

Numerička analiza

8. predavanje

Autori: Saša Singer i Nela Bosner

Predavač: Nela Bosner

nela@math.hr

web.math.hr/~nela/nad.html

PMF – Matematički odjel, Zagreb

Sadržaj predavanja

- Matrična formulacija linearnog problema najmanjih kvadrata:
 - Karakterizacija rješenja za puni i defektni rang.
 - Geometrijska interpretacija rješenja.
 - Rješavanje problema najmanjih kvadrata.
- QR faktorizacija:
 - Egzistencija i jedinstvenost
 - Gram–Schmidtov postupak
- Givensove rotacije:
 - Poništavanje elementa pomoću rotacije
 - Sustavno poništavanje — QR faktorizacija

Sadržaj predavanja (nastavak)

- Householderovi reflektori:
 - Poništavanje elemenata pomoću reflektora
 - QR faktorizacija korištenjem reflektora
- QR faktorizacija i pivotiranje
- Rješenje matricne formulacije korištenjem QR faktorizacije:
 - Rješenje za puni rang
 - Rješenje za defektni rang

Matrična formulacija linearnog problema najmanjih kvadrata

Matrična formulacija

Diskretni **linearni** problem najmanjih kvadrata najčešće se rješava u **matričnom** obliku.

Da bismo formirali **matrični zapis** linearnog problema najmanjih kvadrata, zgodno je **preimenovati** nepoznanice,

- tako da **matricu**,
- vektor **desne** strane i
- **nepoznanice** u linearnom sustavu

pišemo u uobičajenoj formi:

- **standardno** su nepoznanice x_1, \dots, x_n ,
- a ne a_0, \dots, a_n .

Matrična formulacija (nastavak)

Pretpostavimo da skup podataka (t_k, y_k) , za $k = 1, \dots, m$, želimo aproksimirati **linearnom** funkcijom

$$\varphi(t) = x_1\varphi_1(t) + \dots + x_n\varphi_n(t).$$

Želimo pronaći parametre x_j tako da podaci (t_k, y_k) zadovoljavaju

$$y_k = \sum_{j=1}^n x_j\varphi_j(t_k), \quad k = 1, \dots, m.$$

Primijetite da to nije uvijek moguće, jer je podataka uobičajeno **znatno više** nego parametara.

Matrična formulacija (nastavak)

Ako označimo

$$a_{kj} = \varphi_j(t_k), \quad b_k = y_k,$$

onda prethodne jednađžbe možemo napisati u **matričnom obliku**

$$Ax = b.$$

Budući da je matrica A “**dugačka**”, postavlja se pitanje što je **najbolje** rješenje ovog sustava.

Najčešće određujemo x tako da se minimizira **rezidual** $r = Ax - b$, tj. tražimo rješenje problema

$$\min_x \|r\|_2 = \min_x \|Ax - b\|_2, \quad A \in \mathbb{R}^{m \times n}, \quad b \in \mathbb{R}^m.$$

Komentar

Ako smo dobro birali bazične funkcije φ_i , onda je razumno pretpostaviti da su one **linearno nezavisne** na **zadanim podacima**, pa

- matrica A ima **puni stupčani rang**, tj. $\text{rang}(A) = n$.

S druge strane, ako je $\text{rang}(A) < n$, onda

- rješenje x **nije jedinstveno**, jer mu možemo dodati bilo koji vektor iz jezgre od A , a da se rezidual ne promijeni.
- Među svim rješenjima x problema najmanjih kvadrata **uvijek postoji jedinstveno** rješenje x **najmanje norme**, tj. koje još **minimizira** i $\|x\|_2$.

Karakterizacija rješenja

Teorem. Skup svih rješenja problema $\min_x \|r\|_2$ označimo s

$$\mathcal{S} = \{x \in \mathbb{R}^n \mid \|Ax - b\|_2 = \min\}.$$

Tada je $x \in \mathcal{S}$ ako i samo ako vrijedi sljedeća relacija ortogonalnosti

$$A^T(Ax - b) = 0,$$

koju obično nazivamo **sustav normalnih jednažbi** i pišemo u obliku

$$A^T Ax = A^T b.$$

Karakterizacija rješenja (nastavak)

Dokaz. Pretpostavimo da \hat{x} zadovoljava normalne jednadžbe

$$A^T \hat{r} = 0, \quad \hat{r} = A\hat{x} - b.$$

Tada za bilo koji $x \in \mathbb{R}^n$ imamo

$$r = Ax - b = \hat{r} + Ax - A\hat{x} = \hat{r} + A(x - \hat{x}).$$

Ako označimo $e = x - \hat{x}$, onda je $r = \hat{r} + Ae$, pa imamo

$$\begin{aligned} \|r\|_2^2 &= r^T r = (\hat{r} + Ae)^T (\hat{r} + Ae) \\ &= \hat{r}^T \hat{r} + \hat{r}^T Ae + (Ae)^T \hat{r} + (Ae)^T Ae \\ &= \|\hat{r}\|_2^2 + (A^T \hat{r})^T e + e^T (A^T \hat{r}) + \|Ae\|_2^2 = \{A^T \hat{r} = 0\} \\ &= \|\hat{r}\|_2^2 + \|Ae\|_2^2 = \|\hat{r}\|_2^2 + \|A(x - \hat{x})\|_2^2, \end{aligned}$$

što je **minimizirano** kad je $e \in \mathcal{N}(A)$, tj. $x = \hat{x} + e$.

