

# Numerička analiza

## 25. predavanje

Autor: Nela Bosner

Predavač: Nela Bosner

[nela@math.hr](mailto:nela@math.hr)

[web.math.hr/~nela/nad.html](http://web.math.hr/~nela/nad.html)

PMF – Matematički odjel, Zagreb

# Sadržaj predavanja

- Numeričko rješavanje parcijalnih diferencijalnih jednadžbi:
  - Numeričko rješavanje paraboličke jednadžbe — difuzijske jednadžbe .
    - Eksplicitna metoda konačnih razlika.
    - Potpuna implicitna metoda konačnih razlika.
    - Crank–Nicolsonova metoda
  - Numeričko rješavanje eliptičke jednadžbe — Poissonove jednadžbe.

# Numeričko rješavanje difuzijske jednadžbe

# Difuzijska jednadžba

Difuzijska jedadžba opisuje razne procese u praksi:

- u fizici: **distribuciju topline** po vremenu u nekom objektu
- u financijama: ponašanje **vrijednosti opcija** (financijski instrument koji dozvoljava “klađenje” da li će vrijednost te imovine rasti ili padati)

Opći oblik difuzijske (**paraboličke** parcijalne diferencijalne) jednadžbe je

$$\frac{\partial u(x, t)}{\partial t} - \nabla \cdot (a(x) \nabla u(x, t)) = f(x, t), \quad t \in [0, T], \quad x \in \Omega$$

pri čemu je potrebno još zadati

- **inicijalni uvjet** za  $t = 0$ , i
- **rubne uvjete** za  $x \in \partial\Omega$ .

# Difuzijska jednadžba (nastavak)

Mi ćemo zbog jednostavnosti promatrati jednostavniji oblik jednadžbe

$$\frac{\partial u}{\partial t}(x, t) = \frac{\partial^2 u}{\partial x^2}(x, t), \quad x \in [a, b], \quad t \in [0, T],$$

s Dirichletovim rubnim uvjetima.

Standardna metoda za dobivanje aproksimacija rješenja parcijalne diferencijalne jednadžbe, kao što je difuzijska, je diskretizacija pomoću konačnih diferencija.

- U toj metodi iz danog područja  $[a, b] \times [0, T]$  izabran je skup točaka koji čini mrežu.
- U svakoj točki mreže derivacije u diferencijalnoj jednadžbi zamjenjuju se sa kvocijentima koji se približavaju derivaciji kada mreža postaje sve finija.

# Konačne razlike

Parcijalnu derivaciju  $\partial u / \partial t$  možemo definirati kao

$$\frac{\partial u}{\partial t}(x, t) = \lim_{\delta t \rightarrow 0} \frac{u(x, t + \delta t) - u(x, t)}{\delta t}.$$

Umjesto računanja limesa kada  $\delta t \rightarrow 0$ , uzet ćemo  $\delta t > 0$  koji je vrlo mali, i budući da vrijedi

$$\frac{\partial u}{\partial t}(x, t) = \frac{u(x, t + \delta t) - y(x, t)}{\delta t} + \mathcal{O}(\delta t)$$

definirat ćemo **aproksimaciju**

$$\frac{\partial u}{\partial t}(x, t) \approx \frac{u(x, t + \delta t) - y(x, t)}{\delta t}.$$

Ovime smo dobili **konačnu razliku** od  $\partial y / \partial t$ , a konačnu razliku ovoga oblika posebno ćemo još zvati i **konačna razlika unaprijed**.

# Konačne razlike (nastavak)

Alternativno možemo definirati

$$\frac{\partial u}{\partial t}(x, t) = \lim_{\delta t \rightarrow 0} \frac{u(x, t) - u(x, t - \delta t)}{\delta t},$$

tako da je na sličan način **aproksimacija** dana sa

$$\frac{\partial u}{\partial t}(x, t) \approx \frac{u(x, t) - u(x, t - \delta t)}{\delta t}.$$

Konačnu razliku ovoga oblika zovemo **konačna razlika unazad**.

Također možemo primijetiti da je

$$\frac{\partial u}{\partial t}(x, t) = \lim_{\delta t \rightarrow 0} \frac{u(x, t + \delta t) - u(x, t - \delta t)}{2\delta t}, \text{ i}$$

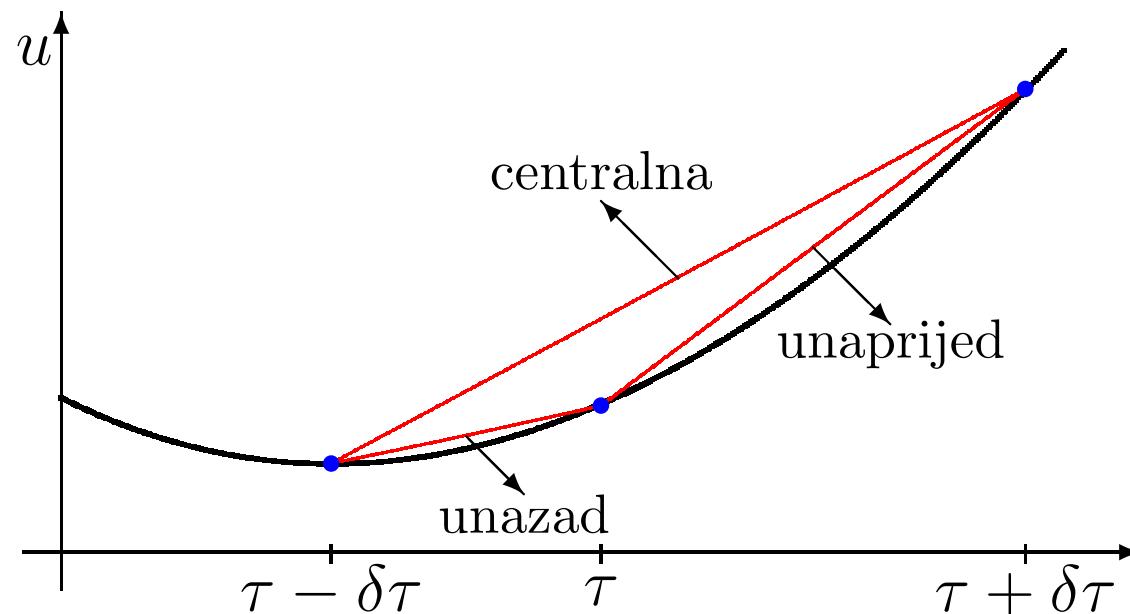
$$\frac{\partial u}{\partial t}(x, t) = \frac{u(x, t + \delta t) - u(x, t - \delta t)}{2\delta t} + \mathcal{O}((\delta t)^2),$$

# Konačne razlike (nastavak)

pa možemo definirati centralnu konačnu razliku

$$\frac{\partial u}{\partial t}(x, t) \approx \frac{u(x, t + \delta t) - u(x, t - \delta t)}{2\delta t}.$$

Vidimo da je centralna konačna razlika **točnija**.



Konačna razlika unazad, unaprijed, i centralna.

# Konačne razlike u difuzijskoj jednadžbi

- Kada se primjenjuju na difuzijsku jednadžbu, konačne razlike unaprijed i unazad koje aproksimiraju  $\partial u / \partial t$  vode do eksplicitne odnosno implicitne metode konačnih razlika.
- Centralna konačna razlika gornjeg oblika po varijabli  $t$  se ne koriste u praksi jer daje nestabilne metode.
- Centralna konačna razlika oblika

$$\frac{\partial u}{\partial t}(x, t) \approx \frac{u(x, t + \delta t/2) - u(x, t - \delta t/2)}{\delta t}$$

pojavljuje se u Crank–Nicolsonovoj shemi za konačne razlike.

# Konačne razlike u difuzijskoj jednadžbi (nast.)

Parcijalne derivacije po varijabli  $x$  možemo definirati na analogan način:

- konačna razlika unaprijed

$$\frac{\partial u}{\partial x}(x, t) \approx \frac{u(x + \delta x, t) - u(x, t)}{\delta x}$$

- konačna razlika unazad

$$\frac{\partial u}{\partial x}(x, t) \approx \frac{u(x, t) - u(x - \delta x, t)}{\delta x}$$

- centralna konačna razlika

$$\frac{\partial u}{\partial x}(x, t) \approx \frac{u(x + \delta x, t) - u(x - \delta x, t)}{2\delta x}$$

# Konačne razlike u difuzijskoj jednadžbi (nast.)

Za drugu parcijalnu derivaciju  $\partial^2 u / \partial x^2$  možemo definirati simetričnu centralnu konačnu razliku kao

- konačnu razliku unaprijed od konačnih razlika unazad
- konačnu razliku unazad od konačnih razlika unaprijed

U oba slučaja dobivamo

$$\begin{aligned}\frac{\partial^2 u}{\partial x^2}(x, t) &= \frac{\frac{u(x+\delta x, t) - u(x, t)}{\delta x} - \frac{u(x, t) - u(x-\delta x, t)}{\delta x}}{\delta x} + \mathcal{O}((\delta x)^2) \\ &\approx \frac{u(x + \delta x, t) - 2u(x, t) + u(x - \delta x, t)}{(\delta x)^2}.\end{aligned}$$

# Mreža za difuzijsku jednadžbu

Kako bismo mogli primijeniti metodu konačnih razlika na difuzijsku jednadžbu moramo **podijeliti**

- $x$  os na **ekvidistantne čvorove** sa razmakom od  $\delta x$
- $t$  os na **ekvidistantne čvorove** sa razmakom od  $\delta t$

pri čemu uzimamo

$$\delta x = \frac{b - a}{n}, \quad \delta t = \frac{T}{m}.$$

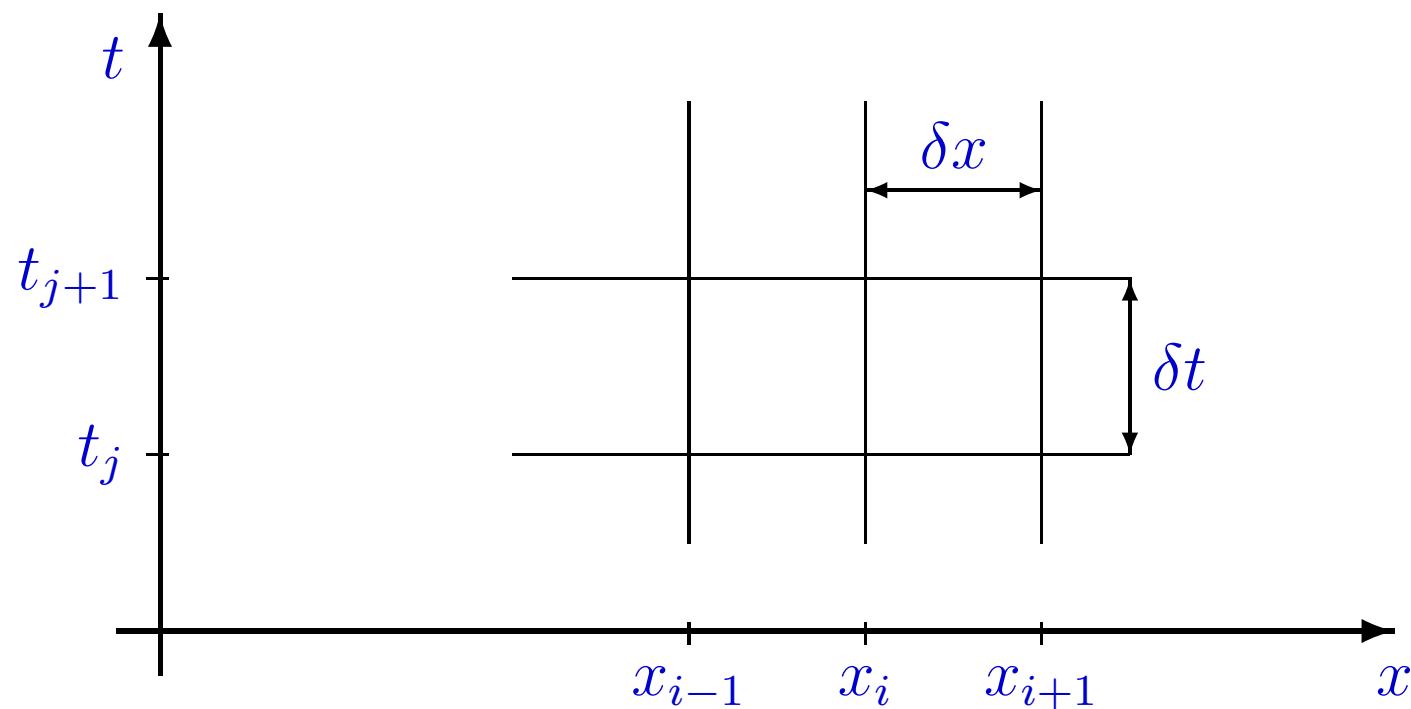
Ovime na  $(x, t)$  ravnini, unutar domene  $[a, b] \times [0, T]$ , definiramo **mrežu**, pri čemu **čvorovi** mreže imaju oblik

$$(x_i, t_j) = (a + i\delta x, j\delta t), \quad i = 0, \dots, n, \quad j = 0, \dots, m.$$

U tom slučaju **računat** ćemo **aproksimativno** rješenje samo u **čvorovima** mreže, i pišemo

$$u_{i,j} \approx u(a + i\delta x, j\delta t).$$

# Mreža za difuzijsku jednadžbu (nastavak)



Oznake na mreži.

# Eksplicitna metoda konačnih razlika

Razmatramo difuzijsku jednadžbu

$$\frac{\partial u}{\partial t} = \frac{\partial^2 u}{\partial x^2},$$

sa rubnim i inicijalnim uvjetima

$$u(a, t) = y_a(t),$$

$$u(b, t) = u_b(t),$$

$$u(x, 0) = u_0(x).$$

Želimo naći aproksimaciju rješenja u čvorovima mreže koristeći

- konačnu razliku unaprijed za  $\partial u / \partial t$ ,
- simetričnu centralnu konačnu razliku za  $\partial^2 u / \partial x^2$ .

# Eksplisitna metoda konačnih razlika (nastavak)

Pri tome se difuzijska jednadžba transformira u

$$\frac{u_{i,j+1} - u_{i,j}}{\delta t} + \mathcal{O}(\delta t) = \frac{u_{i+1,j} - 2u_{i,j} + u_{i-1,j}}{(\delta x)^2} + \mathcal{O}((\delta x)^2).$$

Zanemarujući izraze  $\mathcal{O}(\delta t)$  i  $\mathcal{O}((\delta x)^2)$  dobivamo diferencijsku jednadžbu

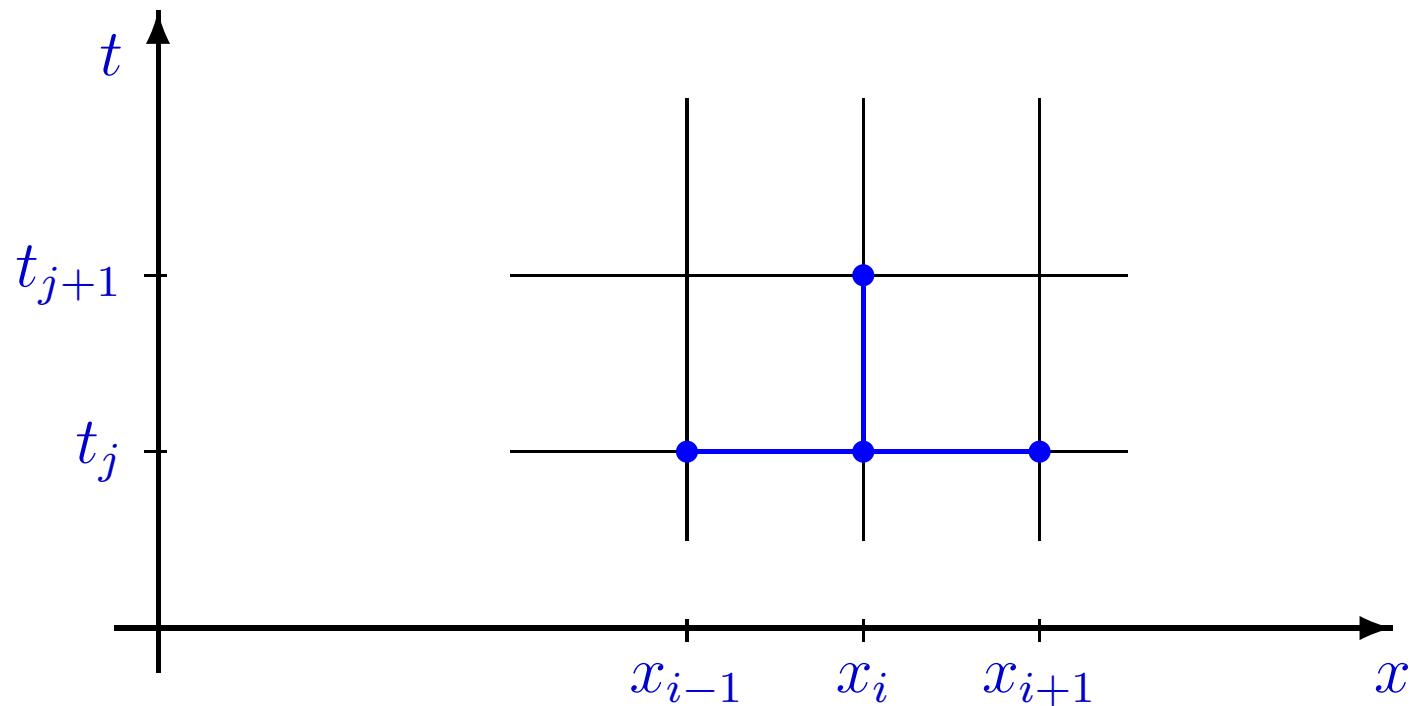
$$u_{i,j+1} = \lambda u_{i-1,j} + (1 - 2\lambda)u_{i,j} + \lambda u_{i+1,j},$$

gdje je

$$\lambda = \frac{\delta t}{(\delta x)^2}, \quad \text{Courantov broj.}$$

Ako u vremenskom koraku  $j$  znamo  $u_{i,j}$  za sve vrijednosti od  $i$ , tada  $u_{i,j+1}$  možemo izračunati eksplisitno.

