencije od x koliko se god može (ovdje do x^1) dobivamo

$$\beta = f(0, \alpha), \quad 2\gamma = \frac{\partial f}{\partial x}(0, \alpha) + \beta \frac{\partial f}{\partial y}(0, \alpha).$$

Stavimo li $\gamma = 0$ dobijemo Eulerovu metodu, linearnu ekstrapolaciju

$$y(h) = y(0) + hf(0, y_0) + \frac{h^2}{2} \left[\frac{\partial f}{\partial x}(0, y_0) + f(0, y_0) \frac{\partial f}{\partial y}(0, y_0) \right].$$

Sada treba aproksimirati $\frac{\partial f}{\partial x}(0, y_0)$ i $\frac{\partial f}{\partial y}(0, y_0)$. Dovoljno je uzeti najjednostavniju aproksimaciju konačnim razlikama jer su već množene sa h^2 , što je malo.

$$\begin{aligned} \frac{\partial f}{\partial x}(0, y_0) &= \frac{1}{h} [f(h, y_0) - f(0, y_0)] \\ \frac{\partial f}{\partial y}(0, y_0) &= \frac{1}{h} [f(j, y_0 + k) - f(j, y_0)]. \end{aligned}$$

Ovdje su j i k veličine sličnog reda kao i h . Možemo ih odabrati po volji. Neki od mogućih izbora su:

$$\begin{array}{ll} (1) & j = 0, \quad k = hf(0, y_0) \\ (2) & j = 0, \quad k = hf(h, y_0) \end{array} \quad \begin{array}{ll} (3) & j = h, \quad k = hf(0, y_0) \\ (4) & j = h, \quad k = hf(h, y_0) \end{array}$$

Na primjer, treći izbor daje

$$y = y_0 + hf(0, y_0) + \frac{h^2}{2} \left[\frac{1}{h} (f(h, y_0) - f(0, y_0)) + f(0, y_0) \frac{f(h, y_0 + h) - f(h, y_0)}{hf(0, y_0)} \right]$$

$$y = y_0 + \frac{h}{2} \underbrace{f(0, y_0)}_{k_1} + \frac{h}{2} \underbrace{f(h, y_0 + hf(0, y_0))}_{k_2}$$

Uz gornje oznake imamo

$$k_1 = hf(0, y_0)$$

$$k_2 = hf\left(h, y_0 + \frac{k_1}{2}\right)$$

$$y(h) = y_0 + \frac{1}{2}k_1 + \frac{1}{2}k_2$$

Općenito iz (x_i, y_i) dobivamo (x_{i+1}, y_{i+1}) formulama

$$\left. \begin{aligned} k_1 &= hf(x_i, y_i) \\ k_2 &= hf\left(x_{i+1}, y_i + \frac{1}{2}k_1\right) \\ y_{i+1} &= y_i + \frac{1}{2}k_1 + \frac{1}{2}k_2 \end{aligned} \right\} \text{Runge-Kutta metoda drugog reda (= poboljšana Eulerova metoda). Odgovara integraciji trapeznom formulom u kojoj je } y(h) \text{ ocijenjen jednostavnom Eulerovom metodom.}$$

$$y(h) \approx y_0 + \frac{h}{2} \left[f(0, h) + f\left(h, \underbrace{y(h)}_{y_0 + hf(0, y_0)}\right) \right].$$

Korištenjem Taylorovih polinoma višeg stupnja dobiju se formule za Runge-Kutta metode viših redova. Najčešće se koriste Runge-Kutta metode četvrtog reda:


$$\left. \begin{aligned} k_1 &= hf(x_i, y_i) \\ k_2 &= hf\left(x_i + \frac{h}{2}, y_i + \frac{k_1}{2}\right) \\ k_3 &= hf\left(x_i + \frac{h}{2}, y_i + \frac{k_2}{2}\right) \\ k_4 &= hf(x_{i+1}, y_i + k_3) \\ y_{i+1} &= y_i + \frac{1}{6}k_1 + \frac{1}{3}k_2 + \frac{1}{3}k_3 + \frac{1}{6}k_4 \end{aligned} \right\} \text{Runge-Kutta metoda četvrtog reda. Koeficijenti se dobivaju kao (nejednoznačna) rješenja nelinearnih sustava.}$$

Sve opisane metode su **jednokoračne**. Postoje i **višekoračne** metode, prediktor-korektor formule itd.

6 Matrice i linearni sustavi

6.1 Izvori problema

Brojni fizikalni (posebno građevinski) problemi vode na sustave linearnih jednažbi. Npr., sile koje djeluju na most na slici (težina mosta i vozila) uravnotežene su silama na krajevima mosta. Te se sile propagiraju duž nosača i u svakom čvoru njihova rezultanta mora biti jednaka nuli (inače bi se most počeo gibati). Razložimo li ih u horizontalne i vertikalne komponente, zbroj



Slika 35: Ovo bi moglo voditi na linearni sustav ...

komponentata svakog tipa mora biti 0 u svakom čvoru; dakle u svakom čvoru imamo dvije jednažbe. Za m čvorova dobijemo $\sim 2m$ jednažbi. Poznate veličine (težine mosta i vozila) idu na desnu stranu, ostale se slažu u matricu sustava koja obično ima specijalnu strukturu.

Drugi tip izvora problema s linearnim sustavima su metode diskretizacije i aproksimacije. Tako se numeričko rješavanje običnih i parcijalnih diferencijalnih jednažbi svodi na rješavanja linearnih sustava, u kojima su nepoznanice vrijednosti rješenja u čvorovima (metoda konačnih razlika) ili koeficijenti u prikazu rješenja pomoću baznih funkcija (metode konačnih elemenata). I matrice takvih sustava obično imaju specijalnu strukturu.


6.2 Tipovi matrica

Najčešće ćemo promatrati **kvadratne** matrice $A \in M_n$. U praksi se često javljaju matrice visokog reda često i do $n \sim 100000$.

Kod takvih matrica bi i sam smještaj na računalu bio velik problem. Sretna okolnost je da je većina matrica koje se javljaju u praksi **rijetka**. Matrica reda n je **rijetka** (engl. *sparse*) ako je većina njenih elemenata jednaka nuli. Obično se smatra da je matrica rijetka ako je broj ne-nul elemenata mali u usporedbi s n^2 . U praksi to najčešće znači da je broj ne-nul elemenata linearan u n .

Rijetkost matrice je najčešće posljedica **lokalnosti** modela, tj. činjenice da udaljeni dijelovi modela ne interagiraju ili dovoljno slabo utječu jedan na drugoga da to možemo zanemariti. Npr., izvori na modelu mosta interagiraju samo ako su povezani nosačem. Konačni elementi daju ne-nul element u matrici krutosti samo ako su blizu.