Karakterizacija rješenja (nastavak)

S druge strane, pretpostavimo da \hat{x} **minimizira** normu reziduala, ali **ne zadovoljava** sustav normalnih jednadžbi

$$A^T \hat{r} = z \neq 0.$$

Tada možemo definirati

$$x = \hat{x} - \varepsilon z,$$

za proizvoljni dovoljno **mali** broj $\varepsilon > 0$, pa je

$$r = \hat{r} - \varepsilon Az$$

i

$$\|r\|_2^2 = r^T r = \hat{r}^T \hat{r} - 2\varepsilon z^T z + \varepsilon^2 (Az)^T (Az) < \hat{r}^T \hat{r} = \|\hat{r}\|_2^2,$$

što znači da, **protivno** pretpostavci, \hat{x} **nije** rješenje problema minimizacije reziduala $\|r\|_2$, za **svaki** dovoljno **mali** $\varepsilon > 0$. ■

Karakterizacija rješenja (nastavak)

Prethodni teorem, zapravo je rekao da je rješenje problema minimizacije $\|r\|_2$ isto što i rješenje sustava normalnih jednadžbi

$$A^T A x = A^T b.$$

Sada odmah vidimo:

- matrica $A^T A$ je simetrična i pozitivno semidefinitna, jer za svaki vektor x vrijedi

$$x^T A^T A x = (x^T A^T)(Ax) = (Ax)^T (Ax) = \|Ax\|_2^2 \geq 0,$$

- sustav normalnih jednadžbi uvijek ima rješenje, jer je

$$A^T b \in \mathcal{R}(A^T) = \mathcal{R}(A^T A),$$

(v. teorem Kronecker–Capelli i još je $\mathcal{R}(A) \perp \mathcal{N}(A^T)$).

Karakterizacija rješenja (nastavak)

Vrijedi čak i jače.

Teorem. Matrica $A^T A$ je **pozitivno definitna** (pa onda i regularna) ako i samo ako su stupci od A **linearno nezavisni**, tj. ako je $\text{rang}(A) = n$.

Dokaz. Ako su stupci od A **linearno nezavisni**, tada za svaki $x \neq 0$ vrijedi $Ax \neq 0$ (definicija linearne nezavisnosti), pa je za takav x

$$x^T A^T A x = \|Ax\|_2^2 > 0,$$

tj. $A^T A$ je **pozitivno definitna**.

Karakterizacija rješenja (nastavak)

S druge strane, ako su stupci **linearno zavisni**, tada postoji $x_0 \neq 0$ takav da je $Ax_0 = 0$, pa je za takav x_0

$$x_0^T A^T Ax_0 = \|Ax_0\|_2^2 = 0.$$

Ako je x takav da je $Ax \neq 0$, onda je

$$x^T A^T Ax = \|Ax\|_2^2 > 0,$$

pa je $A^T A$ **pozitivno semidefinitna**. ■

Karakterizacija rješenja — drugi način

Napomena. Karakterizaciju rješenja danu prethodnim teoremima možemo dobiti i na alternativni način.

- Definirajmo diferencijabilnu funkciju

$$\psi(x) = \frac{1}{2} \|Ax - b\|_2^2,$$

i izjednačimo $\nabla\psi(x) = 0$.

- Tada možemo raspisati $\psi(x)$ kao

$$\begin{aligned}\psi(x) &= \frac{1}{2} (Ax - b)^T (Ax - b) = \frac{1}{2} x^T A^T Ax - x^T A^T b + \frac{1}{2} b^T b \\ &= \frac{1}{2} \sum_{i,j=1}^n x_i (A^T A)_{ij} x_j - \sum_{i=1}^n x_i (A^T b)_i + \frac{1}{2} b^T b\end{aligned}$$

Karakterizacija rješenja — drugi način (nast.)

odnosno, kada $\psi(x)$ bolje pripremimo za deriviranje, imamo

$$\psi(x) = \frac{1}{2} \sum_i^n (A^T A)_{ii} x_i^2 + \frac{1}{2} \sum_{i \neq j} (A^T A)_{ij} x_i x_j - \sum_{i=1}^n (A^T b)_i x_i + \frac{1}{2} b^T b.$$

- Izračunajmo sada k -tu parcijalnu derivaciju od $\psi(x)$ i izjednačimo ju sa nulom.

$$\begin{aligned} \frac{\partial}{\partial x_k} \psi(x) &= (A^T A)_{kk} x_k + \frac{1}{2} \sum_{j \neq k} (A^T A)_{kj} x_j + \frac{1}{2} \sum_{i \neq k} (A^T A)_{ik} x_i - (A^T b)_k \\ &= \underbrace{\{(A^T A)_{ji} = (A^T A)_{ij}\}}_{\hookrightarrow} \sum_{i=1}^n (A^T A)_{ki} x_i - (A^T b)_k = (A^T A x - A^T b)_k. \end{aligned}$$

Karakterizacija rješenja — drugi način (nast.)

• Dakle,

$$\nabla\psi(x) = A^T Ax - A^T b,$$

a iz $\nabla\psi(x) = 0$ slijedi $A^T(Ax - b) = A^T r = 0$, ili da rješenje problema najmanjih kvadrata zadovoljava sustav **normalnih jednadžbi** $A^T Ax = A^T b$, što već znamo.

• Da bi to rješenje bilo zaista **minimum** funkcije ψ moramo provjeriti **Hessian**.

• Vrijedi

$$\frac{\partial^2}{\partial x_l \partial x_k} \psi(x) = (A^T A)_{kl},$$

što znači da je

$$H\phi = A^T A.$$

Karakterizacija rješenja — drugi način (nast.)

● $H\psi$ je

- pozitivno definitna u slučaju da je matrica A punog stupčanog ranga, pa tada postoji jedinstveni minimum, i on je rješenje sustava

$$A^T Ax = A^T b$$

- pozitivno semidefinitna u slučaju da matrica A nema puni stupčani rang, pa se tada minimum postiže na čitavom afinom potprostu.

- To možemo provjeriti na sljedeći način.

- Neka je x rješenje problema najmanjih kvadrata, i neka je i $x + z$ također rješenje istog problema.

- Tada x i $x + z$ moraju zadovoljavati $A^T r = 0$, pa imamo

$$0 = A^T [A(x + z) - b] = A^T (Ax - b) + A^T Az = A^T Az.$$

Karakterizacija rješenja — drugi način (nast.)

- Ako prethodnu jednakost **skalarno pomnožimo** sa z , dobit ćemo da je $\|Az\|_2 = 0$, odakle slijedi da je $Az = 0$ odnosno $z \in \mathcal{N}(A)$.
- Dakle **skup rješenja** u ovom slučaju čini skup

$$\mathcal{S} = x + \mathcal{N}(A).$$

- Ako je $x \perp \mathcal{N}(A)$, onda je

$$\|x + z\|_2^2 = \|x\|_2^2 + \|z\|_2^2,$$

pa je x **jedinstveno rješenje** problema najmanjih kvadrata koje ima **minimalnu 2-normu** (za $z = 0$).