# Eksplicitna metoda konačnih razlika (nastavak)



$u_{i,j+1}$  ovisi samo o  $u_{i-1,j}$ ,  $u_{i,j}$  i  $u_{i+1,j}$ .

# Eksplicitna metoda konačnih razlika (nastavak)

Sada možemo riješiti diferencijsku jednadžbu za

$$0 < i < n, \quad 0 < j \leq m.$$

Rubne uvjete koristimo za određivanje  $u_{0,j}$  i  $u_{n,j}$ :

$$u_{0,j} = u_a(j\delta t), \quad 0 < j \leq m,$$

$$u_{n,j} = u_b(j\delta t), \quad 0 < j \leq m.$$

Za pokretanje ove iterativne metode koristimo inicijalni uvjet

$$u_{i,0} = u_0(a + i\delta x), \quad 0 \leq i \leq n.$$

Iterativna metoda završava za  $j = m$  i rješenjem

$$u_{i,m}, \quad 0 \leq i \leq n,$$

što predstavlja aproksimaciju rješenja za  $u(a + i\delta x, T)$ ,  
 $0 \leq i \leq n$ .

# Algoritam eksplicitne metode konačnih razlika

```
 $\lambda = \frac{\delta t}{(\delta x)^2};$ 
for  $i = 0 : n$ 
     $u_{stari}(i) = u_0(a + i \cdot \delta x);$ 
end
for  $j = 1 : m$ 
     $u_{novi}(0) = u_a(j \cdot \delta t);$ 
     $u_{novi}(n) = u_b(j \cdot \delta t);$ 
    for  $i = 1 : (n - 1)$ 
         $u_{novi}(i) = \lambda \cdot u_{stari}(i - 1) + (1 - 2 \cdot \lambda) \cdot u_{stari}(i) +$ 
                     $+ \lambda \cdot u_{stari}(i + 1);$ 
    end
     $u_{stari} = u_{novi};$ 
end
 $u = u_{stari};$ 
```

# Stabilnost eksplicitne metode konačnih razlika

- Stabilnost numeričke metode je u bliskoj vezi sa numeričkom greškom.
- Metoda konačnih razlika je **stabilna** ako greška učinjena u jednom koraku metode **ne utječe** na **povećanje** greške u koracima koji slijede.
- Kod **neutralno stabilne** metode greška ostaje konstantna u svim koracima.
- Ako greške **opadaju** i po mogućnosti se **prigušuju**, kažemo da je numerička metoda **stabilna**.
- Ako, s druge strane, greška **raste** sa povećanjem broja koraka, **aproksimativno rješenje divergira**, i kažemo da je numerička metoda **nestabilna**.

# Stabilnost eksplicitne metode konačnih razlika

Za daljnju analizu korisno je sve vrijednosti  $u_{i,j}$  za fiksni vremenski korak  $j$  organizirati u vektor

$$u^{(j)} = [ u_{1,j} \quad \cdots \quad u_{n-1,j} ]^T.$$

Za matrični oblik diferencijske jednadžbe definiramo  $(n - 1) \times (n - 1)$  matricu  $A$

$$A = \begin{bmatrix} 1 - 2\lambda & \lambda & 0 & \cdots & 0 \\ \lambda & 1 - 2\lambda & \ddots & \ddots & \vdots \\ 0 & \ddots & \ddots & \ddots & 0 \\ \vdots & \ddots & \ddots & \ddots & \lambda \\ 0 & \cdots & 0 & \lambda & 1 - 2\lambda \end{bmatrix}.$$

# Stabilnost eksplisitne metode konačnih razlika

Tada eksplisitnu metodu možemo zapisati kao

$$u^{(j+1)} = Au^{(j)} + u_r^{(j)},$$

gdje je

$$u_r^{(j)} = \lambda [ \begin{array}{ccccc} u_{0,j} & 0 & \cdots & 0 & u_{n,j} \end{array} ]^T.$$

Prepostavimo sada da našu numeričku metodu izvršavamo na računalu u aritmetici konačne preciznosti. U tom slučaju ćemo u svakom koraku  $j$  umjesto  $u^{(j+1)}$  izračunati aproksimativnu vrijednost  $\tilde{u}^{(j+1)}$  koja sadrži i greške zaokruživanja. Neka je

$$\tilde{u}^{(j+1)} = A\tilde{u}^{(j)} + \tilde{u}_r^{(j)} + f^{(j+1)},$$

gdje  $f^{(j+1)}$  sadrži greške zaokruživanja koje su se dogodile kod računanja  $A\tilde{u}^{(j)} + \tilde{u}_r^{(j)}$ .

# Stabilnost eksplicitne metode konačnih razlika

Definirajmo ukupnu grešku

$$e^{(j)} = \tilde{u}^{(j)} - u^{(j)}, \quad j \geq 0.$$

Možemo zaključiti da vrijedi sljedeće:

$$e^{(j+1)} = Ae^{(j)} + (\tilde{u}_r^{(j)} - u_r^{(j)}) + f^{(j+1)}.$$

Usredotočimo se sada na utjecaj grešaka zaokruživanja  $e^{(0)}$  kod računanja inicijalnog uvjeta (za  $j = 0$ ). Zbog jednostavnosti, pretpostavimo da su svi daljnji koraci ( $j > 0$ ) izračunati egzaktno, tj. da je

$$\tilde{u}_r^{(j)} = u_r^{(j)}, \quad f^{(j)} = 0, \quad j > 0.$$

Tada imamo

$$e^{(j+1)} = Ae^{(j)} = A^{j+1}e^{(0)}.$$

# Stabilnost eksplicitne metode konačnih razlika

Da bi metoda bila stabilna, greška  $e^{(0)}$  mora biti prigušena, a za to treba biti

$$\lim_{j \rightarrow \infty} A^j e^{(0)} = 0,$$

što nam je poznata situacija iz iterativnih metoda za sustave linearnih jednadžbi. Od tamo znamo da će metoda biti stabilna ako i samo ako je

$$\rho(A) < 1,$$

gdje je  $\rho(A)$  spektralni radius matrice  $A$ . Dakle, da bi metoda bila stabilna zahtijevamo da za sve svojstvene vrijednosti  $\mu_1(A), \dots, \mu_{n-1}(A)$  od  $A$  vrijedi

$$|\mu_k(A)| < 1, \quad k = 1, \dots, n - 1.$$

# Stabilnost eksplicitne metode konačnih razlika

Slijedeći korak je računanje svojstvenih vrijednosti od  $A$ . U tu svrhu, matricu pišemo kao

$$A = I - \lambda \cdot \underbrace{\begin{bmatrix} 2 & -1 & & & 0 \\ -1 & 2 & \ddots & & \\ & \ddots & \ddots & \ddots & \\ & & \ddots & \ddots & -1 \\ 0 & & & -1 & 2 \end{bmatrix}}_{=G}.$$

Preostaje nam sada samo naći svojstvene vrijednosti  $\mu_k(G)$  od matrice  $G$ , jer su tada

$$\mu_k(A) = 1 - \lambda \cdot \mu_k(G), \quad k = 1, \dots, n-1.$$

# Svojstvene vrijednosti TST matrice

$G$  je matrica sa posebnom strukturom i njen oblik je poznat pod imenom TST, gdje “TST” dolazi od Toeplitzova (konstantna duž svih dijagonala), simetrična i tridiagonalna.

Teorem. Neka je  $G$   $m \times m$  TST matrica sa dijagonalnim elementima  $\alpha$  i vandijagonalnim elementima  $\beta$ . Tada su svojstvene vrijednosti od  $G$  dane sa

$$\mu_k(G) = \alpha + 2\beta \cos\left(\frac{k\pi}{m+1}\right), \quad k = 1, \dots, m,$$

a odgovarajući ortonormirani svojstveni vektori dani su, po komponentama, sa

$$q_\ell^{(k)} = \sqrt{\frac{2}{m+1}} \sin\left(\frac{\ell k \pi}{m+1}\right), \quad \ell, k = 1, \dots, m.$$

## Svojstvene vrijednosti TST matrice (nastavak)

Dokaz. Prepostavimo da je  $\beta \neq 0$ , jer bi inače  $G$  bio multipl od identitete, čime je tvrdnja teorema trivijalna.

Prepostavimo da je  $\mu$  svojstvena vrijednost od  $G$  sa odgovarajućim svojstvenim vektorom  $q$ . Ako definiramo  $q_0 = q_{m+1} = 0$ , jednakost  $Aq = \mu q$  možemo napisati u obliku

$$\beta q_{\ell-1} + (\alpha - \mu)q_\ell + \beta q_{\ell+1} = 0, \quad \ell = 1, \dots, m.$$

To je linearna diferencijska jednadžba, za koju ponovo razmatramo karakteristični polinom

$$\chi(z) = \beta + (\alpha - \mu)z + \beta z^2.$$

Ako korijene ovog polinoma označimo sa  $z_1$  i  $z_2$ , tada općenito rješenje diferencijske jednadžbe ima oblik

$$q_\ell = c_1 z_1^\ell + c_2 z_2^\ell, \quad \text{za konstante } c_1, c_2,$$

gdje su konstante određene iz rubnih uvjeta  $q_0 = q_{m+1} = 0$ .

# Svojstvene vrijednosti TST matrice (nastavak)

Korijeni od  $\chi(z)$  su

$$z_{1,2} = \frac{\mu - \alpha \pm \sqrt{(\mu - \alpha)^2 - 4\beta^2}}{2\beta}, \quad (*)$$

a iz uvjeta  $q_0 = 0$  slijedi da je  $c_1 + c_2 = 0$ . S druge strane, iz uvjeta  $q_{m+1} = 0$  slijedi:

$$c_1 z_1^{m+1} + c_2 z_2^{m+1} = 0,$$

odnosno, zbog prethodne napomene je  $c_2 = -c_1$ , a kako nas interesira netrivijalno rješenje slijedi  $c_1 \neq 0$ , imamo

$$z_1^{m+1} = z_2^{m+1}.$$

Postoji  $m + 1$  rješenja ove jednadžbe, i to

$$z_2 = z_1 \exp \left( \frac{2\pi k \iota}{m+1} \right), \quad k = 0, 1, \dots, m, \quad \iota = \sqrt{-1}.$$

## Svojstvene vrijednosti TST matrice (nastavak)

Međutim, slučaj za  $k = 0$  se može odbaciti, jer je tada  $z_2 = z_1$ , a odatle je

$$q_\ell = c_1 z_1^\ell + c_2 z_2^\ell = c_1 z_1^\ell - c_1 z_1^\ell = 0.$$

Množeći prethodnu jednakost koja povezuje  $z_1$  i  $z_2$  sa  $\exp(-\pi k \iota / (m+1))$  i uvrštavajući vrijednosti za  $z_1$  i  $z_2$  iz jednadžbe za korijene (\*) dobivamo

$$\begin{aligned} & \left( \mu - \alpha + \sqrt{(\mu - \alpha)^2 - 4\beta^2} \right) \exp\left(\frac{-\pi k \iota}{m+1}\right) = \\ &= \left( \mu - \alpha - \sqrt{(\mu - \alpha)^2 - 4\beta^2} \right) \exp\left(\frac{\pi k \iota}{m+1}\right). \end{aligned}$$

Nakon potrebnih skraćivanja, i dijeljenja jednakosti sa 2 imamo

## Svojstvene vrijednosti TST matrice (nastavak)

$$\sqrt{(\mu - \alpha)^2 - 4\beta^2} \cos\left(\frac{k\pi}{m+1}\right) = (\mu - \alpha)\iota \sin\left(\frac{k\pi}{m+1}\right),$$

a nakon **kvadriranja** obaju strana jednakosti i rješavanja kvadratne jednadžbe po  $\mu$

$$\mu^2 - 2\alpha\mu + \alpha^2 - 4\beta^2 \cos^2\left(\frac{\pi k}{m+1}\right) = 0,$$

dobivamo rješenja

$$\mu_{1,2} = \alpha \pm 2\beta \cos\left(\frac{\pi k}{m+1}\right), \quad k = 1, \dots, m.$$

Ako uzmemo rješenje sa znakom **plus** dobivamo tražene svojstvene vrijednosti, dok rješenje sa znakom **minus** samo ponavlja te iste vrijednosti, pa se stoga može **odbaciti**.

# Svojstvene vrijednosti TST matrice (nastavak)

Uvrštavajući dobiveni izraz za svojstvene vrijednosti u jednadžbu za korijene (\*) dobivamo

$$z_{1,2} = \cos\left(\frac{k\pi}{m+1}\right) \pm \iota \sin\left(\frac{k\pi}{m+1}\right),$$

pa je zbog toga

$$q_\ell^{(k)} = c_1(z_1^\ell - z_2^\ell) = 2c_1\iota \sin\left(\frac{\pi k \ell}{m+1}\right), \quad k, \ell = 1, \dots, m.$$

Ako uzmemo da je  $c_1 = -(\iota/2)\sqrt{2/(m+1)}$ , onda se lako provjeri da svaki od vektora  $q^{(k)}$  ima normu jedan, jer je

# Svojstvene vrijednosti TST matrice (nastavak)

$$\begin{aligned}\sum_{\ell=1}^m \left( q_\ell^{(k)} \right)^2 &= \frac{2}{m+1} \sum_{\ell=1}^m \sin^2 \left( \frac{\ell k \pi}{m+1} \right) \\ &= \frac{2}{m+1} \cdot \frac{1}{2} \sum_{\ell=1}^m \left[ 1 - \cos \left( \frac{2\ell k \pi}{m+1} \right) \right] \\ &= \frac{2}{m+1} \left[ \frac{m}{2} - \frac{1}{2} \sum_{\ell=1}^m \cos \left( \frac{2\ell k \pi}{m+1} \right) \right]\end{aligned}$$

odakle se, prelaskom sa kosinusa na realni dio kompleksnog broja, dobiva da je suma kosinusa u zadnjoj jednakosti jednaka -1, čime smo dobili traženi rezultat.

Svojstveni vektori su ortogonalni, budući da je matrica simetrična.



# Stabilnost eksplicitne metode konačnih razlika

Dakle, svojstvene vrijednosti naše matrice  $G$  dane su sa

$$\begin{aligned}\mu_k(G) &= 2 - 2 \cos\left(\frac{k\pi}{n}\right) \\ &= 4 \sin^2\left(\frac{k\pi}{2n}\right), \quad k = 1, \dots, n-1.\end{aligned}$$

Dalje vrijedi

$$\mu_k(A) = 1 - 4\lambda \sin^2\left(\frac{k\pi}{2n}\right), \quad k = 1, \dots, n-1.$$

Da bi uvjet stabilnosti  $|\mu_k(A)| < 1$  bio zadovoljen, mora vrijediti

$$\left|1 - 4\lambda \sin^2\left(\frac{k\pi}{2n}\right)\right| < 1, \quad k = 1, \dots, n-1.$$

# Stabilnost eksplicitne metode konačnih razlika

Budući da je  $\lambda > 0$  po definiciji slijedi da je uvijek  $1 - 4\lambda \sin^2\left(\frac{k\pi}{2n}\right) < 1$ . S druge strane, uvjet

$$-1 < 1 - 4\lambda \sin^2\left(\frac{k\pi}{2n}\right)$$

se može pojednostaviti na

$$\lambda \sin^2\left(\frac{k\pi}{2n}\right) < \frac{1}{2}.$$

Dakle, gornji uvjet stabilnosti ekvivalentan je dvjema jednadžbama

$$\lambda > 0$$

$$\lambda \sin^2\left(\frac{k\pi}{2n}\right) < \frac{1}{2}.$$

# Stabilnost eksplicitne metode konačnih razlika

Najveći izraz sa sinusom je

$$\sin\left(\frac{(n-1)\pi}{2n}\right) < 1,$$

a ako povećavamo dimenziju matrice  $A$   $d = n - 1$  tada vrijedi

$$\lim_{d \rightarrow \infty} \sin\left(\frac{d\pi}{2(d+1)}\right) = 1.$$

Ovime smo dobili konačan uvjet.

Teorem. Za

$$0 < \lambda \leq \frac{1}{2}$$

eksplicitna metoda konačnih razlika za difuzijsku jednadžbu je stabilna. ■

# Stabilnost eksplicitne metode konačnih razlika

- Ovaj kriterij stabilnosti daje uvjet na veličinu koraka:

$$0 < \delta t \leq \frac{(\delta x)^2}{2}.$$

- Kao posljedica uvjeta stabilnosti, parametri  $m$  i  $n$  ne mogu biti izabrani nezavisno jedan od drugoga.
- Ako moramo izračunati rješenje sa velikom točnošću, tada  $\delta x$  mora biti malen, što daje kvadratnu ogradi za  $\delta t$  koji mora biti još manji.
- Zato nam je praktičnije naći numeričku metodu koja je bezuvjetno stabilna.

