

# Analiza rijetkih komponenata

Marko Filipović

1. travnja 2010.

# Sadržaj

## 1 Uvod

## 2 Analiza rijetkih komponenata

- Grupiranje podataka (clustering). Osnovne metode
- Faktorizacija nenegativnih matrica (NMF)
- Rijetka rekonstrukcija

## 3 Primjeri

# Pododređeno razdvajanje signala

## Definicija problema i terminologija

- $X \in \mathbb{R}^{m \times T}$ ,  $m \ll T$ , matrica podataka; prepostavljamo:

$$X = AS + E$$

gdje je  $A \in \mathbb{R}^{m \times n}$ ,  $m < n \ll T$ ,  $S$  rijetka, a  $E$  aditivni šum, greška mjerena ili greška modela

- Cilj: naći  $A$  i  $S$
- “Definicija”: vektor  $x \in \mathbb{R}^n$  je *rijedak* ako je “većina” elemenata od  $x$  jednaka nuli
- $S$  rijetka: svaki stupac od  $S$  je rijedak
- $n > m$  : problem je *pododređen* (“underdetermined”)

# Pododređeno razdvajanje signala

- Terminologija:
  - retci matrice  $S$  : *komponente* (ili izvorni signali)
  - $A$  : *matrica miješanja* (ili bazna matrica)
  - stupci od  $A$  : *bazni vektori*
  - retci matrice  $X$  : *miješani signali*
  - $t, 1 \leq t \leq T$  : *(vremenski) trenutak*
  - $X \rightarrow X \approx AS$ ,  $S$  rijetka : *razdvajanje signala (analiza rijetkih komponenata)*
- Rješavanje u dvije faze:
  - ➊ Aproksimacija matrice miješanja grupiranjem podataka (clustering-om) [1]
  - ➋ Rijetka rekonstrukcija - rješavamo pododređeni linearni sustav s ograničenjem rijetkosti
- Alternativa: faktorizacija nenegativnih matrica (Nonnegative Matrix Factorization); može se koristiti i za simultanu aproksimaciju  $A$  i  $S$

# Pododređeno razdvajanje signala

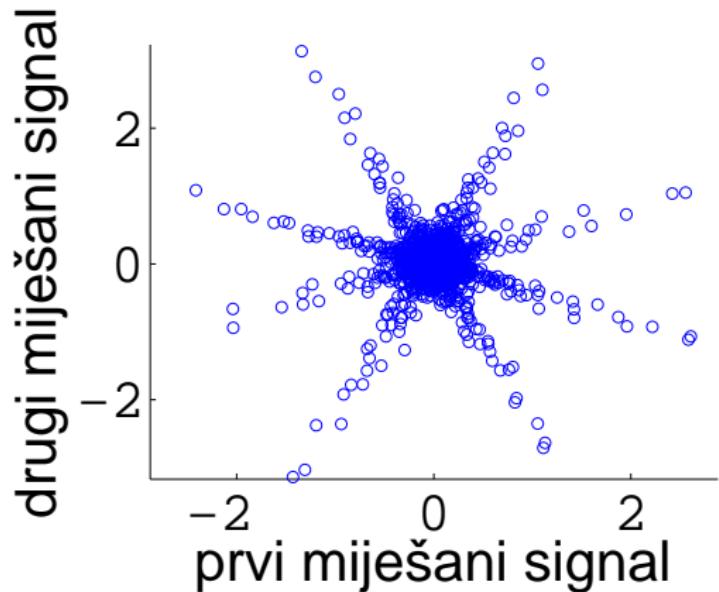
## Aproksimacija matrice miješanja

- Radi jednostavnosti uzmimo  $E = 0$
- Označimo  $X = [x_1 \dots x_T]$ ,  $A = [a_1 \dots a_n]$ ,  
 $S = [s_1 \dots s_n]^\tau$ . Za  $1 \leq t \leq T$  je

$$x_t = s_{1,t} a_1 + \dots + s_{n,t} a_n$$

- Rijetkost: za većinu  $i$ ,  $1 \leq i \leq n$ , je  $s_{i,t} = 0$  (mali broj komponenata  $s_i$  je "aktivan" u trenutku  $t$ )
- $k$  = (prosječan) broj aktivnih komponenata:
  - $k = 1$  ("single-dominant case") - grupiranje podataka
  - $k > 1$  ("multiple-dominant case") - clustering ne pomaže; standardni pristup - alternirajuća optimizacija po  $A$  i  $S$ , uz ograničenje rijetkosti na  $S$

## Grupiranje podataka (clustering)



## Klasični clustering problem

- Klasični clustering problem:

$$x_1, \dots, x_n \in \mathbb{R}^d, k \in \mathbb{N}, d(x, y) = \|x - y\|_2;$$

$$E = \sum_{i=1}^n \min_{j=1, \dots, k} d(x_i, C_j) \rightarrow \min_{C_1, \dots, C_k \in \mathbb{R}^d}$$

- Osnovne činjenice: NP-težak (čak i za  $k = 2$  ili  $d = 2$ ); za fiksne  $k$  i  $d$  može se egzaktno riješiti u vremenu  $O(n^{dk+1} \log n)$  [4]?
- Klasični clustering problem je optimizacijski problem: minimiziramo nekonveksnu funkciju (problem lokalnih minimuma)
- Najbolje čemu se možemo nadati je lokalni minimum (za koji ne znamo koliko dobro aproksimira globalni)