Geometrijska interpretacija rješenja

Desna strana b može se napisati kao

$$b = Ax - r,$$

pri čemu je $Ax \in \mathcal{R}(A)$. Nadalje, iz sustava normalnih jednadžbi

$$A^T(b - Ax) = -A^T r = 0,$$


izlazi da je $r \in \mathcal{N}(A^T)$. Prisjetimo li se da je

$$\mathcal{R}(A) \oplus \mathcal{N}(A^T) = \mathbb{R}^m$$

dobivamo **geometrijsku** interpretaciju problema najmanjih kvadrata.

Geometrijska interpretacija rješenja (nastavak)

Rješenje problema najmanjih kvadrata dobivamo tako da napravimo **ortogonalnu projekciju** vektora b na potprostor $\mathcal{R}(A)$.



Rješenje problema najmanjih kvadrata

Treba još samo pronaći način kako jednostavno “pročitati” rješenje. U slučaju **punog ranga** mogli bismo riješiti sustav **normalnih jednadžbi**. Jasno je da se matrica $A^T A$ ne invertira, nego se rješava linearni sustav

$$A^T A x = A^T b.$$

Ovaj **pozitivno definitni** sustav normalnih jednadžbi mogli bismo riješiti tako da iskoristimo **faktorizaciju Choleskog**.

Prednosti/nedostaci metode:

- ukupan broj aritmetičkih operacija za rješenje je $mn^2 + \frac{1}{3}n^3 + O(n^2)$, što je **brzo**,
- ali, rješavanje na ovaj način **nije naročito točno**.

Korištenje QR faktorizacije

Ponovno, neka je $A^T A$ pozitivno definitna. Promatramo problem minimizacije

$$\|Ax - b\|_2 \rightarrow \min.$$

Prisjetite se, za proizvoljnu ortogonalnu matricu Q^T vrijedi da čuva skalarni produkt, (onda i kvadrat norme, pa i normu).

Dakle, rješenje problem minimizacije možemo lako zapisati kao

$$\|Ax - b\|_2 = \|Q^T(Ax - b)\|_2 = \|Q^T Ax - Q^T b\|_2 \rightarrow \min.$$

Pitanje je samo kako naći pogodan Q^T tako da lako pročitamo rješenje.

Odgovor: korištenjem QR faktorizacije.

QR faktorizacija

Definicija QR faktorizacije

Neka je zadana matrica G tipa $m \times n$ koja ima **puni** stupčani rang, tj. $\text{rang}(G) = n \leq m$. Rastav matrice G tako da je

$$G = QR = Q \begin{bmatrix} R_0 \\ 0 \end{bmatrix},$$

gdje je

- Q **ortogonalna** matrica reda m , a
- R_0 **gornja trokutasta** matrica reda n , s **pozitivnim** dijagonalnim elementima,

zove se **QR faktorizacija** matrice G .

Definicija QR faktorizacije (nastavak)

Ako postoji, prethodna faktorizacija može se pisati i u **jednostavnijoj** (tzv. skraćenoj) formi.

- Prvih n stupaca matrice Q označimo s Q_0 ,
- a **preostale** stupce, koji su **okomiti** na Q_0 , s Q_0^\perp .

Onda je

$$G = QR = [Q_0 \quad Q_0^\perp] \begin{bmatrix} R_0 \\ 0 \end{bmatrix} = Q_0 R_0, \quad Q_0^T Q_0 = I_n.$$

Ostaje samo pokazati da takva faktorizacija **postoji**.

Egzistencija i jedinstvenost QR faktorizacije

Teorem. Neka je $G \in \mathbb{R}^{m \times n}$, $m \geq n$, i neka je $\text{rang}(G) = n$. Tada **postoji jedinstvena** faktorizacija oblika

$$G = Q_0 R_0,$$

pri čemu je Q_0 matrica tipa $m \times n$, s **ortonormiranim** stupcima, tj. vrijedi

$$Q_0^T Q_0 = I_n,$$

a R_0 je **gornja trokutasta** matrica s **pozitivnim** dijagonalnim elementima (dovoljno je **fiksirati** predznake na dijagonali).

Pravokutnu matricu Q_0 s **ortonormiranim** stupcima, također, skraćeno zovemo “**ortogonalnom**”.

Egzistencija i jedinstvenost QR faktorizacije

Dokaz. Najjednostavniji dokaz ovog teorema dobiva se korištenjem **Gram-Schmidtove ortogonalizacije**.

Ako stupce matrice

$$G = [g_1, g_2, \dots, g_n]$$

ortogonaliziramo slijeva udesno, dobit ćemo **ortonormalni** niz vektora q_1, \dots, q_n , koji razapinju **isti potprostor** kao i stupci od G .

Stavimo li

$$Q_0 = [q_1, q_2, \dots, q_n],$$

dobili smo $m \times n$ **ortogonalnu** matricu.

Egzistencija i jedinstvenost QR faktorizacije

Gram–SchmidtoV postupak ortogonalizacije računa i koeficijente

$$r_{ji} = q_j^T g_i$$

koji polazni stupac g_i izražavaju kao linearnu kombinaciju prvih i vektora q_j ortonormirane baze, tako da je

$$g_i = \sum_{j=1}^i r_{ji} q_j.$$

Koeficijenti r_{ji} su upravo elementi matrice R_0 .

Iz Gram–SchmidtoVog algoritma bit će jasno da se može uzeti $r_{ii} > 0$ (dovoljno je $r_{ii} \neq 0$ za fiksiranje predznaka). ■

Gram–Schmidtov postupak ortogonalizacije

U praksi se **nikad** ne koristi **klasični Gram–Schmidtov** postupak ortogonalizacije (skraćeno **CGS**), jer

- vektore ortogonalizira obzirom na prethodne **originalne** vektore g_j .
- Zbog toga je **nestabilan** kad su stupci od G skoro **linearno zavisni**.

Umjesto CGS-a, može se koristiti tzv. **modificirani Gram–Schmidtov** postupak (skraćeno **MGs**),

- koji ortogonalizira vektore obzirom na prethodno **ortogonaliziranu bazu** q_j , pa je mnogo stabilniji.
- No, i kod njega se može dogoditi da je izračunati Q_0 vrlo **daleko** od ortogonalnog, tj. $\|Q_0^T Q_0 - I\| \gg u$, kad je G **vrlo loše** uvjetovana.