# Konvergencija eksplicitne metode kon. razlika

Da bi numerička metoda bila uopće korisna u primjenama, mora biti **konvergentna**:

- aproksimacije moraju **težiti** točnom **rješenju** kada  $\delta x$  i  $\delta t$  **teže** ka nuli

Prvo nas zanima **lokalna pogreška diskretizacije**, to je ostatak koji dobijemo kada u **relaciju** koja definira metodu **uvrstimo** točno **rješenje**:

$$\epsilon_{i,j+1} = u(x_i, t_{j+1}) - \lambda u(x_{i-1}, t_j) - (1 - 2\lambda)u(x_i, t_j) - \lambda u(x_{i+1}, t_j).$$

Izraze u **lokalnoj pogrešci diskretizacije** razvijamo u **Taylorov red** i dobivamo

# Konvergencija eksplicitne metode kon. razlika

$$\epsilon_{i,j+1} =$$

$$\begin{aligned} &= u(x_i, t_j) + \delta t \frac{\partial u}{\partial t}(x_i, t_j) + \frac{1}{2}(\delta t)^2 \frac{\partial^2 u}{\partial t^2}(x_i, t_j) + \mathcal{O}((\delta t)^3) - \\ &\quad - \lambda \left[ u(x_i, t_j) - \delta x \frac{\partial u}{\partial x}(x_i, t_j) + \frac{1}{2}(\delta x)^2 \frac{\partial^2 u}{\partial x^2}(x_i, t_j) - \frac{1}{6}(\delta x)^3 \frac{\partial^3 u}{\partial x^3}(x_i, t_j) + \right. \\ &\quad \left. + \frac{1}{24}(\delta x)^4 \frac{\partial^4 u}{\partial x^4}(x_i, t_j) + \mathcal{O}((\delta x)^5) \right] - (1 - 2\lambda)u(x_i, t_j) - \\ &\quad - \lambda \left[ u(x_i, t_j) + \delta x \frac{\partial u}{\partial x}(x_i, t_j) + \frac{1}{2}(\delta x)^2 \frac{\partial^2 u}{\partial x^2}(x_i, t_j) + \frac{1}{6}(\delta x)^3 \frac{\partial^3 u}{\partial x^3}(x_i, t_j) + \right. \\ &\quad \left. + \frac{1}{24}(\delta x)^4 \frac{\partial^4 u}{\partial x^4}(x_i, t_j) + \mathcal{O}((\delta x)^5) \right] \end{aligned}$$

# Konvergencija eksplicitne metode kon. razlika

Ako uvrstimo da je  $\delta t = \lambda(\delta x)^2$ , sređivanjem prethodnog izraza dobivamo

$$\begin{aligned}\epsilon_{i,j+1} &= \delta t \left( \frac{\partial u}{\partial t}(x_i, t_j) - \frac{\partial^2 u}{\partial x^2}(x_i, t_j) \right) + \\ &\quad + \frac{(\delta t)^2}{2} \frac{\partial^2 u}{\partial t^2}(x_i, t_j) - \lambda \frac{(\delta x)^4}{12} \frac{\partial^4 u}{\partial x^4}(x_i, t_j) + \mathcal{O}((\delta t)^3) + \mathcal{O}((\delta x)^5) \\ &= \frac{(\delta t)^2}{2} \frac{\partial^2 u}{\partial t^2}(x_i, t_j) - \lambda \frac{(\delta x)^4}{12} \frac{\partial^4 u}{\partial x^4}(x_i, t_j) + \mathcal{O}((\delta t)^3) + \mathcal{O}((\delta x)^5)\end{aligned}$$

jer je  $u$  rješenje difuzijske jednadžbe. Dakle, vrijedi

$$\begin{aligned}u(x_i, t_{j+1}) &= \lambda u(x_{i-1}, t_j) + (1 - 2\lambda)u(x_i, t_j) + \lambda u(x_{i+1}, t_j) + \\ &\quad + \mathcal{O}((\delta t)^2) + \mathcal{O}((\delta x)^4) (\approx \mathcal{O}((\delta x)^4)).\end{aligned}$$

# Konvergencija eksplicitne metode kon. razlika

Drugim riječima, ako bismo u vremenskom koraku  $j$  metodi dali **egzaktne vrijednosti** rješenja u svim čvorovima, pogreška u  $(j + 1)$ -vom koraku bi bila reda veličine  $\mathcal{O}(\delta t(\delta x)^2)$ .

Ako definiramo

$$u_{egz}^{(j)} = [ u(x_1, t_j) \ \cdots \ u(x_{n-1}, t_j) ]^T$$
$$\epsilon^{(j+1)} = [ \epsilon_{1,j+1} \ \cdots \ \epsilon_{n-1,j+1} ]^T$$

tada izraz sa lokalnom pogreškom diskretizacije možemo napisati i u matričnom obliku kao

$$u_{egz}^{(j+1)} = Au_{egz}^{(j)} + u_r^{(j)} + \epsilon^{(j+1)}, \quad j = 0, \dots, m-1.$$

Pri tome je za svaki indeks  $j$

$$\|\epsilon^{(j)}\|_\infty \leq K\delta t(\delta x)^2.$$

# Konvergencija eksplisitne metode kon. razlika

**Teorem.** Promatramo eksplisitnu metodu konačnih razlika za difuzijsku jednadžbu u kojoj je Courantov broj  $\lambda$  konstantan kada  $\delta t \rightarrow 0$  i  $\delta x \rightarrow 0$ , i još je  $\lambda \leq 1/2$ . Neka je rješenje aproksimirano na vremenskom intervalu  $[0, T]$ , s korakom  $\delta t = \lambda(\delta x)^2$ , te neka je  $m = \lfloor T/\delta t \rfloor$ . Tada metoda konvergira, tj. za  $e^{(j)} = u^{(j)} - u_{egz}^{(j)}$  vrijedi

$$\lim_{\delta x \rightarrow 0} \max_{j=0, \dots, m} \|e^{(j)}\|_\infty = 0.$$

**Dokaz.** Prvo primijetimo da je inicijalna vrijednost rješenja zadana, pa je (u egzaktnoj aritmetici)  $e^{(0)} = 0$ . Drugo, za  $\lambda \leq 1/2$  je

$$\|A\|_\infty = \lambda + 1 - 2\lambda + \lambda = 1.$$

# Konvergencija eksplicitne metode kon. razlika

Oduzimanjem matričnih oblika iteracije metode i izraza za lokalnu pogrešku diskretizacije dobivamo

$$e^{(j+1)} = Ae^{(j)} - \epsilon^{(j+1)},$$

pa onda **induktivno** možemo zaključiti da je za svaki  $j$

$$e^{(j)} = A^j e^{(0)} - \sum_{i=0}^{j-1} A^i \epsilon^{(j-i)} = - \sum_{i=0}^{j-1} A^i \epsilon^{(j-i)}.$$

Sada uzimanjem norme dobivamo

$$\begin{aligned} \|e^{(j)}\|_\infty &\leq \sum_{i=0}^{j-1} \|A\|_\infty^i \|\epsilon^{(j-i)}\|_\infty \leq j K \delta t (\delta x)^2 \\ &\leq m K \delta t (\delta x)^2 \leq T K (\delta x)^2, \end{aligned}$$

# Konvergencija eksplicitne metode kon. razlika

jer je  $m\delta t \leq T$ .



Iz dokaza prethodnog teorema jasno je vidljivo da

- Konzistentnost: lokalna pogreška diskretizacije zadovoljava  $\|e^{(j)}\|/\delta t \rightarrow 0$  kada  $\delta x \rightarrow 0$ .
- Stabilnost: Courantov broj zadovoljava  $\lambda \leq 1/2$

osiguravaju konvergenciju metode.

# Potpuna implicitna metoda konačnih razlika

- Implicitne metode se koriste kako bi se **izbjegla** ograničenja vezana uz **stabilnost** eksplicitne metode.
- Ove metode nam omogućuju da koristimo **mreže** u  $x$  koordinati sa **velikim brojem čvorova**, bez da moramo uzeti **jako mali  $\delta t$** .
- Jedna od implicitnih metoda je i **potpuna implicitna metoda** konačnih razlika, koja računa aproksimaciju rješenja difuzijske jednadžbe u čvorovima mreže koristeći
  - konačnu razliku **unazad** za  $\partial u / \partial t$ ,
  - simetričnu **centralnu** konačnu razliku za  $\partial^2 u / \partial x^2$ .

# Potpuna implicitna metoda konačnih razlika (n.)

Pri tome se difuzijska jednadžba transformira u

$$\frac{u_{i,j+1} - u_{i,j}}{\delta t} + \mathcal{O}(\delta t) = \frac{u_{i+1,j+1} - 2u_{i,j+1} + u_{i-1,j+1}}{(\delta x)^2} + \mathcal{O}((\delta x)^2).$$

Zanemarujući izraze  $\mathcal{O}(\delta t)$  i  $\mathcal{O}((\delta x)^2)$  dobivamo diferencijsku jednadžbu

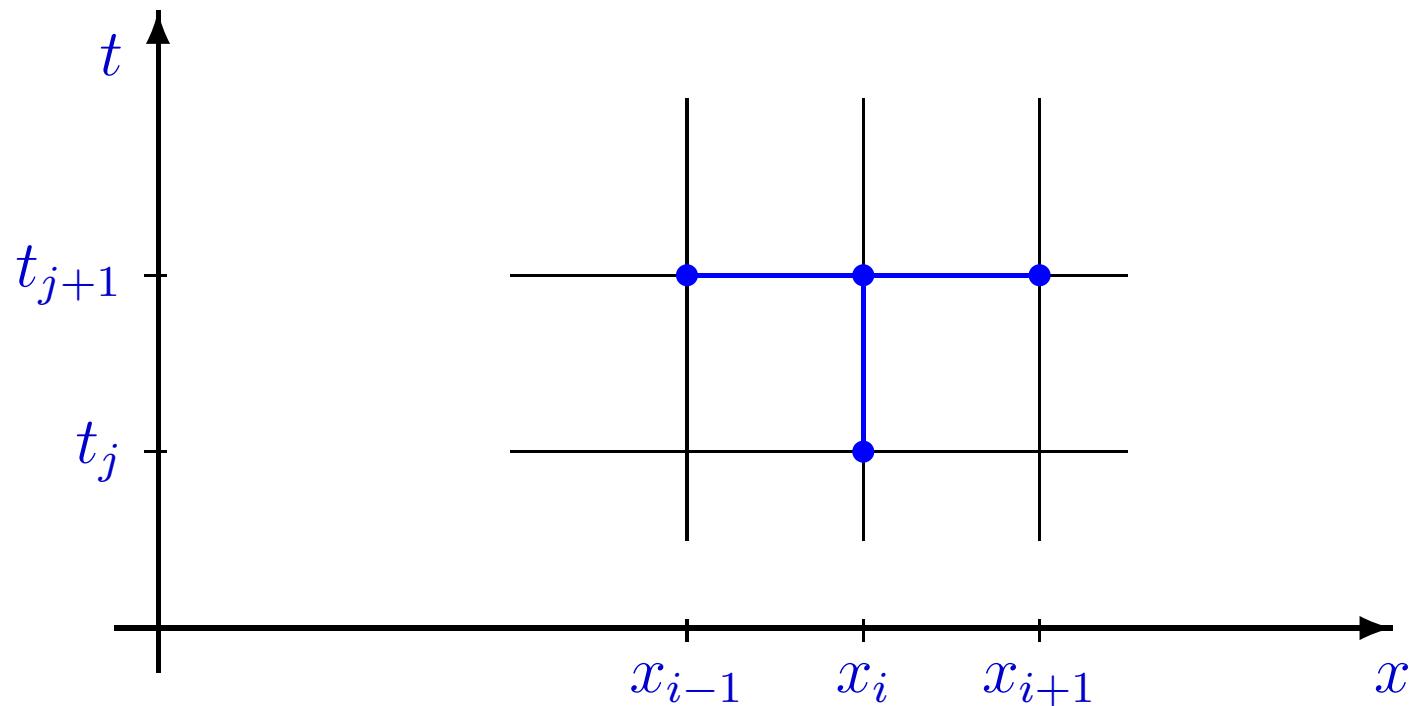
$$-\lambda u_{i-1,j+1} + (1 + 2\lambda)u_{i,j+1} - \lambda u_{i+1,j+1} = u_{i,j},$$

gdje je opet

$$\lambda = \frac{\delta \tau}{(\delta x)^2}.$$

U potpunoj implicitnoj metodi  $u_{i-1,j+1}$ ,  $u_{i,j+1}$  i  $u_{i+1,j+1}$  implicitno ovise o  $u_{i,j}$ .

# Potpuna implicitna metoda konačnih razlika (n.)



$u_{i-1,j+1}$ ,  $u_{i,j+1}$  i  $u_{i+1,j+1}$  ovise o  $u_{i,j}$ .

# Potpuna implicitna metoda konačnih razlika (n.)

- nove vrijednosti se ne mogu razdvojiti i eksplisitno izračunati iz starih vrijednosti.
- Radi se o simultanom rješavanju jednadžbi, odnosno o rješavanju sustava linearnih jednadžbi.

Sada možemo riješiti diferencijsku jednadžbu za

$$0 < i < n, \quad 0 < j \leq m.$$

Rubne uvjete koristimo za određivanje  $u_{0,j}$  i  $u_{n,j}$ :

$$u_{0,j} = u_a(j\delta t), \quad 0 < j \leq m,$$

$$u_{n,j} = u_b(j\delta t), \quad 0 < j \leq m.$$

Za pokretanje ove iterativne metode koristimo inicijalni uvjet

$$u_{i,0} = u_0(a + i\delta x), \quad 0 \leq i \leq n.$$

## Potpuna implicitna metoda konačnih razlika (n.)

Iterativna metoda završava za  $j = m$  i rješenjem

$$u_{i,m}, \quad 0 \leq i \leq n,$$

što predstavlja aproksimaciju rješenja za  $u(a + i\delta x, T)$ ,  
 $0 \leq i \leq n$ .

S obzirom da moramo rješavati sustave, sada nam i u fazi računanja treba matrični oblik diferencijske jednadžbe.

# Potpuna implicitna metoda konačnih razlika (n.)

Definiramo  $(n - 1) \times (n - 1)$  matricu  $A$

$$A = \begin{bmatrix} 1 + 2\lambda & -\lambda & 0 & \cdots & 0 \\ -\lambda & 1 + 2\lambda & \ddots & \ddots & \vdots \\ 0 & \ddots & \ddots & \ddots & 0 \\ \vdots & \ddots & \ddots & \ddots & -\lambda \\ 0 & \cdots & 0 & -\lambda & 1 + 2\lambda \end{bmatrix},$$

i vektor desne strane sustava

$$b = u^{(j)} + u_r^{(j+1)},$$

gdje su

$$u^{(j)} = [ u_{1,j} \ \cdots \ u_{n-1,j} ]^T,$$

$$u_r^{(j+1)} = \lambda [ u_{0,j+1} \ 0 \ \cdots \ 0 \ u_{n,j+1} ]^T.$$

## Potpuna implicitna metoda konačnih razlika (n.)

Sada potpunu implicitnu metodu možemo napisati u matričnom obliku kao

$$Au^{(j+1)} = u^{(j)} + u_r^{(j+1)} = b^{(j)}.$$

Vektor  $u_r^{(j+1)}$  se pojavljuje zbog rubnih uvjeta, npr. iz prve jednadžbe slijedi

$$(1 + 2\lambda)u_{1,j+1} - \lambda u_{2,j+1} = u_{1,j} + \lambda u_{0,j+1}.$$

Pokazat ćemo da je matrica  $A$  regularna pa se korak implicitne metode može napisati eksplicitno kao

$$u^{(j+1)} = A^{-1} (u^{(j)} + u_r^{(j+1)}).$$

# Algoritam potpune implicitne metode kon. razl.

definiraj rješavač s matricom  $A$ ;  $\lambda = \frac{\delta t}{(\delta x)^2}$ ;

**for**  $i = 0 : n$

$u(i) = u_0(a + i \cdot \delta x);$

**end**

**for**  $j = 1 : m$

**for**  $i = 1 : n - 1$

$b(i) = u(i);$

**end**

$u(0) = u_a(j \cdot \delta t);$

$u(n) = u_b(j \cdot \delta t);$

$b(1) = b(1) + \lambda \cdot u(0);$

$b(n - 1) = b(n - 1) + \lambda \cdot u(n);$

riješi sustav  $Au(1 : n - 1) = b;$

**end**

# Stabilnost potpune implicitne metode kon. razl.

- Kao i kod eksplisitne metode prepostavimo da našu numeričku metodu izvršavamo na računalu u aritmetici konačne preciznosti.
- U tom slučaju ćemo u svakom koraku  $j$  umjesto  $u^{(j+1)}$  izračunati aproksimativnu vrijednost  $\tilde{u}^{(j+1)}$  koja sadrži i greške zaokruživanja.
- Neka je

$$\tilde{u}^{(j+1)} = A^{-1} (\tilde{u}^{(j)} + \tilde{u}_r^{(j+1)}) + f^{(j+1)},$$

gdje  $f^{(j+1)}$  sadrži greške zaokruživanja koje su se dogodile kod računanja  $A^{-1} (\tilde{u}^{(j)} + \tilde{u}_r^{(j+1)})$ .

