

NLA: prva domača naloga

Rok oddaje: 3. maj 2017

Na spletno učilnico oddajte `.zip` arhiv (ali kaj podobnega), ki vsebuje vse datoteke (skripta in slike), s katerimi ste prišli do rezultatov, rezultate in poročilo, v katerem jih opišete.

Metode, ki jih implementirate, naj bodo zapisane v skriptih kot funkcije z ustreznimi argumenti. Poleg tega dodajte še skripta, v katerih te metode uporabite na konkretnih podatkih (oglej si primer DN na učilnici).

Sledi opis ozadja problema, ki ga rešujemo. Nato pokažemo, kako določene stvari izvedemo v Matlabu. Zaključimo z opisom nalog.

Ozadje problema

Ukvarjali se bomo z ostrenjem slike $\hat{B}$, ki je zaradi atmosferskih motenj ter dodatnega naključnega šuma zamegljena podoba prave slike X . Atmosferskim motnjam ustreza t. i. Gaussova zameglitev. Izberemo jo zato, ker lahko v tem primeru končno zameglitev razcepimo na zameglitev po stolpcih in vrsticah. Ko si izberemo matriko zameglitve A , lahko torej najdemo taki matriki A_c in A_r , da velja

$$A \operatorname{vec}(X) = \operatorname{vec}(A_c X A_r^T). \quad (1)$$

Tehnično podrobnost, zaradi katere smo izbrali A_r namesto A_r^T , bomo kmalu pojasnili. Ker matriki $X \in \mathbb{R}^{m \times n}$ s stolpci x_i pripada vektor

$$\operatorname{vec}(X) = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \in \mathbb{R}^{mn},$$

je matrika zamegljevanja $A \in \mathbb{R}^{mn \times mn}$ lahko zelo velika: za sliko velikosti 500×500 dobimo matriko A velikosti 250000×250000 , kar onemogoči direktno računanje z njo.

Rezultat zamegljevanja je matrika $B = A_c X A_r^T$. Dodali ji bomo še nekaj šuma, tako da izberemo parameter σ in definiramo

$$\hat{B} = B + E,$$

kjer so elementi matrike E realizacije neodvisnih slučajnih spremenljivk, porazdeljenih kot $N(0, \sigma)$. Poskrbite, da se ob zagonu ustrezne `.m` datoteke vedno zgenerirala ista matrika E (to omogoča preverljivost rezultatov in olajša odkrivanje hroščev v kodi). Pri tem vam lahko koristi funkcija `rng`.

Zaradi dodanega šuma naivna rešitev

$$\hat{X} = A_c^{-1} \hat{B} A_r^{-T} = A_c^{-1} (B + E) A_r^{-T} = X + A_c^{-1} E A_r^{-T} \quad (2)$$

ni dobra. Če najdemo singularna razcepa

$$A_c = U_c \Sigma_c V_c^T = [u_{c,1} \ \cdots \ u_{c,m}] \text{diag}(\sigma_{c,1}, \dots, \sigma_{c,m}) [v_{c,1} \ \cdots \ v_{c,m}]^T$$

in

$$A_r = U_r \Sigma_r V_r^T = [u_{r,1} \ \cdots \ u_{r,n}] \text{diag}(\sigma_{r,1}, \dots, \sigma_{r,n}) [v_{r,1} \ \cdots \ v_{r,n}]^T,$$

potem lahko (2) zapišemo kot

$$\begin{aligned} \hat{X} &= \left(\sum_{i=1}^m \frac{1}{\sigma_{c,i}} v_{c,i} u_{c,i}^T \right) \hat{B} \left(\sum_{j=1}^n \frac{1}{\sigma_{r,j}} u_{r,j} v_{r,j}^T \right) \\ &= \sum_{i=1}^m \sum_{j=1}^n \underbrace{\frac{u_{c,i}^T \hat{B} u_{r,j}}{\sigma_{c,i} \sigma_{r,j}}}_{\hat{\beta}_{ij}} \underbrace{v_{c,i} v_{r,j}^T}_{V_{ij}}. \end{aligned}$$

