

Problem najmanjih kvadrata

4. dio kolegija Numeričke metode financijske matematike

Nela Bosner

Problem najmanjih kvadrata

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Generalizirani problem najmanjih kvadrata

Primjer

- *U modelu portfelja kad je broj vrijednosnica jako velik računanje sustava linearnih jednadžbi s matricama velikih dimenzija postaje vrlo zahtjevno.*
- *Capital Asset Pricing Model (CAMP) s druge strane nudi efikasnije računanje, bez korištenja \mathbf{C}^{-1} .*
- *U tom modelu pretpostavlja se da svi investitori koriste iste očekivane povrate, iste standardne devijacije i korelacije za sve vrijednosnice.*
- *Nadalje, pretpostavit ćemo da na raspolaganju imamo:*
 - *neriskantnu vrijednosnicu s povratom μ_n i standardnom devijacijom $\sigma_n = 0$*
 - *određeni portfelj riskantnih vrijednosnica tzv. tržišni portfelj s očekivanim povratom $\mu_T = E(R_T)$ i standardnom devijacijom σ_T*

Primjer (nastavak)

- *određeni broj riskantnih vrijednosnica označenih indeksom j s očekivanim povratima $\mu_j = E(R_j)$ i standardnim devijacijama σ_j*
- *Mi želimo predvidjeti povrat j -te vrijednosnice na temelju poznavanja povrata tržišnog portfelja.*
- *Koristit ćemo linearno predviđanje povrata R_j u ovisnosti o R_T , koje je predstavljeno funkcijom*

$$f(\beta_0, \beta_1) = \beta_0 + \beta_1 R_T,$$

gdje su β_0 i β_1 parametri koje na neki način moramo odabrati.

Primjer (nastavak)

- *Najbolje linearno predviđanje znači da moramo naći β_0 i β_1 takve da je očekivana kvadrirana greška predviđanja dana sa*

$$E((R_j - (\beta_0 + \beta_1 R_T))^2)$$

minimalna, što znači da predviđanje u prosjeku bude što je bliže moguće vrijednosti R_j .

- *Očekivanu kvadriranu grešku predviđanja dalje možemo raspisati kao*

$$E((R_j - (\beta_0 + \beta_1 R_T))^2) = E(R_j^2) - 2\beta_0 E(R_j) - 2\beta_1 E(R_T R_j) + \beta_0^2 + 2\beta_0 \beta_1 E(R_T) + \beta_1^2 E(R_T^2)$$

Primjer (nastavak)

- *Minimum ćemo naći tako da parcijalne derivacije po β_0 i β_1 gornjeg izraza izjednačimo s 0. Dobit ćemo*

$$0 = -E(R_j) + \beta_0 + \beta_1 E(R_T)$$

$$0 = -E(R_T R_j) + \beta_0 E(R_T) + \beta_1 E(R_T^2)$$

- *Rješenje ovog sustava linearnih jednadžbi je*

$$\hat{\beta}_1 = \frac{E(R_T R_j) - E(R_T)E(R_j)}{E(R_T^2) - E(R_T)^2} = \frac{\sigma_{jT}}{\sigma_T^2}$$

$$\hat{\beta}_0 = E(R_j) - \hat{\beta}_1 E(R_T) = E(R_j) - \frac{\sigma_{jT}}{\sigma_T^2} E(R_T)$$

Primjer (nastavak)

- *Hessian od $E((R_j - (\beta_0 + \beta_1 R_T))^2)$ glasi*

$$\begin{bmatrix} 1 & E(R_T) \\ E(R_T) & E(R_T^2) \end{bmatrix}$$

pa je pozitivno definitna matrica, i zaista se radi o minimumu.

- *Dakle, najbolje linearno predviđanje za R_j glasi*

$$\hat{R}_j = \hat{\beta}_0 + \hat{\beta}_1 R_T = E(R_j) + \frac{\sigma_{jT}}{\sigma_T^2} (R_T - E(R_T)).$$

- *U praksi gornji izraz za \hat{R}_j ne može se direktno koristiti jer obično ne znamo $E(R_T)$, $E(R_j)$, σ_{jT} i σ_T^2 .*

Primjer (nastavak)

- Zato se koristi **linearna regresija** u kojoj se ti nepoznati parametri zamjenjuju aproksimativnim vrijednostima.
- Da bismo mogli primijeniti linearnu regresiju, pretpostavimo da imamo bivariatni vremenski niz opažanja $(R_{j,t}, R_{T,t})_{t=1}^n$ povrata j -te vrijednosnice i tržišnog portfelja.
- Tada nam model linearne regresije predviđa da je

$$R_{j,t} = \beta_0 + \beta_1 R_{T,t} + \epsilon_t,$$

gdje su nam β_0 i β_1 ponovo nepoznanice a ϵ_t slučajni šum.

- Koeficijenti regresije β_0 i β_1 mogu se odrediti **metodom najmanjih kvadrata**.

Primjer (nastavak)

- Rezultat problema najmanjih kvadrata su vrijednosti $\tilde{\beta}_0$ i $\tilde{\beta}_1$ koje minimiziraju sumu kvadrata greški

$$\sum_{t=1}^n (R_{j,t} - (\beta_0 + \beta_1 R_{T,t}))^2.$$

- U ovom poglavlju upoznat ćemo se sa tehnikama za rješavanje ovog problema, a pomoću njih dobiju se koeficijenti

$$\begin{aligned} \tilde{\beta}_1 &= \frac{\sum_{t=1}^n R_{j,t}(R_{T,t} - \bar{R}_T)}{\sum_{t=1}^n (R_{T,t} - \bar{R}_T)^2} = \frac{\sum_{t=1}^n (R_{j,t} - \bar{R}_j)(R_{T,t} - \bar{R}_T)}{\sum_{t=1}^n (R_{T,t} - \bar{R}_T)^2} \\ &= \frac{s_{jT}}{s_T^2} \end{aligned}$$

$$\tilde{\beta}_0 = \bar{R}_j - \tilde{\beta}_1 \bar{R}_T,$$

Primjer (nastavak)

gdje su

$$\bar{R}_j = \frac{1}{n} \sum_{t=1}^n R_{j,t}, \quad \bar{R}_T = \frac{1}{n} \sum_{t=1}^n R_{T,t}.$$

- Procjena dobivena metodom najmanjih kvadrata je

$$\tilde{R}_j = \tilde{\beta}_0 + \tilde{\beta}_1 R_T = \bar{R}_j + \frac{S_{jT}}{S_T^2} (R_T - \bar{R}_T),$$

što je diskretna verzija najboljeg linearnog predviđanja za R_j .

- Dakle, $\tilde{\beta}_1$ je aproksimacija $\hat{\beta}_1$.
- Na kraju, CAMP nam daje rezultat

$$\mu_j - \mu_n = \hat{\beta}_1 (\mu_T - \mu_n).$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija


Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Generalizirani problem najmanjih kvadrata



Slika: Pravac $\tilde{R}_j = \tilde{\beta}_0 + \tilde{\beta}_1 R_T$ dobiven metodom najmanjih kvadrata

Regresija

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Generalizirani problem najmanjih kvadrata

- Regresija je jedna od najviše korištenih statističkih metoda.
- Od dostupnih podataka imamo
 - jednu promatranu zavisnu varijablu Y koja predstavlja reakciju promatranog modela na neki ulaz
 - n nezavisnih poznatih varijabli X_j na temelju kojih se vrši predviđanje

sve varijable su izmjerene u m različitih mjerenja, gdje je često $m > n$.

- Označimo sa
 - Y_i vrijednost varijable Y u i -tom mjerenju
 - $X_{i,1}, \dots, X_{i,n}$ vrijednosti varijabli X_1, \dots, X_n u i -tom mjerenju

gdje je $i = 1, \dots, m$.

- Zadatak modela regresije je naći način na koji je Y povezan sa X_1, \dots, X_n , zatim procjenu uvjetnog očekivanja od Y i predviđanje budućih vrijednosti od Y .

- Model višestruke **linearne regresije** koja povezuje Y i X_1, \dots, X_n je

$$Y_i = \beta_1 X_{i,1} + \dots + \beta_n X_{i,n} + \epsilon_i,$$

gdje je ϵ_i slučajni šum.