Osim rijetkosti, lokalnost najčešće diktira i **vrpčastu** ili **trakastu** strukturu matrice (engl. *band matrix*). Matrica A je vrpčasta ako postoji neki $d > 0$ takav da je $a_{ij} = 0$ za $|i - j| > d$. Ne moraju svi elementi u vrpci širine d biti različiti od nule.



Slika 36: Vrpčasta matrica.

Primjere vrpčastih matrica smo vidjeli kod metode konačnih razlika i metoda konačnih elemenata. Najjednostavnije (netrivijalne) vrpčaste matrice su **trodiagonalne** matrice za koje je $d = 1$.

Matrica A je **simetrična** ako je $A = A^T$, tj. $a_{ij} = a_{ji}$, $\forall i, j$.

Mnogi fizikalni problemi, posebno ravnotežni, vode na simetrične matrice. Takve matrice trebaju manje memorije i (obično) manje računanja.

Ako za svaki $\vec{x} \neq \vec{0}$ vektor vrijedi $\vec{x}^T A \vec{x} > 0$ (≥ 0), matrica A je **pozitivno definitna** (**pozitivno semidefinitna**). Ovdje oznaka $\vec{x}^T A \vec{x}$ znači $(\vec{x}^T A) \vec{x}$. Simetrične matrice su često i pozitivno (semi)definitne. Pozitivno definitne matrice su regularne. Dobra vijest je da mnoge metode diskretizacije vode na pozitivno definitne matrice, što znači da su sustavi jednoznačno rješivi. Za simetrične i pozitivno definitne matrice postoje metode koje su efikasnije od metoda za općenite matrice.

Matrica A je **donja (gornja) trokutasta** ako je $a_{ij} = 0$ za $i < j$ ($i > j$). Sustavi s takvim matricama se vrlo lako rješavaju pa se one često javljaju kao matrice na koje se svode općenite matrice.

Matrica A je **ortogonalna** ako je $A^{-1} = A^T$, odnosno $AA^T = I$. Sustav $A\vec{x} = \vec{b}$ se trivijalno rješava kao $\vec{x} = A^T \vec{b}$. Ortogonalne matrice ne mijenjaju duljinu vektora koje množe.

Matrica A je **dijagonalna** ako je $a_{ij} = 0$ za $i \neq j$. Računanje s dijagonalnim matricama je trivijalno. Nalaženje baze u kojoj će prikaz matrice A biti dijagonalan vodi na problem svojstvenih vrijednosti.

Matrica A je **dijagonalno dominantna** ako vrijedi

$$|a_{ii}| \geq \sum_{i=1, j \neq i}^n |a_{ij}|, \quad \forall i = 1, \dots, n,$$

i za bar jedan i vrijedi stroga nejednakost. A je **strogo dijagonalno dominantna** ako stroga nejednakost vrijedi za sve $i = 1, \dots, n$.

6.3 Tipovi problema

U praksi se najčešće javljaju **linearni sustavi**, tj. **sustav linearnih jednadžbi**:

$$A\vec{x} = \vec{b}.$$

Matrična jednadžba $AX = B$ u kojoj treba naći nepoznatu matricu X tipa (u, p) nije ništa drugo nego skup od p linearnih sustava, $A\vec{x}_1 = \vec{b}_1$, $A\vec{x}_2 = \vec{b}_2$, $\dots$, $A\vec{x}_p = \vec{b}_p$. Znamo li riješiti linearni sustav, znamo i matričnu jednadžbu.

U teoriji, rješenje sustava $A\vec{x} = \vec{b}$ (ako postoji i jedinstveno je) dano je formulom $\vec{x} = A^{-1}\vec{b}$. U praksi, gotovo se nikad ne radi tako, jer je računanje inverzne matrice neefikasno.

Također, u praksi malu važnost ima i determinanta. **Cramerovo pravilo** je iznimno neefikasan način rješavanja sustava. Ni kriterij $\det A \neq 0$ nije ključan, jer se u praksi uvijek javljaju greške zaokruživanja.

Glavna ideja kod rješavanja sustava je manipulacijom svesti njegovu matricu na oblik iz kojeg se rješenja lako dobivaju. Dakle sustav $A\vec{x} = \vec{b}$ svodi se na $T\vec{x} = \vec{c}$, gdje je T trokutasta matrica ili na neki drugi pogodan oblik.

Pokušamo li matricu sustava svesti na najjednostavniji oblik, tj. na dijagonalan, imamo problem svojstvenih vrijednosti. Ako za matricu A postoji matrica E takva da je $E^{-1}AE = D$, gdje je D dijagonalna matrica, onda stupce od E zovemo **svojstvenim vektorima**, a (dijagonalne) elemente od D **svojstvenim vrijednostima**. Iz $AE = ED$ vidimo da to znači $A\vec{e}_i = d_i\vec{e}_i$, što je upravo definicija svojstvene vrijednosti d_i i pripadnog svojstvenog vektora $\vec{e}_i$. Ako je A simetrična, onda su sve njene svojstvene vrijednosti realne.

6.4 Tipovi metoda

Metode za rješavanje linearnih sustava dijele se na **izravne** (direktne) i **iteracijske**.

Izravnim metodama se poslije konačnog broja računskih operacija, ako nema pogrešaka zaokruživanja, dolazi do točnog rješenja sustava. Kod iteracijskih metoda rješenje sustava dobivamo kao limes beskonačnog niza aproksimacija.

Zašto bi itko htio koristiti iteracijske metode kad daju samo približno rješenje? Dva razloga: U praksi se i izravnim metodama (u pravilu) dobivaju približna rješenja, zbog pogrešaka zaokruživanja. Osim toga, za mnoge matrice sa specijalnom strukturom iteracijske metode konvergiraju brzo i ukupan broj računskih operacija može biti osjetno manji nego za izravnu metodu, a točnost je još uvijek prihvatljiva. U pravilu je izravnim metodama potrebno $\sim n^3$ operacija. Taj se broj smanjuje za rijetke matrice, no red veličine ostaje. Iteracijske metode za rijetke matrice obično trebaju puno manje od n^2 operacija za jedan korak iterativnog postupka, što znači da i uz puno koraka još mogu biti brže od izravnih. Manje su osjetljive i na grešku zaokruživanja. Činjenica da je konvergencija zajamčena samo za dijagonalno dominantne simetrične matrice nije veliki problem jer su mnoge matrice koje se javljaju u nama zanimljivim primjenama upravo toga tipa. Iteracijski postupci obično zahtijevaju i manje memorije.