Lahko je preveriti, da iz ortogonalnosti V_c in V_r sledi $\|V_{ij}\|_F = 1$, zato koeficienti $\hat{\beta}_{ij}$ ne smejo biti preveliki. Ker je $\hat{B} = B + E$, lahko koeficient $\hat{\beta}_{ij}$ zapišemo kot vsoto $\hat{\beta}_{ij} = \beta_{ij} + \varepsilon_{ij}$, kjer je

$$\beta_{ij} = \frac{u_{c,i}^T B u_{r,j}}{\sigma_{c,i} \sigma_{r,j}} \quad \text{in} \quad \varepsilon_{ij} = \frac{u_{c,i}^T E u_{r,j}}{\sigma_{c,i} \sigma_{r,j}}.$$

Ker so lahko produkti $\sigma_{c,i} \sigma_{r,j}$ zelo majhni, hkrati pa se zaradi naključnosti šuma vrednost $|u_{c,i}^T E u_{r,j}|$ ne spreminja močno z i in j , lahko dobimo pri naivnem reševanju povsem zmoteno rešitev. Zato - podobno kot smo to storili pri regularizaciji rešitve $Ax = b$ v vektorskem primeru - vpeljemo faktorje regularizacije ϕ_{ij} in raje zapišemo

$$\hat{X} = \sum_{i=1}^m \sum_{j=1}^n \phi_{ij} \hat{\beta}_{ij} V_{ij}. \quad (3)$$

Za to, da postopamo analogno kot v vektorskem primeru, imamo torej dobro praktično motivacijo, vendar je vse tudi teoretično utemeljeno. Izkaže se, da za matriko zamegljevanja A in njena faktorja A_c ter A_r velja zveza

$$A = A_r \otimes A_c,$$

kjer je Kroneckerjev produkt $\otimes$ med splošnima matrikama $C \in \mathbb{R}^{m \times n}$ in $D \in \mathbb{R}^{p \times q}$ definiran kot

$$C \otimes D = \begin{bmatrix} c_{11}D & \cdots & c_{1n}D \\ \vdots & & \vdots \\ c_{m1}D & \cdots & c_{mn}D \end{bmatrix}.$$

Z neposrednim računom se da hitro prepričati, da je $\otimes$ povezan s standardnimi matričnimi operacijami preko naslednjih zvez:

- a) $(A \otimes B)\text{vec}(X) = \text{vec}(BXA^T)$,
- b) $(A_1 \otimes B_1)(A_2 \otimes B_2) = (A_1A_2) \otimes (B_1B_2)$,
- c) $(A \otimes B)^T = A^T \otimes B^T$,
- d) $(A \otimes B)^{-1} = A^{-1} \otimes B^{-1}$.

Zveza a) nam omogoča računanje z matriko zameglitve A , če poznamo njena faktorja A_c in A_r . Tiho smo jo uporabili že pri (1) in sedaj je tudi jasno, zakaj dobimo na desni A_r^T . Iz zvez b) in c) lahko izpeljemo

$$(U_r \Sigma_r V_r^T) \otimes (U_c \Sigma_c V_c^T) = (U_r \otimes U_c)(\Sigma_r \otimes \Sigma_c)(V_r \otimes V_c)^T.$$

Lahko se je prepričati, da je $A = (U_r \otimes U_c)(\Sigma_r \otimes \Sigma_c)(V_r \otimes V_c)^T$ singularni razcep matrike A , vendar moramo paziti, saj diagonalni elementi σ_{ij} v matriki $\Sigma_r \otimes \Sigma_c$, ki so produkti singularnih vrednosti A_r in A_c , **niso** urejeni po velikosti. S pomočjo zveze d) pridemo do (izpeljave) rešitve (3).

0.1 Filtri regularizacije

Neurejenost singularnih vrednosti σ_{ij} pri regularizaciji Tihonova ne pride do izraza, še vedno definiramo filtre kot

$$\phi_{ij} = \frac{\sigma_{ij}^2}{\sigma_{ij}^2 + \alpha^2}$$

za neko izbrano vrednost parametra α .

Tudi pri odrezanem singularnem razcepu neurejenosti ni težko zaobiti. Namesto indeksa k , od koder naprej so v standardnem primeru vsi filtri enaki 0, postavimo ekvivalenten pogoj

$$\phi_{ij} = \begin{cases} 1 & ; \quad \sigma_{ij} \geq t \\ 0 & ; \quad \text{sicer} \end{cases} \quad (4)$$

pri izbrani vrednosti parametra t .

0.2 Delo z Matlabom

Oglejmo si nekatere uporabne funkcije za delo s slikami ter nekatere druge, ki nam bodo koristile.