- β_1, \dots, β_n su nepoznati koeficijenti koje želimo odrediti.
- ϵ_i se često nazivaju greškama mjerenja, ali to nije uvijek slučaj.
- Pretpostavljamo da su ϵ_i bijeli šum, tj.
 - $\epsilon_1, \dots, \epsilon_m$ su nezavisne i imaju iste distribucije,
 - sa očekivanjem 0 i konstantnom varijancom σ_ϵ^2 .
- U tom slučaju je

$$\text{Cov}(\epsilon_1, \dots, \epsilon_m) = \sigma_\epsilon^2 I_m.$$

- Ako definiramo matricu \mathbf{X} i vektore \mathbf{b} i \mathbf{y} sa

$$\mathbf{X} = \begin{bmatrix} X_{1,1} & \cdots & X_{1,n} \\ \vdots & & \vdots \\ X_{m,1} & \cdots & X_{m,n} \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} \beta_1 \\ \vdots \\ \beta_n \end{bmatrix}, \quad \mathbf{y} = \begin{bmatrix} Y_1 \\ \vdots \\ Y_m \end{bmatrix},$$

tada sumu kvadrata grešaka možemo napisati kao

$$S(\mathbf{b}) = \sum_{i=1}^m \left(Y_i - \sum_{j=1}^n \beta_j X_{i,j} \right)^2 = (\mathbf{y} - \mathbf{Xb})^T (\mathbf{y} - \mathbf{Xb}).$$

- Rezultat metode najmanjih kvadrata je $\tilde{\mathbf{b}}$ sa svojstvom

$$S(\tilde{\mathbf{b}}) = \min S(\mathbf{b}).$$
- Da bismo bili konzistentni sa oznakama u numerici, od sada pa na dalje označavat ćemo:

$$A = \mathbf{X}, \quad x = \mathbf{b}, \quad b = \mathbf{y}.$$

Napomena

Ulogu vektora b je promijenjena, što je rezultat nesretne podudarnosti u statističkim i numeričkim oznakama za različite vektore.

Opis linearnog problema najmanjih kvadrata

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Generalizirani problem najmanjih kvadrata

Matrična formulacija

- Za $A \in \mathbb{R}^{m \times n}$, uz pretpostavku, $m \geq n$, i b rješavamo problem

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2$$

tj. određujemo x tako da minimizira rezidual $r = Ax - b$

$$\min_x \|r\|_2$$

- Ako je $\text{rang}(A) < n$, onda rješenje x ovog problema očito **nije** jedinstveno, jer mu možemo dodati bilo koji vektor iz nul-potprostora 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 $\|x\|_2$.

- Iz geometrijske interpretacije problema najmanjih kvadrata odmah vidimo da je za rješenje x , Ax ortogonalna projekcija vektora b na $\text{Im}(A)$.
- To se lako može provjeriti ako definiramo diferencijabilnu funkciju

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

i izjednačimo $\nabla\phi(x) = 0$.

- Tada možemo raspisati $\phi(x)$ kao

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

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

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

- Dakle,

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

a iz $\nabla \phi(x) = 0$ slijedi

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

ili da rješenje problema najmanjih kvadrata zadovoljava sustav **normalnih jednažbi**

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

Ovime smo dokazali sljedeći teorem.

Teorem

Skup svih rješenja problema najmanjih kvadrata 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

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

- Ako sa \vec{b} , \vec{Ax} i \vec{r} označimo vektore u vektorskom prostoru \mathbb{R}^m , pri čemu je x je rješenje problema najmanjih kvadrata, tada imamo da je

$$\vec{b} = \vec{Ax} - \vec{r},$$

a zbog $A^T r = 0$ je $(Ay)^T r = 0$ za svaki $y \in \mathbb{R}^n$, odnosno

$$\vec{r} \perp \text{Im}(A).$$

- Na kraju možemo zaključiti da je \vec{Ax} dobiven iz \vec{b} , tako što mu se oduzela komponenta okomita na $\text{Im}(A)$, pa je \vec{Ax} zaista ortogonalna projekcija od \vec{b} na $\text{Im}(A)$.

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija


Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Generalizirani problem najmanjih kvadrata



Slika: Okomitost reziduala rješenja x problema $\|Ax - b\|_2 \rightarrow \min$ na $\text{Im}(A)$.

- Vratimo se ponovo sustavu normalnih jednažbi.
- Matrica $A^T A$ je simetrična i pozitivno semidefinitna, a sustav normalnih jednažbi je uvijek konzistentan, jer je

$$A^T b \in \text{Im}(A^T) = \text{Im}(A^T A).$$

- Kada smo računali rješenje sustava $\nabla \phi(x) = 0$, odnosno sustava normalnih jednažbi, da bi ono bilo zaista minimum funkcije ϕ moramo provjeriti Hessian.
- Vrijedi

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

što znači da je

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

• $H\phi$ je

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

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

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

- To možemo provjeriti na sljedeći način.
- Neka je x rješenje problema najmanjih kvadrata, i neka je $x + z$ također rješenje istog problema.
- Tada x i $x + z$ moraju zadovoljavati $A^T r = 0$, pa imamo

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

- Ako gornju jednakost skalarno pomnožimo sa z , dobit ćemo da je $\|Az\|_2 = 0$, odakle slijedi da je $Az = 0$ odnosno $z \in \text{Ker}(A)$ (z je u jezgri od A).

- Dakle skup rješenja u ovom slučaju čini skup

$$S = x + \text{Ker}(A).$$

- Ako je $x \perp \text{Ker}(A)$, 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.

Primjer

- *Provjerimo sada rezultat linearne regresija iz primjera sa početka poglavlja.*
- *Matrični oblik tog problema glasi:*

$$\min_{x \in \mathbb{R}^n} \|Ax - b\|_2$$

gdje su

$$A = \begin{bmatrix} 1 & R_{T,1} \\ \vdots & \vdots \\ 1 & R_{T,n} \end{bmatrix}, \quad x = \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix}, \quad b = \begin{bmatrix} R_{j,1} \\ \vdots \\ R_{j,n} \end{bmatrix}.$$

- *Sustav normalnih jednadžbi za ovaj problem onda glasi*

Primjer (nastavak)

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

$$\begin{bmatrix} n & \sum_{i=1}^n R_{T,i} \\ \sum_{i=1}^n R_{T,i} & \sum_{i=1}^n R_{T,i}^2 \end{bmatrix} \begin{bmatrix} \beta_0 \\ \beta_1 \end{bmatrix} = \begin{bmatrix} \sum_{i=1}^n R_{j,i} \\ \sum_{i=1}^n R_{T,i} R_{j,i} \end{bmatrix}.$$

- *Rješenje ovog sustava je*

$$\tilde{\beta}_1 = \frac{\sum_{i=1}^n R_{T,i} R_{j,i} - \frac{(\sum_{k=1}^n R_{T,k})(\sum_{\ell=1}^n R_{j,\ell})}{n}}{\sum_{i=1}^n R_{T,i}^2 - \frac{(\sum_{k=1}^n R_{T,k})^2}{n}}$$

$$\tilde{\beta}_0 = \frac{\sum_{i=1}^n R_{j,i}}{n} - \tilde{\beta}_1 \frac{\sum_{i=1}^n R_{T,i}}{n}$$

- *Malim manipulacijama suma dobije se rezultat naveden u početnom primjeru.*

Numeričko rješavanje problema najmanjih kvadrata

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

Postoji nekoliko načina rješavanja problema najmanjih kvadrata u praksi. Obično se koristi jedna od sljedećih metoda:

- 1 rješavanje sustava normalnih jednadžbi,
- 2 transformacija u linearni sustav većih dimenzija i njegovo rješavanje,
- 3 rješavanje problema najmanjih kvadrata pomoću **QR faktorizacije**.
- 4 rješavanje problema najmanjih kvadrata pomoću **dekompozicije singularnih vrijednosti (SVD)**.

Rješavanje sustava normalnih jednačbi

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednačbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

- Ova metoda je najbrža, ali je najmanje točna.
- Koristi se kad je $A^T A$ pozitivno definitna (A punog ranga) i kad je njena uvjetovanost mala:

$$\kappa(A^T A) = \|A^T A\|_2 \|(A^T A)^{-1}\|_2 = \|A\|_2^2 \|A^{-1}\|_2^2 = \kappa(A)^2.$$

- Matrica $A^T A$ rastavi se faktorizacijom Choleskog, a zatim se riješi linearni sustav

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

- Ukupan broj aritmetičkih operacija za računanje $A^T A$, $A^T b$, te zatim faktorizaciju Choleskog je $mn^2 + \frac{1}{3}n^3 + O(n^2)$.
- Budući da je običo $m \geq n$, onda je prvi član dominantan u ovom izrazu, a potječe od formiranja $A^T A$.

Transformacija u linearni sustav većih dimenzija

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osjettljivost numeričkog rješenja problema najmanjih

- Ako matrica A ima puni rang po stupcima, onda problem najmanjih kvadrata možemo transformirati i na linearni sustav različit od sustava normalnih jednadžbi.
- Simetrični linearni sustav

$$\begin{bmatrix} I & A \\ A^T & 0 \end{bmatrix} \begin{bmatrix} r \\ x \end{bmatrix} = \begin{bmatrix} b \\ 0 \end{bmatrix},$$

ekvivalentan je sustavu normalnih jednadžbi.