Najpoznatije izravne metode su Gaussove eliminacije (s modifikacijama kao što su Gauss-Jordanove eliminacije i uz djelomično ili potpuno pivotiranje) te rastav Choleskog. Najčešće korištene iteracijske metode su Jacobijeva, Gauss-Seidelova i SOR metoda.

6.5 Gaussove eliminacije

Gaussove eliminacije koriste se za rješavanje linearnih sustava još od antike. Glavna ideja je svesti sustav $A\vec{x} = \vec{b}$ na ekvivalentan sustav s jednostavnijom matricom (dva sustava su ekvivalentna ako je svako rješenje jednog sustava ujedno i rješenje drugog sustava i obratno). To se postiže konačnim brojem elementarnih transformacija:

- (i) zamjena dviju jednadžbi;
- (ii) množenje jedne jednadžbe brojem različitim od nule;
- (iii) dodavanje jedne jednadžbe pomnožene nekim brojem nekoj drugoj jednadžbi.

Za sustav $A\vec{x} = \vec{b}$ s kvadratnom matricom koja je regularna, elementarne transformacije se rade tako da se matrica A svede na gornju trokutastu. Ako matrica A nije regularna, elementarnim transformacijama se dobiva ekvivalentan sustav koji nema jedinstveno rješenje. Radi se s proširenom matricom sustava

$$\left[\begin{array}{cccc|c} a_{11} & a_{12} & \cdots & a_{1n} & b_1 \\ a_{21} & a_{22} & \cdots & a_{2n} & b_2 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} & b_n \end{array} \right] \sim \dots \sim \left[\begin{array}{cccc|c} u_{11} & \cdots & u_{1p} & u_{1,p+1} & \cdots & u_{1n} & c_1 \\ \vdots & \ddots & \vdots & & & & \vdots \\ 0 & & u_{pp} & u_{p,p+1} & \cdots & u_{pn} & c_p \\ 0 & \cdots & 0 & 0 & \cdots & 0 & c_{p+1} \\ \vdots & & \vdots & \vdots & & \vdots & \vdots \\ 0 & \cdots & 0 & 0 & \cdots & 0 & c_n \end{array} \right],$$

gdje su $u_{ii} \neq 0$ za $i = 1, \dots, p$.

Ako je $p < n$ i barem jedan od $c_{p+1}, \dots, c_n \neq 0$, sustav nema rješenja. Ako je $p = n$, dobili smo ekvivalentan sustav $U\vec{y} = \vec{c}$, u kojem je matrica sustava gornja trokutasta, a vektor nepoznanica $\vec{y}$ je neka permutacija vektora nepoznanica $\vec{x}$ (ako se rade transformacije samo nad retcima, $\vec{y} = \vec{x}$).

Elementarne transformacije nad retcima mogu se zapisati pomoću matričnog množenja. Primjena transformacija zamjene i -tog i j -tog retka može se zapisati kao množenje matrice A s lijeva matricom P_{ij} koja se dobiva od jedinične matrice I zamjenom i -tog i j -tog retka (matrica P_{ij} je **permutacijska** matrica). Matrice kojima opisujemo elementarne transformacije zovemo **elementarnim matricama**.


Može se pokazati da je produkt svih elementarnih matrica kojima smo množili A , kako bismo dobili U , regularna donja trokutasta matrica. Označimo ju s E . Imamo, dakle, $EA = U$, odnosno $A = E^{-1}U$, pri čemu je E^{-1} i sama donja trokutasta. Označimo ju s L . Imamo $A = LU$, tj. matrica sustava A je prikazana kao produkt donje (L) i gornje (U) trokutaste matrice. Kažemo da Gaussove eliminacije daju **LU - faktORIZACIJU** matrice A .

Broj operacija potrebnih za rješavanje sustava $A\vec{x} = \vec{b}$ je reda veličine $O(n^3)$. Točnije:

Teorem 7. *Neka je A regularna matrica reda n . Tada se sustav linearnih jednadžbi $A\vec{x} = \vec{b}$ može riješiti Gaussovim postupkom eliminacije s $\frac{n}{3}(n^2 + 3n - 1)$ množenja i $\frac{n}{6}(2n^2 + 3n - 5)$ zbrajanja.* $\square$

6.5.1 Modifikacije Gausovih eliminacija - pivotiranje

Zbog numeričke stabilnosti algoritma dobro je birati **ključni element** (onaj kojim radimo eliminacije) tako da bude što je moguće veći (po apsolutnoj vrijednosti). To možemo postići tako da na glavnu dijagonalu u k -tom koraku dovedemo najveći (po modulu) element k -tog stupca (zamjenom redaka) ili najveći (po modulu) element dolje desno od k (zamjenom odgovarajućih redaka i stupaca). Prvi postupak se zove **parcijalno** (djelomično), a drugi **potpuno pivotiranje**. Teorijski se realiziraju množenjem permutacijskim matricama. To poskupljuje račun, posebno potpuno pivotiranje kod kojeg je potrebno i prenumerirati nepoznanice. U praksi se pokazuje da je djelomično pivotiranje dobar kompromis, tj. da uz razumno produljenje računa dobivamo zadovoljavajuću numeričku stabilnost.



Slika 37: Djelomično (lijevo) i potpuno (desno) pivotiranje.

6.5.2 Gauss-Jordanove eliminacije

Ako Gaussovim eliminacijama matricu sustava ne svodimo prvo na gornju trokutastu već odmah na dijagonalnu, dobivamo Gauss-Jordanove eliminacije.

$$\left[\begin{array}{ccc|c} a_{11} & \cdots & a_{1n} & b_1 \\ \vdots & & \vdots & \vdots \\ a_{n1} & \cdots & a_{nn} & b_n \end{array} \right] \sim \left[\begin{array}{ccc|c} a'_{11} & 0 & & b'_1 \\ & \ddots & & \vdots \\ 0 & & a'_{kk} & \vdots \\ \hline & & 0 & \vdots \\ & & a'_{kn} & \vdots \\ & & & \ddots \\ 0 & & & b'_k \end{array} \right] \sim \left[\begin{array}{ccc|c} a'_{11} & & 0 & c_1 \\ & \ddots & & \vdots \\ 0 & & a'_{nn} & c_n \end{array} \right]$$

Gauss-Jordanov postupak treba oko 50% više operacija za rješavanje linearnog sustava ($\sim \frac{n^3}{2}$), no ravnopravan je Gaussovim eliminacijama za problem nalaženja inverzne matrice.