0.2.1 Branje in shranjevanje slik


Slike so predstavljene kot matrice. Če v A shranimo matriko

$$\begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 8 & 8 & 0 & 0 & 0 & 0 & 4 & 4 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 8 & 8 & 0 & 0 & 0 & 0 & 4 & 4 & 0 & 3 & 3 & 3 & 3 & 3 & 0 \\ 0 & 8 & 8 & 0 & 0 & 0 & 0 & 4 & 4 & 0 & 3 & 3 & 3 & 3 & 3 & 0 \\ 0 & 8 & 8 & 0 & 0 & 0 & 0 & 4 & 4 & 0 & 3 & 3 & 3 & 3 & 3 & 0 \\ 0 & 8 & 8 & 0 & 0 & 0 & 0 & 4 & 4 & 0 & 3 & 3 & 3 & 3 & 3 & 0 \\ 0 & 8 & 8 & 8 & 8 & 8 & 0 & 4 & 4 & 0 & 3 & 3 & 3 & 3 & 3 & 0 \\ 0 & 8 & 8 & 8 & 8 & 8 & 0 & 4 & 4 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix},$$

v Matlabu z ukazi


```
imagesc(A), axis image, colormap(gray)
```

dobimo




Na podoben način so barvne slike predstavljene s tridimenzionalnimi matrikami.

$$R = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 8 & 8 & 8 & 8 & 8 & 0 & 0 \\ 0 & 6 & 6 & 6 & 6 & 6 & 6 & 0 \\ 0 & 4 & 4 & 4 & 4 & 4 & 4 & 0 \\ 0 & 2 & 2 & 2 & 2 & 2 & 2 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \quad G = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 8 & 8 & 8 & 8 & 0 \\ 0 & 0 & 0 & 6 & 6 & 6 & 6 & 0 \\ 0 & 0 & 0 & 4 & 4 & 4 & 4 & 0 \\ 0 & 0 & 0 & 4 & 4 & 4 & 4 & 0 \\ 0 & 0 & 0 & 6 & 6 & 6 & 6 & 0 \\ 0 & 0 & 0 & 8 & 8 & 8 & 8 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}, \quad B = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 8 & 8 & 8 & 8 & 0 & 0 & 0 \\ 0 & 6 & 6 & 6 & 6 & 0 & 0 & 0 \\ 0 & 4 & 4 & 4 & 4 & 0 & 0 & 0 \\ 0 & 4 & 4 & 4 & 4 & 0 & 0 & 0 \\ 0 & 6 & 6 & 6 & 6 & 0 & 0 & 0 \\ 0 & 8 & 8 & 8 & 8 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$



```
X(:,:,1)=R/8; X(:,:,2)=G/8; X(:,:,3)=B/8; imagesc(X)
```



Zunanje slike preberemo v Matlabu s pomočjo ukaza `imread`. Tako npr. z

```
A = imread('butterflies.tif');
imagesc(A)
axis image
```

v Matlabu dobimo tridimenzionalno matriko $A \in \mathbb{R}^{474 \times 852 \times 3}$, ki predstavlja sliko



Če smo prebrali črno-belo sliko, uporabimo še ukaz `colormap gray`, da bo narisana slika res črno-bela (ukaz spremeni zgolj prikaz slike in ne slike same).

Za pretvorbo barvne slike A v črno-belo uporabimo klic `rgb2gray(A)`. Če ni na voljo, potem lahko uporabimo ukaz

```
CB = 0.2989 * A(:,:,1) + 0.5870 * A(:,:,2) + 0.1140 * A(:,:,3);
```

(glej dokumentacijo za `rgb2gray`). Tipično so števila a_{ij} v matriki A tipa `int` in zavzemajo vrednosti $0 \leq a_{ij} \leq 255$. Če želimo sliki prišteti nekaj šuma, ki je po navadi realna matrika, in rezultat shraniti, lahko to storimo tako, da

- 1) pretvorimo števila a_{ij} v realna: ukaz `A = im2double(A)` opravi transformacijo $a_{ij} \mapsto a_{ij}/255$,
- 2) prištejemo šum $A = A + E$,
- 3) shranimo novo sliko z ukazom `imwrite(A, 'mojaNovaSlika.jpg')`.

Opazimo lahko, da bo ukaz `imread('mojaNovaSlika.jpg')` vseeno vrnil matriko z elementi tipa `int`.