- Ako napišemo prvu i drugu blok-komponentu

$$r + Ax = b, \quad A^T r = 0,$$

onda uvrštavanjem r -a iz prve blok-jednadžbe u drugu dobivamo sustav

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

- Ovaj sustav ima bitno manji raspon elemenata i bolju uvjetovanost od sustava normalnih jednadžbi.

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednačini

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Teorem (QR dekompozicija)

- *Neka je $A \in \mathbb{C}^{m \times n}$, uz $m \geq n$. Tada postoji unitarna matrica $Q \in \mathbb{C}^{m \times m}$ takva da je*

$$Q^* A = R = \begin{bmatrix} R_1 \\ 0 \end{bmatrix},$$

gdje je $R \in \mathbb{C}^{m \times n}$, a $R_1 \in \mathbb{C}^{n \times n}$ gornje trokutasta matrica s nenegativnim dijagonalnim elementima.

- *Neka je $A \in \mathbb{R}^{m \times n}$, uz $m \geq n$. Tada postoji ortogonalna matrica $Q \in \mathbb{R}^{m \times m}$ takva da je*

$$Q^T A = R = \begin{bmatrix} R_1 \\ 0 \end{bmatrix},$$

gdje je $R \in \mathbb{R}^{m \times n}$, a $R_1 \in \mathbb{R}^{n \times n}$ gornje trokutasta matrica s nenegativnim dijagonalnim elementima.

Napomena

Ako izvršimo particiju matrica

$$Q = \begin{bmatrix} Q_1 & Q_2 \end{bmatrix} \\ \begin{matrix} n & m-n \end{matrix}$$

onda iz prethodnog teorema slijedi

$$A = \begin{bmatrix} Q_1 & Q_2 \end{bmatrix} \begin{bmatrix} R_1 \\ 0 \end{bmatrix} = Q_1 R_1.$$

Dakle, QR dekompoziciju možemo napisati u skraćenom obliku

$$A = Q_1 R_1,$$

pri čemu je $Q_1 \in \mathbb{C}^{m \times n}$ ortonormirana matrica, a $R_1 \in \mathbb{C}^{n \times n}$ gornjetrokutasta matrica s nenegativnim dijagonalnim elementima.

Korolar

Ako je $A \in \mathbb{C}^{n \times n}$ regularna matrica, tada je matrica Q jedinstvena.

- Kao što znamo, QR faktorizaciju možemo izračunati na više načina.
- Najčešća su dva načina računanja kod kojih se ortogonalna matrica Q dobije uzastopnim množenjem elementarnih ortogonalnih matrica, kao što su: reflektori ili rotacije.

QR faktorizacija pomoću Householderovih reflektora – podsjetnik

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednažbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

- Householderove reflektore primijenjujemo direktno na stupce matrice, i to od dijagonale na dolje.
- Neka je $A = [a_1^{(1)} \ \dots \ a_n^{(1)}] \in \mathbb{R}^{m \times n}$ za $m \geq n$.
- Ako je $a_1^{(1)} \neq 0$, stavimo li

$$e^{(1)} = e_1 \in \mathbb{R}^m,$$

znamo naći Householderov reflektor H_1 takav da je

$$H_1 a_1^{(1)} = \alpha_1 e^{(1)}.$$

- Tada je

$$\begin{aligned} A^{(2)} = H_1 A^{(1)} &= [H_1 a_1^{(1)} \ \dots \ H_1 a_n^{(1)}] = \\ &= \begin{bmatrix} \alpha_1 & * & * & \dots & * \\ 0 & & & & \\ \vdots & a_2^{(2)} & a_3^{(2)} & \dots & a_n^{(2)} \\ 0 & & & & \end{bmatrix}. \end{aligned}$$

- Ako je $a_1^{(1)} = 0$, stavimo $H_1 = I$.
- Ako je $a_2^{(2)} \neq 0 \in \mathbb{R}^{m-1}$, postoji Householderova matrica $\bar{H}_2 \in \mathbb{R}^{(m-1) \times (m-1)}$ takva da je

$$\bar{H}_2 a_2^{(2)} = \alpha_2 e_1,$$

uz $e_1 \in \mathbb{R}^{m-1}$.

- Za

$$H_2 = \begin{bmatrix} 1 & 0 \\ 0 & \bar{H}_2 \end{bmatrix}$$

je

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednačija

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

$$\begin{aligned} H_2 A^{(2)} &= \begin{bmatrix} 1 & 0 \\ 0 & \bar{H}_2 \end{bmatrix} \begin{bmatrix} \alpha_1 & * & * & \dots & * \\ 0 \\ \vdots & a_2^{(2)} & a_3^{(2)} & \dots & a_n^{(2)} \\ 0 \end{bmatrix} \\ &= \begin{bmatrix} \alpha_1 & * & * & \dots & * \\ 0 & \alpha_2 \\ \vdots & \vdots & \bar{H}_2 a_3^{(2)} & \dots & \bar{H}_2 a_n^{(2)} \\ 0 & 0 \end{bmatrix} \\ &= \begin{bmatrix} \alpha_1 & * & * & \dots & * \\ 0 & \alpha_2 & * & \dots & * \\ 0 & 0 \\ \vdots & \vdots & a_3^{(3)} & \dots & a_n^{(3)} \\ 0 & 0 \end{bmatrix} \end{aligned}$$

- Nastavljamo tako dalje, svaki puta smanjujući dimenziju problema i radeći sa

$$A^{(k)}(k : m, k : n) \quad \text{i} \quad \bar{H}_k \in \mathbb{R}^{(m-k+1) \times (m-k+1)},$$

a $H_k \in \mathbb{R}^{m \times m}$ definiramo sa

$$H_k = \begin{bmatrix} I_{k-1} & 0 \\ 0 & \bar{H}_k \end{bmatrix}.$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije


Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih



Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednačini

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije


Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osejtljivost numeričkog rješenja problema najmanjih



- Na kraju imamo

$$H_n H_{n-1} \cdots H_1 A = \begin{bmatrix} \alpha_1 & * & * & \cdots & * \\ 0 & \alpha_2 & * & \cdots & * \\ & & \ddots & & \\ & & & \ddots & \\ 0 & 0 & & & \alpha_n \\ 0 & 0 & & & 0 \\ \vdots & \vdots & & & \vdots \\ 0 & 0 & & & 0 \end{bmatrix} = R,$$

tj. $A = QR$, gdje je $Q = H_1 \cdots H_n$.

- Želimo li u R nenegativnu dijagonalu, prethodnu jednakost slijeva još pomnožimo matricom

$$H_{n+1} = \text{diag}(\text{sign}(\alpha_1), \dots, \text{sign}(\alpha_n), 1, \dots, 1),$$

koja je ortogonalna.

Napomena

- I kod QR faktorizacije se može **pivotirati** i to tako da se u k -tom koraku u matrici $A^{(k)}$ stupac najveće norme (od dijagonale na dolje $a_k^{(k)}, \dots, a_n^{(k)}$) dovede na pivotno mjesto i ponište njegovi elementi ispod dijagonale.
- To se koristi kad želimo naći rang matrice, jer su dijagonalni elementi matrice R sortirani padajuće po apsolutnim vrijednostima.
- Imamo

$$H_n H_{n-1} (\cdots H_2 ((H_1 (A I_{1,j_1})) I_{2,j_2}) \cdots I_{n-1,j_{n-1}}) = R,$$

$$Q = H_1 \cdots H_n, \quad P = I_{1,j_1} \cdots I_{n-1,j_{n-1}},$$

tj.

$$Q^T A P = R, \quad \implies \quad A P = Q R.$$

Napomena (nastavak)

$$A^{(k)} = \begin{array}{cccccccc} \alpha_1 & * & \cdots & * & * & \cdots & * & \cdots & * \\ & \alpha_2 & \cdots & * & * & \cdots & * & \cdots & * \\ & & \ddots & \vdots & \vdots & & & & \\ & & & \alpha_{k-1} & * & \cdots & * & \cdots & * \end{array} \begin{array}{c} \boxed{a_k^{(k)}} \quad \cdots \quad \boxed{a_{j_k}^{(k)}} \quad \cdots \quad \boxed{a_n^{(k)}} \\ \underbrace{\hspace{10em}} \\ I_{k,j_k} \end{array}$$

- $\|a_{j_k}^{(k)}\|_2 = \max_{j=k,\dots,n} \|a_j^{(k)}\|_2$
- k -ti i j_k -ti stupac zamijene mjesta pomoću permutacije $I_{k,j_k} \rightarrow A^{(k)} \cdot I_{k,j_k}$, i tada se računa H_k .

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednažbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

Napomena (nastavak)

- Kad se nakon pivotiranja u tekućem koraku i poništavanja ispoddijagonalnih elemenata u tekućem stupcu, na dijagonali nađe 0, tada znamo da je donji desni $(m - r) \times (n - r)$ blok matrice R jednak nulmatrici.
- U tom slučaju je matrica R , a onda i matrica A , ranga r .