# Sadržaj

## 1 Uvod

## 2 Analiza rijetkih komponenata

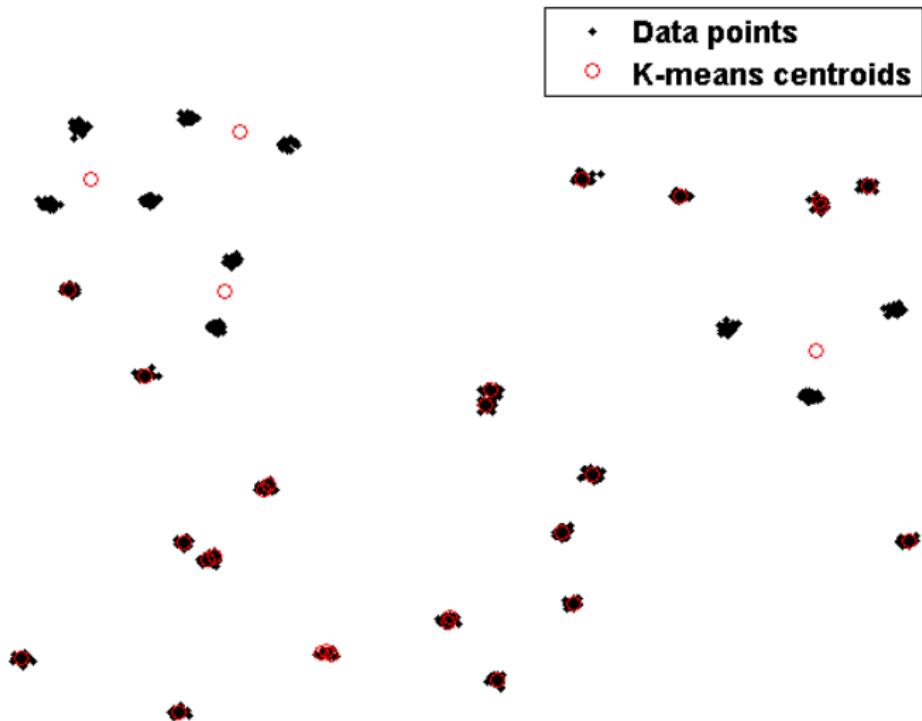
- Grupiranje podataka (clustering). Osnovne metode
- Faktorizacija nenegativnih matrica (NMF)
- Rijetka rekonstrukcija

## 3 Primjeri

## k-sredine (k-means)

- k-means [5] - najjednostavniji i najpoznatiji clustering algoritam:
  - inicijalizacija (najčešće slučajna) centara  $C_1, \dots, C_k$
  - ponavljam do konvergencije:
    - ❶ pridruži  $x_i$   $j$ -tom centru  $C_j$  t.d. je
$$d(x_i, C_j) = \min_{l=1, \dots, k} d(x_i, C_l)$$
    - ❷  $I(C_j) = \text{točke pridružene centru } C_j; C_j \leftarrow \sum_{i \in I(C_j)} x_i / |I(C_j)|$
- $d$  je ovdje euklidska udaljenost; inače treba prilagoditi korak (2)
- Konvergira k lokalnom minimumu ciljne funkcije  $E$  u konačno mnogo iteracija
- Složenost:  $O(nkd)$  po iteraciji
- Osnovna mana: osjetljivost na inicijalizaciju zbog lokalnih minimuma

## k-means



## k-means

- Ponekad je korisno koristiti kosinusnu mjeru udaljenosti:  
 $d(x, y) = 1 - \frac{|\langle x, y \rangle|}{\|x\| \|y\|}$ ; treba prilagoditi k-means algoritam
- Za  $x_{i_1}, \dots, x_{i_l} \in I(C_j)$  tražimo  $\arg \min_{C_j} \sum_p d(x_{i_p}, C_j)$ , odnosno  
 $\arg \max_{C_j} \sum_p \frac{|\langle x_{i_p}, C_j \rangle|}{\|x_{i_p}\| \|C_j\|}$
- Označimo  $m_j = \frac{1}{n_j} \sum_{x \in I(C_j)} x$ , gdje je  $n_j = |I(C_j)|$ . Centroide računamo s  $C_j = \frac{m_j}{\|m_j\|}$ . Uočimo: za svaki  $z$ ,  $\|z\|_2 = 1$ , iz Cauchyjeve nejednakosti slijedi

$$\sum_{x \in I(C_j)} x^\tau z \leq \sum_{x \in I(C_j)} x^\tau C_j \quad (1)$$

- Treba pokazati da za ovakav odabir centroida algoritam konvergira

## k-means

- S  $C_j^{(t)}$  označimo vrijednost  $C_j$  u t-toj iteraciji, a s  $I_j^{(t+1)}$  indekse pripadnih točaka,  
 $I_j^{(t+1)} = \{x : x^\tau C_j^{(t)} > x^\tau C_l^{(t)}, l \neq j\}$ . Vrijedi:

$$\begin{aligned}\sum_{j=1}^k \sum_{x \in I_j^{(t)}} x^\tau C_j^{(t)} &= \sum_{j=1}^k \left( \sum_{l=1}^k \sum_{x \in I_j^{(t)} \cap I_l^{(t+1)}} x^\tau C_j^{(t)} \right) \\ &\leq \sum_{j=1}^k \left( \sum_{l=1}^k \sum_{x \in I_j^{(t)} \cap I_l^{(t+1)}} x^\tau C_l^{(t)} \right) \\ &= \sum_{l=1}^k \sum_{j=1}^k \sum_{x \in I_j^{(t)} \cap I_l^{(t+1)}} x^\tau C_l^{(t)} \\ &= \sum_{l=1}^k \sum_{x \in I_l^{(t+1)}} x^\tau C_l^{(t)} \\ &\stackrel{(1)}{\leq} \sum_{l=1}^k \sum_{x \in I_l^{(t+1)}} x^\tau C_l^{(t+1)}\end{aligned}$$

- Dakle, algoritam konvergira (općenito k lokalnom minimumu)  
[6]

## k-means varijacije

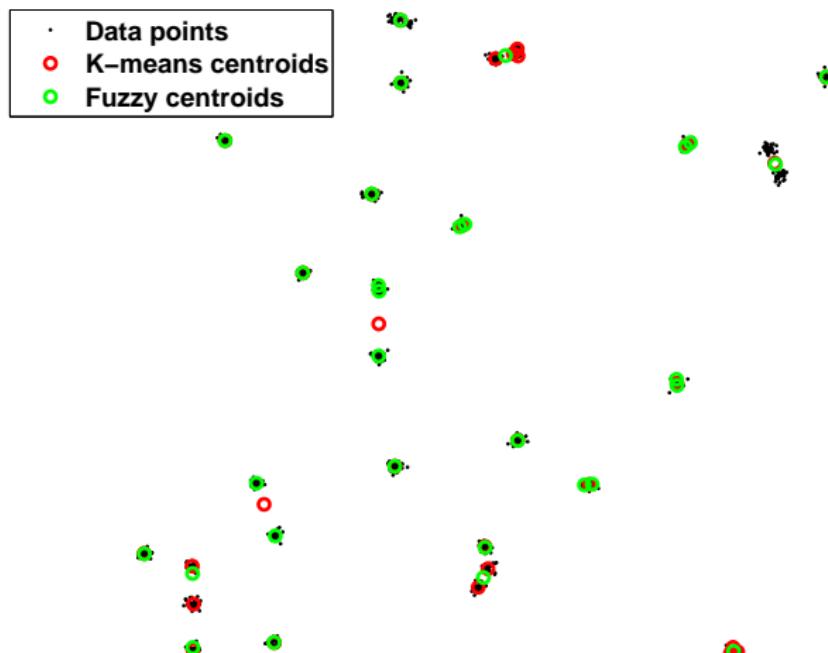
### Algoritmi temeljeni na centru

- Fuzzy k-means (c-means):

$$E(U, C) = \sum_{i=1}^n \sum_{j=1}^k u_{ij}^q d(x_i, C_j) \rightarrow \min_{U, C}, \text{ gdje je:}$$