Teorem 8. Inverzna matrica A^{-1} regularne matrice A reda n , može se odrediti Gaussovim (ili Gauss-Jordanovim) eliminacijama uz n^3 množenja i $n(n-1)^2$ zbrajanja. $\square$

6.6 Simetrične matrice

Za neke simetrične matrice je moguće sačuvati simetriju i u njihovom LU-rastavu.

Teorem 9. Simetrična realna matrica A reda n može se faktorizirati kao $A = LL^T$, gdje je L regularna realna donja trokutasta matrica, ako i samo ako je matrica A pozitivno definitna. $\square$

Ako matrica A nije pozitivno definitna u jednom se trenutku u računu pojavljuju kompleksni brojevi. Gornji rezultat daje i najjeftiniji kriterij provjere pozitivne definitnosti.

Metoda rješavanja linearnog sustava temeljem LL^T rastava zove se još i **metoda drugog korijena** ili **metoda Choleskog**. Broj operacija se reducira (otprilike) na pola u odnosu na Gaussove eliminacije.

Daljnje smanjenje broja potrebnih operacija moguće je za rijetke i/ili vrpčaste matrice. Primjerice, za matrice s vrpcom širine d , broj operacija je $\sim d^2n$. Mnoge matrice koje se javljaju u diskretizacijama PDJ imaju $d \sim \sqrt{n}$ pa za njih Gaussove eliminacije trebaju $\sim n^2$ operacija.

	1	2				k
k+1						2k

$n(= k^2)$

Zašto je $d \sim \sqrt{n}$?

6.7 Analiza pogreške izravnih metoda

Glavni izvor pogrešaka kod izravnih metoda su početne greške u koeficijentima i greške zaokruživanja tijekom postupka.

Sustav $A\vec{x} = \vec{b}$ je loše uvjetovan ako male relativne promjene u elementima od A i $\vec{b}$ mogu dovesti do velikih relativnih promjena u rješenju $\vec{x}$. U suprotnom je sustav **dobro uvjetovan**.

Primjer 6.1:

Promatramo sustave

$$2x_1 - x_2 = 3$$

$$x_1 + x_2 = 3$$

$$2x_1 - x_2 = 3$$

$$2x_1 - 1.0001x_2 = 2.9999$$

Rješenje oba sustava je $x_1 = 2, x_2 = 1$. Promijenimo sada slobodni član druge jednadžbe u oba sustava za $\Delta = 0.0003$:

$$2x_1 - x_2 = 3$$

$$x_1 + x_2 = 3.0003$$

$$2x_1 - x_2 = 3$$

$$2x_1 - 1.0001x_2 = 3.0002$$

Rješenje prvog sustava je $x_1 = 2.0001, x_2 = 1.0002$ dok je rješenje drugog sustava $x_1 = 0.5, x_2 = -2$! Drugi sustav je primjer loše uvjetovanog sustava. $\square$

Treba nam nešto za matrice što bi odgovaralo pojmu duljine (norme) vektora. Time ćemo moći ocijeniti učinjenu pogrešku iz “ostatka”, tj. iz toga koliko dobro približno rješenje zadovoljava jednadžbu.

Primjer 6.2:

Neka je x' približno rješenje linearne jednadžbe $ax = b$. Neka je $r = b - ax'$. Tada je

$$|x - x'| \leq |a^{-1}| |r|.$$

Tvrdnja slijedi iz $r = b - ax' = ax - ax' = a(x - x')$, tj.

$$|r| = |a| |x - x'|.$$

Vidimo da “kvaliteta” rješenja ovisi o “kvaliteti” koeficijenta a . Nešto slično će vrijediti i za linearne sustave.

Teorem 10. Neka je A regularna matrica i $\vec{x}'$ približno rješenje sustava $A\vec{x} = \vec{b}$ i neka je $\vec{r} = \vec{b} - A\vec{x}'$. Tada je

$$\|\vec{x} - \vec{x}'\| \leq \|A^{-1}\| \cdot \|\vec{r}\|.$$

gdje je s $\|\vec{r}\|$ označena neka norma vektora $\vec{r}$, npr. $\|\vec{r}\| = \sqrt{\vec{r} \cdot \vec{r}}$. Odgovarajuća norma $\|A\|$ matrice A definira se kao

$$\|A\| = \sup_{\vec{x} \neq \vec{0}} \frac{\|A\vec{x}\|}{\|\vec{x}\|}.$$

□

Ovako definirana matricna norma zove se **prirodna matricna norma** inducirana vektorskom normom $\|\cdot\|$. Ima puno vektorskih (pa onda i matricnih) normi, no može se pokazati da su one sve ekvivalentne.

Uvjetovanost $k(A)$ kvadratne regularne matrice A za danu prirodnu normu $\|\cdot\|$ je broj $k(A) = \|A\| \cdot \|A^{-1}\|$. Uvjetovanost je uvijek veća ili jednaka od 1, jer je za svaku prirodnu normu $\|I\| = 1$, a za sve norme vrijedi $\|AB\| \leq \|A\| \cdot \|B\|$. Poželjna uvjetovanost je mala, iako velika uvjetovanost ne znači nužno da je i sustav loše uvjetovan.

6.8 Jacobijeva metoda

Jacobijeva metoda spada u iteracijske metode. Kod iteracijskih metoda se rješenje dobiva kao limes niza približnih rješenja $\vec{x}^0, \vec{x}^1, \dots, \vec{x}^k, \dots$. Postavlja se pitanje konvergencije.

Iteracijski postupci imaju zajamčenu konvergenciju za dosta usku klasu matrica (može se dogoditi da postupak konvergira i za matricu izvan te klase, no ne možemo se osloniti na to). Srećom, matrice koje se javljaju u primjenama kao što su diskretizacija rubnih problema, često spadaju baš u tu klasu.

Niz vektora $\vec{x}^0, \vec{x}^1, \dots, \vec{x}^k, \dots$ konvergira prema vektoru $\vec{x}$ ako i samo ako je $\lim_{k \rightarrow \infty} x_i^k = x_i$, $\forall i = 1, \dots, n$. Dakle konvergenciju niza vektora definiramo po komponentama. Indeks niza pišemo kao $\vec{x}^k$, $k = 0, 1, \dots$. Oznaku n čuvamo za red sustava, tj. duljinu (dimenziju) vektora. Ne postoji opasnost od konfuzije s potencijom.

$$\vec{x} = \lim_{k \rightarrow \infty} \vec{x}^k \Leftrightarrow x_i = \lim_{k \rightarrow \infty} x_i^k.$$

Slično se definira i konvergencija niza matrica.