Definirajmo ukupnu grešku

$$e^{(j)} = \tilde{u}^{(j)} - u^{(j)}, \quad j \geq 0.$$

# Stabilnost potpune implicitne metode kon. razl.

Možemo zaključiti da vrijedi sljedeće:

$$e^{(j+1)} = A^{-1}e^{(j)} + A^{-1}(\tilde{u}_r^{(j+1)} - u_r^{(j+1)}) + f^{(j+1)}.$$

Usredotočimo se opet na **utjecaj grešaka zaokruživanja**  $e^{(0)}$  kod računanja inicijalnog uvjeta (za  $j = 0$ ). Zbog jednostavnosti, **prepostavimo** da su svi daljnji koraci ( $j > 0$ ) izračunati **egzaktno**, tj. da je

$$\tilde{u}_r^{(j)} = u_r^{(j)}, \quad f^{(j)} = 0, \quad j > 0.$$

Tada imamo

$$e^{(j+1)} = A^{-1}e^{(j)} = A^{-(j+1)}e^{(0)}.$$

Da bi metoda bila stabilna, greška  $e^{(0)}$  mora biti **prigušena**, a za to treba biti

$$\lim_{j \rightarrow \infty} A^{-j}e^{(0)} = 0.$$

## Stabilnost potpune implicitne metode kon. razl.

Znamo da će metoda biti stabilna ako i samo ako je

$$\rho(A^{-1}) < 1,$$

Dakle, da bi metoda bila stabilna zahtijevamo da za sve svojstvene vrijednosti  $\mu_1(A^{-1}), \dots, \mu_{n-1}(A^{-1})$  od  $A^{-1}$  vrijedi

$$|\mu_k(A^{-1})| < 1, \quad k = 1, \dots, n-1.$$

Dalje vrijedi da je  $\mu_k(A^{-1}) = (\mu_k(A))^{-1}$ , a svojstvene vrijednosti matrice  $A$  dobit ćemo iz rastava

# Stabilnost potpune implicitne metode kon. razl.

$$A = I + \lambda \cdot \underbrace{\begin{bmatrix} 2 & -1 & & & 0 \\ -1 & 2 & \ddots & & \\ & \ddots & \ddots & \ddots & \\ & & \ddots & \ddots & -1 \\ 0 & & & -1 & 2 \end{bmatrix}}_{=G}.$$

Budući da znamo svojstvene vrijednosti  $\mu_k(G)$  od matrice  $G$ , tada je

$$\mu_k(A^{-1}) = \frac{1}{1 + \lambda \cdot \mu_k(G)}, \quad k = 1, \dots, n-1.$$

Kako je

# Stabilnost potpune implicitne metode kon. razl.

$$\mu_k(G) = 4 \sin^2 \left( \frac{k\pi}{2n} \right), \quad k = 1, \dots, n-1,$$

imamo

$$\mu_k(A) = 1 + 4\lambda \sin^2 \left( \frac{k\pi}{2n} \right), \quad k = 1, \dots, n-1.$$

Jer je  $\lambda > 0$ , a  $\sin \left( \frac{k\pi}{2n} \right) \neq 0$  za  $k = 1, \dots, n-1$ , onda je

$$\mu_k(A) > 1$$

$$0 < \mu_k(A^{-1}) < 1, \quad k = 1, \dots, n-1.$$

Dakle, za bilo koji  $\lambda > 0$  je  $0 < \mu_k(A^{-1}) < 1$ , što znači da je potpuna implicitna metoda konačnih razlika bezuvjetno stabilna.

# Stabilnost potpune implicitne metode kon. razl.

S druge strane, vidimo da su sve svojstvene vrijednosti matrice  $A$  pozitivne, što znači da je matrica pozitivno definitna.

- Zbog toga za rješavanje sustava  $Au^{(j+1)} = b^{(j)}$  možemo koristiti metode
  - faktorizaciju Choleskog
  - Gauss–Seidelovu i SOR metodu
  - metodu konjugiranih gradijenatakoje su specijalno prilagođene za tridijagonalnu matricu.
- Kod efikasno implementirane eksplisitne i implicitne metode broj operacija je istog reda veličine, pa rješavanje sustava kod implicitne metode ne predstavlja preveliki dodatni trošak u odnosu na eksplisitnu.

# Crank–Nicolsonova metoda

- Crank–Nicolsonova metoda je također implicitna metoda koja nema problema sa stabilnošću, ali ima grešku diskretizacije derivacije  $\partial u / \partial t$  reda veličine  $\mathcal{O}((\delta t)^2)$ .
- Crank–Nicolsonova metoda računa aproksimaciju rješenja difuzijske jednadžbe u čvorovima mreže tako da uzima srednju vrijednost diferencijskih jednadžbi eksplicitne i potpuno implicitne metode.

Dakle, ako koristimo konaču razliku unaprijed za  $\partial u / \partial t$  dobivamo eksplicitnu metodu

$$\frac{u_{i,j+1} - u_{i,j}}{\delta t} + \mathcal{O}(\delta t) = \frac{u_{i+1,j} - 2u_{i,j} + u_{i-1,j}}{(\delta x)^2} + \mathcal{O}((\delta x)^2),$$

# Crank–Nicolsonova metoda (nastavak)

a ako koristimo konaču razliku unazad za  $\partial u / \partial t$  dobivamo potpunu implicitnu metodu

$$\frac{u_{i,j+1} - u_{i,j}}{\delta t} + \mathcal{O}(\delta t) = \frac{u_{i+1,j+1} - 2u_{i,j+1} + u_{i-1,j+1}}{(\delta x)^2} + \mathcal{O}((\delta x)^2).$$

Srednja vrijednost tih dviju jednadžbi je

$$\begin{aligned} & \frac{u_{i,j+1} - u_{i,j}}{\delta t} + \mathcal{O}(\delta t) = \\ &= \frac{1}{2} \left( \frac{u_{i+1,j} - 2u_{i,j} + u_{i-1,j}}{(\delta x)^2} + \frac{u_{i+1,j+1} - 2u_{i,j+1} + u_{i-1,j+1}}{(\delta x)^2} \right) + \\ & \quad + \mathcal{O}((\delta x)^2). \end{aligned}$$

# Crank–Nicolsonova metoda (nastavak)

Ovom metodom zapravo **aproksimiramo** vrijednost difuzijske jednadžbe u točki  $(x_i, t_{j+\frac{1}{2}})$ , koja se nalazi na **pola puta** između  $(x_i, t_j)$  i  $(x_i, t_{j+1})$ :

$$\frac{\partial u}{\partial t}(x_i, t_{j+\frac{1}{2}}) = \frac{\partial^2}{\partial x^2}(x_i, t_{j+\frac{1}{2}}).$$

U ovom slučaju, prvu derivaciju po varijabli  $t$  **aproksimiramo** centralnom konačnom razlikom

$$\frac{\partial u}{\partial t}(x_i, t_{j+\frac{1}{2}}) \approx \frac{u_{i,j+1} - u_{i,j}}{\delta t},$$

a drugu derivaciju po varijabli  $x$  sa

$$\begin{aligned} \frac{\partial^2}{\partial x^2}(x_i, t_{j+\frac{1}{2}}) \approx & \frac{1}{2} \left( \frac{u_{i+1,j} - 2u_{i,j} + u_{i-1,j}}{(\delta x)^2} + \right. \\ & \left. \frac{u_{i+1,j+1} - 2u_{i,j+1} + u_{i-1,j+1}}{(\delta x)^2} \right). \end{aligned}$$

# Crank–Nicolsonova metoda (nastavak)

Provjerimo točno koliku smo **gresku** napravili u varijabli  $t$ . Za egzaktne vrijednosti  $u_{i,j} = u(x_i, t_j)$  imamo

$$u_{i,j+1} = u_{i,j+\frac{1}{2}} + \frac{\delta t}{2} \frac{\partial u}{\partial t}(x_i, t_{j+\frac{1}{2}}) + \frac{(\delta t)^2}{8} \frac{\partial^2 u}{\partial t^2}(x_i, t_{j+\frac{1}{2}}) + \mathcal{O}((\delta t)^3)$$
$$u_{i,j} = u_{i,j+\frac{1}{2}} - \frac{\delta t}{2} \frac{\partial u}{\partial t}(x_i, t_{j+\frac{1}{2}}) + \frac{(\delta t)^2}{8} \frac{\partial^2 u}{\partial t^2}(x_i, t_{j+\frac{1}{2}}) + \mathcal{O}((\delta t)^3).$$

To znači da za **centralnu** konačnu razliku vrijedi

$$\frac{u_{i,j+1} - u_{i,j}}{\delta t} = \frac{\partial u}{\partial t}(x_i, t_{j+\frac{1}{2}}) + \mathcal{O}((\delta t)^2).$$

S druge strane, moramo još provjeriti odnos **desne strane** u Crank–Nicolsonovoj iteraciji sa  $\frac{\partial^2}{\partial x^2}(x_i, t_{j+\frac{1}{2}})$ .

# Crank–Nicolsonova metoda (nastavak)

Uzimanjem srednje vrijednosti prethodno izraženih konačnih razlika **unaprijed** i **unazad**, dobivamo jednakost

$$\begin{aligned} & \frac{1}{2} \left( \frac{u_{i+1,j} - 2u_{i,j} + u_{i-1,j}}{(\delta x)^2} + \frac{u_{i+1,j+1} - 2u_{i,j+1} + u_{i-1,j+1}}{(\delta x)^2} \right) = \\ &= \frac{1}{2} \left( \frac{\partial^2 u}{\partial x^2}(x_i, t_j) + \frac{\partial^2 u}{\partial x^2}(x_i, t_{j+1}) \right) + \mathcal{O}((\delta x)^2) \\ &= \frac{1}{2} \left( \frac{\partial^2 u}{\partial x^2}(x_i, t_{j+\frac{1}{2}}) - \frac{\delta x}{2} \frac{\partial^3 u}{\partial x^3}(x_i, t_{j+\frac{1}{2}}) + \right. \\ &\quad \left. + \frac{\partial^2 u}{\partial x^2}(x_i, t_{j+\frac{1}{2}}) + \frac{\delta x}{2} \frac{\partial^3 u}{\partial x^3}(x_i, t_{j+\frac{1}{2}}) \right) + \mathcal{O}((\delta x)^2) \\ &= \frac{\partial^2 u}{\partial x^2}(x_i, t_{j+\frac{1}{2}}) + \mathcal{O}((\delta x)^2). \end{aligned}$$

## Crank–Nicolsonova metoda (nastavak)

Znači, aproksimirajući difuzijsku jednadžbu u točki  $(x_i, t_{j+\frac{1}{2}})$  iteracijama Crank–Nicolsonove metode napravili smo grešku reda veličine  $\mathcal{O}((\delta x)^2) + \mathcal{O}((\delta t)^2)$ .

Srednja vrijednost tih dviju jednadžbi točije sada glasi

$$\begin{aligned} & \frac{u_{i,j+1} - u_{i,j}}{\delta t} + \mathcal{O}((\delta t)^2) = \\ &= \frac{1}{2} \left( \frac{u_{i+1,j} - 2u_{i,j} + u_{i-1,j}}{(\delta x)^2} + \frac{u_{i+1,j+1} - 2u_{i,j+1} + u_{i-1,j+1}}{(\delta x)^2} \right) + \\ & \quad + \mathcal{O}((\delta x)^2). \end{aligned}$$

# Crank–Nicolsonova metoda (nastavak)

Zanemarujući izraze  $\mathcal{O}((\delta t)^2)$  i  $\mathcal{O}((\delta x)^2)$  dobivamo diferencijsku jednadžbu

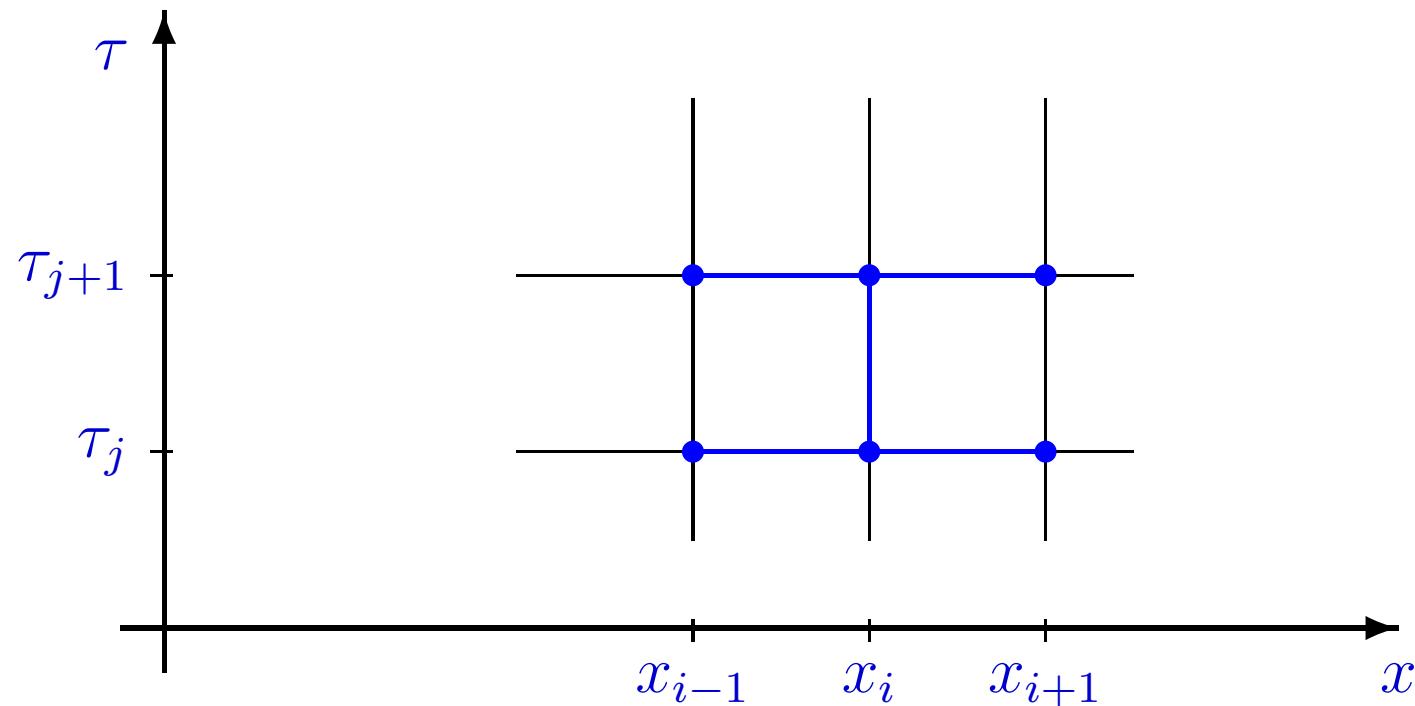
$$\begin{aligned}-\frac{\lambda}{2}u_{i-1,j+1} + (1 + \lambda)u_{i,j+1} - \frac{\lambda}{2}u_{i+1,j+1} = \\ = \frac{\lambda}{2}u_{i-1,j} + (1 - \lambda)u_{i,j} + \frac{\lambda}{2}u_{i+1,j},\end{aligned}$$

gdje je opet

$$\lambda = \frac{\delta t}{(\delta x)^2}.$$

U Crank–Nicolsonovoj metodi  $u_{i-1,j+1}$ ,  $u_{i,j+1}$  i  $u_{i+1,j+1}$  implicitno ovise o  $u_{i-1,j}$ ,  $u_{i,j}$  i  $u_{i+1,j}$ .

# Crank–Nicolsonova metoda (nastavak)



$u_{i-1,j+1}$ ,  $u_{i,j+1}$  i  $u_{i+1,j+1}$  ovise o  $u_{i-1,j}$ ,  $u_{i,j}$  i  $u_{i+1,j}$

# Crank–Nicolsonova metoda (nastavak)

Sada možemo riješiti diferencijsku jednadžbu za

$$0 < i < n, \quad 0 < j \leq m.$$

Rubne uvjete koristimo za određivanje  $u_{0,j}$  i  $u_{n,j}$ :

$$u_{0,j} = u_a(j\delta t), \quad 0 < j \leq m,$$

$$u_{n,j} = u_b(j\delta t), \quad 0 < j \leq m.$$

Za pokretanje ove iterativne metode koristimo inicijalni uvjet

$$u_{i,0} = u_0(a + i\delta x), \quad 0 \leq i \leq n.$$

Iterativna metoda završava za  $j = m$  i rješenjem

$$u_{i,m}, \quad 0 \leq i \leq n,$$

što predstavlja aproksimaciju rješenja za  $u(a + i\delta x, T)$ ,  
 $0 \leq i \leq n$ .

# Crank–Nicolsonova metoda (nastavak)

Također ćemo i ovdje morati rješavati sustave, pa nam opet treba matrični oblik diferencijske jednadžbe. Definiramo  $(n - 1) \times (n - 1)$  matricu  $A$

$$A = \begin{bmatrix} 1 + \lambda & -\frac{\lambda}{2} & 0 & \cdots & 0 \\ -\frac{\lambda}{2} & 1 + \lambda & \ddots & \ddots & \vdots \\ 0 & \ddots & \ddots & \ddots & 0 \\ \vdots & \ddots & \ddots & \ddots & -\frac{\lambda}{2} \\ 0 & \cdots & 0 & -\frac{\lambda}{2} & 1 + \lambda \end{bmatrix},$$

# Crank–Nicolsonova metoda (nastavak)

i  $(n - 1) \times (n - 1)$  matricu  $B$

$$B = \begin{bmatrix} 1 - \lambda & \frac{\lambda}{2} & 0 & \cdots & 0 \\ \frac{\lambda}{2} & 1 - \lambda & \ddots & \ddots & \vdots \\ 0 & \ddots & \ddots & \ddots & 0 \\ \vdots & \ddots & \ddots & \ddots & \frac{\lambda}{2} \\ 0 & \cdots & 0 & \frac{\lambda}{2} & 1 - \lambda \end{bmatrix}.$$

Isto tako nam još trebaju vektori

$$u^{(j)} = [ u_{1,j} \ \cdots \ u_{n-1,j} ]^T,$$

$$u_r^{(j)} = \lambda [ u_{0,j} \ 0 \ \cdots \ 0 \ u_{n,j} ]^T.$$

# Crank–Nicolsonova metoda (nastavak)

Tada Crank–Nicolsonovu metodu možemo napisati u matričnom obliku kao

$$Au^{(j+1)} = Bu^{(j)} + \frac{1}{2}u_r^{(j)} + \frac{1}{2}u_r^{(j+1)} = b^{(j)}.$$

Pokazat ćemo da je matrica  $A$  regularna pa se korak Crank–Nicolsonove metode može napisati eksplicitno kao

$$u^{(j+1)} = A^{-1} \left( Bu^{(j)} + \frac{1}{2}u_r^{(j)} + \frac{1}{2}u_r^{(j+1)} \right).$$

# Algoritam Crank–Nicolsonove metode

definiraj rješavač s matricom  $A$ ;  $\lambda = \frac{\delta t}{(\delta x)^2}$ ;

**for**  $i = 0 : n$

$$u(i) = u_0(a + i \cdot \delta x);$$

**end**

**for**  $j = 1 : m$

**for**  $i = 1 : n - 1$

$$b(i) = \frac{\lambda}{2}u(i - 1) + (1 - \lambda)u(i) + \frac{\lambda}{2}u(i + 1);$$

**end**

$$u(0) = y_a(j \cdot \delta t);$$

$$u(n) = u_b(j \cdot \delta t);$$

$$b(1) = b(1) + \frac{\lambda}{2} \cdot u(0);$$

$$b(n - 1) = b(n - 1) + \frac{\lambda}{2} \cdot u(n);$$

riješi sustav  $Au(1 : n - 1) = b$ ;

**end**

# Stabilnost Crank–Nicolsonove metode

- Kao i do sada pretpostavimo da našu numeričku metodu izvršavamo na računalu u aritmetici konačne preciznosti.
- U tom slučaju ćemo u svakom koraku  $j$  umjesto  $u^{(j+1)}$  izračunati aproksimativnu vrijednost  $\tilde{u}^{(j+1)}$  koja sadrži i greške zaokruživanja.
- Neka je

$$\tilde{u}^{(j+1)} = A^{-1} \left( B\tilde{u}^{(j)} + \frac{1}{2}\tilde{u}_r^{(j)} + \frac{1}{2}\tilde{u}_r^{(j+1)} \right) + f^{(j+1)},$$

gdje  $f^{(j+1)}$  sadrži greške zaokruživanja koje su se dogodile kod računanja  $A^{-1} \left( B\tilde{u}^{(j)} + \frac{1}{2}\tilde{u}_r^{(j)} + \frac{1}{2}\tilde{u}_r^{(j+1)} \right)$ .