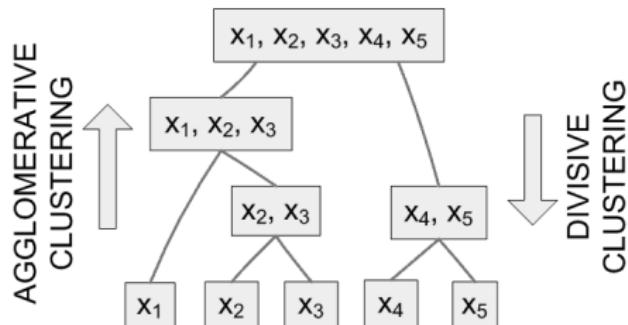
- $U \in \mathbb{R}^{n \times k}, \sum_{i=1}^n u_{ij} > 0, \sum_{j=1}^k u_{ij} = 1$ ;  $u_{ij}$  određuje nivo pripadnosti točke  $x_i$  clusteru  $C_j$  ("soft assignment")
- $q > 1$ ; parametar  $q$  kontrolira nivo pripadnosti ("fuzziness") točaka grupama
- Za  $q = 1$  algoritam je sličan k-meansu

# Fuzzy k-means



# Hijerarhijski clustering

- Particijski clustering - particija skupa podataka (npr. kmeans), hijerarhijski - niz ugnježđenih particija
- Osnovna podjela:  
*agglomerativni*  
(češći) i divizivni
- Zaustavljanje: zadani broj clustera, prevelika udaljenost među clusterima...
- Prednosti nad partičijskim metodama: ne zahtijeva broj clustera kao ulaz, radi s proizvoljnom metrikom



# Hijerarhijski clustering

- Lance-Williams formula:

$$\begin{aligned} D(C, C_i \cup C_j) = & \alpha_i D(C, C_i) + \alpha_j D(C, C) + \\ & + \beta D(C_i, C_j) + \gamma |D(C, C_i) - D(C, C_j)| \end{aligned}$$

- Neki posebni slučajevi:

- $D(C_1, C_2) = \min_{x \in C_1, y \in C_2} d(x, y)$  ("single-link")
- $D(C_1, C_2) = \max_{x \in C_1, y \in C_2} d(x, y)$  ("complete-link")
- $D(C_1, C_2) = \frac{1}{|C_1||C_2|} \sum_{x \in C_1, y \in C_2} d(x, y)$  ("group-average")

- Neki hijerarhijski algoritmi zahtijevaju  $O(n^2)$  memorijskog prostora (matrica udaljenosti), što je nepraktično za velike  $n$

## Spektralni clustering [7]

- Uzmimo  $k = 2$ ;  $\{C_1, C_2\}$  particija skupa podataka,  $y$  indikator particije ( $y_i = \begin{cases} 1 & , x_i \in C_1 \\ -1 & , x_i \in C_2 \end{cases}$ ),  $w_{ij} = \exp(-d^2(x_i, x_j)/\sigma^2)$ ,  $W = (w_{ij})$ ,  $D = \text{diag}(d_1, \dots, d_n)$ ,  $d_i = \sum_j w_{ij}$ ; želimo

$$\frac{1}{4} \sum_{i \in C_1, j \in C_2} w_{ij} (y_i - y_j)^2 = \frac{1}{4} y^\tau (D - W) y \rightarrow \min_{y \in \{-1, 1\}^n}$$

- $L \doteq D - W$ ; uz dodatnu pretpostavku  $|C_1| = |C_2|$ , imamo dodatni uvjet na  $y$ :  $\sum_i y_i = 0$ , odn. uz oznaku  $e = [1, \dots, 1]^\tau$ ,  $y \cdot e = 0$ ; dakle imamo diskretni problem  
 $y^\tau L y \rightarrow \min_{y \in \{-1, 1\}^n, y \cdot e = 0}$  koji aproksimiramo neprekidnim  
 $y^\tau L y \rightarrow \min_{\|y\|_2=1, y \cdot e = 0}$  čije je rješenje drugi najmanji svojstveni vektor od  $L$

## Spektralni clustering

- Drugi pristup [8]: definiramo  $\text{cut}(C_1, C_2) = \sum_{i \in C_1, j \in C_2} w_{ij}$ ,  $V = \{s_1, \dots, s_n\}$ ; minimiziramo funkciju

$$\text{Ncut}(C_1, C_2) = \frac{\text{cut}(C_1, C_2)}{\text{cut}(C_1, V)} + \frac{\text{cut}(C_1, C_2)}{\text{cut}(C_2, V)}$$

- Uz prethodne oznake, slično kao prije, rješenje možemo aproksimirati rješavanjem

$$\min_{y^\tau D e = 0} \frac{y^\tau L y}{y^\tau D y}$$

Rješenje je drugi najmanji svojstveni vektor generaliziranog problema svojstvenih vrijednosti  $Ly = \lambda Dy$

- Proširenje na  $k > 2$ : ponavljamo algoritam na dobivenim clusterima
- Problem:  $L$  je  $n \times n$  matrica ( $\rightarrow$  općenito  $O(n^2)$  memorijskog prostora)