Gram–Schmidtov algoritam

Klasični i modificirani Gram–Schmidtov algoritam:

```
za i = 1 do n radi {  
  /* Nađi i-ti stupac od Q_0 i R_0 */  
  q_i = g_i;  
  za j = 1 do i - 1 radi {  
    /* Oduzmi komponentu od q_j u smjeru g_i */  
    /* kod CGS-a je */  
    r_ji = q_jT g_i;  
    /* ILI */  
    /* kod MGS-a je */  
    r_ji = q_jT q_i;  
    q_i = q_i - r_ji q_j;  
  };
```

Gram–Schmidtov algoritam (nastavak)

```
r_ii = ||q_i||2;  
ako je r_ii > 0 onda {  
    q_i = q_i / r_ii;  
}  
inače {  
    /* Matrica R_0 je singularna -- stani */  
};  
};
```

Napomena: $r_{ii} = 0$ je ekvivalentno s tim da je

- g_i linearna kombinacija **prethodnih** stupaca matrice G (linearna zavisnost, pad ranga).

Pokažite da su **dvije** formule za r_{ji} koje koriste **CGS** i **MGS** matematički **ekvivalentne**. **Numerički**, naravno, **nisu** (greške).

Gram–Schmidtov algoritam — komentari

Gram–Schmidtov algoritam daje **skraćenu QR** faktorizaciju $G = Q_0 R_0$. Za “**punu**” faktorizaciju, tj. **kvadratni Q**,

☛ fali nam **ortogonalni komplement** Q_0^\perp ,

kojeg **nemamo** iz čega izračunati — “fale” stupci u G .

Čim je $\|q_i\|_2 \neq 0$, za dijagonalni element r_{ii} možemo uzeti bilo koji od **dva** predznaka

$$r_{ii} = \pm \|q_i\|_2.$$

Dakle, bilo kojim **fiksiranjem predznaka** na dijagonali od R_0 ,

☛ opet dobivamo **jedinstvenu skraćenu QR** faktorizaciju.

Drugi algoritmi

U praksi, kad želimo **ortogonalan** Q , koristimo

- ili **Givensove rotacije**,
- ili **Householderove reflektore**

kojima **poništavamo** odgovarajuće elemente u matrici G . To ponovno daje konstrukciju **QR** faktorizacije.

Bitna razlika između ta dva algoritma:

- **Givensove rotacije** poništavaju po **jedan** element u stupcu,
- **Householderovi reflektori** poništavaju **sve osim jednog** elementa u (**skraćenom**) stupcu.

Oba algoritma mogu dati **skraćenu** i **punu QR** faktorizaciju.

Givensove rotacije

Givensove rotacije


Matrica oblika

$$R(\varphi) = \begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix}$$

zove se **Givensova rotacija** u ravnini.

Ova transformacija **rotira** svaki vektor $x \in \mathbb{R}^2$ za kut φ , u smjeru **obrnutom** od kazaljke na satu.

Slika za $x' = R(\varphi)x$ je



Poništavanje korištenjem Givensovih rotacija

Matrica $R(i, j, \varphi)$ je **ortogonalna**, i $R(i, j, \varphi)^{-1} = R(i, j, \varphi)^T = R(i, j, -\varphi)$. Za zadani vektor $x \in \mathbb{R}^m$,

- **poništavamo** njegovu j -tu komponentu x_j , korištenjem rotacije $R(i, j, \varphi)$.

Množenjem matrice $R(i, j, \varphi)$ **slijeva** na x mijenjamo

- **samo** i -tu i j -tu komponentu u x ,
- pa poništavanje možemo gledati samo u (i, j) ravnini.

Dobiveni sustav je

$$\begin{bmatrix} \cos \varphi & -\sin \varphi \\ \sin \varphi & \cos \varphi \end{bmatrix} \begin{bmatrix} x_i \\ x_j \end{bmatrix} = \begin{bmatrix} x'_i \\ 0 \end{bmatrix}.$$

Traže se elementi matrice **rotacije** $R(i, j, \varphi)$ i **novi** element x'_i .

Poništavanje korištenjem Givensovih rotacija

Drugi redak u matricnoj jednadžbi opisuje poništavanje

$$\sin \varphi x_i + \cos \varphi x_j = 0.$$

Ako je $x_j = 0$, nemamo što poništavati. Ako nije, dobivamo

$$\operatorname{ctg} \varphi = -\frac{x_i}{x_j}.$$

Oдавде, korištenjem trigonometrijskog identiteta

$$1 + \operatorname{ctg}^2 \varphi = \frac{1}{\sin^2 \varphi},$$

slijedi

$$\sin^2 \varphi = \frac{x_j^2}{x_i^2 + x_j^2}, \quad \cos^2 \varphi = 1 - \sin^2 \varphi = \frac{x_i^2}{x_i^2 + x_j^2}.$$

Poništavanje korištenjem Givensovih rotacija

Predznake za $\sin \varphi$ i $\cos \varphi$ biramo tako da x'_i bude pozitivan. Ako stavimo

$$\sin \varphi = -\frac{x_j}{\sqrt{x_i^2 + x_j^2}}, \quad \cos \varphi = \frac{x_i}{\sqrt{x_i^2 + x_j^2}},$$

iz prve jednačbe dobivamo

$$\begin{aligned} x'_i &= \frac{x_i}{\sqrt{x_i^2 + x_j^2}} x_i + \frac{x_j}{\sqrt{x_i^2 + x_j^2}} x_j = \frac{x_i^2 + x_j^2}{\sqrt{x_i^2 + x_j^2}} \\ &= \sqrt{x_i^2 + x_j^2} > 0. \end{aligned}$$

Element x'_i je norma i -te i j -te komponente polaznog vektora. Ove formule vrijede i kad je $x_j = 0$ (tada je $\varphi = 0$ ili $\varphi = \pi$).

Sustavno poništavanje — QR faktorizacija

Sustavnim **poništvanjem** elemenata, konstruirat ćemo QR faktorizaciju matrice G .

- Postoji **puno** redosljeda kako **napraviti** nule u faktoru G .
- U sljedećem primjeru uzet je “**standardni**” redosljed **redom, po stupcima, odozgo nadolje**.