Promatrajmo sustav linearnih jednadžbi $A\vec{x} = \vec{b}$, gdje je $A \in M_n$ regularna matrica i $a_{ii} \neq 0$, $\forall i = 1, \dots, n$. Rastavimo matricu A kao $D - B$, gdje je D dijagonalna matrica s elementima a_{ii} :

$$A\vec{x} = \vec{b} \Leftrightarrow (D - B)\vec{x} = \vec{b} \Rightarrow D\vec{x} = B\vec{x} + \vec{b}.$$

Uzmimo neki $\vec{x}^0 \in \mathbb{R}^n$ i definirajmo niz $\vec{x}^k \in \mathbb{R}^n$.

$$D\vec{x}^{k+1} = B\vec{x}^k + \vec{b}, \quad \text{za } k = 0, 1, 2, \dots$$

Zbog $a_{ii} \neq 0$ možemo lako naći $D^{-1} = \text{diag} \left[\frac{1}{a_{ii}} \right]$ pa je $\vec{x}^{k+1} = D^{-1}B\vec{x}^k + \vec{d}$, odnosno

$$\boxed{\vec{x}^{k+1} = B_J \vec{x}^k + \vec{d}}$$

gdje je $B_J = D^{-1}B$, $\vec{d} = D^{-1}\vec{b}$. Matricu B_J možemo lako eksplicitno izračunati:

$$B_J = \begin{bmatrix} 0 & -\frac{a_{12}}{a_{11}} & -\frac{a_{13}}{a_{11}} & \cdots & -\frac{a_{1n}}{a_{11}} \\ -\frac{a_{21}}{a_{22}} & 0 & -\frac{a_{23}}{a_{22}} & \cdots & -\frac{a_{2n}}{a_{22}} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ -\frac{a_{n1}}{a_{nn}} & -\frac{a_{n2}}{a_{nn}} & -\frac{a_{n3}}{a_{nn}} & \cdots & 0 \end{bmatrix}$$

Raspisano po komponentama:

$$x_i^{k+1} = -\frac{1}{a_{ii}} \sum_{\substack{j=1 \\ j \neq i}}^n a_{ij} x_j^k + \frac{b_i}{a_{ii}}, \quad i = 1, 2, \dots, n.$$

Uz koje uvjete na A (dakle na B_J) niz $\vec{x}^k$ konvergira? Može se pokazati da je dovoljno da neka matrična norma matrice B_J bude manja od 1, $\|B_J\| < 1$. To je uvijek zadovoljeno za dvije klase dijagonalno dominantnih matrica.

Matrica A je **razloživa**, ako se može presložiti tako da je

$$PAP^T = \begin{bmatrix} B_{11} & B_{12} \\ 0 & B_{22} \end{bmatrix},$$

gdje je P permutacijska matrica reda n , a B_{11} i B_{22} su kvadratne matrice reda manjeg od n .

Matrica A je **nerazloživa** ako nije razloživa. Svaka matrica čiji su svi elementi različiti od nule je nerazloživa.

Teorem 11. *Neka je A strogo dijagonalno dominantna matrica ili nerazloživa dijagonalno dominantna matrica. Tada Jacobijev iteracijski postupak za rješavanje linearnog sustava $A\vec{x} = \vec{b}$ konvergira za svaki početni vektor $\vec{x}^0$.* $\square$

6.9 Gauss-Seidelova metoda

Promatramo sustav $A\vec{x} = \vec{b}$ s regularnom matricom $A \in M_n$ za koju je $a_{ii} \neq 0$ za sve $1 \leq i \leq n$. Prikažimo matricu A u obliku $A = N - P$, gdje su

$$N = \begin{bmatrix} a_{11} & & & & \\ a_{21} & a_{22} & & & \\ \vdots & \vdots & \ddots & & \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix}, \quad P = \begin{bmatrix} 0 & -a_{12} & -a_{13} & \cdots & -a_{1n} \\ 0 & & -a_{23} & \cdots & -a_{2n} \\ & & 0 & \ddots & \vdots \\ \mathbf{0} & & & & -a_{n-1,n} \\ & & & & 0 \end{bmatrix}$$

Sada iz $A\vec{x} = \vec{b}$ slijedi $N\vec{x} = P\vec{x} + \vec{b}$. Za neki $\vec{x}^0 \in \mathbb{R}^n$ definiramo niz $\vec{x}^k$ iterativno formulom

$$N\vec{x}^{k+1} = P\vec{x}^k + \vec{b}, \quad k = 0, 1, \dots$$

Zbog regularnosti matrice N ($\det N = \prod_{i=1}^n a_{ii} \neq 0$) možemo množiti gornju relaciju s lijeva s N^{-1} pa dobivamo $\vec{x}^{k+1} = N^{-1}P\vec{x}^k + N^{-1}\vec{b}$, odnosno

$$\boxed{\vec{x}^{k+1} = B_G \vec{x}^k + \vec{d}},$$

gdje je $B_G = N^{-1}P$, $\vec{d} = N^{-1}\vec{b}$.

Formule za raspis po komponentama su složenije nego za Jacobijevu metodu:

$$\begin{aligned}x_1^{k+1} &= -\frac{1}{a_{11}} \sum_{j=2}^n a_{1j}x_j^k + \frac{b_1}{a_{11}} \\x_i^{k+1} &= -\frac{1}{a_{ii}} \left[\sum_{j=1}^{i-1} a_{ij}x_j^{k+1} + \sum_{j=i+1}^n a_{ij}x_j^k \right] + \frac{b_i}{a_{ii}}, \quad 2 \leq i \leq n-1 \\x_n^{k+1} &= -\frac{1}{a_{nn}} \sum_{j=1}^{n-1} a_{nj}x_j^{k+1} + \frac{b_n}{a_{nn}}.\end{aligned}$$

Vidimo da se pri računanju i -te komponente vektora $\vec{x}^{k+1}$ koriste već izračunate komponente (od 1. do $(i-1)$ -ve) tog vektora.

Uvjeti konvergencije su slični kao za Jacobijevu metodu

Teorem 12. *Neka je A strogo dijagonalno dominantna ili nerazloživa dijagonalno dominantna matrica. Tada Gauss-Seidelov iteracijski postupak za rješavanje sustava $A\vec{x} = \vec{b}$ konvergira za svaki izbor početne aproksimacije $\vec{x}^0$.* $\square$

Teorem 13. *Ako je matrica $A \in M_n$ simetrična i pozitivno definitna, onda Gauss-Seidelov iteracijski postupak za rješavanje sustava $A\vec{x} = \vec{b}$ konvergira za sve $\vec{x}^0 \in \mathbb{R}^n$.* $\square$

Kako možemo prepoznati pozitivno definitnu matricu?