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

QR faktorizacija pomoću Givensovih rotacija – podsjetnik

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednačini

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih

- Givensove rotacije poništavaju element po element matrice A .
- Za dobivanje QR faktorizacije potrebno je poništiti sve elemente donjeg trokuta matrice A , i to tako da se jednom poništeni element (jednak nuli) više ne mijenja.
- Način na koji biramo kojim redom ćemo ih poništavati zove se **pivotna strategija**.
- Najčešća pivotna strategija je poništavanje po stupcima:

$$\begin{bmatrix} * & * & * & * & * \\ 5 & * & * & * & * \\ 4 & 9 & * & * & * \\ 3 & 8 & 12 & * & * \\ 2 & 7 & 11 & 14 & * \\ 1 & 6 & 10 & 13 & 15 \end{bmatrix} \cdot$$

- Na poziciji (i, j) element se poništava Givensovom rotacijom $G_j(i - 1, i)$, gdje su $i - 1$ i i pivotni indeksi.
- Na kraju, za $A \in \mathbb{R}^{m \times n}$, $m \geq n$ dobivamo da je

$$G_n(n, n + 1)^T \cdots G_n(m - 2, m - 1)^T G_n(m - 1, m)^T \cdots G_2(2, 3)^T \cdots G_2(m - 2, m - 1)^T \cdot G_2(m - 1, m)^T \cdot G_1(1, 2)^T \cdots G_1(m - 2, m - 1)^T G_1(m - 1, m)^T A = R,$$

tj. $A = QR$, gdje se matrica Q tada dobiva kao produkt odgovarajućih Givensovih rotacija

$$Q = G_1(m - 1, m) \cdots G_1(1, 2) G_2(m - 1, m) \cdots G_2(2, 3) \cdots G_n(m - 1, m) \cdots G_n(n, n + 1).$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednažbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije


Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih



Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednažbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije


Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a


Zadaci

Problem određivanja numeričkog ranga


Osjetljivost numeričkog rješenja problema najmanjih




$$\xrightarrow{G_1(1,2)^T}$$



$$\xrightarrow{G_2(5,6)^T}$$



$$\xrightarrow{G_2(4,5)^T}$$



$$\xrightarrow{G_2(3,4)^T}$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednažbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije


Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a


Zadaci

Problem određivanja numeričkog ranga


Osetljivost numeričkog rješenja problema najmanjih




$$\xrightarrow{G_2(2,3)^T}$$



$$\xrightarrow{G_3(5,6)^T}$$



$$\xrightarrow{G_3(4,5)^T}$$



$$\xrightarrow{G_3(3,4)^T}$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

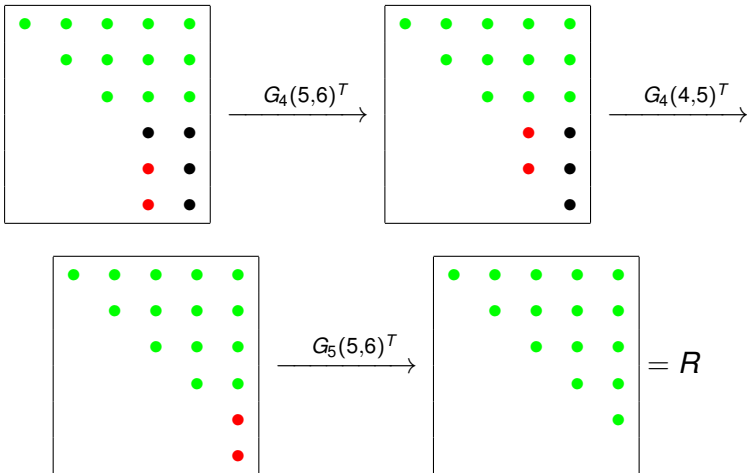
Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih



Rješenje problema najmanjih kvadrata

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

Postoje dvije različite situacije kod rješavanja problema najmanjih kvadrata $\min \|Ax - b\|_2$.

Matrica A je punog stupčanog ranga

- U tom slučaju rješenje problema je jednako rješenju sustava normalnih jednadžbi

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

- Sada napišemo QR faktorizaciju matrice A

$$A = QR = Q_1 R_1,$$

gdje je Q_1 ortonormalna $m \times n$ matrica, a R_1 $n \times n$ regularna trokutasta matrica i uvrstimo u rješenje.

- Dobivamo

$$\begin{aligned} x &= (A^T A)^{-1} A^T b = (R_1^T Q_1^T Q_1 R_1)^{-1} R_1^T Q_1^T b \\ &= (R_1^T R_1)^{-1} R_1^T Q_1^T b = R_1^{-1} R_1^{-T} R_1^T Q_1^T b = R_1^{-1} Q_1^T b. \end{aligned}$$

- Dakle, x se dobiva primjenom “invertirane” skraćene QR faktorizacije od A na b .
- Preciznije, da bismo našli x , rješavamo trokutasti linearni sustav

$$R_1 x = Q_1^T b.$$

- Na ovakav se način najčešće rješavaju problemi najmanjih kvadrata.
- Nije teško pokazati da je cijena računanja $2mn^2 - \frac{2}{3}n^3$.

Matrica A nema puni stupčani 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

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

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

- Kod rješavanja problema najmanjih kvadrata tada imamo

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

gdje je

$$P^T x = \begin{bmatrix} y \\ z \end{bmatrix} \begin{matrix} r \\ n-r \end{matrix}, \quad Q^T b = \begin{bmatrix} c \\ d \end{bmatrix} \begin{matrix} r \\ m-r \end{matrix} \Rightarrow c = Q(:, 1:r)^T b.$$

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

$$(c - R_{12}z) - R_{11}y = 0, \implies x = P \begin{bmatrix} y \\ z \end{bmatrix} = P \begin{bmatrix} R_{11}^{-1}(c - R_{12}z) \\ z \end{bmatrix}$$

- Sljedeći korak je pronalaženje vektora z takvog da $\|x\|_2$ ima minimalnu normu, ali to nije jednostavno iz oblika rješenja

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

smeta nam podmatrica R_{12} , jer kad bi ona bila jednaka nul-matrici tada bi se minimalno rješenje moglo postići za $z = 0$.

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

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

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

- 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

$$\begin{bmatrix} R_{11}^T \\ R_{12}^T \end{bmatrix} = Z^T \begin{bmatrix} L_{11}^T \\ 0 \end{bmatrix}, \text{ tj. } [R_{11} \ R_{12}] = [L_{11} \ 0] Z,$$

što nazivamo **LQ faktorizacijom**. Odnosno, vrijedi

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

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

- Tada slijedi

$$Q^T APZ^T = (Q^T AP)Z^T = \begin{bmatrix} R_{11} & R_{12} \\ 0 & 0 \\ 0 & 0 \end{bmatrix} Z^T$$

$$= \begin{bmatrix} L_{11} & 0 \\ 0 & 0 \end{bmatrix},$$

odnosno, možemo zaključiti da je

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

gdje je $S = PZ^T$.

- Time smo eliminirali blok R_{12} .
- Primijetimo da je $\text{Ker}(A) = \text{Im}(S(1 : n, r + 1 : n))$.

- Kod rješavanja problema najmanjih kvadrata tada imamo

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

gdje je

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

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

- U tom slučaju je

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

- Vrijedi da je

$$x \in \text{Im}(S(:, 1 : r)) \perp \text{Im}(S(:, r + 1 : n)) = \text{Ker}(A),$$

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

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

$$w = L_{11}^{-1}c = L_{11}Q(:, 1 : r)^T b \text{ glasi}$$

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

Zadaci

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih

Zadatak

Riješite problem najmanjih kvadrata iz primjera sa početka poglavlja. Opažanja povrata j -te vrijednosnice i tržišnog portfelja u vremenskim instancama dana su u datoteci

`primjer_regresija_vrijednosnice.mat`

na adresi

<http://www.math.hr/~nela/nmf.html>

Vaš zadatak je:

- 1 *generirati matricu A i vektor b u problemu najmanjih kvadrata,*
- 2 *izračunati QR faktorizaciju matrice A s pivotiranjem pomoću MATLAB-ove funkcije `qr()`,*

Zadatak (nastavak)

- 3 *izračunati rješenje problema najmanjih kvadrata*
 $[\tilde{\beta}_0 \quad \tilde{\beta}_1]^T$,
- 4 *nacrtati graf sa prikazanim točkama opažanja*
 $(R_{T,t}, R_{j,t})$ *i pravcem* $R_{j,t} = \tilde{\beta}_0 + \tilde{\beta}_1 R_{T,t}$, *sa pravilno označenim osima.*