# Bayesovske tehnike

Grupiranje bazirano na statističkom modelu podataka

- Podaci su slučajni uzorak iz neke distribucije s gustoćom  $f$
- Najčešće - mješavine Gausovskih distribucija (“mixtures of Gaussians”):

$$f(x) = \sum_{j=1}^k \pi_j \Phi(x|\mu_j, \Sigma_j) \quad (2)$$

gdje je

$$\Phi(x|\mu, \Sigma) = \frac{1}{(2\pi)^{\frac{d}{2}} \det \Sigma} \exp \left( -\frac{1}{2} (x - \mu)^\tau \Sigma^{-1} (x - \mu) \right)$$

gustoća višedimenzionalne normalne distribucije

## Bayesovske tehnike

- Motivacija:  $z$  binarna slučajna varijabla, jedan element je  $= 1$ , svi ostali  $= 0$ ; neka je gustoća od  $z$   $P(z_k = 1) = \pi_k$ ,  $0 \leq \pi_k \leq 1$ ,  $\sum_k \pi_k = 1$ ; dakle,  $P(z) = \prod_k \pi_k^{z_k}$ ;  $z$  je *latentna* varijabla
- Za distribuciju podataka  $x$  prepostavljamo  $P(x|z_k = 1) = N(x|\mu_k, \Sigma_k)$ ; slijedi

$$P(x) = \sum_z P(z) P(x|z) = \sum_k \pi_k N(x|\mu_k, \Sigma_k)$$

- Na ovaj način moguće je modelirati podatke raznim distribucijama
- Parametre  $\mu_k, \Sigma_k$  procjenjujemo metodom maksimalne vjerodostojnosti: maksimiziramo logaritam funkcije vjerodostojnosti

$$\ln P(X|\pi, \mu, \Sigma) = \sum_{i=1}^N \ln \left\{ \sum_k \pi_k N(x_i|\mu_k, \Sigma_k) \right\} \quad (3)$$

gdje je  $X = \{x_1, \dots, x_n\}$  skup podataka (slučajni uzorak)

# Bayesovske tehnike

## Expectation-maximization (EM) algoritam [9]

- Maksimizacija funkcije u (3) je netrivijalna
- EM je općeniti algoritam za procjenu parametara vjerojatnosnih modela
- EM za mješavine Gausovskih distribucija:
  - ① Inicijalizacija parametara  $\mu_k$ ,  $\Sigma_k$  i  $\pi_k$
  - ② “E-korak”:
$$\gamma(z_{ik}) = P(z_k=1|x_i) = \frac{P(z_k=1)P(x_i|z_k=1)}{\sum_j P(z_j=1)P(x_i|z_j=1)} = \frac{\pi_k N(x_i|\mu_k, \Sigma_k)}{\sum_j \pi_j N(x_i|\mu_j, \Sigma_j)}$$
  - ③ “M-korak”: update parametara,  $\mu_k^{new} \leftarrow \frac{1}{N_k} \sum_i \gamma(z_{ik}) x_i$ ,  
 $\Sigma_k \leftarrow \frac{1}{N_k} \sum_i \gamma(z_{ik}) (x_i - \mu_k^{new})(x_i - \mu_k^{new})^\top$ ,  $\pi_k \leftarrow \frac{N_k}{n}$ , gdje je  
 $N_k = \sum_i \gamma(z_{ik})$
  - ④ Ponavljam (2) i (3) do konvergencije
- M-korak: gledamo stacionarne točke funkcije vjerodostojnosti (3)

# Bayesovske tehnike

## Općeniti EM algoritam

- $X$  podaci,  $Z$  latentne varijable,  $\Theta$  parametri,  $P(X, Z|\Theta)$  zajednička distribucija određena parametrima  $\Theta$ ; cilj je maksimizirati funkciju vjerodostojnosti  $P(X|\Theta)$  po  $\Theta$
- EM algoritam:
  - ➊ Inicijalizacija parametara,  $\Theta^{old}$
  - ➋ E-korak:  $P(Z|X, \Theta^{old})$
  - ➌ M-korak:  $\Theta^{new} = \arg \max_{\Theta} \sum_Z P(Z|X, \Theta^{old}) \ln P(X, Z|\Theta)$
  - ➍ Ponavljam (2) i (3) do konvergencije
- Fuzzy k-means je vrlo specijalan slučaj EM-a

# Problemi

## Preprocesiranje skupa podataka

- Glavni problem: veličina skupa podataka; korisni algoritmi prije clusteringa reduciraju broj (možda i dimenzionalnost) podataka
- Neke metode redukcije skupa podataka:
  - “random subsampling”
  - particioniranje [16]: ideja je particionirati skup podataka na  $p$  particija veličine  $\frac{n}{p}$ ; zatim se radi grupiranje u  $\frac{n}{pq}$  grupa, za neki  $q > 1$ , na svakoj particiji posebno; zatim se dobivenih  $\frac{n}{q}$  grupa spoji prema nekom od kriterija, kao u hijerarhijskom grupiranju

# Redukcija skupa podataka

## Random subsampling

- Ideja: slučajno (uniformno) se generira podskup  $D = \{x_1, \dots, x_s\}$  skupa podataka  $X$
- Pitanje: koliki je minimalan  $s$  da s velikom vjerojatnošću za svaku grupu  $C_j \subseteq X$  vrijedi  $|C_j \cap D| \geq f \cdot |C_j|$ ,  $0 \leq f \leq 1$  unaprijed zadan
- Pretpostavke:  $X_j$  slučajna varijabla,  $C$  neki cluster,  
$$X_j = \begin{cases} 1 & x_j \in C \\ 0 & x_j \notin C \end{cases} \Rightarrow P(X_j = 1) = \frac{|C|}{n}, X_j \text{ nezavisne Bernoullijeve}$$
- $X = \sum_j X_j$  je broj točaka u  $C \cap D$ ; to je binomna slučajna varijabla; aproksimiramo ju Poissonovom (k njoj i teži za  $n \rightarrow \infty$ )

# Redukcija skupa podataka

## Random subsampling

- Chernoff-Ijeva ograda [2]: za  $X$  Poissonovu,  $0 < \varepsilon \leq 1$ , uz oznaku  $\mu = E(X)$ , vrijedi

$$P(X < (1 - \varepsilon)\mu) < \exp\left(\frac{-\mu\varepsilon^2}{2}\right)$$

- Za zadani  $\delta$  dobijemo minimalni  $s$  za koji je  $P(X < f \cdot |C|) < \delta$  [16] ( $\mu = \frac{s|C|}{n}$ )

# Sadržaj

## 1 Uvod

## 2 Analiza rijetkih komponenata

- Grupiranje podataka (clustering). Osnovne metode
- Faktorizacija nenegativnih matrica (NMF)
- Rijetka rekonstrukcija

## 3 Primjeri

## Konveksni NMF

- Želimo  $X = AS$ ,  $S$  rijetka (i možda nenegativnost  $A$  i  $S$ ); alternirajuća minimizacija; glavni problem: lokalni minimumi, suboptimalno rješenje
- $A = XW$ , odnosno  $a_i = \sum_j w_{ji}x_j$ ;  $W \geq 0$ ; dakle,  $X = XWS$ ; stupce od  $A$  modeliramo kao centroide [17]
- Prednost nad k-meansom: k-means staje kad nema promjene pripadnosti točaka clusterima jer bi promjena jedne točke povećala grešku; ali, promjena više točaka bi ju možda smanjila! K-means je vrlo “lokalan” algoritam
- Dodatna prednost: može biti i  $k > 1$ , iako ovdje ne razmatramo taj slučaj

# Konveksni NMF

- Minimiziramo

$$J = \|X - XWS\|_F^2 \quad (4)$$

po  $W$  i  $S$ , uz uvjet  $W \geq 0$

## Definicija

Neka je  $f : \mathbb{R}^n \rightarrow \mathbb{R}$ . Funkcija  $g : \mathbb{R}^{2n} \rightarrow \mathbb{R}$  je pomoćna funkcija za  $f$  ako vrijedi

$$g(x, y) \geq f(x), g(x, x) = f(x)$$

za sve  $x, y \in \mathbb{R}^n$ .