Definirajmo ukupnu grešku

$$e^{(j)} = \tilde{u}^{(j)} - u^{(j)}, \quad j \geq 0.$$

## Stabilnost Crank–Nicolsonove metode (nast.)

Možemo zaključiti da vrijedi sljedeće:

$$e^{(j+1)} = A^{-1}Be^{(j)} + \frac{1}{2}A^{-1}(\tilde{u}_r^{(j)} - u_r^{(j)} + \tilde{u}_r^{(j+1)} - u_r^{(j+1)}) + f^{(j+1)}.$$

Usredotočimo se opet na **utjecaj grešaka zaokruživanja**  $e^{(0)}$  kod računanja inicijalnog uvjeta (za  $j = 0$ ). Zbog jednostavnosti, **pretpostavimo** da su svi daljnji koraci ( $j > 0$ ) izračunati **egzaktno**, tj. da je

$$\tilde{u}_r^{(j)} = u_r^{(j)}, \quad f^{(j)} = 0, \quad j > 0.$$

Tada imamo

$$e^{(j+1)} = A^{-1}Be^{(j)} = (A^{-1}B)^{j+1}e^{(0)}.$$

Da bi metoda bila stabilna, greška  $e^{(0)}$  mora biti **prigušena**, a za to treba biti

$$\lim_{j \rightarrow \infty} (A^{-1}B)^j e^{(0)} = 0.$$

## Stabilnost Crank–Nicolsonove metode (nast.)

Znamo da će metoda biti stabilna ako i samo ako je

$$\rho(A^{-1}B) < 1,$$

Dakle, da bi metoda bila stabilna zahtijevamo da za sve svojstvene vrijednosti  $\mu_1(A^{-1}B), \dots, \mu_{n-1}(A^{-1}B)$  od  $A^{-1}B$  vrijedi

$$|\mu_k(A^{-1}B)| < 1, \quad k = 1, \dots, n-1.$$

Tražene svojstvene vrijednosti dobit ćemo iz rastava matrica  $A$  i  $B$

# Stabilnost Crank–Nicolsonove metode (nast.)

$$A = I + \frac{\lambda}{2} \cdot \underbrace{\begin{bmatrix} 2 & -1 & & & 0 \\ -1 & 2 & \ddots & & \\ & \ddots & \ddots & \ddots & \\ & & \ddots & \ddots & -1 \\ 0 & & & -1 & 2 \end{bmatrix}}_{=G}.$$

$$B = I - \frac{\lambda}{2} \cdot \underbrace{\begin{bmatrix} 2 & -1 & & & 0 \\ -1 & 2 & \ddots & & \\ & \ddots & \ddots & \ddots & \\ & & \ddots & \ddots & -1 \\ 0 & & & -1 & 2 \end{bmatrix}}_{=G}.$$

## Stabilnost Crank–Nicolsonove metode (nast.)

Sada jednakost  $Ae^{(j+1)} = Be^{(j)}$  možemo napisati kao

$$\begin{aligned} \left(I + \frac{\lambda}{2}G\right)e^{(j+1)} &= \left(I - \frac{\lambda}{2}G\right)e^{(j)} \\ (2I + \lambda G)e^{(j+1)} &= (2I - \lambda G)e^{(j)} \\ &= (4I - (2I + \lambda G))e^{(j)}. \end{aligned}$$

Ako definiramo  $C = 2I + \lambda G$ , tada je

$$Ce^{(j+1)} = (4I - C)e^{(j)},$$

Odnosno

$$e^{(j+1)} = (4C^{-1} - I)e^{(j)}.$$

## Stabilnost Crank–Nicolsonove metode (nast.)

Budući da znamo svojstvene vrijednosti  $\mu_k(G)$  od matrice  $G$ , tada je

$$\mu_k(C) = 2 + \lambda\mu_k(G), \quad k = 1, \dots, n-1,$$

i

$$\mu_k(4C^{-1} - I) = \frac{4}{2 + \lambda\mu_k(G)} - 1, \quad k = 1, \dots, n-1.$$

Kako je

$$\mu_k(G) = 4 \sin^2 \left( \frac{k\pi}{2n} \right), \quad k = 1, \dots, n-1,$$

## Stabilnost Crank–Nicolsonove metode (nast.)

zbog toga što je  $\lambda > 0$ , i  $\sin^2\left(\frac{k\pi}{2n}\right) > 0$  za  $k = 1, \dots, n - 1$ , vrijedi da je

$$\mu_k(G) > 0,$$

$$\mu_k(C) = 2 + \lambda\mu_k(G) > 2,$$

$$0 < \frac{4}{\mu_k(C)} = \frac{4}{2 + \lambda\mu_k(G)} < 2,$$

$$-1 < \mu_k(4C^{-1} - I) < 1, \quad k = 1, \dots, n - 1.$$

Dakle, za bilo koji  $\lambda > 0$  je  $|\mu_k(4C^{-1} - I)| < 1$ , što znači da je Crank–Nicolsonova metoda bezuvjetno stabilna.

# Stabilnost Crank–Nicolsonove metode (nast.)

- Kao i kod potpuno implicitne metode, može se vidjeti da su sve svojstvene vrijednosti matrice  $A$  pozitivne, što znači da je matrica pozitivno definitna.
- Zbog toga za rješavanje sustava  $Au^{(j+1)} = b^{(j)}$  možemo koristiti metode
  - faktorizaciju Choleskog
  - Gauss–Seidelovu i SOR metodu
  - metodu konjugiranih gradijenatakoje su specijalno prilagođene za tridijagonalnu matricu.

# Numeričko rješavanje Poissonove jednadžbe

# Poissonova jednadžba

Poissonova jednadžba opisuje razne procese u fizici:

- prijenos **topline**,
- procese u **elektrostatiki**,
- i **gravitacijskom polju**.

Ona je zapravo **stacionarni oblik** (koji ne ovisi o vremenu) difuzijske jednadžbe uz uvjet da je funkcija  $a$  konstantna, čiji je općeniti oblik

$$-\Delta u(x, t) = f(x, t), \quad x \in \Omega$$

pri čemu je potrebno još zadati

- **rubne uvjete** za  $x \in \partial\Omega$ .

# 1D Poissonova jednadžba

Promotrimo prvo najjednostavniji slučaj Poissonove jednadžbe u jednoj dimenziji — na nekom segmentu, recimo  $[0, 1]$ . Jednadžba glasi

$$-\frac{d^2u(x)}{dx^2} = f(x), \quad x \in [0, 1],$$

pri čemu je funkcija  $f$  zadana, a  $u$  nepoznata funkcija.

- Da bi Poissonova jednadžba bila dobro zadana, moramo još zadati rubne uvjete na rubu tog segmenta.
- U ovom slučaju, uzmimo najjednostavnije rubne uvjete, tj. zahtijevajmo da na rubu segmenta za funkciju  $u$  vrijedi

$$u(0) = u(1) = 0.$$

# Diskretizacija 1D Poissonova jednadžba

Da bismo numerički riješili 1D Poissonovu jednadžbu, zajedno s rubnim uvjetima, moramo je diskretizirati, tj. odabrati niz točaka  $x_i$  u kojima želimo naći približno rješenje.

- Neka su točke  $x_i$  ekvidistantne, tj. neka je

$$x_i = ih, \quad h = \frac{1}{N+1}, \quad i = 0, \dots, N+1.$$

Sada imamo  $N+1$  podsegmenata, tako da dobivena matrica (slično kao kod difuzijske jednadžbe) bude dimenzija  $N \times N$ .

- Također, neka je približno rješenje jednadžbe u točkama  $x_i$  označeno s  $u_i \approx u(x_i)$ , i neka je funkcija s desne strane u tim točkama  $f_i = f(x_i)$ .

# Diskretizacija 1D Poissonova jednadžba (nast.)

Drugu derivaciju aproksimirat ćemo simetričom konačnom razlikom:

$$\frac{d^2u}{dx^2}(x_i) \approx \frac{u_{i-1} - 2u_i + u_{i+1}}{h^2}.$$

Sada **uvrstimo** aproksimaciju za drugu derivaciju u diferencijalnu **jednadžbu**, za sve točke  $x_i$ . Dobivamo

$$-u_{i-1} + 2u_i - u_{i+1} = h^2 f(x_i), \quad i = 1, \dots, N.$$

U matričnom obliku, ova jednadžba glasi:

$$G_N u = h^2 f,$$

pri čemu je  $G_N$  matrica koja se pojavljivala i kod difuzijske jednadžbe (samo što je sada dimenzije  $N$ ):

# Diskretizacija 1D Poissonova jednadžba (nast.)

$$G_N = \begin{bmatrix} 2 & -1 & & & \\ -1 & 2 & -1 & & \\ & \ddots & \ddots & \ddots & \\ & & -1 & 2 & -1 \\ & & & -1 & 2 \end{bmatrix},$$

$u = [u_1, u_2, \dots, u_N]^T$  je nepoznati vektor rješenja, a  
 $f = [f_1, f_2, \dots, f_N]^T$  vektor desne strane sustava.

Iz teorema o svojstvenim vrijednostima TLS matrica znamo da su svojstvene vrijednosti matrice  $G_N$  jednake

$$\lambda_j = 2 \left( 1 - \cos \left( \frac{\pi j}{N+1} \right) \right) = 4 \sin^2 \left( \frac{\pi j}{2(N+1)} \right), \quad j = 1, \dots, N.$$

## Uvjetovanost matrice $G_N$

Najveća svojstvena vrijednost prethodne matrice približno je jednaka 4, dok je najmanja svojstvena vrijednost  $\lambda_1$  približno jednaka

$$\lambda_1 \approx 2 \left( 1 - \left( 1 - \frac{\pi^2}{2(N+1)^2} \right) \right) = \left( \frac{\pi}{N+1} \right)^2.$$

U prethodnoj formuli koristili smo aproksimaciju funkcije kosinus s njezina prva dva člana Taylorovog reda.

Sada je odmah jasno da je matrica  $G_N$  pozitivno definitna i da je njezina uvjetovanost približno jednaka

$$\kappa(G_N) = \frac{\lambda_N}{\lambda_1} \approx \frac{4(N+1)^2}{\pi^2}.$$

## Uvjetovanost matrice $G_N$ (nastavak)

To znači da **uvjetovanost brzo raste s porastom broja podintervala** (podsetite se veze uvjetovanosti i rješenja linearnih sustava).

## 2D Poissonova jednadžba

Sada promatramo slučaj Poissonove jednadžbe (eliptičku parcijalnu diferencijalnu) u dvije dimenzije — na nekom kvadratu, recimo  $[0, 1] \times [0, 1]$ . Jednadžba glasi

$$-\frac{\partial^2 u(x, y)}{\partial x^2} - \frac{\partial^2 u(x, y)}{\partial y^2} = f(x, y), \quad (x, y) \in [0, 1] \times [0, 1],$$

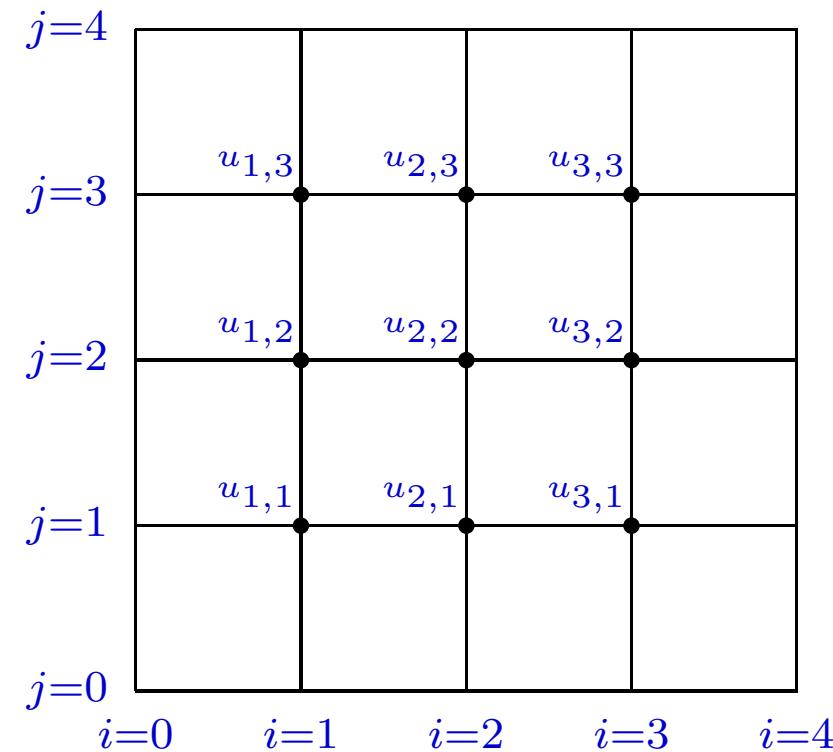
uz rubni uvjet  $u = 0$ , tj. funkcija  $u$  je jednaka 0 na rubu kvadrata.

Kvadrat podijelimo u mrežu čvorova, a da nam bude jednostavnije, pretpostavimo da je i ta mreža kvadratna, tj. korak u  $x$  i  $y$  smjeru je jednak

$$h = \frac{1}{N + 1}.$$

# Diskretizacija 2D Poissonove jednadžbe

Uz tako definirane korake, **unutarnji čvorovi** mreže su točke  $(x_i, y_j)$ , gdje je  $x_i = ih$ ,  $y_j = jh$ , za  $i, j = 1, \dots, N$ . Dakle, imamo  $n := N^2$  unutarnjih čvorova mreže. Takva **mreža** za  $N = 3$  izgleda ovako:



## Diskretizacija 2D Poissonove jednadžbe (nast.)

Vrijednost aproksimacije rješenja u čvoru  $(x_i, y_j)$  označavamo s  $u_{i,j} \approx u(ih, jh)$ , a funkciju vrijednost s  $f_{i,j} = f(ih, jh)$ .