Uputa: QR faktorizacija s pivotiranjem u MATLAB-u se računa tako da se kao izlazne vrijednosti stave tri varijable:

$$[Q, R, P] = \text{qr}(A).$$

Rješavanje problema najmanjih kvadrata pomoću dekompozicije singularnih vrijednosti

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktORIZACIJE

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Ocjeljivost numeričkog rješenja problema najmanjih

Teorem (Dekompozicija singularnih vrijednosti (SVD))

Neka je $A \in \mathbb{R}^{m \times n}$ matrica ranga r . Tada postoje ortogonalne matrice $U \in \mathbb{R}^{m \times m}$ i $V \in \mathbb{R}^{n \times n}$ takve da je na jedinstven način određena dijagonalna matrica

$$U^T A V = \Sigma = \begin{matrix} \begin{bmatrix} \Sigma_+ & 0 \\ 0 & 0 \end{bmatrix} & \begin{matrix} r \\ m-r \end{matrix} \\ \begin{matrix} r & n-r \end{matrix} & \end{matrix}$$

*gdje je $\Sigma_+ = \text{diag}(\sigma_1, \dots, \sigma_r)$, uz $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$. Kažemo da je $A = U \Sigma V^T$ **dekompozicija singularnih vrijednosti (SVD)** matrice A .*

Napomena

Ako izvršimo particiju matrica

$$U = \begin{bmatrix} U_1 & U_2 \end{bmatrix} \quad V = \begin{bmatrix} V_1 & V_2 \end{bmatrix}$$

$r \quad m-r \qquad \qquad \qquad r \quad n-r$

onda iz prethodnog teorema slijedi:

$$\begin{bmatrix} \Sigma_+ & 0 \\ 0 & 0 \end{bmatrix} = \begin{bmatrix} U_1^T \\ U_2^T \end{bmatrix} A \begin{bmatrix} V_1 & V_2 \end{bmatrix},$$

odnosno

$$\Sigma_+ = U_1^T A V_1 \quad i \quad A = U_1 \Sigma_+ V_1^T.$$

Matrica A je punog stupčanog ranga

- U tome slučaju rješenje problema je jednako rješenju sustava normalnih jednadžbi

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

- Sada napišemo SVD matrice A

$$A = U \Sigma V^T = U_1 \Sigma_+ V^T,$$

gdje je U_1 ortonormalna $m \times n$ matrica, V ortogonalna $n \times n$ matrica, a Σ_+ $n \times n$ dijagonalna matrica, i uvrstimo u rješenje.

- Dobivamo

$$\begin{aligned} x &= (A^T A)^{-1} A^T b = (V \Sigma_+ U_1^T U_1 \Sigma_+ V^T)^{-1} V \Sigma_+ U_1^T b \\ &= (V \Sigma_+^2 V^T)^{-1} V \Sigma_+ U_1^T b = V \Sigma_+^{-2} V^T V \Sigma_+ U_1^T b \\ &= V \Sigma_+^{-2} \Sigma_+ U_1^T b = V \Sigma_+^{-1} U_1^T b. \end{aligned}$$

- Dakle, x se dobiva primjenom “invertiranog” skraćenog SVD-a od A na b .

Matrica A nije punog stupčanog ranga

- Uobičajeno se SVD primjenjuje u metodi najmanjih kvadrata i kad matrica A nema puni stupčani rang, a za razliku od QR faktorizacije ne moraju se raditi dodatne faktorizacije.
- Rješenja su istog oblika, samo što moramo znati izračunati “inverz” matrice Σ kad ona nije regularna, tj. kad ima neke nule na dijagonali.
- Takav inverz zove se generalizirani inverz i označava sa Σ^+ ili Σ^\dagger .
- U slučaju da je

$$\Sigma = \begin{bmatrix} \Sigma_+ & 0 \\ 0 & 0 \end{bmatrix},$$

pri čemu je Σ_+ regularna, onda je

$$\Sigma^\dagger = \begin{bmatrix} \Sigma_+^{-1} & 0 \\ 0 & 0 \end{bmatrix}.$$

- Neka matrica A ima rang $r < n$.
- Rješenje x koje minimizira $\|Ax - b\|_2$ može se karakterizirati na sljedeći način.
- Neka je $A = U\Sigma V^T$ SVD od A i neka je

$$A = U\Sigma V^T = [U_1, U_2, U_3] \begin{bmatrix} \Sigma_+ & 0 \\ 0 & 0 \\ 0 & 0 \end{bmatrix} [V_1, V_2]^T = U_1 \Sigma_+ V_1^T,$$

gdje je Σ_+ regularna matrica reda r , matrice U_1 i V_1 imaju r stupaca, matrice U_2 i V_2 imaju $n - r$ stupaca, a matrica U_3 ima $m - n$ stupaca.

- Tada se sva rješenja problema najmanjih kvadrata mogu napisati u formi

$$x = V_1 \Sigma_+^{-1} U_1^T b + V_2 z,$$

gdje je z proizvoljni vektor.

- Rješenje x koje ima minimalnu 2-normu je ono za koje je $z = 0$, tj.

$$x = V_1 \Sigma_+^{-1} U_1^T b.$$

- Prethodne tvrdnje ćemo sada provjeriti.
- Korištenjem unitarne invarijantnosti 2-norme, dobivamo

$$\begin{aligned} \|Ax - b\|_2^2 &= \|U^T(Ax - b)\|_2^2 = \left\| \begin{bmatrix} U_1^T \\ U_2^T \\ U_3^T \end{bmatrix} (U_1 \Sigma_+ V_1^T x - b) \right\|_2^2 \\ &= \left\| \begin{bmatrix} \Sigma_+ V_1^T x - U_1^T b \\ -U_2^T b \\ -U_3^T b \end{bmatrix} \right\|_2^2 \\ &= \|\Sigma_+ V_1^T x - U_1^T b\|_2^2 + \|U_2^T b\|_2^2 + \|U_3^T b\|_2^2. \end{aligned}$$

- Očito, prethodni izraz je minimiziran kad je prva od tri norme u posljednjem redu jednaka 0, tj. ako je

$$\Sigma_+ V_1^T x = U_1^T b,$$

ili

$$x = V_1 \Sigma_+^{-1} U_1^T b.$$

- Stupci matrica V_1 i V_2 su međusobno ortogonalni, pa je $V_1^T V_2 z = 0$ za sve vektore z .
- Odavde vidimo da x ostaje rješenje problema najmanjih kvadrata i kad mu dodamo $V_2 z$, za bilo koji z , tj. ako je

$$x = V_1 \Sigma_+^{-1} U_1^T b + V_2 z.$$

- To su ujedno i sva rješenja, jer stupci matrice V_2 razapinju nul-potprostor $\text{Ker}(A)$.
- Osim toga, zbog spomenute ortogonalnosti vrijedi i

$$\|x\|_2^2 = \|V_1 \Sigma_+^{-1} U_1^T b\|_2^2 + \|V_2 z\|_2^2,$$

a to je minimalno za $z = 0$.

- Rješenje problema najmanjih kvadrata korištenjem SVD-a je najstabilnije, a može se pokazati da je, za $m \gg n$, njegovo trajanje približno jednako kao i trajanje rješenja korištenjem QR-a.
- Za manje m , trajanje je približno $4mn^2 - \frac{4}{3}n^3 + O(n^2)$.

Generalizirani inverz

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednažbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktORIZACIJE

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

- Ako želimo proširiti pojam inverza (X) i na matrice koje nisu regularne ili čak nisu kvadratne, onda zahtijevamo da on mora zadovoljavati malo oslabljene uvjete nego standardni inverz:

$$AX = XA = I.$$

- Najpoznatiji generalizirani inverz je tzv. **Moore–Penroseov inverz**, koji je određen sa sljedeća četiri uvjeta.
Moore–Penroseovi uvjeti:

- 1 $AXA = A$
- 2 $XAX = X$
- 3 $(AX)^* = AX$
- 4 $(XA)^* = XA$

Za generalizirani inverz vrijede sljedeća svojstva

- Neka je $A \in \mathbb{C}^{m \times n}$. Tada postoji jedinstvena matrica $X \in \mathbb{C}^{n \times m}$, koja zadovoljava Penroseove uvjete. Ta matrica ima oblik

$$A^\dagger = V \begin{bmatrix} \Sigma_+^{-1} & 0 \\ 0 & 0 \end{bmatrix} U^*, \quad \text{pri čemu je } A = U \begin{bmatrix} \Sigma_+ & 0 \\ 0 & 0 \end{bmatrix} V^*$$

singularna dekompozicija matrice A .