Teorem 14. *Neka je A simetrična strogo dijagonalno dominantna ili simetrična nerazloživa dijagonalno dominantna matrica s pozitivnim dijagonalnim elementima. Tada je matrica A pozitivno definitna.* $\square$

U većini slučajeva Gauss-Seidelov postupak konvergira brže od Jacobijevog, no ne nužno. Postoje sustavi za koje jedan postupak konvergira, a drugi ne i obratno. Takvi primjeri u pravilu narušavaju neki od dozvoljenih uvjeta iz gornjih teorema. Za trodijagonalnu matricu A ili obje metode konvergiraju ili obje divergiraju. Ako obje konvergiraju, Gauss-Seidelova je brža.

6.10 Ocjena pogreške iteracijskih metoda

Promatramo iteracijsku shemu $\vec{x}^{k+1} = M\vec{x}^k + \vec{d}$, $k = 0, 1, \dots$ za koju znamo da konvergira za proizvoljan $\vec{x}^0$. Dakle vrijedi $\vec{x} = \lim_{k \rightarrow \infty} \vec{x}^k$. Koliko je ta konvergencija brza? Kad smo dovoljno blizu točnom rješenju $\vec{x}$? Kad možemo stati s iteracijskim postupkom?

Teorem 15. *Neka za matricu M vrijedi*

$$\|M\vec{y} - M\vec{z}\| \leq L\|\vec{y} - \vec{z}\|,$$

za sve $\vec{y}, \vec{z} \in \mathbb{R}^n$ i za neki $L \in [0, 1)$. Ako je $\vec{x}^{k+1} = M\vec{x}^k + \vec{d}$, $k = 0, 1, \dots$ uz proizvoljni $\vec{x}^0 \in \mathbb{R}^n$, onda je

$$\|\vec{x} - \vec{x}^k\| \leq \frac{L}{1-L} \|\vec{x}^k - \vec{x}^{k-1}\|, \quad k = 1, 2, \dots,$$

gdje je $\vec{x}$ traženo rješenje sustava $\vec{x} = M\vec{x} + \vec{d}$. $\square$

Ovo nam daje kriterij zaustavljanja na temelju razlike dviju uzastopnih aproksimacija.

Ocjena greške iz Teorema 15 je **aposteriorna**, jer je dobivena poslije računanja $\vec{x}^k$. Može se dokazati i **apriorna** ocjena

$$\|\vec{x} - \vec{x}^k\| \leq \frac{L^k}{1-L} \|\vec{x}^1 - \vec{x}^0\|, \quad k = 1, 2, \dots$$

Apriorna je jer se njome može ocjenjivati $\|\vec{x} - \vec{x}^k\|$ prije računanja samog $\vec{x}^k$. Na temelju apriorne ocjene može se odrediti potreban broj iteracija za postizanje zadane točnosti ε . Primijetimo da je aposteriorna ocjena bolja od apriorne.

Gornja analiza ne uzima u obzir grješke zaokruživanja. Iteracijskim postupcima mogu se korigirati približna rješenja linearnih sustava i poboljšavati približno izračunate inverzne matrice.

6.11 OR metode

OR je zajednički naziv za klasu iteracijskih metoda koje poopćuju Jacobijevu i Gauss-Seidelovu metodu uvođenjem parametra čijim se variranjem i optimalnim izborom ubrzava konvergencija. OR dolazi od **over-relaxation**. Postoje razne verzije - mi ćemo ovdje izložiti poopćenje Gauss-Seidelove metode poznate kao SOR (**successive over-relaxation**).

Promatramo sustav $A\vec{x} = \vec{b}$ za čiju matricu A vrijedi: $a_{ii} \neq 0$, $1 \leq i \leq n$. Rastavimo matricu A kao $A = N - P$, pri čemu je

$$N = \frac{1}{\omega}D - T, \quad P = \frac{1-\omega}{\omega}D + S,$$

za neki $\omega \in \mathbb{R}$, $\omega \neq 0$. Ovdje je $D = \text{diag}[a_{11}, \dots, a_{nn}]$, T je (strogo) donji trokut od $-A$, a S je (strogo) gornji trokut od $-A$ (dakle vrijedi $A = D - T - S$). Realni broj ω zove se **relaksacijski parametar**. Uz ovu supstituciju imamo

$$\begin{aligned} A\vec{x} = \vec{b} &\implies N\vec{x} = P\vec{x} + \vec{b} \\ \vec{x} &= M\vec{x} + \vec{d}, \end{aligned}$$

gdje je $M = N^{-1}P = (D - \omega T)^{-1}[(1-\omega)D + \omega S]$, $\vec{d} = N^{-1}\vec{b} = \omega(D - \omega T)^{-1}\vec{b}$. Stavimo $L = D^{-1}T$, $U = D^{-1}S$ pa imamo $M = (I - \omega L)^{-1}[(1-\omega)I + \omega U]$. Za $\omega = 1$ dobijemo $B_G = (I - L)^{-1}U$, matricu Gauss-Seidelovog postupka.

Teorem 16. *Neka je A simetrična pozitivno definitna matrica. Tada SOR postupak konvergira za sve $\omega \in \langle 0, 2 \rangle$* □

6.12 Problem svojstvenih vrijednosti

Realni broj λ je **svojstvena vrijednost (vlastita vrijednost)** kvadratne matrice A , ako postoji ne-nul vektor $\vec{x} \in \mathbb{R}^n$ takav da je $A\vec{x} = \lambda\vec{x}$. Vektor $\vec{x}$ je **svojstveni (vlastiti) vektor** koji odgovara svojstvenoj vrijednosti λ .

Iz definicije slijedi da vektor $\vec{x}$ mora biti netrivialno rješenje sustava $(A - \lambda I)\vec{x} = \vec{0}$. Znamo da homogeni sustav ima netrivialno rješenje samo ako mu je matrica singularna. Dakle, takva rješenja postoje za one vrijednosti λ za koje je

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

Ovo je svojstvena ili **karakteristična jednadžba** matrice A . Funkcija $\det(A - \lambda I)$ je polinom u varijabli λ čiji je stupanj jednak redu matrice A . To je **karakteristični polinom** matrice (determinantu $\det(A - \lambda I)$ ponekad još zovu i **sekularnom determinantom**).