- Ako definiramo  $x^{(t+1)} = \arg \min_x g(x, x^{(t)})$ , vidi se da vrijedi  $f(x^{(t)}) = g(x^{(t)}, x^{(t)}) \geq g(x^{(t+1)}, x^{(t)}) \geq f(x^{(t+1)})$ , dakle niz  $f(x^{(t)})$  je opadajući

# Konveksni NMF

## Teorem

Uz označke  $B = X^\tau X S^\tau$ ,  $A = X^\tau X$ ,  $C = S S^\tau$ , funkcija

$$\begin{aligned} Z(W, \tilde{W}) &= Tr(A) - \sum_{i,k} 2B_{ik}^+ \tilde{W}_{ik} \left( 1 + \log \frac{W_{ik}}{\tilde{W}_{ik}} \right) \\ &\quad + \sum_{ik} B_{ik}^- \frac{W_{ik}^2 + \tilde{W}_{ik}^2}{\tilde{W}_{ik}} + \sum_{ik} \frac{(A^+ \tilde{W} C)_{ik} W_{ik}^2}{\tilde{W}_{ik}} \\ &\quad - \sum_{ijkl} A_{ij}^- \tilde{W}_{jk} C_{kl} \tilde{W}_{il} \left( 1 + \log \frac{W_{jk} W_{il}}{\tilde{W}_{jk} \tilde{W}_{il}} \right) \end{aligned} \tag{5}$$

gdje je  $W \geq 0$ , je pomoćna funkcija za  $J = J(W)$  iz (4).

## Konveksni NMF

- $Z(W, \tilde{W})$  je konveksna funkcija od  $W$ ; minimum se postiže u

$$W_{ik} = \tilde{W}_{ik} \sqrt{\frac{[(X^\tau X)^+ S^\tau]_{ik} + [(X^\tau X)^- \tilde{W} S S^\tau]_{ik}}{[(X^\tau X)^- S^\tau]_{ik} + [(X^\tau X)^+ \tilde{W} S S^\tau]_{ik}}} \quad (6)$$

- Treba provjeriti da li fiksna točka zadovoljava nužne uvjete optimalnosti (KKT uvjeti) za početni problem
- Ako da, možemo očekivati konvergenciju k lokalnom minimumu
- Pokazuje se da je manja osjetljivost na početne uvjete u odnosu na k-means (barem empirijski)

## Konveksni NMF

- Uvjeti optimalnosti su

$$\begin{aligned} W &\geq 0 \\ \lambda = (\lambda_{ij}) &\geq 0 \end{aligned}$$

$$\begin{aligned} (\nabla_W J(W))_{ij} - \lambda_{ij} &= (-2X^\tau XS^\tau + 2X^\tau XWSS^\tau)_{ij} - \lambda_{ij} = 0 \\ \lambda_{ij} W_{ij} &= 0 \end{aligned}$$

- Zadnja dva uvjeta povlače  $(-X^\tau XS^\tau + X^\tau XWSS^\tau)_{ij} W_{ij} = 0$
- Fiksna točka iteracija (6) zadovoljava  $(-X^\tau XS^\tau + X^\tau XWSS^\tau)_{ij} W_{ij}^2 = 0$ , što je ekvivalentno gornjem uvjetu
- Uvjet  $W \geq 0$  je implicitno zadovoljen ako je  $W^{(0)} \geq 0$  (početna vrijednost)
- Isti postupak i za  $S$

## Višeslojni lokalni NMF

- Ciljna funkcija:  $D(X||AS) = \frac{1}{2} \|X - AS\|_F^2 + \alpha J(S)$ ; minimiziramo po  $A$  i  $S$ ;  $J(S)$  je regularizacijski član koji forsira rijetkost od  $S$
- Definiramo lokalne ciljne funkcije:

$$D^{(m)}(X^{(m)} || a_m s_m) = \frac{1}{2} \|X^{(m)} - a_m s_m\|_F^2 + \alpha^{(m)} J(s_m)$$

gdje je  $a_m$   $m$ -ti stupac od  $A$ ,  $s_m$   $m$ -ti redak od  $S$ , i

$$X^{(m)} = X - \sum_{j \neq m} a_j s_j$$

- $J(s_m) = \sum_t s_{mt}$
- $D^{(m)}(X^{(m)} || a_m s_m)$  je konveksna funkcija po  $a_m$  i  $s_m$  posebno

## Višeslojni lokalni NMF

- Alternirajuća minimizacija:

$$\begin{aligned}\underline{s}_m &\leftarrow \left[ a_m^\tau X^{(m)} - \alpha e \right]_+, \quad m = 1, \dots, M \\ A &\leftarrow \left[ X S^\tau (S S^\tau + \lambda I)^{-1} \right]_+ \\ a_m &\leftarrow \frac{a_m}{\|a_m\|_2}, \quad m = 1, \dots, M\end{aligned}$$

gdje je  $e$  vektor jedinica,  $[\xi]_+ = \max(\xi, \varepsilon)$ ,  $\varepsilon$  mala konstanta (npr.  $\varepsilon = 10^{-16}$ ),  $M$  broj redaka od  $S$ , i  $\lambda$  regularizacijska konstanta

- Empirijski se pokazuje da se efikasnost ovog algoritma može značajno poboljšati uzastopnom primjenom (u više "slojeva"):  $X \approx A^{(1)} S^{(1)}$ ,  $S^{(1)} \approx A^{(2)} S^{(2)}$ , ...,  $X = A^{(1)} A^{(2)} \dots A^{(L)} S^{(L)}$
- Naime, to je jedna od heuristika za izbjegavanje lokalnih minimuma; zajedno s "multi-start" inicijalizacijom empirijski se pokazuje vrlo korisnom [11, 12, 10]