Poništavanje.

- Počinjemo s **prvim** stupcem i poništavamo redom elemente g_{21}, \dots, g_{m1} .
- Ponovimo to isto za **drugi, treći** i svaki daljnji stupac od **dijagonalnog mjesta** nadolje.
- Time nećemo “**pokvariti**” već sređene **nule** u prethodnim stupcima.

Sustavno poništavanje - primjer

Primjer. Za jednu matricu G , tipa 4×3 , to izgleda ovako.

1. stupac:

U radnoj matrici G , redom **poništavamo** elemente

$$g_{i1}, \quad i = 2, \dots, m = 4,$$

rotacijama $R(1, i, \varphi_{1i})$, koje “**nabacuju**” normu **prvog** stupca na **prvi** element u stupcu.

$$\begin{bmatrix} x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ x & x & x \\ x & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ x & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \end{bmatrix}$$

Sustavno poništavanje - primjer (nastavak)

2. stupac:

- U radnoj matrici G , redom **poništavamo** elemente

$$g_{i2}, \quad i = 3, \dots, m = 4,$$

rotacijama $R(2, i, \varphi_{2i})$, koje “**nabacuju**” normu **drugog** stupca (od dijagonale nadolje) na **drugi** element u stupcu.

- To neće “**pokvariti**” već sređene **nule** u **prvom** stupcu.
- Prvi** redak se više **ne mijenja**.

$$\begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & x & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & x \end{bmatrix}$$

Sustavno poništavanje - primjer (kraj)

3. stupac:

- U radnoj matrici G , redom **poništavamo** elemente

$$g_{i3}, \quad i = 4, \dots, m = 4,$$

rotacijama $R(3, i, \varphi_{3i})$, koje “**nabacuju**” normu **trećeg** stupca (od dijagonale nadolje) na **treći** element u stupcu.

- To neće “**pokvariti**” već sređene **nule** u prva **dva** stupca.
- Prva **dva** retka se više **ne mijenjaju**.

$$\begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & x \end{bmatrix} \rightarrow \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & 0 \end{bmatrix}$$

Poredak poništavanja

Drugi rasporedi poništavanja.

- Za **ocjenu greške** zaokruživanja postoji i **bolji** raspored poništavanja elemenata.
- Gore opisanim algoritmom, pri “sređivanju” prvog stupca **prvi redak** se mijenja $m - 1$ puta, a svi ostali samo **jednom**.
- **Poboljšanje** dobivamo “**ujednačavanjem**”, tako da se svaki redak transformira **podjednak** broj puta.
- To se postiže korištenjem niza **nezavisnih** rotacija koje **ne** zahvaćaju iste retke.
- Takav raspored odvijanja rotacija, usput, još dozvoljava i **paralelizaciju** algoritma.

Poredak poništavanja (nastavak)

Grafički, za jednu matricu tipa 4×3 to izgleda ovako.

Crveno i zeleno su nezavisne rotacije koje možemo istovremeno primjenjivati (samo su dvije, jer je m premalen).

$$\begin{array}{ccc} \begin{bmatrix} x & x & x \\ x & x & x \\ x & x & x \\ x & x & x \end{bmatrix} & \rightarrow & \begin{bmatrix} x & x & x \\ 0 & x & x \\ x & x & x \\ 0 & x & x \end{bmatrix} & \rightarrow & \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & x & x \\ 0 & 0 & x \end{bmatrix} \\ & & \rightarrow & & \rightarrow & \\ & & \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & x \end{bmatrix} & \rightarrow & \begin{bmatrix} x & x & x \\ 0 & x & x \\ 0 & 0 & x \\ 0 & 0 & 0 \end{bmatrix} \end{array}$$

Parovi su: $(1, 2)$ i $(3, 4)$, $(1, 3)$ i $(2, 4)$, a na samom kraju više “ne ide”.

Kako doći do Q ?

Na kraju algoritma, na mjestu matrice G piše matrica R .

Do matrice Q se dolazi **nakupljanjem** primijenjenih rotacija

$$R(n, m, \varphi_{nm}) \cdots R(1, 2, \varphi_{12}) G := Q^{-1} G = R.$$

Dakle, matricu G smo

- **slijeva** množili produktom **ortogonalnih** matrica, koji označimo s Q^{-1} .
- Zaključak: $G = QR$.
- Produkt ortogonalnih matrica je **ortogonalna**, pa je $Q^{-1} = Q^T$. Dakle, Q se lako računa iz Q^T .

Matrica Q^T dobiva se primjenom **istih** rotacija, samo na početnu matricu I — “što na G , to na I ”.

Puni i skraćeni Q

U punoj QR faktorizaciji, kvadratnu matricu Q , reda m , dobivamo akumulacijom inverza rotacija slijeva, na početnu jediničnu matricu I_m reda m , ali u obrnutom poretku

$$Q = R(1, 2, -\varphi_{12}) \cdots R(n, m, -\varphi_{nm}) I_m.$$

Pravokutnu matricu Q_0 iz skraćene QR faktorizacije

• dobivamo trivijalno — radeći na prvih n stupaca!

Dovoljno je startati s matricom $I_m(:, 1:n)$ koja sadrži prvih n stupaca jedinične matrice I_m

$$Q_0 = R(1, 2, -\varphi_{12}) \cdots R(n, m, -\varphi_{nm}) I_m(:, 1:n).$$

A obratno? Napravimo punu QR faktorizaciju matrice Q_0 !

Householderovi reflektori

Householderovi reflektori

Za zadani **jedinični** vektor $u \in \mathbb{R}^m$, matrica H definirana s

$$H = H(u) := I - 2uu^T, \quad \|u\|_2 = 1,$$

zove se **Householderov reflektor**.

Matrica H je


- **simetrična**,
- i **ortogonalna**, jer je

$$\begin{aligned} HH^T &= H^2 = (I - 2uu^T)(I - 2uu^T) \\ &= I - 4uu^T + 4u(u^T u)u^T \\ &= I - 4uu^T + 4\|u\|_2^2 uu^T = I. \end{aligned}$$

Zašto baš ime reflektor?

Promatrajmo **hiperravninu** koja je **okomita** na vektor u .

- Reflektor H sve vektore x preslikava u **simetrične** obzirom na tu hiperravninu.