- Za proizvoljnu matricu $A \in \mathbb{C}^{m \times n}$ vrijedi:

- 1 $(A^\dagger)^\dagger = A$
- 2 $(\bar{A})^\dagger = \overline{(A^\dagger)}$
- 3 $(A^T)^\dagger = (A^\dagger)^T$
- 4 $\text{rang}(A) = \text{rang}(A^\dagger) = \text{rang}(AA^\dagger) = \text{rang}(A^\dagger A)$
- 5 Ako matrica $A \in \mathbb{C}^{m \times n}$ ima rang n , tada je

$$A^\dagger = (A^* A)^{-1} A^* \quad \text{i} \quad A^\dagger A = I_n.$$

- 6 Ako matrica $A \in \mathbb{C}^{m \times n}$ ima rang m , tada je

$$A^\dagger = A^*(AA^*)^{-1} \quad \text{i} \quad AA^\dagger = I_m.$$

- 7 Ako je $A = FG$ i $\text{rang}(A) = \text{rang}(F) = \text{rang}(G)$, tada je

$$A^\dagger = G^\dagger F^\dagger.$$

- 8 Ako su U i V unitarne matrice, tada je

$$(UAV)^\dagger = V^* A^\dagger U^*.$$

- Dakle, kod problema najmanjih kvadrata za $m \geq n$, $r = \text{rang}(A) \leq n$, i za

$$V = [V_1 \quad V_2], \quad \Sigma = \begin{bmatrix} \Sigma_+ & 0 \\ 0 & 0 \end{bmatrix}, \quad U = [U_1 \quad U_2],$$

pri čemu su $U \in \mathbb{R}^{m \times m}$ i $U_1 \in \mathbb{R}^{m \times r}$, $\Sigma \in \mathbb{R}^{m \times n}$ i $\Sigma_+ \in \mathbb{R}^{r \times r}$, $V \in \mathbb{R}^{n \times n}$ i $V_1 \in \mathbb{R}^{n \times r}$, bez obzira da li je matrica punog ranga ili nije, rješenje glasi

$$\begin{aligned} x &= V_1 \Sigma_+^{-1} U_1^T b = [V_1 \quad V_2] \begin{bmatrix} \Sigma_+^{-1} & 0 \\ 0 & 0 \end{bmatrix} [U_1 \quad U_2]^T b \\ &= V \begin{bmatrix} \Sigma_+^{-1} & 0 \\ 0 & 0 \end{bmatrix} U^T b = A^\dagger b \end{aligned}$$

- U slučaju kada je matrica kvadratna i regularna tada je $A^\dagger = A^{-1}$, pa je rješenje problema najmanjih kvadrata $x = A^{-1}b$ ujedno i rješenje sustava linearnih jednadžbi $Ax = b$.

- Za matricu A punog stupčanog ranga, za rješenje najmanjih kvadrata x i za aproksimaciju rješenja y vrijedi sljedeća ocjena:

$$\begin{aligned} \frac{\|y - x\|_2}{\|x\|_2} &= \frac{\|A^\dagger A(y - x)\|_2}{\|x\|_2} \cdot \frac{\|A\|_2}{\|A\|_2} \leq \|A\|_2 \|A^\dagger\|_2 \frac{\|Ay - Ax\|_2}{\|A\|_2 \|x\|_2} \\ &\leq \kappa(A) \frac{\|Ay - Ax\|_2}{\|Ax\|_2} = \kappa(A) \frac{\|Ay - b + b - Ax\|_2}{\|Ax\|_2} \\ &= \kappa(A) \frac{\|r_y - r_x\|_2}{\|b + r_x\|_2} \end{aligned}$$

pri čemu je $\kappa(A) = \|A\|_2 \|A^\dagger\|_2$ broj uvjetovanosti, a $r_y = Ay - b$ i $r_x = Ax - b$ su reziduali kod kojih r_x ima minimalnu normu.

- To znači da relativna norma greška rješenja ovisi o broju uvjetovanosti matrice A i o razlici između reziduala.

- Numeričke metode za rješavanje problema najmanjih kvadrata primijenjene na loše uvjetovane matrice mogu dati vrlo netočne aproksimacije rješenja.
- Specijalno za sustave linearnih jednadžbi je $r_x = 0$, pa imamo

$$\frac{\|y - x\|_2}{\|x\|_2} \leq \kappa(A) \frac{\|r_y\|_2}{\|b\|_2},$$

gdje na desnoj strani imamo broj uvjetovanosti matrice A i relativnu normu reziduala.

- To znači da kada zaustavimo iterativnu metodu za rješavanje sustava linearnih jednadžbi u iteraciji u kojoj je postignuta mala relativna norma reziduala, ako je matrica loše uvjetovana relativna norma greške ne mora biti mala i možemo imati netočnu aproksimaciju rješenja.

Zadaci

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Rješavanje sustava normalnih jednadžbi

Transformacija u linearni sustav većih dimenzija

Rješavanje problema najmanjih kvadrata pomoću QR faktorizacije

Zadaci

Rješavanje problema najmanjih kvadrata pomoću SVD-a

Zadaci

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih

Zadatak

Riješite problem najmanjih kvadrata iz primjera sa početka poglavlja. Opažanja povrata j -te vrijednosnice i tržišnog portfelja u vremenskim instancama dana su u datoteci

`primjer_regresija_vrijednosnice.mat`

na adresi

<http://www.math.hr/~nela/nmf.html>

Vaš zadatak je:

- 1** *generirati matricu A i vektor b u problemu najmanjih kvadrata,*
- 2** *izračunati SVD faktorizaciju matrice A pomoću MATLAB-ove funkcije `svd()`,*

Zadatak (nastavak)

- 3 *izračunati rješenje problema najmanjih kvadrata*
 $[\tilde{\beta}_0 \quad \tilde{\beta}_1]^T$,
- 4 *nacrtati graf sa prikazanim točkama opažanja*
 $(R_{T,t}, R_{j,t})$ *i pravcem* $R_{j,t} = \tilde{\beta}_0 + \tilde{\beta}_1 R_{T,t}$, *sa pravilno*
označenim osima.

Problem određivanja numeričkog ranga

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Generalizirani problem najmanjih kvadrata

- Vidjeli smo da je kod rješavanja problema najmanjih kvadrata važno da li matrica A ima puni stupčani rang ili nema.
- U egzaktnoj aritmetici to je lako odrediti:
 - kod QR faktorizacije ako se pojavljuje 0 na dijagonali matrice R ona nije regularna, pa nije regularna niti matrica A ,
 - kod SVD-a ako postoje singularne vrijednosti jednake 0 matrica A nije regularna.
- U aritmetici konačne preciznosti taj problem nije tako jednostavan: što znači da je neki broj jednak 0?
- Ako 0 mora biti rezultat neke računске operacije, onda ćemo umjesto nje vrlo često dobiti neki vrlo mali broj koji je rezultat grešaka zaokruživanja i grešaka računskih operacija.

- U toj situaciji teško je odrediti da li je taj vrlo mali broj rezultat operacije koja je u egzaktnoj aritmetici zaista i trebala dati vrlo mali broj, ili operacije koja je trebala dati 0.

Primjer

$$f(1.0000000000000001 - 1) = 1.1102e - 015$$

$$f(1.0000000000000001 - 1 - 1e - 16) = - 1.0000e - 016$$

- Vrlo često je kod numeričkog rješavanja nekog problema i svejedno na koji način smo dobili taj mali broj:
 - on će stvarati problema kao da je zaista jednak 0.

- Konkretno, u slučaju određivanja numeričkog ranga, ukoliko izračunamo singularnu vrijednost matrice A koja je npr. reda 10^{-16} , iako je matrica čak i trebala biti punog ranga, točnije rješenje ćemo dobiti ako problem rješavamo kao da matrica nije punog ranga.
- Sličan problem je i kod QR faktorizacije: pivotiranje se uvodi da bi se lakše numerički mogli odrediti oni elementi na dijagonali matrice R koje možemo poistovjetiti sa 0 (zbog padajućih apsolutnih vrijednosti dijagonalnih elemenata).
 - Zbog toga, kada na dijagonali dobijemo dovoljno mali broj, bez obzira trebao li on biti u egzaktnoj aritmetici jednak 0 ili ne, cijeli donji dijagonalni blok matrice R poistovijećujemo s 0.

Primjer

- *Zbog grešaka zaokruživanja, umjesto pravog R , izračunamo*

$$R' = \begin{bmatrix} R_{11} & R_{12} \\ 0 & R_{22} \\ 0 & 0 \end{bmatrix}.$$

- *Naravno, željeli bismo da je $\|R_{22}\|_2$ vrlo mala, reda veličine $\varepsilon\|A\|_2$, pa da je možemo “zaboraviti”, tj. staviti $R_{22} = 0$ i tako odrediti numerički rang od A .*
- *Nažalost, to nije uvijek tako. Na primjer, bidiagonalna matrica*

$$A = \begin{bmatrix} \frac{1}{2} & 1 & & & \\ & \ddots & \ddots & & \\ & & \ddots & \ddots & \\ & & & \ddots & 1 \\ & & & & \frac{1}{2} \end{bmatrix}$$

Primjer

je skoro singularna ($\det(A) = 2^{-n}$), njena QR faktorizacija je $Q = I$, $R = A$, i nema niti jednog R_{22} koji bi bio po normi malen.