# Sadržaj

## 1 Uvod

## 2 Analiza rijetkih komponenata

- Grupiranje podataka (clustering). Osnovne metode
- Faktorizacija nenegativnih matrica (NMF)
- Rijetka rekonstrukcija

## 3 Primjeri

## Konveksna aproksimacija

- Clusteringom dobijemo matricu  $A$ ; za svaki  $1 \leq i \leq n$  želimo naći rijetko rješenje pododređenog linearног sustava  $As_i = x_i$
- Idealna, ali nepraktična mjera rijetkosti je  $\|x\|_0 = |\{i : x_i \neq 0\}|$ ; najčešće se zamjenjuje neprekidnom, konveksnom aproksimacijom  $\|x\|_1 = \sum_i |x_i|$  (1-norma)
- Dakle, rješavamo

$$\min_s \|s\|_1 \text{ uz uvjet } \|As - x_i\|_2 \leq \varepsilon \quad (7)$$

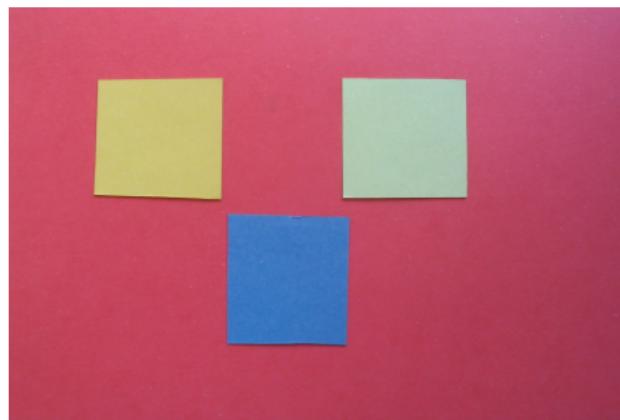
- To je problem konveksne optimizacije, može se riješiti standardnim metodama [3]; može se pokazati [13, 14]: ako je najrjeđe (u smislu mјere  $\|\cdot\|_0$ ) rješenje (odnosno približno rješenje) sustava  $As = x_i$  dovoljno rijetko, uz neke prihvatljive pretpostavke na matricu  $A$  (npr. koherencija od  $A$ ,  $\mu(A) = \max_{i,j} \frac{|\langle a_i, a_j \rangle|}{\|a_i\|_2 \|a_j\|_2}$ , dovoljno mala), to rješenje možemo aproksimirati rješavanjem (7)

## Pohlepne metode

- “Matching pursuit” (MP) algoritam:
  - ❶ Inicijalizacija: rješenje  $s = 0$ , rezidual  $r = x_i$ , normalizacija  $\|a_i\|_2 = 1, \forall i$
  - ❷ Ponavljam do konvergencije:  $\hat{i} = \arg \max_i \langle r, a_i \rangle$ ;  
 $s_{\hat{i}} \leftarrow s_{\hat{i}} + \langle r, a_{\hat{i}} \rangle; r \leftarrow r - \langle r, a_{\hat{i}} \rangle a_{\hat{i}}$
- Moguće su razne varijacije
- Pokazuje se da konveksna aproksimacija ima bolja svojstva od pohlepnih algoritama (stabilnost, teorijske garancije); prednost pohlepnih algoritama je brzina [15]

## Segmentacija višespektralne slike

- Segmentacija slike: particija slike na homogene dijelove
- RGB slika = 3D tenzor ( $\in \mathbb{R}^{m \times n \times 3}$ ); pikseli = vektori u  $\mathbb{R}^3$



- Klasični “toy example” za segmentaciju slike; rezolucija slike:  $1380 \times 2048$

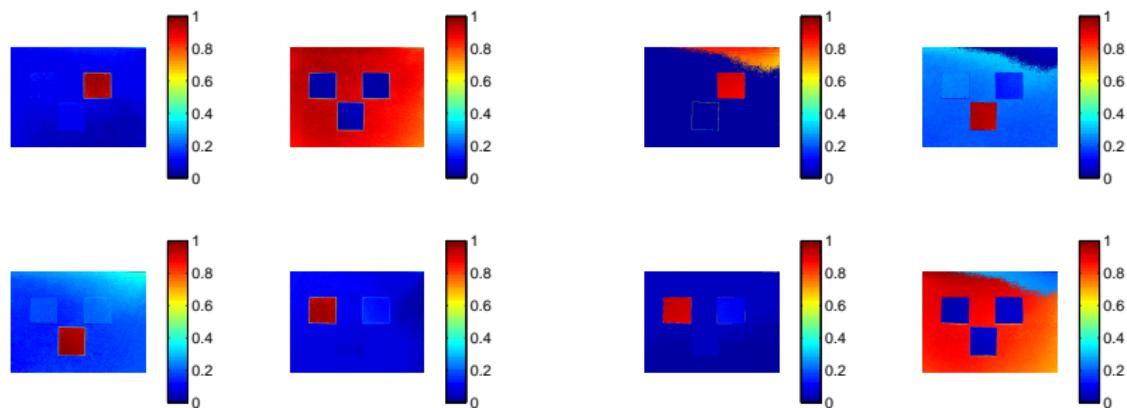
## Segmentacija višespektralne slike

- RGB slika  $R \in \mathbb{R}^{m \times n \times 3} \rightarrow \hat{R} \in \mathbb{R}^{3 \times mn}$ ,  $\hat{R}(:, i) = R(i_1, i_2, :)$  za neke  $i_1$  i  $i_2$  ("matricizacija" tenzora)
- Interpretacija modela  $X = AS + E$ :
  - $X = \hat{R}$  (matrica podataka)
  - $A \in \mathbb{R}^{3 \times k}$  - matrica "spektralnih profila" materijala prisutnih na slici (broj materijala  $k$  je najčešće nepoznat, ovdje  $k = 4$ )
  - $S$  - komponente (retci od  $S$ ) predstavljaju prostornu distribuciju materijala
- Ideja: matricu spektralnih profila aproksimiramo grupiranjem piksela (stupaca matrice  $\hat{R}$ )
- Nakon grupiranja, za svaki piksel se traži prikaz u obliku rijetke linearne kombinacije dobivenih spektralnih profila

## Segmentacija višespektralne slike

- Glavni problem: već za sliku osrednje rezolucije (npr.  $1000 \times 1000$ ) imamo  $10^6$  točaka; matrica udaljenosti bi uzela  $O(10^{12})$  prostora
- Nužna je redukcija broja točaka
- Pokazuje se da random subsampling kao metoda preprocesiranja daje dobre rezultate; reduciramo s faktorom 16000
- Hijerarhijsko grupiranje je najpouzdanije jer ne zahtijeva inicijalizaciju; na istom skupu uvijek daje isti rezultat
- Mogući nedostatak metode je što zanemaruje prostorni položaj piksela u slici