0.2.2 Paket HNO

Algoritmi za zameglitev slik v Matlabu so na voljo v paketu HNO, ki ga je pripravil Per Christian Hansen. Paket dobimo v datoteki HNO.zip, ki se nahaja na naslovu

<http://www.imm.dtu.dk/~pcha/HNO/>

Denimo, da imate sliko velikosti $m \times n$. Matriki A_r in A_c , na kateri razcepimo Gaussovo zameglitev, dobite v Matlabu z ukazi:

```
[PSF, center] = psfGauss([n,m],s);  
[Ar, Ac] = kronDecomp(PSF, center);
```

Tu je s parameter Gaussove zameglitve (večji ko je, bolj je slika zamegljena, normalna vrednost je npr. 2). Ukaz

```
imagesc(PSF)
```

prikaže, kako zameglitev, ki je podana z matriko PSF (point spread function), deluje na sliko, ki ima en sam bel piksel v sredini. Zameglitev potem na isti način razmaže vse piksele v sliki, ukaz `kronDecomp` pa iz PSF izračuna ustrezni matriki A_r in A_c .

Pomagate si lahko tudi z ukazoma `tsvd_sep` in `tik_sep`, katerih uporabo raziščite sami.

0.2.3 Razno

Singularni razcep dobimo z ukazom `[U, S, V] = svd(A)`. Če se želite poigrati z vektorizacijo matričnih enačb, sta koristna npr. `reshape`¹ (za funkcijo `vec`) in `kron` (za izračun $\otimes$).

Regularizirano rešitev $\hat{X}$ iz (3) lahko dobimo tako:

1) Izračunamo števila $\phi_{ij}\hat{\beta}_{ij}$ in jih shranimo v matriko M :

- izračunamo $W = \Sigma_c^{-1} U_c^T \hat{B} U_r \Sigma_r^{-1} \in \mathbb{R}^{m \times n}$: `W = Sc\Uc'*B*Ur/Sr`,
- izberemo filtre ϕ_{ij} in jih shranimo v matriko F ,
- izračunamo produkt po komponentah: `M = F .* W`,

2) Izračunamo še `Xreg = Vc * M * Vr'`.

¹V Octavu `vec`.

Za konec dodajmo še naslednje:

- Kubični polinomski zlepek razreda $\mathcal{C}^2(\mathbb{R})$ dobimo s pomočjo funkcije `spline`². Odvod polinoma lahko dobimo s `polyder`.
- Podatke iz datotek tipa `<ime>.mat` naložimo z ukazom `load <ime>.mat`.
- Ukaz `[urejen, indeksi] = sort(seznam)` vrne seznama `urejen` in `indeksi`, za katera velja

$$\text{urejen}(i) \leq \text{urejen}(i + 1) \quad \text{in} \quad \text{seznam}(\text{indeksi}) = \text{urejen},$$

kar bomo potrebovali pri nalogi 2 pri urejanju singularnih vrednosti σ_{ij} in izrisovanju števil $u_{c,i}^T \hat{B} u_{r,j}$ v skladu s to ureditvijo.

Osnovni opis naloge

Ukvarjali se bomo s tremi slikami: dvema, ki ju dobimo iz datotek `tabla.mat` in `skrivnost.mat`, ter eno, ki si jo izberete sami (naj bo ostra in primerne velikosti, lahko je črnobela). V `.mat` datotekah se poleg zamegljene črnobeke slike, ki je shranjena v spremenljivki `B`, nahajajo še matrike `Ac` in `Ar` ter PSF in `center`.

Pri opisu sledečih nalog bomo zapis nekoliko standardizirali ter iskanje začetne matrike X , ki predstavlja sliko, obravnavali kot reševanje enačbe $A\mathbf{x} = \mathbf{b}$, pri čemer je A naša matrika zamegljevanja in $\mathbf{b} = \hat{B}$.

V nalogah bomo na različne načine skušali priti do faktorjev filtra ϕ_i in rešitev zapisali kot

$$\mathbf{x} = \sum_i \phi_i \frac{u_i^T \mathbf{b}}{\sigma_i} v_i,$$

kjer vektorje v_i in u_i ter števila σ_i dobimo iz singularnega razcepa matrike A .