Druge parcijalne derivacije aproksimirat ćemo simetričim konačnim razlikama:

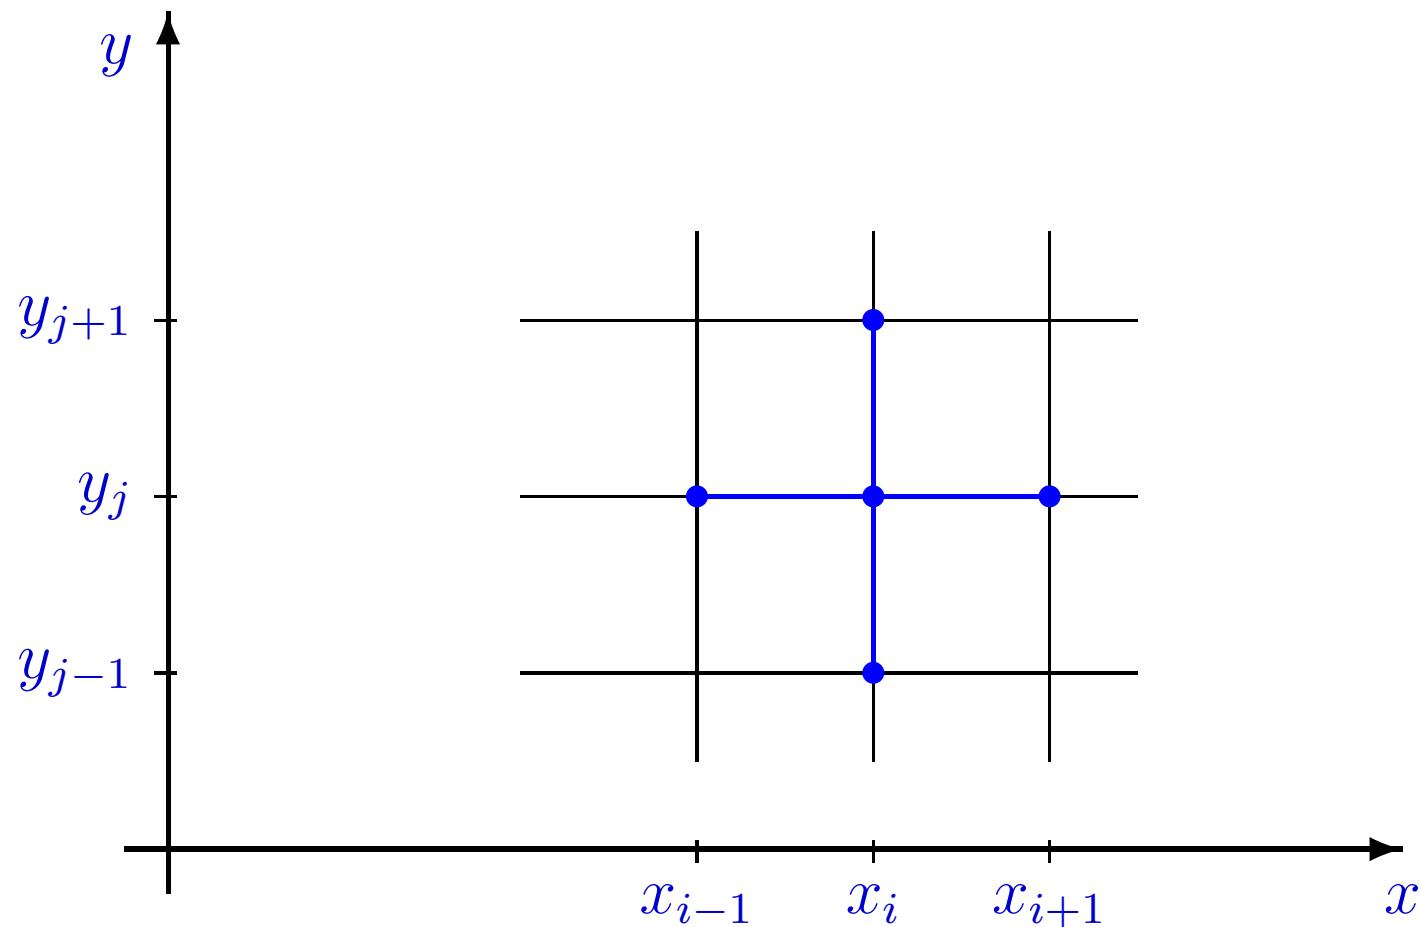
$$\frac{\partial^2 u}{\partial x^2}(x_i, y_j) \approx \frac{u_{i-1,j} - 2u_{i,j} + u_{i+1,j}}{h^2},$$

$$\frac{\partial^2 u}{\partial y^2}(x_i, y_j) \approx \frac{u_{i,j-1} - 2u_{i,j} + u_{i,j+1}}{h^2}.$$

Uvrstimo li te aproksimacije derivacija u diferencijalnu jednadžbu, dobivamo

$$4u_{i,j} - u_{i-1,j} - u_{i+1,j} - u_{i,j-1} - u_{i,j+1} = h^2 f_{i,j}, \quad i, j = 1, \dots, N.$$

# Diskretizacija 2D Poissonove jednadžbe (nast.)



$u_{i,j}$  OVIŠI O  $u_{i-1,j}$ ,  $u_{i+1,j}$ ,  $u_{i,j-1}$  i  $u_{i,j+1}$ .

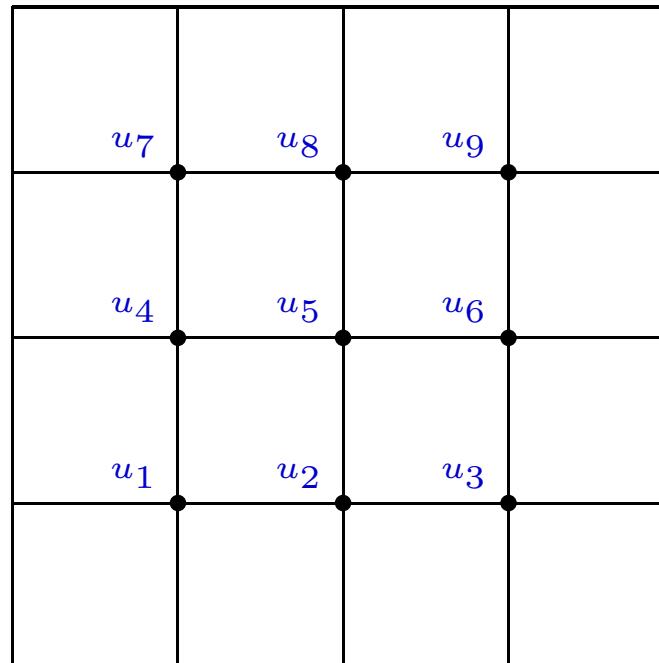
# Numeriranje čvorova u kvadratnoj mreži

Pitanje je **kako** treba napisati ove jednadžbe, tako da se dobije linearni sustav s nekom **strukturom**. Postoje **dva** načina da bi se to napravilo.

- Jedan je **sekvencijalno numeriranje**  $u_{i,j}$  po **recima** ili **stupcima** (slijeva nadesno, ili zdesna nalijevo, odozgo nadolje ili odozdo nagore),
- a drugi tzv. **crveno–crni** poredak čvorova, kao kod šahovnice.

# Sekvencijalno numeriranje čvorova

Ako  $u_{i,j}$  sekvencijalno numeriramo po recima odozdo nagore, na primjer za  $N = 3$ , dobivamo ovakav poredak čvorova:



Dakle, lako zamjenjujemo  $u_{i,j}$  s  $u_k$ , gdje  $k = (j - 1)N + i$ .

## Aproksimativni lin. sustav za 2D Poisson. jedn.

Ako se na isti način transformiraju i  $f_{i,j}$  u  $f_k$ , onda dobivamo linearни sustav

$$G_{N \times N} u = h^2 f,$$

gdje je  $u = [u_1, u_2, \dots, u_{N \times N}]^T$ ,  $f = [f_1, f_2, \dots, f_{N \times N}]^T$ , a matrica  $G_{N \times N}$  ima  $N$  blok-redaka i blok-stupaca, svaki dimenzije  $N$ .  $G_{N \times N}$  je  $N^2 \times N^2$  matrica oblika

$$G_{N \times N} = \begin{bmatrix} G_N + 2I_N & -I_N & & \\ -I_N & \ddots & \ddots & \\ & \ddots & \ddots & -I_N \\ & & -I_N & G_N + 2I_N \end{bmatrix},$$

pri čemu je  $I_N$  jedinična matrica reda  $N$ , a opet je

## Aproksimativni lin. sustav za 2D Poisson. jedn.

$$G_N = \begin{bmatrix} 2 & -1 & & & \\ -1 & \ddots & \ddots & & \\ & \ddots & \ddots & -1 & \\ & & -1 & 2 & \end{bmatrix}.$$

$G_N$  matrica koja nastaje **diskretizacijom** odgovarajuće 1D Poissonove jednadžbe.

Na primjer, za  $N = 3$ , matrica linearog sustava je

# Aproksimativni lin. sustav za 2D Poisson. jedn.

$$G_{3 \times 3} = \begin{bmatrix} 4 & -1 & & -1 & & \\ -1 & 4 & -1 & & -1 & \\ & -1 & 4 & & -1 & \\ \hline -1 & & & 4 & -1 & -1 \\ -1 & & -1 & 4 & -1 & -1 \\ & -1 & & -1 & 4 & -1 \\ \hline & & -1 & & 4 & -1 \\ & & & -1 & -1 & 4 & -1 \\ & & & & -1 & & 4 \end{bmatrix}$$

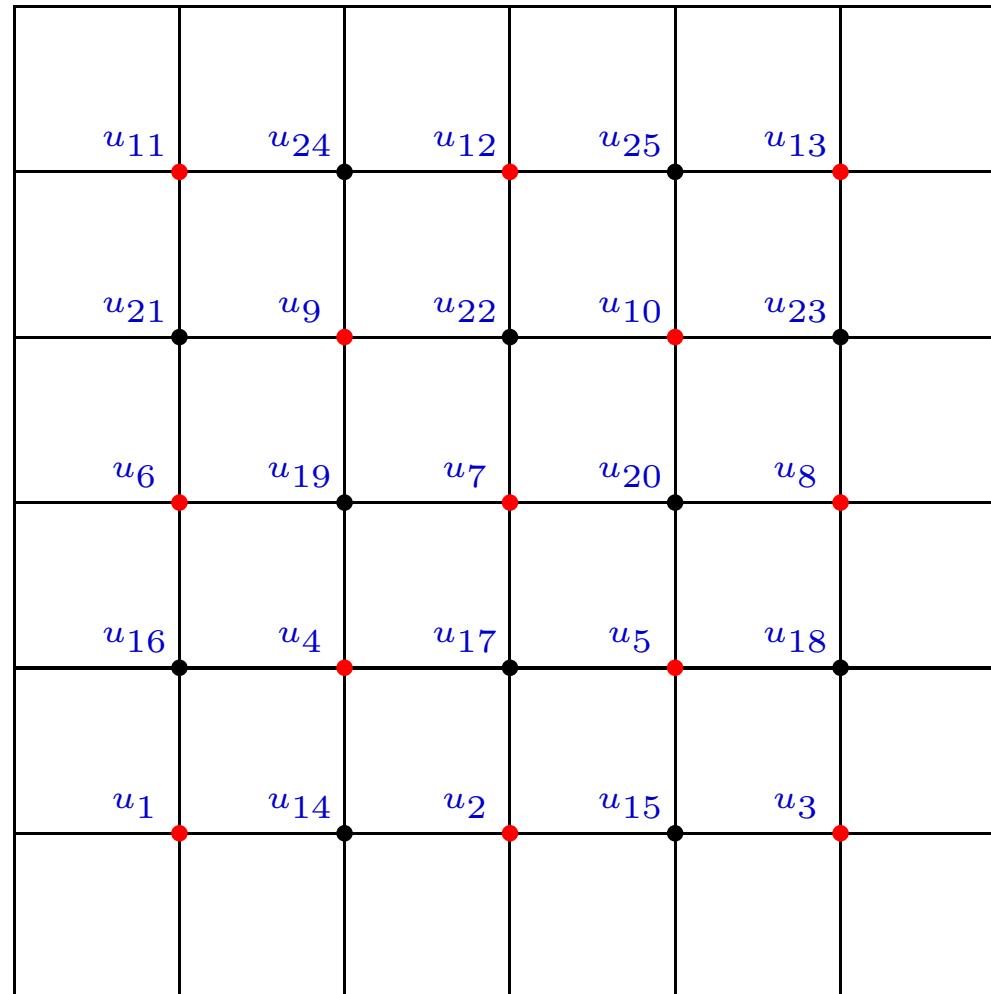
## Crveno-crno numeriranje čvorova

Ako čvorove  $u_{i,j}$  poredamo u tzv. crveno–crni poredak, dobit ćemo konzistentno poredanu matricu (definicija kasnije).

Crveno–crni poredak dobivamo tako da ih obojamo poput šahovske ploče: svaki crveni čvor (osim rubnog) je okružen s četiri crna susjeda i obratno.

Na primjer, za  $N = 5$  takvo crveno–crno bojanje čvorova izgleda ovako:

# Crveno-crno numeriranje čvorova (nastavak)



## Crveno-crno numeriranje čvorova (nastavak)

Ako zatim sve čvorove koji su **crveno** obojani popišemo **prije crnih** (dodijelimo im indekse prije crnih), ili obratno, dobit ćemo **blok** matricu oblika

$$PG_{N \times N}P^T = \begin{bmatrix} D_1 & G_{12} \\ G_{21} & D_2 \end{bmatrix}.$$

Lako je vidjeti da su **dijagonalni blokovi** baš **dijagonalne matrice**, jer ne postoji veza između dva crvena ili dva crna čvora (osim čvora sa samim sobom).

Konkretno, crveno–crni poredak za matricu  $G_{3 \times 3}$  daje

# Crveno-crno numeriranje čvorova (nastavak)

$$PG_{3 \times 3}P^T = \begin{bmatrix} 4 & & & & & & \\ & 4 & & & & & \\ & & 4 & & & & \\ & & & 4 & & & \\ & & & & 4 & & \\ & & & & & 4 & \\ & & & & & & \\ \hline -1 & -1 & -1 & & & 4 & \\ -1 & & -1 & -1 & & & 4 \\ & -1 & -1 & & -1 & & \\ & & -1 & -1 & -1 & & 4 \\ & & & -1 & -1 & & \\ & & & & -1 & -1 & \\ & & & & & 4 & \\ & & & & & & 4 \end{bmatrix}.$$

# Svojstvene vrijednosti matrice $G_{N \times N}$

Teorem. Svojstvene vrijednosti matrice  $G_{N \times N}$  su

$$\lambda_{j,k} = 4 \left( \sin^2 \left( \frac{j\pi}{2(N+1)} \right) + \sin^2 \left( \frac{k\pi}{2(N+1)} \right) \right), \quad j, k = 1, \dots, N,$$

a odgovarajući svojstveni vektori su

$$u_{m,\ell}^{(j,k)} = \frac{2}{N+1} \sin \left( \frac{mj\pi}{N+1} \right) \sin \left( \frac{\ell k\pi}{N+1} \right), \quad j, k, m, \ell = 1, \dots, N,$$

gdje  $u_{m,\ell}^{(j,k)}$  označava komponentu koja odgovara točki mreže  $(m, \ell)$  svojstvenog vektora, pridruženog svojstvenoj vrijednosti  $\lambda_{j,k}$ .

## Svojstvene vrijednosti matrice $G_{N \times N}$ (nastavak)

Dokaz. Neka je  $\lambda$  neka svojstvena vrijednost od  $G_{N \times N}$  sa odgovarajućim svojstvenim vektorom  $u$ , koji se može particionirati u oblik

$$u = \begin{bmatrix} u_1 \\ \vdots \\ u_N \end{bmatrix}, \quad u_\ell = \begin{bmatrix} u_{1,\ell} \\ \vdots \\ u_{N,\ell} \end{bmatrix}, \quad \ell = 1, \dots, N.$$

Jednakost  $G_{N \times N}u = \lambda u$  može se tada napisati u obliku

$$Tu_{\ell-1} + (S - \lambda I_N)u_\ell + Tu_{\ell+1} = 0, \quad \ell = 1, \dots, N, \quad (*)$$

gdje smo postavili da je  $T = -I_N$ ,  $S = G_N + 2I_N$ , i  $u_0 = u_{N+1} = 0$ .

# Svojstvene vrijednosti matrice $G_{N \times N}$ (nastavak)

Prema teoremu o svojstvenim vrijednostima i svojstvenim vektorima TST matrica, možemo napisati da je  $S = Q\Lambda_S Q^T$  i  $T = Q\Lambda_T Q^T$ , gdje su  $\Lambda_S$  i  $\Lambda_T$  dijagonalne matrice, sa dijagonalnim elementima jednakim

$$\lambda_{S,j} = 4 - 2 \cos \left( \frac{j\pi}{N+1} \right), \quad \lambda_{T,j} = -1.$$

$m$ -ti element  $j$ -toga stupca od  $Q$  jednak je

$$q_m^{(j)} = \sqrt{\frac{2}{N+1}} \sin \left( \frac{mj\pi}{N+1} \right), \quad m, j = 1, \dots, N.$$

Pomnožimo blok-rekurziju (\*) sa  $Q^T$  slijeva kako bismo dobili  $\Lambda_T v_{\ell-1} + (\Lambda_S - \lambda I)v_\ell + \Lambda_T v_{\ell+1} = 0$ ,  $v_\ell = Q^T u_\ell$ ,  $\ell = 1, \dots, N$ .

# Svojstvene vrijednosti matrice $G_{N \times N}$ (nastavak)

Budući da su ovdje sve matrice **dijagonalne**, jednakosti duž vertikalnih linija u mreži imaju oblik

$$\lambda_{T,j} v_{j,\ell+1} + \lambda_{S,j} v_{j,\ell} + \lambda_{T,j} v_{j,\ell-1} = \lambda v_{j,\ell}, \quad j = 1, \dots, N.$$

Ako je, za **fiksnu** vrijednost od  $j$ , vektor  $[v_{j,1} \dots v_{j,N}]^T$  svojstveni vektor **TST** matrice

$$\begin{bmatrix} \lambda_{S,j} & \lambda_{T,j} & & \\ \lambda_{T,j} & \ddots & \ddots & \\ & \ddots & \ddots & \lambda_{T,j} \\ & & \lambda_{T,j} & \lambda_{S,j} \end{bmatrix},$$

sa odgovarajućom svojstvenom vrijednošću  $\lambda$ , i ako uzmemo da su sve **ostale komponenete** vektora  $v$  **jednake 0**, tada će prethodna jednakost biti zadovoljena.