- *Zbog toga koristimo pivotiranje, koje R_{11} pokušava držati što bolje uvjetovanim, a R_{22} po normi što manjim.*

Zadatak

U MATLAB-u generirajte bidijagonalnu matricu iz prethodnog primjera reda 100.

- *Izračunajte njenu QR faktorizaciju s pivotiranjem, i provjerite dijagonalne elemente matrice R .*
- *Izračunajte njen SVD, i provjerite njene singularne vrijednosti.*

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata

Primjer

U datoteci

`primjer_osjetljivosti_pnk_Ax.mat`

na adresi

<http://www.math.hr/~nela/nmfm.html>

spremljeni su matrica A i vektor \bar{x} .

- *Izračunajmo najprije SVD matrice A i provjerimo da li je ona punog ranga.*
- *Vidimo da je matrica A punog ranga i da je njena uvjetovanost velika: $\kappa(A) = 2.924 \cdot 10^9$.*

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

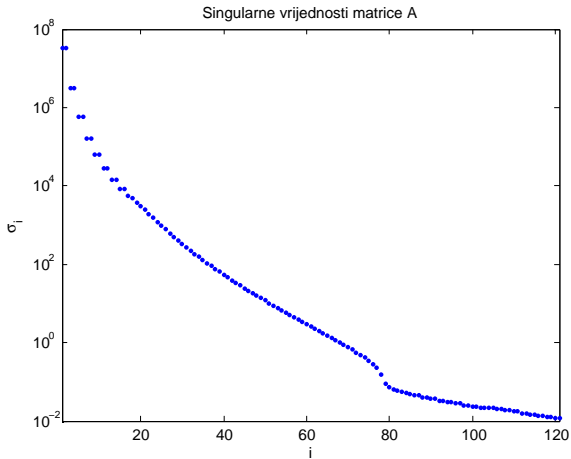
Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Primjer (nastavak)

- *Izračunajte $\bar{b} = A \cdot \bar{x}$, pri čemu treba ispasti da je $\bar{b} = [10000 \quad \dots \quad 10000]^T$.*
- *U ovom slučaju \bar{x} je egzaktno rješenje problema najmanjih kvadrata $\min \|Ax - \bar{b}\|_2$.*
- *Sada ćemo malo pokvariti vektor \bar{b} i vidjeti kako to utječe na rješenje problema najmanjih kvadrata.*
- *Izračunajmo*

$$b = \bar{b} + \eta,$$

gdje su elementi od η slučajni brojevi iz normalne distribucije.

- *Ovime se elementi od \bar{b} i b poklapaju u prve 4 vodeće znamenke, a u 5. znamenci se u prosjeku pojavljuje greška.*

Primjer (nastavak)

- *Riješimo sada problem najmanjih kvadrata $\min \|Ax - b\|_2$ pomoću SVD-a, i usporedimo ga sa \bar{x} .*
- *Rješenje ćemo označiti sa x_{nk} .*
- *Najprije ćemo provjeriti norme reziduala:*

$$\|A\bar{x} - \bar{b}\|_2 = 0$$

$$\|Ax_{nk} - b\|_2 \approx 4.7955$$

- *Dalje, provjerimo normu razlike $x_{nk} - \bar{x}$:*

$$\|x_{nk} - \bar{x}\|_2 \approx 224.1275.$$

- *Dakle, možemo zaključiti da smo dobili minimalnu normu reziduala, ali greška je ogromna.*

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i rješenje najmanjih kvadrata.

- U prethodnom primjeru imali smo loše uvjetovanu matricu, čija je najmanja svojstvena vrijednost

$$\sigma_{min} = 1.1610 \cdot 10^{-2} < 10^{-9} \cdot \|A\|_2$$

što je izgleda “dovoljno mala vrijednost” da utječe na numerički rang.

- Efekt toga je činjenica da smo malo pokvarili vektor b , a dobili smo totalno drugačije i oscilirajuće rješenje, daleko od očekivanog.
- Razmotrit ćemo sada dvije tehnike koje se koriste za stabiliziranje jako oscilirajućih rješenja.

Regularizacija

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Kirna dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata

- Najčešće korištena metoda za stabiliziranje oscilirajućih rješenja problema najmanjih kvadrata je uvođenje uvjeta na rješenje x oblika

$$\|Q(x - x_0)\|_2^2 \leq \beta^2.$$

Ovdje su

- x_0 opcionalna inicijalna aproksimacija od \bar{x} ,
 - Q je matična reprezentacija linearnog operatora uvjeta,
 - β^2 je konstanta koja određuje jačinu uvjeta.
- Aproksimacija x_λ dobiva se rješavanjem problema

$$\min_x \left(\|b - Ax\|_2^2 + \lambda \|Q(x - x_0)\|_2^2 \right),$$

gdje je parametar λ Lagrangeov multiplikator čija vrijednost ovisi o β^2 .

- Rješenje je oblika

$$x_\lambda = (A^T A + \lambda^2 Q^T Q)^{-1} (A^T b + \lambda^2 Q^T Q x_0).$$

- Uspjeh regularizacije ovisi o izboru parametra λ , a za to postoji nekoliko načina.
- Najčešći izbor za Q je identiteta $I_n \in \mathbb{R}^{n \times n}$.
- U tom slučaju problem se može izraziti kao prošireni problem

$$\begin{bmatrix} b \\ \lambda x_0 \end{bmatrix} = \begin{bmatrix} A \\ \lambda I_n \end{bmatrix} \bar{x} + \begin{bmatrix} \eta \\ \lambda \gamma \end{bmatrix},$$

sa

$$\begin{bmatrix} \eta \\ \gamma \end{bmatrix} \sim N(0, I_{m+n}).$$

- Parametar λ postaje težinska konstanta koja bi trebala biti dovoljno velika da priguši oscilacije aproksimativnog rješenja x_λ tako da ga drži blizu x_0 , a s druge strane dovoljno mala da ne prouzroči preveliki rast kvadrata norme $\|Ax_\lambda - b\|_2^2$.

Primjer

- *Sada ćemo primijeniti regularizaciju na naš primjer.*
- *Ako ne znamo kakvog nam je oblika rješenje najbolje je uzeti $x_0 = 0$.*
- *Najčešći način za odabir optimalnog parametra λ bazira se na L krivulji.*
- *Koordinate točaka na L krivulji predstavljaju $\log_{10} \|x_\lambda\|_2$ i $\log_{10} \|Ax_\lambda - b\|_2$ za rješenje problema x_λ pomoću regularizacije s parametrom λ .*
- *Odabire se ona vrijednost λ za koju je $\|x_\lambda\|_2$ ograničen na najbolji mogući način, dok istovremeno $\|Ax_\lambda - b\|_2$ nije prevelik.*
- *Takav λ odgovara točki u uglu L krivulje.*
- *Za naš primjer optimalni λ je $\lambda_{opt} = 0.748$.*

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: L krivulja za $0.1 \leq \lambda \leq 100$ sa točkama koje odgovaraju λ_{opt} i λ_{naj} .

Primjer (nastavak)

- Dakle, rješavamo problem najmanjih kvadrata $\min_x \|\mathbf{Ax} - \mathbf{b}\|_2$, gdje su

$$\mathbf{A} = \begin{bmatrix} \mathbf{A} \\ \lambda_{opt} \mathbf{I}_n \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} \mathbf{b} \\ \lambda_{opt} \mathbf{x}_0 \end{bmatrix},$$

koristeći SVD.

- Za rješenje $x_{\lambda_{opt}}$ ovog problema provjerit ćemo normu reziduala:

$$\|\mathbf{Ax}_{\lambda_{opt}} - \mathbf{b}\|_2 \approx 7.3050.$$

- S druge strane je norma razlike $x_{\lambda_{opt}} - \bar{x}$:

$$\|x_{\lambda_{opt}} - \bar{x}\|_2 \approx 2.2425.$$

- Dakle, norma reziduala je malo narasla, ali greška je puno bolja nego kod rješenja najmanjih kvadrata.

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i rješenje regularizacije za λ_{opt} .

Primjer (nastavak)

- *Nekim statističkim metodama može se pokazati da aproksimaciju s najboljom greškom možemo dobiti za $\lambda_{naj} = 77.5$.*
- *Zato ćemo na kraju riješiti problem najmanjih kvadrata $\min_x \|\mathbf{Ax} - \mathbf{b}\|_2$, za*

$$\mathbf{A} = \begin{bmatrix} \mathbf{A} \\ \lambda_{naj} \mathbf{I}_n \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} \mathbf{b} \\ \lambda_{naj} \mathbf{x}_0 \end{bmatrix},$$

koristeći SVD.