# Segmentacija višespektralne slike

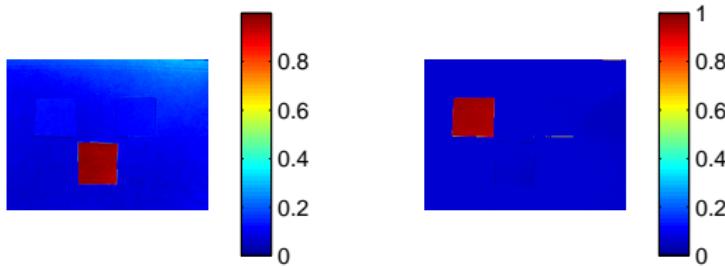
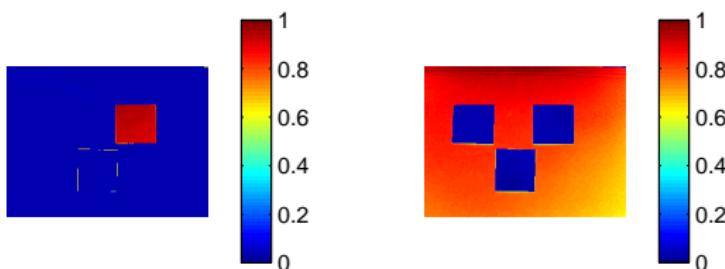


Dobivena segmentacija:  
hijerarhijsko grupiranje +  
minimizacija 1-norme

Tipična segmentacija dobivena  
k-means algoritmom + MP  
rekonstrukcija

# Segmentacija višespektralne slike

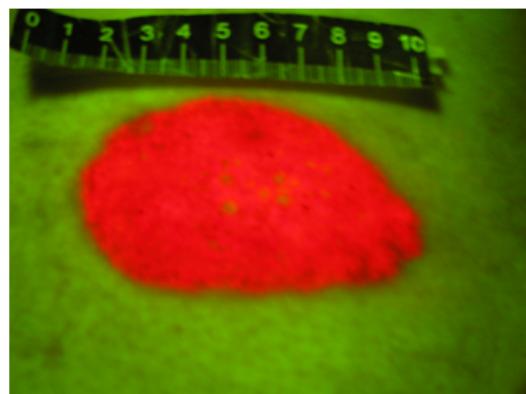
- Hijerarhijsko grupiranje + MP rekonstrukcija



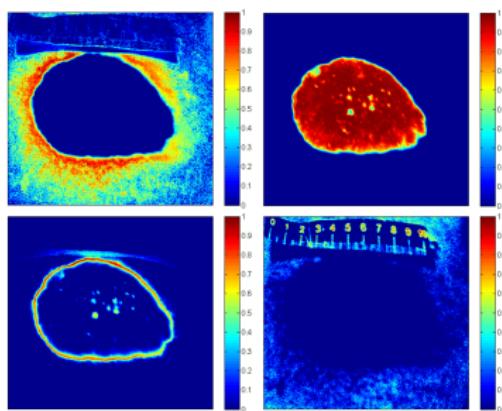
- Brzina izvršavanja: konveksna optimizacija -  $\sim 1\text{h}$ , MP -  $< 5$  sekundi

# Segmentacija višespektralne slike

Realni primjer



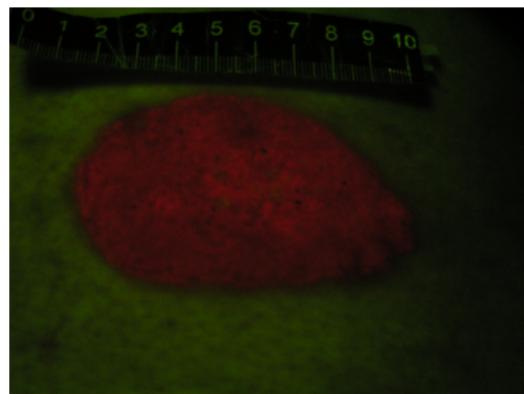
RGB slika kožnog tumora



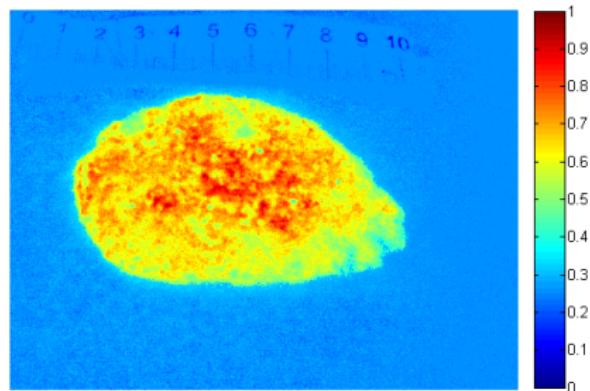
Dobivena segmentacija  
višeslojnim lokalnim NMF-om  
[10]