Poništavanje Householderovim reflektorima

Ako je zadan vektor x , nađimo vektor u koji definira **Householderov reflektor** koji **poništava** sve (osim **prve**) komponente vektora x .

Tražimo da je

$$Hx = \begin{bmatrix} c \\ 0 \\ \vdots \\ 0 \end{bmatrix} = c \cdot e_1.$$

Raspišimo tu jednadžbu

$$Hx = (I - 2uu^T)x = x - 2u(u^T x) = c \cdot e_1.$$

($u^T x$ je broj — skalarni produkt!)

Poništavanje Householderovim reflektorima

Premještanjem pribrojnika, dobivamo

$$u = \frac{1}{2(u^T x)}(x - ce_1),$$

pa je u linearna kombinacija od x i e_1 . Preciznije, mora biti

$$u = \alpha(x - ce_1),$$

za neki broj α . Unitarne matrice čuvaju normu, pa je

$$\|x\|_2 = \|Hx\|_2 = |c|.$$

Nadalje, u mora biti jedinične norme, a paralelan s vektorom

$$\tilde{u} = x \pm \|x\|_2 e_1.$$

Poništavanje Householderovim reflektorima

Prema tome,

$$u = \frac{\tilde{u}}{\|\tilde{u}\|_2}.$$

Oba izbora znakova u definiciji \tilde{u} zadovoljavaju

$$Hx = ce_1,$$

dok je $\tilde{u} \neq 0$. U praksi se, zbog **numeričke stabilnosti**, koristi

$$\tilde{u} = x + \text{sign}(x_1)\|x\|_2 e_1,$$

jer to znači da **nema kraćenja** pri računanju prve komponente od \tilde{u} , koja je jednaka

$$\tilde{u}_1 = x_1 + \text{sign}(x_1)\|x\|_2,$$

tj. oba su pribrojnika **istog** znaka.

Drugi način definicije H

Napomena. Računanje u se može izbjeći, ako definiramo

$$H(\tilde{u}) = I - \gamma \tilde{u} \tilde{u}^T \quad \text{gdje je } \gamma = \frac{2}{\tilde{u}^T \tilde{u}}.$$

Kako djelovati na ostale stupce?

Kad smo jednom izračunali u , **ne treba** računati cijelu matricu H . Dovoljno je pogledati kako ona djeluje na vektor z :

$$Hz = (I - \gamma \tilde{u} \tilde{u}^T)z = z - \gamma(\tilde{u}^T z)\tilde{u}.$$

Dakle, treba izračunati **skalarni produkt** $\tilde{u}^T z$, a zatim **modificirati** vektor z .

QR faktorizacija korištenjem reflektora


QR faktorizacija provodi se sustavnom primjenom **Householderovih reflektora** na matricu G i to **slijeva**.

- Prvo se **ponište** svi elementi **prvog** stupca (do na prvi), a na ostale stupce se djeluje **reflektorom** H_1 .
- Zatim se **ponište** elementi dijela **drugog** stupca od dijagonale nadolje (osim dijagonalnog elementa). To se radi “**skraćenim**” **reflektorom** \bar{H}_2 .

Ortogonalna matrica kojom smo djelovali na radnu matricu je onda

$$H_2 = \begin{bmatrix} 1 & \\ & \bar{H}_2 \end{bmatrix}.$$

QR faktorizacija korištenjem reflektora (nast.)

I tako redom. U k -tom koraku, za $k = 1, \dots, n$, poništava se  k -ti “skraćeni” stupac u radnoj matrici — od dijagonale nadolje. Ortogonalna matrica kojom djelujemo na radnu matricu ima oblik

$$H_k = \begin{bmatrix} I & \\ & \bar{H}_k \end{bmatrix},$$

s tim da je I reda $k - 1$, a \bar{H}_k reda $m - k + 1$.


Ako želimo formirati matricu Q , onda je

$$H_n H_{n-1} \cdots H_1 G = R, \quad \text{tj.} \quad Q^T = H_n H_{n-1} \cdots H_1,$$


ili

$$Q = (H_n H_{n-1} \cdots H_1)^T = H_1 \cdots H_{n-1} H_n.$$

QR faktorizacija korištenjem reflektora (nast.)



QR faktorizacija korištenjem reflektora (nast.)



QR faktorizacija i pivotiranje

Računanje QR faktorizacije

Neka je G zadana matrica tipa $m \times n$, s tim da je $m \geq n$.

Računanje QR faktorizacije matrice G

- provodimo u nizu od n koraka. Ako dozvolimo i $m < n$, broj koraka je $\min\{m, n\}$.

Na početku algoritma označimo $R^{(0)} := G$.

Opišimo kako izgleda k -ti korak algoritma, za $k = 1, \dots, n$.

- Na početku k -tog koraka trenutna radna matrica je $R^{(k-1)}$.
- U njoj prvih $k - 1$ stupaca već ima gornjetrokutastu formu, tj. nule ispod dijagonale.
- Ti stupci se više neće mijenjati!

Računanje QR faktorizacije (nastavak)

Izgled radne matrice $R^{(k-1)}$ na početku k -tog koraka:

$$\left[\begin{array}{cccc|ccc}
 r_{1,1}^{(1)} & r_{1,2}^{(2)} & \cdots & r_{1,k-1}^{(k-1)} & r_{1,k}^{(k-1)} & \cdots & r_{1,n}^{(k-1)} \\
 & r_{2,2}^{(2)} & \cdots & r_{2,k-1}^{(k-1)} & r_{2,k}^{(k-1)} & \cdots & r_{2,n}^{(k-1)} \\
 & & \ddots & \vdots & \vdots & & \vdots \\
 & & & r_{k-1,k-1}^{(k-1)} & r_{k-1,k}^{(k-1)} & \cdots & r_{k-1,n}^{(k-1)} \\
 & & & & r_{k,k}^{(k-1)} & \cdots & r_{k,n}^{(k-1)} \\
 & & & & \vdots & & \vdots \\
 & & & & r_{m,k}^{(k-1)} & \cdots & r_{m,n}^{(k-1)}
 \end{array} \right] .$$

Računanje QR faktorizacije (nastavak)

U k -tom koraku — u matrici $R^{(k-1)}$

- **poništavamo** sve elemente k -tog stupca **ispod** dijagonale, nekom ortogonalnom transformacijom Q_k .
- Tako dobivamo **novu** radnu matricu $R^{(k)}$ koja ima **jedan** “sređeni” stupac **više**.