Polinom n -tog stupnja ima točno n korijena u $\mathbb{C}$, pri čemu se svaki korijen broji sa svojom kratnošću. Dakle matrica $A \in M_n$ ima općenito, n kompleksnih svojstvenih vrijednosti.

Primjer 6.3:

$$A = \begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix}, \quad |A - \lambda I| = \begin{vmatrix} \cos \varphi - \lambda & -\sin \varphi \\ \sin \varphi & \cos \varphi - \lambda \end{vmatrix}$$

$$|A - \lambda I| = \cos^2 \varphi - 2\lambda \cos \varphi + \lambda^2 + \sin^2 \varphi = \lambda^2 - 2\lambda \cos \varphi + 1$$

$$|A - \lambda I| = 0 \Leftrightarrow \lambda^2 - 2\lambda \cos \varphi + 1 = 0$$

$$\lambda_{1,2} = \cos \varphi \pm \sqrt{\cos^2 \varphi - 1}$$

$$= \cos \varphi \pm i \sin \varphi$$

Vidimo da A ima realne svojstvene vrijednosti samo za $\varphi = k\pi$. Zašto? □

Skup svih svojstvenih vrijednosti matrice A naziva se **spektar** od A i označava se sa $\sigma(A)$. Najveća po modulu svojstvena vrijednost od A zove se **spektralni radijus** od A i označava se s $\rho(A)$,

$$\rho(A) = \max_{\lambda \in \sigma(A)} |\lambda|.$$

Ako je matrica A simetrična, onda su sve njene svojstvene vrijednosti realne. U tom slučaju vrijedi

$$\sigma(A) \subset [-\rho(A), \rho(A)].$$

Spektralni radijus nosi puno informacija o ponašanju velikih potencija matrice. Primjerice, nužan i dovoljan uvjet konvergencije Jacobijeve i Gauss-Seidelove metode je $\rho(M) < 1$.

Teorem 17. (Perron) *Ako su svi elementi realne kvadratne matrice pozitivni, tada je i njena najveća svojstvena vrijednost pozitivna i jednostruka. Svojstveni vektor koji pripada toj svojstvenoj vrijednosti ima sve komponente pozitivne.* □

Matrice A i B su **slične** ako postoji regularna matrica S takva da je $B = S^{-1}AS$. Slične matrice imaju iste karakteristične polinome (a onda i isti spektar).

Za razliku od rješavanja linearnih sustava, ne postoje izravne metode kojima se točno (egzaktno) dobivaju svojstvene vrijednosti općenite matrice. To slijedi iz činjenice da za polinome visokog stupnja ne postoje formule za njihove nul-točke (visokog stupnja znači stupnja većeg od četiri). Problemi nalaženja svojstvenih vrijednosti i vektora se u pravilu rješavaju numerički, programskim paketima tipa EISPACK i sličnima.

Dva su osnovna pristupa: U jednom se, egzaktno ili približno, prvo odrede koeficijenti svojstvenog polinoma pa se onda (približnim metodama) određuju njihove nul-točke. Druga klasa metoda, koja se najčešće koristi samo za dobivanje najveće (ili k najvećih) svojstvene vrijednosti ne računa eksplicitno karakteristični polinom, već se tražene svojstvene vrijednosti dobivaju iterativnim postupkom iz matrice i neke početne aproksimacije. Ovdje ćemo se ograničiti na metode prvog tipa.

6.12.1 Karakteristični polinom

Koeficijenti karakterističnog polinoma vezani su sa svojstvenim vrijednostima Vieteovim formulama:

$$\det(A - \lambda I) = (-1)^n [\lambda^n - \sigma_1 \lambda^{n-1} + \sigma_2 \lambda^{n-2} - \dots + (-1)^n \sigma_n]$$

Vrijedi:

$$\begin{aligned}\lambda_1 + \lambda_2 + \dots + \lambda_n &= -\sigma_1 \\ \lambda_1 \cdot \lambda_2 \cdot \dots \cdot \lambda_n &= \sigma_n = \det A.\end{aligned}$$

Ponekad se u literaturi umjesto $\det(A - \lambda I) = 0$ uzima $\det(\lambda I - A) = 0$, što rezultira karakterističnim polinomom s jedinicom kao vodećim koeficijentom, $\lambda^n - \sigma_1 \lambda^{n-1} + \dots + (-1)^n \sigma_n$.

Teorem 18. (Hamilton-Cayley) Svaka kvadratna matrica poništava svoj karakteristični polinom. $\square$

To znači da je

$$A^n - \sigma_1 A^{n-1} + \dots + (-1)^n \sigma_n I = 0.$$

Gornji rezultat je polazište za Krylovljevu metodu računanja koeficijenata karakterističnog polinoma.

Teorem 19. Slične matrice imaju isti karakteristični polinom. $\square$

Na Teoremu 19 se temelji metoda Danilevskog, kod koje se zadana matrica A transformacijama sličnosti svodi na matricu oblika

$$B = \begin{bmatrix} b_{n-1} & b_{n-2} & \cdots & b_1 & b_0 \\ 1 & 0 & \cdots & 0 & 0 \\ 0 & 1 & & 0 & 0 \\ \vdots & & \ddots & \vdots & \vdots \\ 0 & & & 1 & 0 \end{bmatrix},$$

gdje su $b_{n-1}, b_{n-2}, \dots, b_1, b_0$ koeficijenti karakterističnog polinoma.

6.12.2 Krylovljeva metoda

Neka je $p(\lambda) = \lambda^n + b_{n-1} \lambda^{n-1} + \dots + b_1 \lambda + b_0$ karakteristični polinom matrice A . Tada je, po Hamilton-Cayleyjevom teoremu

$$A^n + b_{n-1} A^{n-1} + \dots + b_0 I = 0.$$

Lijeva strana je kvadratna matrica. Djelujemo li njome na proizvoljan vektor $\vec{y}$ dobivamo

$$A^n \vec{y} + b_{n-1} A^{n-1} \vec{y} + \dots + b_0 I \vec{y} = \vec{0}.$$

To je sustav od n linearnih jednadžbi s nepoznicama $b_0, b_1, \dots, b_{n-1}$ (vektor $A^n \vec{y}$ prebacimo na desnu stranu i imamo sustav $b_{n-1} A^{n-1} \vec{y} + \dots + b_0 I \vec{y} = -A^n \vec{y}$). Ako taj sustav ima jedinstveno rješenje, onda su njegove komponente koeficijenti karakterističnog polinoma. Ako je matrica tog sustava singularna, pokušamo s drugim vektorom.