# Segmentacija višespektralne slike

Realni primjer



Slika niskog intenziteta



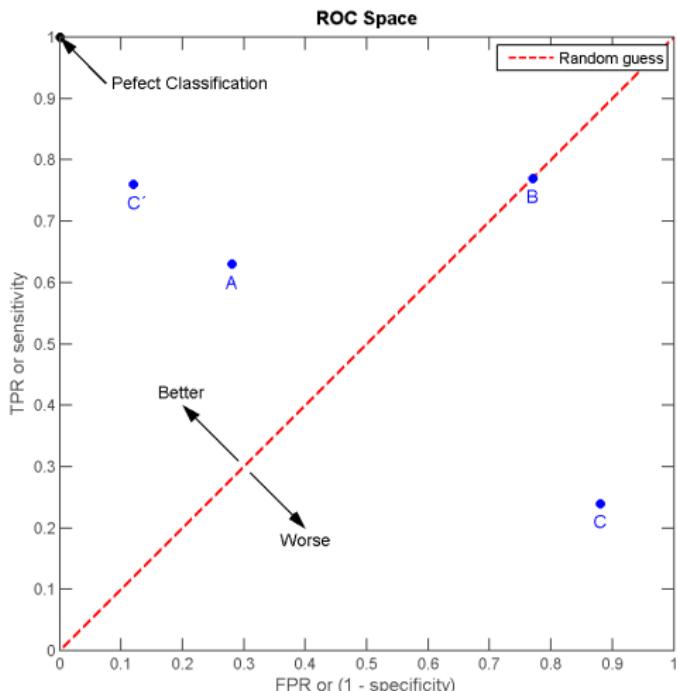
Segmentacija: convex NMF +  
MP

# Segmentacija višespektralne slike

## Realni primjer

- Statistička analiza klasifikacije (segmentacije): za svaki piksel gledamo osjetljivost klasifikacije (tumor ili zdravo tkivo) u odnosu na prag (veće/manje vrijednosti - prisutnost/odsutnost tumora); 4 moguća ishoda klasifikacije:
  - “true positive”: piksel je ispravno klasificiran kao tumor
  - greška tipa 1 (“false positive”): piksel je pogrešno klasificiran kao tumor
  - greška tipa 2 (“false negative”): piksel pogrešno nije klasificiran kao tumor
  - “true negative”: piksel ispravno nije klasificiran kao tumor
- “True positive rate” (TPR): udio ispravno klasificiranih točaka; “false positive rate” (FPR): udio pogrešno klasificiranih točaka
- TPR i FPR su funkcije praga
- Grafički prikaz: “Receiver Operating Characteristic” (ROC) krivulja - TPR vs. FPR

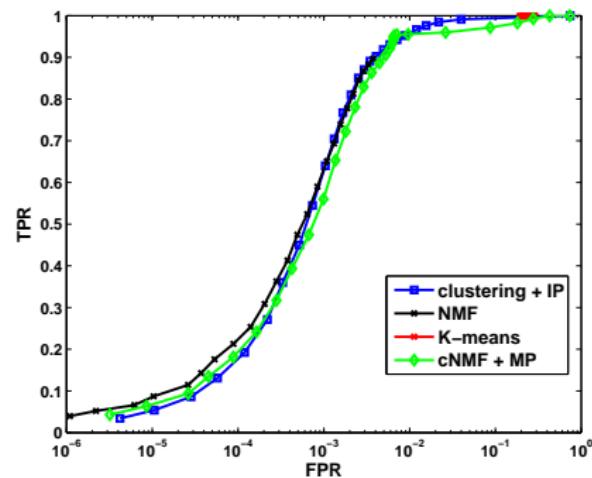
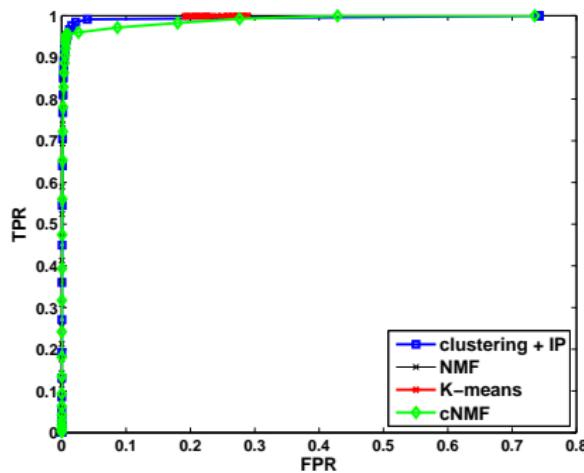
# ROC krivulja



[http://en.wikipedia.org/wiki/File:ROC\\_space-2.png](http://en.wikipedia.org/wiki/File:ROC_space-2.png)

# ROC krivulja za segmentaciju

ROC krivulje za sliku tumora niskog intenziteta



## Zaključak

- Razdvajanje signala - klasični inverzni problem; analiza rijetkih komponenata - jedna metoda rješavanja
- Rijetkost - grupiranje podataka; druga faza - konveksna optimizacija (računski najzahtjevniji dio! - paralelizacija)
- Grupiranje podataka - NP-težak problem; minimizacija nekonveksne funkcije
- Razne heuristike za izbjegavanje lokalnih minimuma; globalna optimizacija
- Nužna je redukcija skupa podataka
- Nema najbolje metode; ovisi o danom problemu
- Možda najviše teorijski utemeljen pristup: Bayesovski

## Literatura |

- [1] G. Gan, C. Ma, J. Wu.  
Data clustering: Theory, algorithms and applications.  
ASA-SIAM, 2007.
- [2] R. Motwani, P. Raghavan.  
Randomized algorithms.  
Cambridge University Press, 1995.
- [3] Boyd, Vandenberghe.  
Convex optimization.
- [4] M. Inaba, N. Katoh, H. Imai.  
Applications of weighted Voronoi diagrams and randomization  
to variance-based k-clustering.  
10th ACM Symposium on Computational Geometry, 1994.

## Literatura II

- [5] J. MacQueen.  
Some methods for classification and analysis of multivariate observations.  
1967.
- [6] I. S. Dhillon, D. S. Modha.  
Concept decompositions for large sparse text data using clustering.  
Machine learning, 2001.
- [7] Y. Weiss.  
Segmentation using eigenvectors: A unifying view.  
Computer Vision, 1999.
- [8] Shi, Malik.  
Normalized cuts and image segmentation.  
IEEE Trans. PAMI, 2000.

## Literatura III

- [9] A. P. Dempster, N. M. Laird, D. B. Rubin.  
Maximum likelihood from incomplete data via the EM  
algorithm.  
1977.
- [10] I. Kopriva, A. Cichocki.  
Blind decomposition of low-dimensional multi-spectral image  
by sparse component analysis.  
*Journal of Chemometrics*, 2009.
- [11] A. Cichocki, R. Zdunek, S. Amari.  
Hierarchical ALS algorithms for nonnegative matrix and 3D  
tensor factorization.  
*LNCS 4666*, pp. 169-176, 2007.
- [12] A. Cichocki, R. Zdunek.  
Multilayer nonnegative matrix factorization.  
*Electronics Letters 42(16)*, 2006.

## Literatura IV

- [13] Gribonval, Nielsen.  
Sparse representations in unions of bases.  
*IEEE Trans. Inf. Theory*, 49(12), 2003.
- [14] Candes, Tao.  
Decoding by linear programming.  
*IEEE Trans. Inf. Theory* 51, 2005.
- [15] J. A. Tropp, S. J. Wright.  
Computational methods for sparse solution of linear inverse problems.  
CalTech ACM Tech. Rep. 2009-01
- [16] S. Guha, R. Rastogi, K. Shim.  
CURE: An efficient clustering algorithm for large databases.  
*Information Systems*, 26(1), 2001.

## Literatura V

- [17] C. Ding, T. Li, M. I. Jordan.  
Convex and semi-nonnegative matrix factorizations.  
IEEE Trans. PAMI, 2010.