- *Za rješenje $x_{\lambda_{naj}}$ ovog problema opet ćemo provjeriti normu reziduala:*

$$\|\mathbf{Ax}_{\lambda_{naj}} - \mathbf{b}\|_2 \approx 20.1267.$$

Primjer (nastavak)

- *S druge strane je norma razlike $x_{\lambda_{naj}} - \bar{x}$:*

$$\|x_{\lambda_{naj}} - \bar{x}\|_2 \approx 0.0221.$$

- *U ovom slučaju norma reziduala je još malo narasla, ali greška je prihvatljivo mala.*

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i rješenje regularizacije za λ_{naj} .

Krnja dekompozicija singularnih vrijednosti (TSVD)

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata

- Za rješavanje loše uvjetovanih problema često se koristi krnja dekompozicija singularnih vrijednosti (TSVD), koja koristi aproksimaciju ranga $p < r = \text{rang}(A)$.
- Ako je $A = U\Sigma V^T$ SVD matrice A , tada je prema jednom teoremu za SVD

$$A_p = \sum_{i=1}^p \sigma_i u_i v_i^T,$$

najbolja aproksimacija ranga p matrice A .

- Za $m \geq n$, neka su matrice $U \in \mathbb{R}^{m \times m}$, $V \in \mathbb{R}^{n \times n}$ i $\Sigma \in \mathbb{R}^{m \times n}$ particionirane na sljedeći način

$$U = \begin{bmatrix} U_1 & U_2 & U_3 \\ p & n-p & m-n \end{bmatrix} \quad V = \begin{bmatrix} V_1 & V_2 \\ p & n-p \end{bmatrix} \quad \Sigma = \begin{bmatrix} \Sigma_1 & 0 \\ 0 & \Sigma_2 \\ 0 & 0 \\ p & n-p \end{bmatrix} \begin{matrix} p \\ n-p \\ m-n \end{matrix}$$

gdje je $\sigma_p > \zeta \sigma_1$ i $\sigma_{p+1} < \zeta \sigma_1$ za neku toleranciju ζ .

- Tada je

$$A_p = U_1 \Sigma_1 V_1^T = U(:, 1 : p) \Sigma(1 : p, 1 : p) V(:, 1 : p)^T.$$

- Rješavanje problema najmanjih kvadrata svodi se na minimizaciju $\|r_{svd}\|_2^2 = \|A\bar{x} - b\|_2^2$, gdje je

$$\|r_{svd}\|_2^2 = \|\Sigma_1 V_1^T \bar{x} - U_1^T b\|_2^2 + \|\Sigma_2 V_2^T \bar{x} - U_2^T b\|_2^2 + \|U_3^T b\|_2^2,$$

što je ekvivalentno minimizaciji prva dva izraza u gornjoj jednadžbi.

- TSVD postavlja $\sigma_i = 0$ za $i = p + 1, \dots, n$ i minimizira samo prvi izraz.
- To je ekvivalentno rješavanju problema najmanjih kvadrata za matricu A_p

$$\min \|r_{tsvd}\|_2^2 = \min(\|\Sigma_1 V_1^T \bar{x} - U_1^T b\|_2^2 + \|U_2^T b\|_2^2 + \|U_3^T b\|_2^2).$$

- Važno je odabrati pogodnu toleranciju ζ ili rang p , tako da norma reziduala i norma rješenja budu male.

- Rješenje pomoću TSVD je tada oblika

$$x_{tsvd} = \sum_{i=1}^p \frac{u_i^T b}{\sigma_i} v_i = V(:, 1 : p) \Sigma(1 : p, 1 : p)^{-1} U(:, 1 : p)^T b.$$

Primjer

- Sada ćemo primijeniti TSVD ponovo na naš primjer.
- Prvo ponovo trebamo pogledati singularne vrijednosti matrice A , i uočiti indekse u kojima singularne vrijednosti padnu za jedan red veličine.

i	1-2	3-4	5-8	9-14	15-24
$\sigma_i \approx$	10^7	10^6	10^5	10^4	10^3

i	25-36	37-51	52-68	69-78	79-121
$\sigma_i \approx$	10^2	10^1	10^0	10^{-1}	10^{-2}

- Dalje ćemo birati TSVD aproksimacije za $p = 2, 4, 8, 14, 24, 36, 51, 68, 78, 121$, i označiti ih sa x_p .
- Za aproksimacije x_2, x_4, x_8 i x_{14} , odgovarajući rang je ipak premali.

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija


Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i TSVD rješenje za $p = 14$:

$$\|Ax_{14} - b\|_2 \approx 76515, \|x_{14} - \bar{x}\|_2 \approx 12.9085.$$



Slika: Egzaktno rješenje i TSVD rješenje za $p = 24$:

$$\|Ax_{24} - b\|_2 \approx 636.9091, \|x_{24} - \bar{x}\|_2 \approx 0.7172.$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i TSVD rješenje za $p = 36$:

$$\|Ax_{36} - b\|_2 \approx 9.7512, \|x_{36} - \bar{x}\|_2 \approx 0.0144.$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i TSVD rješenje za $p = 51$:

$$\|Ax_{51} - b\|_2 \approx 8.6826, \|x_{51} - \bar{x}\|_2 \approx 0.1774.$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i TSVD rješenje za $p = 68$:

$$\|Ax_{68} - b\|_2 \approx 7.5599, \|x_{68} - \bar{x}\|_2 \approx 1.8108.$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i TSVD rješenje za $p = 78$:

$$\|Ax_{78} - b\|_2 \approx 7.0118, \|x_{78} - \bar{x}\|_2 \approx 8.5269.$$

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata


Problem određivanja numeričkog ranga

Osjetljivost numeričkog rješenja problema najmanjih kvadrata

Regularizacija

Krnja dekompozicija singularnih vrijednosti

Generalizirani problem najmanjih kvadrata



Slika: Egzaktno rješenje i TSVD rješenje za $p = 121 = r$:
 $\|Ax_{121} - b\|_2 \approx 4.7955$, $\|x_{121} - \bar{x}\|_2 \approx 224.1275$.

Primjer (nastavak)

- *Možemo zaključiti da je najbolja aproksimacija postignuta za $p = 36$, i ona je čak i bolja od aproksimacije dobivene regularizacijom za λ_{naj} .*
- *Dakle, singularne vrijednosti matrice A manje od 10^2 možemo zanemariti i izjednačiti sa nulom:*

$$\sigma_i \leq 2.6365 \cdot 10^{-6} \sigma_1, \quad i = 37, \dots, 121,$$

i pri tome dobiti prilično zadovoljavajuću aproksimaciju rješenja.

- *To znači da singularni vektori vodećih singularnih vrijednosti koji formiraju matricu*

$A_{36} = U(:, 1 : 36)\Sigma(1 : 36, 1 : 36)V(:, 1 : 36)^T$ sadržavaju dovoljno informacija za rekonstrukciju matrice A ,

Primjer (nastavak)

$$\|A - A_{36}\|_2 = \sigma_{37} = 89.5076 \leq 2.6365 \cdot 10^{-6} \|A\|_2,$$

a pri tome je A_{36} bolje uvjetovana matrica od A

$$\kappa(A_{36}) = 3.1907 \cdot 10^5.$$

Generalizirani problem najmanjih kvadrata

Problem najmanjih kvadrata

Nela Bosner

Problem najmanjih kvadrata

Regresija

Opis linearnog problema najmanjih kvadrata

Numeričko rješavanje problema najmanjih kvadrata

Problem određivanja numeričkog ranga

Osetljivost numeričkog rješenja problema najmanjih kvadrata

Generalizirani problem najmanjih kvadrata

- Kod linearne regresije koja povezuje Y i X_1, \dots, X_n

$$Y_i = \beta_1 X_{i,1} + \dots + \beta_n X_{i,n} + \epsilon_i,$$

pretpostavili smo da je

$$\text{Cov}(\epsilon_1, \dots, \epsilon_m) = \sigma_\epsilon^2 I_m.$$

- U slučaju kada $\text{Cov}(\epsilon_1, \dots, \epsilon_m)$ nije gornjeg oblika, a kada je ta matrica poznata do na skalirajući faktor

$$\text{Cov}(\epsilon_1, \dots, \epsilon_m) = \sigma^2 \mathbf{G},$$

tada rješavamo sustav normalnih jednačbi

generaliziranog problema najmanjih kvadrata

$$(\mathbf{X}^T \mathbf{G}^{-1} \mathbf{X}) \mathbf{b} = \mathbf{X}^T \mathbf{G}^{-1} \mathbf{y}.$$

- Zbog toga se cijeli problem mora preformulirati u problem regresije sa matricom $\mathbf{G}^{-1/2} \mathbf{X}$ i vektorom $\mathbf{G}^{-1/2} \mathbf{y}$, gdje je $\mathbf{G}^{1/2}$ Choleski faktor matrice \mathbf{G} .