U ovom postupku nije važno eksplicitno računati potencije $A^2, A^3, \dots, A^n$. Uz oznake $\vec{y}^0 = \vec{y}$, $\vec{y}^k = A\vec{y}^{k-1}$, vektore $\vec{y}^k$ dobivamo iterativno iz $\vec{y}$. Sustav možemo pisati kao

$$\begin{bmatrix} y_1^{n-1} & y_1^{n-2} & \cdots & y_1^0 \\ y_2^{n-1} & y_2^{n-2} & \cdots & y_2^0 \\ \vdots & \vdots & & \vdots \\ y_n^{n-1} & y_n^{n-2} & \cdots & y_n^0 \end{bmatrix} \begin{bmatrix} b_{n-1} \\ b_{n-2} \\ \vdots \\ b_0 \end{bmatrix} = \begin{bmatrix} -y_1^n \\ -y_2^n \\ \vdots \\ -y_n^n \end{bmatrix}$$

Uočimo da eksponenti gore ne označavaju potenciranje, već se odnose na djelovanje odgovarajuće potencije od A na početni vektor $\vec{y}$, odnosno na korak u iteracijskom procesu.

Krylovljeva metoda zahtijeva oko n^3 množenja i $n(n-1)^2$ zbrajanja za računanje svih vektora $\bar{y}^0, \dots, \bar{y}^n$. Nakon toga nam treba još oko $\frac{n^3}{3}$ množenja i isto toliko zbrajanja za rješavanje sustava i onda tek imamo karakteristični polinom.

Metodom Krylova se mogu računati i svojstveni vektori, no to ne ćemo raditi.

6.12.3 Metoda neodređenih koeficijenata

Općenito, polinom n -tog stupnja je jednoznačno određen svojim vrijednostima za $n + 1$ realnih argumenata. Kako znamo da je vodeći koeficijent svojstvenog polinoma jednak 1, ostaje nam za odrediti n preostalih koeficijenata. Izračunajmo vrijednosti determinante $\det(A - \lambda I)$ za n različitih vrijednosti argumenta. Najjednostavnije je uzeti argumente $0, 1, 2, \dots, n - 1$.

Uvrstimo $\lambda = 0, 1, 2, \dots, n-1$ u $p(\lambda) = \lambda^n + b_{n-1}\lambda^{n-1} + \dots + b_0$.

$$\left. \begin{array}{l} b_0 = p(0) \\ 1^n + b_{n-1}1^{n-1} + \dots + b_11 + b_0 = p(1) \\ 2^n + b_{n-1}2^{n-1} + \dots + b_12 + b_0 = p(2) \\ \dots \\ (n-1)^n + b_{n-1}(n-1)^{n-1} + \dots + b_1(n-1) + b_0 = p(n-1) \end{array} \right\} \text{presložimo}$$

$$\begin{aligned} b_{n-1} + b_{n-2} + \dots + b_1 &= p(1) - p(0) - 1^n \\ 2^{n-1}b_{n-1} + 2^{n-2}b_{n-2} + \dots + 2b_1 &= p(2) - p(0) - 2^n \\ \vdots &\vdots \\ (n-1)^{n-1}b_{n-1} + (n-1)^{n-2}b_{n-2} + \dots + (n-1)b_1 &= p(n-1) - p(0) - (n-1)^n \end{aligned}$$

Dobili smo linearni sustav

$$C\vec{b} = \vec{d},$$

za nepoznanice $b_{n-1}, \dots, b_1$, gdje je

$$C = \begin{bmatrix} 1 & 1 & \cdots & 1 \\ 2^{n-1} & 2^{n-2} & \cdots & 2 \\ \vdots & \vdots & & \vdots \\ (n-1)^{n-1} & (n-1)^{n-2} & \cdots & (n-1) \end{bmatrix}, \quad \vec{d} = \begin{bmatrix} p(1) - p(0) - 1^n \\ p(2) - p(0) - 2^n \\ \vdots \\ p(n-1) - p(0) - (n-1)^n \end{bmatrix}.$$

Matrica C je uvijek regularna (zašto?).

6.12.4 Lokalizacija nul-točaka

Svojstvene vrijednosti realne matrice su, općenito, kompleksni brojevi. Njihov položaj u kompleksnoj ravnini moguće je procijeniti iz odnosa dijagonalnih i nedijagonalnih elemenata matrice.

Teorem 20. (Geršgorin) *Neka je A matrica reda n i neka je C_i krug u kompleksnoj ravnini sa središtem u a_{ii} i polumjerom*

$$r_i = \sum_{\substack{j=1 \\ j \neq i}}^n |a_{ij}|, \quad i = 1, 2, \dots, n.$$

Tada sve svojstvene vrijednosti matrice A leže u skupu

$$S = \bigcup_{i=1}^n C_i.$$

□

Kako matrice A i A^T imaju isti spektar, gornja tvrdnja mora vrijediti i ako polumjere krugova računamo zbrajajući apsolutnu vrijednost nedijagonalnih elemenata po stupcima matrice A , dakle s polumjerima

$$s_j = \sum_{\substack{i=1 \\ i \neq j}}^n |a_{ij}|, \quad j = 1, 2, \dots, n.$$

Ako je $T = \cup D_j$, gdje je D_j krug u $\mathbb{C}$ sa središtem a_{jj} i polumjerom s_j , onda se sve svojstvene vrijednosti matrice A moraju nalaziti u $S \cap T$.

Ako je realna matrica A simetrična, onda su sve njene svojstvene vrijednosti realne. U tom nam slučaju Geršgorinov teorem daje lokaciju svojstvenih vrijednosti u određenim intervalima u $\mathbb{R}$.

Za simetrične matrice se svojstvene vrijednosti i vektori mogu odrediti specijalnim metodama (Jacobijeve i Givensove rotacije itd.).

Literatura

- [1] B. P. Demidovich, I. A. Maron, *Computational Mathematics*, Mir, Moscow, 1987
- [2] Z. Drmač, V. Hari, M. Marušić, M. Rogina, S. Singer, S. Singer, *Numerička analiza*, dostupno na www.math.hr/znanost/iprojekti/numat
- [3] J. R. Rice, *Numerical Methods, Software, and Analysis*, McGraw-Hill, Tokyo, 1983
- [4] G. U. Milovanović, *Numerička analiza II deo*, Naučna knjiga, Beograd, 1985
- [5] Z. Stojaković, D. Herceg, *Numeričke metode linearne algebre*, Građevinska knjiga, Beograd, 1982
- [6] W. H. Preuss, S. A. Teukolsky, *Numerical Recipes*, Cambridge University Press, Cambridge, 1992