Ovu transformaciju možemo prikazati u obliku

$$R^{(k)} = Q_k R^{(k-1)}, \quad k = 1, \dots, n.$$

Na **kraju** dobivamo **gornju** trokutastu matricu $R := R^{(n)}$.

Nije bitno **kako** računamo Q_k — rotacijama ili reflektorima!

Pivotiranje stupaca u QR faktorizaciji

Slično kao kod LR faktorizacije, i kod QR faktorizacije možemo koristiti **pivotiranje**.

- Uobičajeno se koristi pivotiranje **stupaca**

$$GP = QR,$$

gdje je P matrica permutacije.

- Ako su $x_\ell = [r_{k,\ell}^{(k-1)} \cdots r_{m,\ell}^{(k-1)}]^T$, $\ell = k, \dots, n$, **skraćeni** stupci, na prvo mjesto dovodi se onaj s **najvećom** normom, tj. takav da je $\|x_k\|_2$ **maksimalna**.
- Postupak dovođenja na prvo mjesto **ponavljamo** u svakom koraku QR faktorizacije sa sve kraćim i kraćim stupcima.

Svrha pivotiranja

Svrha?

- Ako je matrica G bila takva da su joj stupci (skoro) linearno zavisni, onda se QR faktorizacijom s pivotiranjem određuje rang matrice G .

Teorem. Neka je $G \in \mathbb{R}^{m \times n}$ matrica ranga r . Tada postoje $n \times n$ matrica permutacije P , ortogonalna matrica Q reda m , te gornja trokutasta matrica R_0 ranga r , tipa $r \times n$, tako da vrijedi

$$GP = QR = Q \begin{bmatrix} R_0 \\ 0 \end{bmatrix}$$

i

$$\|(R_0)_{kk}\|^2 \geq \sum_{i=k}^j \|(R_0)_{ij}\|^2, \quad 1 \leq k \leq \min\{m, n\}, \quad k \leq j \leq n.$$

Oblik matrice R nakon pivotiranja

Za $r < n$, R ima zapravo **trapezni** oblik

$$R = \begin{array}{ccccc} * & * & * & * & * \\ & * & * & * & * \\ & & * & * & * \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \end{array} \left. \vphantom{\begin{array}{ccccc} * & * & * & * & * \\ & * & * & * & * \\ & & * & * & * \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \\ & & & & \end{array}} \right\} r$$

pri čemu su **dijagonalni** elementi u **nerastućem poretku**.

Rješenje matrične formulacije problema najmanjih kvadrata korištenjem QR faktorizacije

Korištenje QR faktorizacije — puni rang

Već smo najavili da ćemo za rješenje **diskretnog** problema **najmanjih kvadrata** koristiti **QR** faktorizaciju.

Prisjetimo se, ako je A **punog** stupčanog ranga (tj. vrijedi $\text{rang}(A) = n$), onda **QR** faktorizacija matrice A ima oblik

$$A = QR = [Q_0 \quad Q_0^\perp] \begin{bmatrix} R_0 \\ 0 \end{bmatrix} = Q_0 R_0.$$

Za početak, ako minimiziramo $\|Ax - b\|_2^2$, minimizirali smo i $\|Ax - b\|_2$. Zbog **unitarne invarijantnosti** 2-norme, imamo

$$\min_x \|Ax - b\|_2^2 = \min_x \|Q^T(Ax - b)\|_2^2 = \min_x \|Q^T Ax - Q^T b\|_2^2.$$

Korištenje QR faktorizacije — puni rang (nast.)

Za Q uzmimo ortogonalnu matricu iz QR faktorizacije, pa je

$$\begin{aligned}\min_x \|Q^T(Ax - b)\|_2^2 &= \min_x \left\| \begin{bmatrix} R_0 \\ 0 \end{bmatrix} x - Q^T b \right\|_2^2 \\ &= \min_x \left\| \begin{bmatrix} R_0 \\ 0 \end{bmatrix} x - \begin{bmatrix} Q_0^T \\ (Q_0^\perp)^T \end{bmatrix} b \right\|_2^2 \\ &= \min_x \left\| \begin{bmatrix} R_0 x - Q_0^T b \\ 0 - (Q_0^\perp)^T b \end{bmatrix} \right\|_2^2 \\ &= \min_x \left(\|R_0 x - Q_0^T b\|_2^2 + \|(Q_0^\perp)^T b\|_2^2 \right).\end{aligned}$$

Korištenje QR faktorizacije — puni rang (nast.)

Primijetimo da **samo prvi član** u prethodnom minimumu ovisi o x , a **drugi** ne.

Budući da je R_0 kvadratna i **punog ranga**, onda je i **regularna**, pa postoji **jedinstveno** rješenje x linearnog sustava

$$R_0x = Q_0^T b.$$

Time smo **prvi član** u kvadratu norme napravili **najmanjim** mogućim, jer je $\|R_0x - Q_0^T b\|_2^2 = 0$.

Zaključak. Onda vrijedi

$$\min_x \|Ax - b\|_2 = \|(Q_0^\perp)^T b\|_2,$$

a **postiče** se za vektor x koji je rješenje sustava $R_0x = Q_0^T b$.