1 Regularizacija Tihonova

Začetno sliko bomo poiskali s pomočjo regularizacije Tihonova in poskušali najti optimalno vrednost $\alpha \geq 0$ za minimizacijski problem


$$\min_{\mathbf{x}} \|A\mathbf{x} - \mathbf{b}\|_2^2 + \alpha^2 \|\mathbf{x}\|_2^2. \quad (5)$$

²V Octavu `interp1` z dodatnim argumentom `'spline'`.

Vidimo, da gre pri gornjem problemu za iskanje ravnotežja med členoma $\eta(\mathbf{x}) = \|\mathbf{x}\|_2^2$ ter $\rho(\mathbf{x}) = \|A\mathbf{x} - \mathbf{b}\|_2^2$. Pri majhnih vrednostih α bo ρ majhen in η sorazmerno velik. Z večanjem vrednosti α pričakujemo rast ρ in padanje η . Če za vse $\alpha \in [0, \infty)$ izračunamo rešitev problema (5) in jo označimo z $\mathbf{x}(\alpha)$, potem dobimo t. i. L-krivuljo, podano s parametrizacijo

$$L(\alpha) = (\log \rho(\mathbf{x}(\alpha)), \log \eta(\mathbf{x}(\alpha))).$$

Ime je dobila po svoji značilni obliki, ki je razvidna s slike 1. Namesto ρ in η narišemo raje njuna logaritma, saj je sta tako repa bolj poudarjena in je lažje najti *točko preloma*, ki jo iščemo. Točka preloma bomo definirali kot točko,



Slika 1: L-krivulja (slika je simbolična)

v kateri ima $L(\alpha)$ največjo ukrivljenost $\kappa(\alpha)$. Vpeljimo oznaki

$$\hat{\rho} = \log \rho \quad \text{in} \quad \hat{\eta} = \log \eta,$$

pri čemer smo opustili pisanje argumenta α . Spomnimo se, da je

$$\kappa = \frac{|\hat{\rho}'\hat{\eta}'' - \hat{\rho}''\hat{\eta}'|}{\|(\hat{\rho}', \hat{\eta}')\|_2^3}. \quad (6)$$

Da bi lahko uporabili zgornjo formulo, moramo dokazati naslednji enakosti, v katerih smo vpeljali $\beta_i = u_i^T \mathbf{b}$.

$$\eta(\alpha) = \|\mathbf{x}(\alpha)\|_2^2 = \sum_i \frac{\sigma_i^2 \beta_i^2}{(\alpha^2 + \sigma_i^2)^2} \quad (7)$$

$$\rho(\alpha) = \|A\mathbf{x}(\alpha) - \mathbf{b}\|_2^2 = \|r_\perp\|_2^2 + \sum_i \frac{\alpha^4 \beta_i^2}{(\alpha^2 + \sigma_i^2)^2} \quad (8)$$

Vektor $r_\perp$ je definiran kot $r_\perp = \mathbf{b} - \sum_i \beta_i u_i$, tj. ostanek iz ortogonalnega komplementa podprostora, ki ga razpenjajo u_i , ki bi ga dobili pri metodi najmanjših kvadratov oz. pri $\alpha = 0$.

1.1 Predpriprava

Dokažite zvezi (7) in (8) in izračunajte (prve in druge) odvode, ki nastopajo v (6). Verjetno bo koristno, da izračun $\kappa(\alpha)$ shranite kot funkcijo v neko .m datoteko, saj bo to sestavni del vseh sledečih podnalog te naloge.

1.2 Neposreden izračun ukrivljenosti

Najdite točko $\alpha_{\max}$, v kateri je dosežena maksimalna ukrivljenost, tako da maksimizirate (6).

1.3 Približen izračun

V praksi se lahko zgodi, da je minimizacijski problem, ki ga rešujemo v (5), časovno zahteven, zato bi radi prišli do približka za $\alpha_{\max}$ z malo izračuni $r(\alpha)$. Možen algoritem je sledeč:

Algoritem 1 približni κ

- 1: izračunaj nekaj točk $L(\alpha_i)$ navpičnega dela L-krivulje, $1 \leq i \leq N_1$
 - 2: izračunaj nekaj točk $L(\alpha_i)$ vodoravnega dela L-krivulje, $N_1 < i \leq N$
 - 3: $S \leftarrow \{(\alpha_i, L(\alpha_i)) \mid 1 \leq i \leq N\}$
 - 4: **for** $k = 1, 2, \dots$ **do**
 - 5: $z_S \leftarrow$ kubični zlepek skozi točke iz S
 - 6: $\alpha_{\max}^k \leftarrow \alpha$, pri kateri ima krivulja, ki jo določa z_S , max ukrivljenost
 - 7: $\kappa_k = \kappa_{z_S}(\alpha_{\max}^k)$
 - 8: dodaj $(\alpha_{\max}^k, L(\alpha_{\max}^k))$ v S
 - 9: **end for**
-