# Svojstvene vrijednosti matrice $G_{N \times N}$ (nastavak)

Ponovo prema teoremu o TST matricama, svojstvene vrijednosti ove matrice jednake su

$$\begin{aligned}\lambda_{j,k} &= \lambda_{S,j} + 2\lambda_{T,j} \cos\left(\frac{k\pi}{N+1}\right) \\ &= 4 - 2\cos\left(\frac{j\pi}{N+1}\right) - 2\cos\left(\frac{k\pi}{N+1}\right) \\ &= 4\sin^2\left(\frac{j\pi}{2(N+1)}\right) + 4\sin^2\left(\frac{k\pi}{2(N+1)}\right),\end{aligned}$$

za  $k = 1, \dots, N$ . Pripadajući svojstveni vektori su

$$v_{j,\ell}^{(j,k)} = \sqrt{\frac{2}{N+1}} \sin\left(\frac{\ell k \pi}{N+1}\right).$$

# Svojstvene vrijednosti matrice $G_{N \times N}$ (nastavak)

Budući da je

- $\ell$ -ti blok od  $u^{(j,k)}$  jednak  $Q$  puta  $\ell$ -ti blok od  $v$ ,
- i budući da je samo  $j$ -ta komponenta  $\ell$ -toga bloka od  $v$  različita od nule,

imamo

$$u_{m,\ell} = q_m^{(j)} v_{j,\ell}^{(j,k)} = \frac{2}{N+1} \sin\left(\frac{mj\pi}{N+1}\right) \sin\left(\frac{\ell k \pi}{N+1}\right).$$

Dobivanjem svojstvenih vrijednosti  $\lambda_{j,k}$  i odgovarajućih svojstvenih vektora  $u^{(j,k)}$  za svako  $j = 1, \dots, N$ , sada imamo sve  $N^2$  svojstvene parove od  $G_{N \times N}$ . ■

## Uvjetovanost matrice $G_{N \times N}$

Korolar. Najmanja i najveća svojstvena vrijednost od  $G_{N \times N}$  ponašaju se kao

$$\lambda_{min} \approx 2\pi^2 h^2 + \mathcal{O}(h^4) \quad \text{i} \quad \lambda_{max} \approx 8 + \mathcal{O}(h^2)$$

kada  $h \rightarrow 0$ , tako da se uvjetovanost matrice  $G_{N \times N}$  ponaša kao

$$\kappa(G_{N \times N}) \approx \frac{4}{\pi^2} h^{-2} + \mathcal{O}(1) = \mathcal{O}(N^2).$$

Dokaz. Najmanja svojstvena vrijednost od  $G_{N \times N}$  je ona sa  $j = k = 1$ , a najveća je ona sa  $j = k = N$ :

$$\lambda_{min} = 8 \sin^2 \left( \frac{\pi h}{2} \right), \quad \lambda_{max} = 8 \sin^2 \left( \frac{\pi}{2} - \frac{\pi h}{2} \right).$$

## Uvjetovanost matrice $G_{N \times N}$ (nastavak)

Razvojem funkcija  $\sin(x)$  i  $\sin(\pi/2 - x) = \cos(x)$  u Taylorov red dobivamo traženi rezultat, a dijeljenjem  $\lambda_{\max}$  sa  $\lambda_{\min}$  dobivamo ocjenu za broj uvjetovanosti. ■

Napomena. Kako bi diskretizacija konačnim razlikama bila što točnija poželjno je uzeti što manji  $h$ . S druge strane, uvjetovanost aproksimativnog linearног sustava dramatično raste kao  $\mathcal{O}(h^{-2})$ , što predstavlja veliki izazov za njegovo numeričko rješavanje.

# Rješavanje pomoću standardnih iteracija

Sada ćemo pokazati da matrica  $G_{N \times N}$  spada u jednu posebnu klasu matrica, za koje postoje vrlo konkretni rezultati o konvergenciji standardnih iteracija.

U tu svrhu iznijet ćemo niz definicija i teorema bez dokaza, jer su dokazi prilično tehnički.

**Definicija.** Matrica  $A$  ima svojstvo (A) ako postoji matrica permutacije  $P$  takva da vrijedi

$$PAP^T = \begin{bmatrix} D_1 & A_{12} \\ A_{21} & D_2 \end{bmatrix},$$

gdje su  $D_1$  i  $D_2$  dijagonalne matrice. ■

# Matrice s konzistentnim poretkom

Od sada pa nadalje pretpostavljamo da je matrica **particionirana** kao  $A = L + D + R$ , gdje je  $D$  **regularna dijagonalna** matrica,  $L$  strogog donjetrokutasta, a  $R$  strogogornjetrokutasta.

**Definicija.** Neka je  $\alpha \neq 0$ . Definirajmo familiju matrica

$$T_J(\alpha) = -\alpha D^{-1}L - \frac{1}{\alpha}D^{-1}R.$$

Vidimo da je  $T_J(1) = T_J$  matrica iteracije u **Jacobijevoj metodi**.

**Propozicija.** Za matrice  $A$  sa svojstvom  $(A)$ , svojstvene vrijednosti matrica  $T_J(\alpha)$  ne ovise o  $\alpha$ , s tim da  $D$ ,  $L$  i  $R$  dobivamo iz rastava matrice  $PAP^T$ .

# Matrice s konzistentnim poretkom (nastavak)

Definicija. Neka je  $A$  proizvoljna matrica takva da je

$$A = L + D + R$$

s tim da je  $D$  regularna i

$$T_J(\alpha) = -\alpha D^{-1}L - \frac{1}{\alpha}D^{-1}R.$$

Ako svojstvene vrijednosti matrice  $T_J(\alpha)$  ne ovise o  $\alpha$ , onda kažemo da  $A$  ima konzistentan poredak (engl. consistent ordering). ■

Korolar. Ako  $A$  ima konzistentan poredak, tada je

$$\rho(T_{GS}) = (\rho(T_J))^2,$$

što znači da Gauss–Seidelova metoda konvergira dvostruko brže nego Jacobijeva metoda (ako barem jedna od njih konvergira). ■

# Optimalni parametar $SOR(\omega)$ metode

Kod  $SOR(\omega)$  metode, one vrijednosti parametra  $\omega$  za koje je  $\rho(T_{SOR(\omega)})$  globalno najmanji, zovemo optimalnim relaksacijskim parametrima i označavamo s  $\omega_{opt}$ .

**Teorem.** Prepostavimo da matrica  $A$  ima konzistentan poredak i da matrica  $T_J$  u Jacobijevoj metodi ima samo realne svojstvene vrijednosti. Onda  $SOR(\omega)$  metoda konvergira za bilo koji početni vektor ako i samo ako je  $\mu := \rho(T_J) < 1$  (tj. Jacobijeva metoda konvergira) i vrijedi  $0 < \omega < 2$ . Dodatno, za  $\mu < 1$  onda vrijedi i

$$\omega_{opt} = \frac{2}{1 + \sqrt{1 - \mu^2}},$$

$$\rho(T_{SOR(\omega_{opt})}) = \omega_{opt} - 1 = \frac{\mu^2}{(1 + \sqrt{1 - \mu^2})^2} = \frac{1 - \sqrt{1 - \mu^2}}{1 + \sqrt{1 - \mu^2}},$$

# Optimalni parametar $SOR(\omega)$ metode (nast.)

a za sve  $\omega \in \langle 0, 2 \rangle$  vrijedi

$$\rho(T_{SOR(\omega)}) = \begin{cases} 1 - \omega + \frac{1}{2}\omega^2\mu^2 + \omega\mu\sqrt{1 - \omega + \frac{1}{4}\omega^2\mu^2}, & \text{za } 0 < \omega \leq \omega_{\text{opt}}, \\ \omega - 1, & \text{za } \omega_{\text{opt}} \leq \omega \leq 2. \end{cases}$$



**Teorem.** Neka je  $A$  simetrična (hermitska) i pozitivno definitna matrica i pretpostavimo da  $A$  ima konzistentan poredak. Onda matrica iteracije  $T_J$  u Jacobijevoj metodi ima samo realne svojstvene vrijednosti i vrijedi  $\rho(T_J) < 1$ , tj. Jacobijska metoda konvergira.



## Konvergencija stand. iter. za sustav s $G_{N \times N}$

Može se pokazati da matrica  $G_{N \times N}$ , i svaka matrica dobivena bilo kojom numeracijom čvorova, ima konzistentni poredak.

Dakle, da bismo ispitali konvergenciju iterativnih metoda, dovoljno je naći spektralni radius matrice  $T_J$ . Prvo, nađimo rastav (cijepanje) matrice  $G_{N \times N}$

$$G_{N \times N} = 4I_{N \times N} - (4I_{N \times N} - G_{N \times N}),$$

pa je  $M = 4I_{N \times N}$ ,  $N = (4I_{N \times N} - G_{N \times N})$ ,

$$T_J = M^{-1}N = (4I_{N \times N})^{-1}(4I_{N \times N} - G_{N \times N}) = I_{N \times N} - \frac{1}{4}G_{N \times N}.$$

Drugim riječima,  $T_J$  je polinom od  $G_{N \times N}$ , pa ako je  $\lambda_{i,j}$  svojstvena vrijednost od  $G_{N \times N}$ , onda je  $1 - \lambda_{i,j}/4$  svojstvena vrijednost od  $T_J$ .

## Konvergencija stand. iter. za sustav s $G_{N \times N}$

Znamo da svojstvene vrijednosti matrice  $G_{N \times N}$  na alternativni način možemo napisati kao

$$\lambda_{i,j} = 4 - 2 \left( \cos \frac{\pi i}{N+1} + \cos \frac{\pi j}{N+1} \right),$$

odakle slijedi da je

$$\rho(T_J) = \max_{i,j} \left| 1 - \frac{\lambda_{i,j}}{4} \right| = \left| 1 - \frac{\lambda_{1,1}}{4} \right| = \left| 1 - \frac{\lambda_{N,N}}{4} \right| = \cos \frac{\pi}{N+1}.$$

Odmah je vidljivo da porastom  $N$  argument kosinusa ide prema nuli, pa će  $\rho(T_J)$  biti sve bliže 1, a iterativne će metode sve sporije konvergirati.

## Konvergencija stand. iter. za sustav s $G_{N \times N}$

Čak što više, možemo procijeniti  $\rho(T_J)$  za velike  $N$ . Dovoljno dobra aproksimacija bit će prva dva člana u Taylorovom redu za funkciju kosinus

$$\rho(T_J) = \cos \frac{\pi}{N+1} \approx 1 - \frac{\pi^2}{2(N+1)^2}.$$

Spektralni radius za Gauss–Seidelovu metodu lako je dobiti koristeći

$$\rho(T_{GS}) = (\rho(T_J))^2 = \cos^2 \frac{\pi}{N+1}.$$

Približno, kvadriranjem prva dva člana u Taylorovom redu, vrijedi

$$\rho(T_{GS}) \approx 1 - \frac{\pi^2}{(N+1)^2}.$$

# Konvergencija stand. iter. za sustav s $G_{N \times N}$

Konačno, dobivamo

$$\omega_{opt} = \frac{2}{1 + \sin \frac{\pi}{N+1}}, \quad \rho(T_{SOR(\omega_{opt})}) = \frac{\cos^2 \frac{\pi}{N+1}}{\left(1 + \sin \frac{\pi}{N+1}\right)^2}.$$

Veličinu  $\rho(T_{SOR(\omega_{opt})})$  možemo približno ocijeniti za velike  $N$ .  
Vrijedi

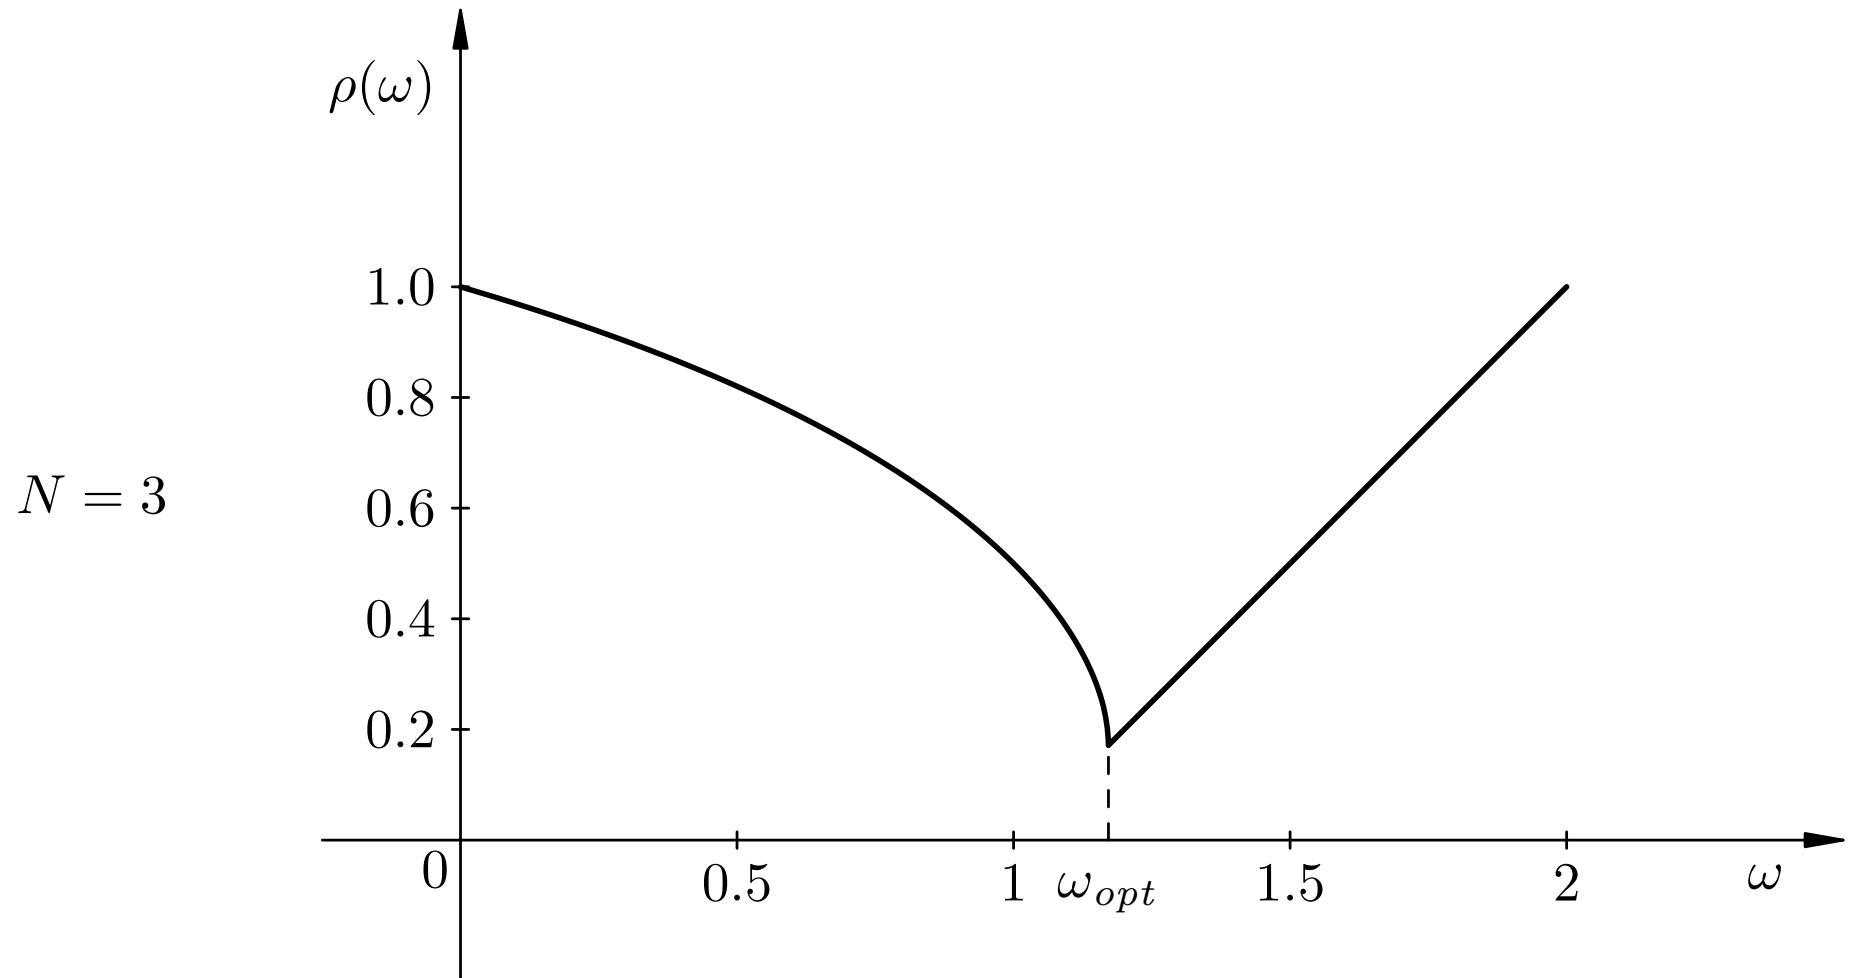
$$\begin{aligned} \frac{\cos^2 \frac{\pi}{N+1}}{\left(1 + \sin \frac{\pi}{N+1}\right)^2} &= \frac{1 - \sin \frac{\pi}{N+1}}{1 + \sin \frac{\pi}{N+1}} = 1 - \frac{2 \sin \frac{\pi}{N+1}}{1 + \sin \frac{\pi}{N+1}} \\ &\approx 1 - 2 \sin \frac{\pi}{N+1} \approx 1 - \frac{2\pi}{N+1}. \end{aligned}$$