Drugi način — puni rang

Napomena. Postoji i lakši način da se dođe do prethodnog zaključka, ako znamo da su rješenja **problema minimizacije**

$$\min_x \|Ax - b\|_2$$

jednaka rješenju **sustava normalnih jednažbi**

$$A^T Ax = A^T b.$$

Ako je $A^T A$ **regularna**, što je ekvivalentno tome da A ima **puni** stupčani rang, onda problem najmanjih kvadrata ima **jedinstveno** rješenje

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

Drugi način — puni rang (nastavak)

Napravimo skraćenu QR faktorizaciju matrice A

$$A = Q_0 R_0.$$

Uvrštavanjem u rješenje x izlazi

$$\begin{aligned}x &= (A^T A)^{-1} A^T b = ((Q_0 R_0)^T Q_0 R_0)^{-1} (Q_0 R_0)^T b \\&= (R_0^T Q_0^T Q_0 R_0)^{-1} R_0^T Q_0^T b = (R_0^T R_0)^{-1} R_0^T Q_0^T b \\&= R_0^{-1} (R_0^T)^{-1} R_0^T Q_0^T b = R_0^{-1} Q_0^T b,\end{aligned}$$

pa je x , očito, rješenje sustava

$$R_0 x = Q_0^T b.$$

Korištenje QR faktorizacije — defektni rang

- U ovom slučaju prvo trebamo **odrediti rang** matrice A i zbog toga se koristi **QR faktorizacija sa stupčanim pivotiranjem**.
- Ako matrica A ima **rang** $r < n$, onda njena QR faktorizacija sa pivotiranjem ima oblik

$$AP = QR = Q \begin{bmatrix} R_{11} & R_{12} \\ 0 & 0 \\ 0 & 0 \end{bmatrix} \begin{matrix} r \\ n - r \\ m - n \end{matrix},$$

$r \quad n - r$

gdje je R_{11} **regularna** reda r , R_{12} neka $r \times (n - r)$ matrica, a matrica P je $n \times n$ matrica **permutacija**.

Korištenje QR faktorizacije — defektni rang (n.)

• Kod **rješavanja** problema najmanjih kvadrata tada imamo

$$\begin{aligned}\|b - Ax\|_2^2 &= \|Q^T b - (Q^T A P)(P^T x)\|_2^2 \\ &= \left\| \begin{bmatrix} c \\ d \end{bmatrix} - \begin{bmatrix} R_{11} & R_{12} \\ 0 & 0 \end{bmatrix} \begin{bmatrix} y \\ z \end{bmatrix} \right\|_2^2 \\ &= \|(c - R_{12}z) - R_{11}y\|_2^2 + \|d\|_2^2,\end{aligned}$$

gdje je

$$P^T x = \begin{bmatrix} y \\ z \end{bmatrix} \begin{matrix} r \\ n - r \end{matrix}, \quad i \quad Q^T b = \begin{bmatrix} c \\ d \end{bmatrix} \begin{matrix} r \\ m - r \end{matrix}.$$

Korištenje QR faktorizacije — defektni rang (n .)

- Prema tome, ako tražimo x koji **minimizira normu reziduala**, tada on mora zadovoljavati

$$x = P \begin{bmatrix} R_{11}^{-1}(c - R_{12}z) \\ z \end{bmatrix}.$$

ali ovdje je **teško** odrediti x sa **minimalnom normom**.

- Ako stavimo da je $z = 0$ tada dobivamo **osnovno rješenje**

$$x = P \begin{bmatrix} R_{11}^{-1}c \\ 0 \end{bmatrix},$$

koje samo **ne mora** imati **minimalnu normu** u skupu svih rješenja, ali ga je jednostavno izračunati i ima najviše r elemenata različitih od nule.

Korištenje QR faktorizacije — defektni rang (n.)

- Do rješenja problema najmanjih kvadrata sa **minimalnom normom** možemo, s druge strane, doći pomoću **potpune ortogonalne dekompozicije**.
- U jednakosti $AP = QR$ možemo izvesti još jednu QR faktorizaciju, i to na sljedeći način.
- Trebamo izračunati $n \times n$ **ortogonalnu** matricu Z takvu da je

$$Z \begin{bmatrix} R_{11}^T \\ R_{12}^T \end{bmatrix} = \begin{bmatrix} L_{11}^T \\ 0 \end{bmatrix} \begin{matrix} r \\ n-r \end{matrix} \quad \text{tj.} \quad \begin{bmatrix} R_{11} & R_{12} \end{bmatrix} Z^T = \begin{bmatrix} L_{11} & 0 \end{bmatrix},$$

gdje je L_{11} $r \times r$ **regularna donje trokutasta** matrica.

Korištenje QR faktorizacije — defektni rang (n.)

• Tada slijedi

$$Q^T AS = L = \begin{bmatrix} L_{11} & 0 \\ 0 & 0 \end{bmatrix} \begin{matrix} r \\ m - r \end{matrix},$$

$r \quad n - r$

gdje je $S = PZ^T$.

• Primijetimo da je $\mathcal{N}(A) = \mathcal{R}(S(1 : n, r + 1 : n))$.

Korištenje QR faktorizacije — defektni rang (n.)

- Kod rješavanja problema najmanjih kvadrata tada imamo

$$\begin{aligned}\|Ax - b\|_2^2 &= \|(Q^T AS)S^T x - Q^T b\|_2^2 \\ &= \left\| \begin{bmatrix} L_{11} & 0 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} w \\ v \end{bmatrix} - \begin{bmatrix} c \\ d \end{bmatrix} \right\|_2^2 \\ &= \|L_{11}w - c\|_2^2 + \|d\|_2^2,\end{aligned}$$

gdje je

$$S^T x = \begin{bmatrix} w \\ v \end{bmatrix} \begin{matrix} r \\ n - r \end{matrix} \quad Q^T b = \begin{bmatrix} c \\ d \end{bmatrix} \begin{matrix} r \\ m - r \end{matrix}.$$

Korištenje QR faktorizacije — defektni rang (n.)

● Jasno je, da ako x treba **minimizirati normu reziduala**, tada moramo imati $w = L_{11}^{-1}c$, a da bi x imao **minimalnu normu** tada mora biti $v = 0$.

● U tom slučaju je

$$\begin{aligned}x &= S \begin{bmatrix} w \\ 0 \end{bmatrix} = \begin{bmatrix} S(:, 1:r) & S(:, r+1:n) \end{bmatrix} \begin{bmatrix} w \\ 0 \end{bmatrix} \\ &= S(:, 1:r)w.\end{aligned}$$

● Vrijedi da je

$$x \in \mathcal{R}(S(:, 1:r)) \perp \mathcal{R}(S(:, r+1:n)) = \mathcal{N}(A),$$

što smo pokazali da mora vrijediti za **jedinstveno rješenje** problema najmanjih kvadrata sa **minimalnom normom**.

Korištenje QR faktorizacije — defektni rang (n.)

- Dakle, konačno rješenje problema najmanjih kvadrata sa minimalnom normom glasi

$$x = PZ^T \begin{bmatrix} L_{11}^{-1}Q(:, 1:r)^T b \\ 0 \end{bmatrix}.$$