Kubični zlepek z_S je torej oblike

$$z_S : \alpha \rightarrow (\bar{\rho}(\alpha), \bar{\eta}(\alpha)),$$

torej najdemo približek ločeno za $\hat{\rho}$ in $\hat{\eta}$. Naj bo dvakrat zvezno odvedljiv, saj je cilj izračunati približek za κ .

Zaustavitveni pogoj ter število izračunanih točk na začetku izberite sami. Lahko preizkusite različne možnosti. Pri izbiri izhajajte iz tega, da je izračun $L(\alpha)$ najdražja operacija v algoritmu.

2 Odrezani singularni razcep

Tu faktorje filtra ϕ_i definiramo kot

$$\phi_i = \mathbf{1}[i \leq K],$$


kjer je $\mathbf{1}$ indikatorska funkcija. Vemo, da je

$$\hat{\mathbf{x}} = A^{-1}\hat{\mathbf{b}} = A^{-1}\mathbf{b} + A^{-1}\mathbf{e} = \mathbf{x} + A^{-1}\mathbf{e},$$

kje je $\mathbf{e}$ vektor šuma in $\mathbf{b}$ zamegljena slika začetne slike $\mathbf{x}$. Ker je vektor $\mathbf{e}$ naključen in je

$$A^{-1}\mathbf{e} = \sum_i \frac{u_i^T \mathbf{e}}{\sigma_i} v_i,$$

so vsi skalarni produkti $u_i^T \mathbf{e}$ približno enako veliki, zato bodo pri majhnih σ_i koeficienti $u_i^T \mathbf{e}/\sigma_i$ veliki in bo pravi $\mathbf{x}$ izgubljen (po navadi namreč $|u_i^T \mathbf{b}|$ pada). Želimo si torej K , pri katerem bomo v rešitev vključili dovolj komponent, hkrati pa bo dovolj majhen, da šum ne bo prišel pretirano do izraza. (S slike 2 je razvidno, da bo od nekega i naprej šum popolnoma zasenčil pravo sliko.)



Slika 2: Singularne vrednosti (zelene pike) ter vrednosti $|u_i^T \hat{\mathbf{b}}|$ v odvisnosti od i . Vir: Str. 60 v Per Christian Hansen, James G. Nagy, Dianne O. O'Leary. *Deblurring Images, Matrices, Spectra and Filtering*, Society for Industrial and Applied Mathematics. Philadelphia, PA, ZDA.

Zapišite vsaj en algoritem, ki iz velikosti skalarnih produktov $|u_i^T \hat{\mathbf{b}}|$ ter singularnih vrednosti σ_i najde smiselno K , pri katerem opravimo odrez. Preizkusite ga na izbranih slikah. Je morda mogoče *na roke* dobiti boljše rezultate?

Spomnimo, da v resnici namesto K iščemo mejo t iz enačbe (4).

3 Obdelava rezultatov

Poženite algoritme in najдите rešitve za različne stopnje šuma in zamegljevanja (kjer matriki A_r in A_c nista že določeni). Rezultate prikažite tudi grafično. Pri regularizaciji Tihonova analognu slike 1 dodajte še točko, ki ustreza optimalnemu α , ki ste ga našli.

Pri odrežanem singularnem razcepu pa lahko analognu slike 2 dodate razmejitveno črto, ki označuje mesto odreza. Tu bo treba singularne vrednosti σ_{ij} matrike A urediti.

- Do kako velike stopnje šuma oz. zamegljevanja še dobimo smiselne rezultate?
- Ali algoritmi vračajo občutno slabše rezultate pri velikih motnjah?
- Kakšne so kvalitete rešitev, ki jih dobimo pri prvi in drugi nalogi? Se močno razlikujejo?
- Ali manjša razlika $\|\hat{X} - X\|$ med začetno sliko in najdeno rešitvijo vedno pomeni tudi večjo kvaliteto slike $\hat{X}$?