## Konvergencija stand. iter. za sustav s $G_{N \times N}$

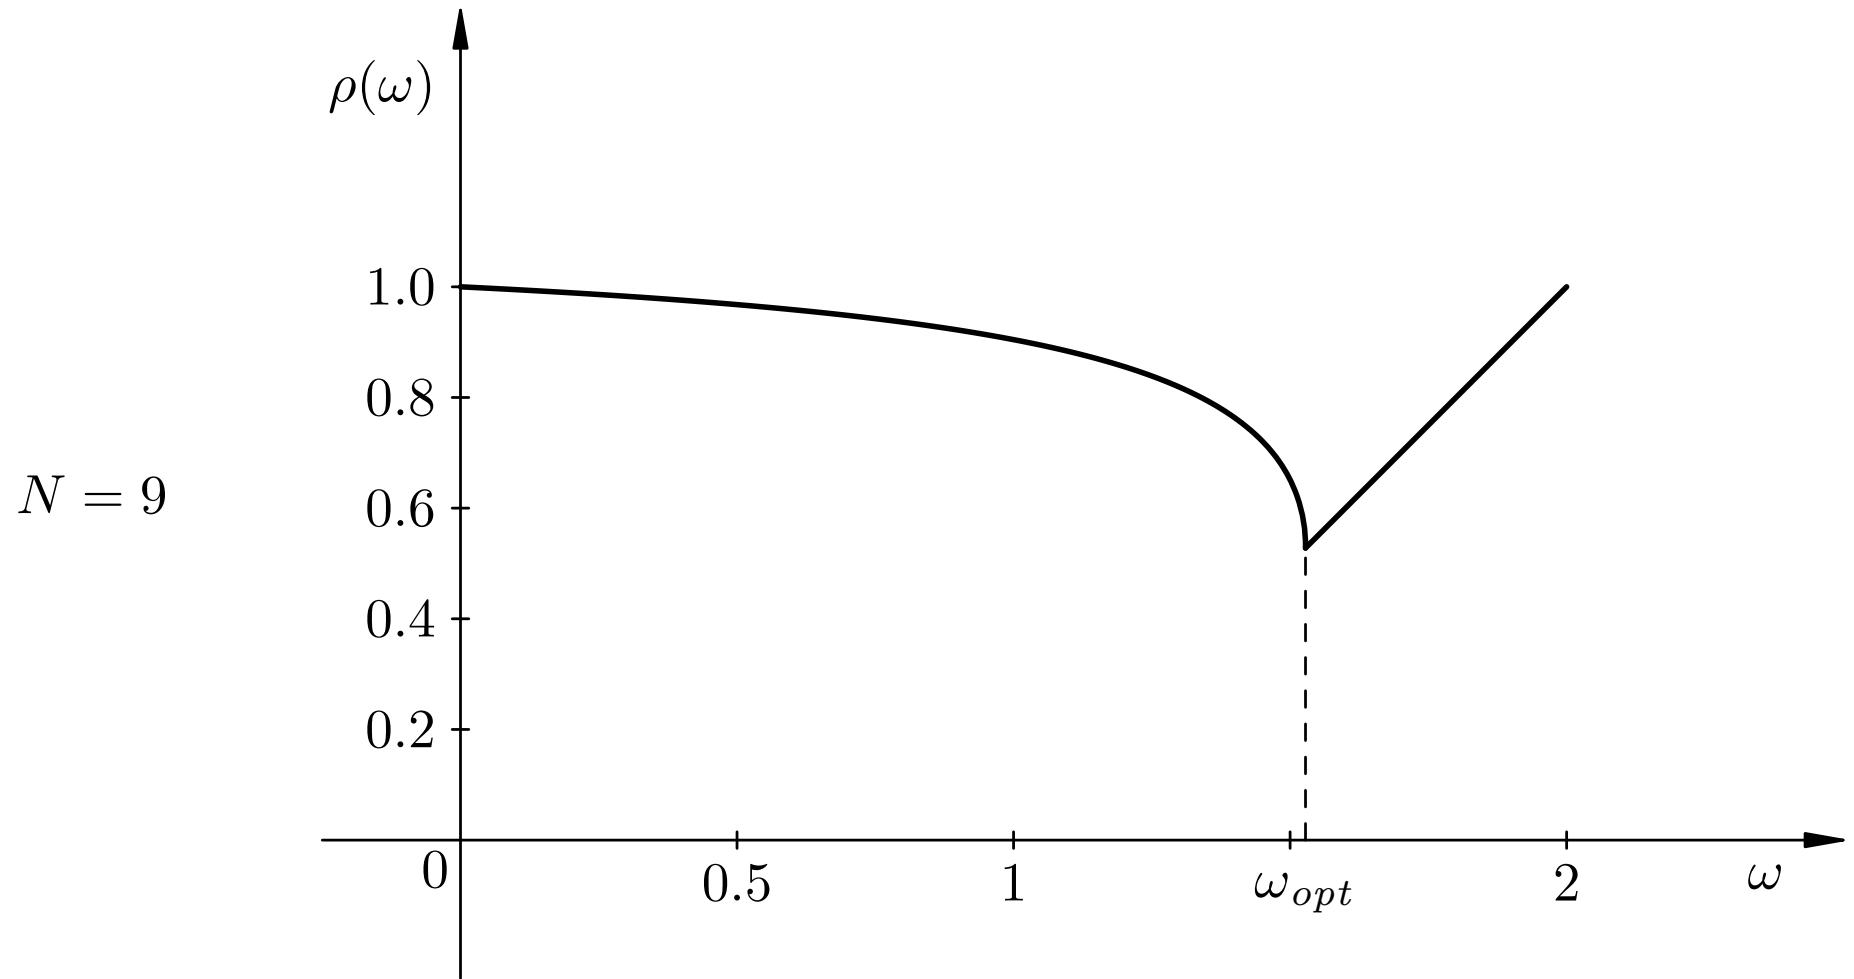
Primijetite da spektralni radius i kod Jacobijeve metode i kod Gauss–Seidelove metode ima oblik  $1 - O(1/N^2)$ , dok kod SOR metode s optimalnim parametrom spektralni radius ima oblik  $1 - O(1/N)$ , što pokazuje da bi SOR za optimalni izbor parametra morao biti reda veličine  $N$  puta brži i od Jacobijeve i od Gauss–Seidelove metode.

Pogledajmo kako se ponaša  $\rho(T_{SOR(\omega)})$  kao funkcija od  $\omega$ , te ovisno o  $N$ , kako se ponaša  $\omega_{opt}$ . Redom, za  $N = 3, 9, 16, 25$ , dobivamo sljedeće grafove.

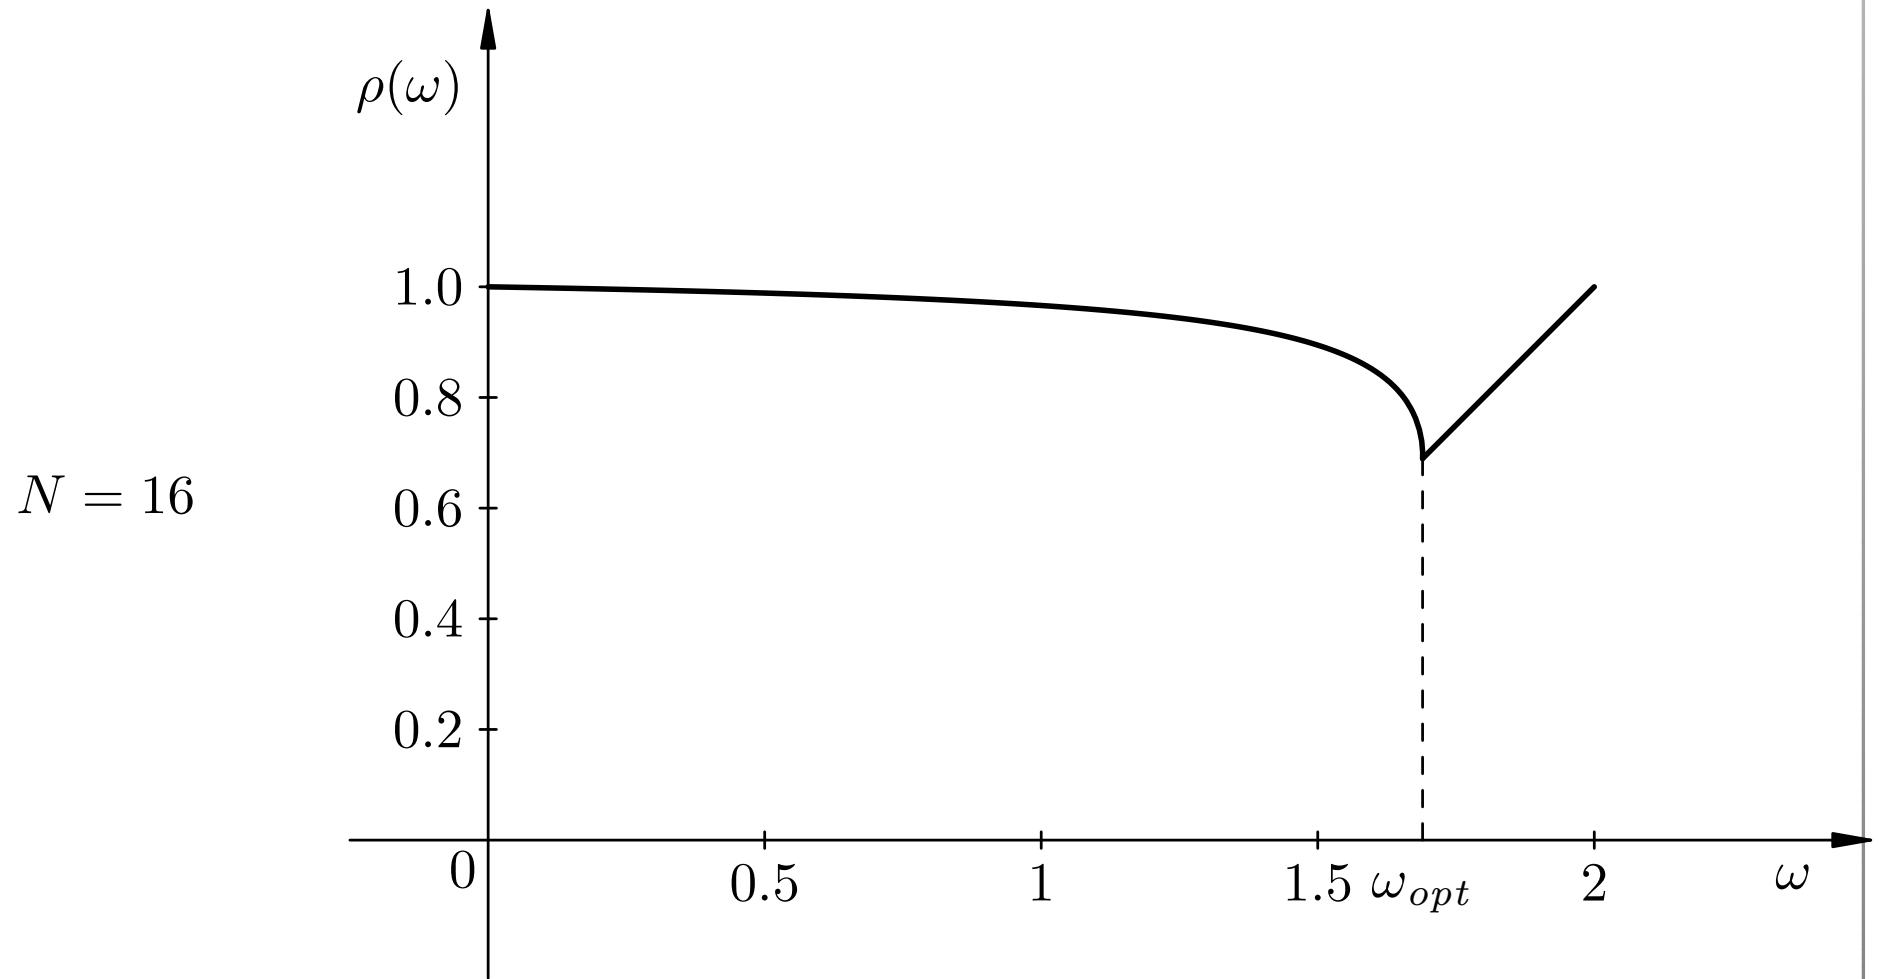
# Konvergencija SOR( $\omega$ ) za sustav s $G_{3 \times 3}$



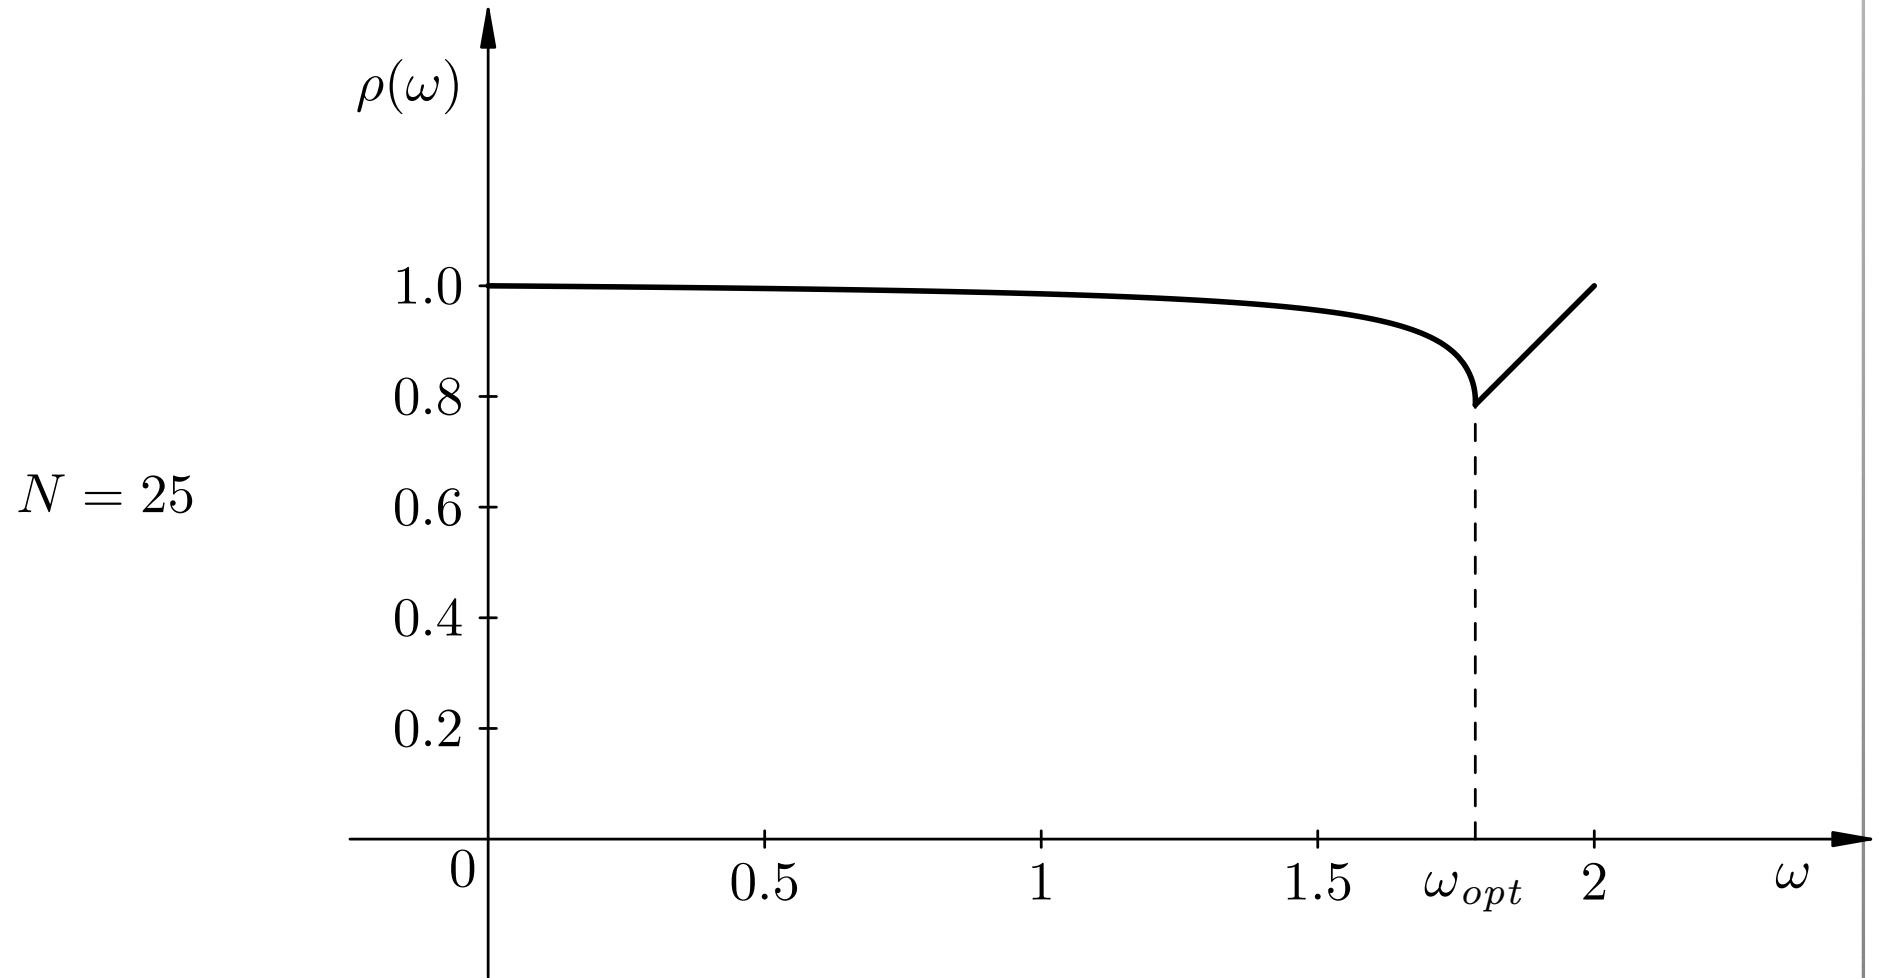
# Konvergencija SOR( $\omega$ ) za sustav s $G_{9 \times 9}$



# Konvergencija SOR( $\omega$ ) za sustav s $G_{16 \times 16}$



# Konvergencija SOR( $\omega$ ) za sustav s $G_{25 \times 25}$



## Konvergencija SOR( $\omega$ ) za sustav s $G_{N \times N}$

Kao što smo očekivali, optimalni se parametar pomiče prema 2, a  $\rho(T_{SOR(\omega_{opt})})$  postaje sve bliže 1.