

*"A mathematician, like a painter or a poet, is a maker of patterns. If his patterns are more permanent than theirs, it is because they are made with ideas."*

Godfrey Harold Hardy

# 6

## Descompunerea valorilor singulare

### ■ *Compresia datelor*



Transmiterea eficienta si stocarea unui volum mare de date au devenit o problema majora a lumii tehnologiei. In cele ce urmeaza vom prezenta o metoda de compresie a datelor in asa fel incat acestea sa poata fi transmise mai rapid si stocate pe mai putin spatiu. Reamintim ca rata de compresie a datelor se calculeaza cu formula:

$$\text{rata compresie} = \frac{\text{marime fisier necomprimat}}{\text{marime fisier comprimat}}$$

Astfel un fisier de 10 MB care este comprimat in unul de 2MB va avea o rata de compresie 5 : 1.

Spre exemplu, o fotografie alb-negru poate fi scanată și apoi stocată ca o matrice  $A$  asociând fiecărui pixel o valoare numerică în funcție de nivelul de gri al acestuia. Dacă folosim 256 nivele diferite de gri (0 = alb, 255 = negru), atunci elementele matricei ar fi numere întregi cuprinse între 0 și 255. Imaginea poate fi recuperată din matricea  $A$  afișând pixelii colorați în funcție de nivelele lor de gri. Dacă matricea este de tip  $m \times n$  atunci am putea să stocăm toate cele  $m \cdot n$  date individual. O alternativă constă în găsirea unei descompuneri a matricei pentru care să fie nevoie de mai puține date. Spre exemplu, dacă am avea o descompunere de tipul:

$$A = \sigma_1 \mathbf{u}_1 \cdot \mathbf{v}_1^T + \sigma_2 \mathbf{u}_2 \cdot \mathbf{v}_2^T + \dots + \sigma_r \mathbf{u}_r \cdot \mathbf{v}_r^T$$

unde  $\mathbf{u}_i \in \mathcal{M}_{1 \times m}(\mathbb{R})$ ,  $\mathbf{v}_i \in \mathcal{M}_{1 \times n}(\mathbb{R})$  și  $\sigma_i > 0$ , atunci nu trebuie să stocăm decât  $rm$  date pentru cei  $r$  de  $u_i$ ,  $rn$  date pentru cei  $r$  de  $v_i$  și  $r$  date pentru cei  $r$  de  $\sigma_i$ . În concluzie  $r + rm + rn = r(m + n + 1)$  date. Ce nu e suficient de evident la această descompunere este că fiecare termen este de fapt o matrice  $m \times n$ . Ținând cont de modul în care am modelat matematic stocarea fotografiei alb-negru o astfel de matrice adaugă câteva nuanțe de gri fiecărui pixel al imaginii urmând ca toate împreună să realizeze reconstrucția totală a acesteia. Să presupunem acum că unii dintre acești  $\sigma_i$  sunt foarte mici atunci eliminând termenii corespunzători lor vom obține ceea ce numim o **aproximare de rang  $k$**  a lui  $A$ :

$$A \approx \sigma_1 \mathbf{u}_1 \cdot \mathbf{v}_1^T + \sigma_2 \mathbf{u}_2 \cdot \mathbf{v}_2^T + \dots + \sigma_k \mathbf{u}_k \cdot \mathbf{v}_k^T, \quad k < r$$

În acest fel am putea stoca doar aceste  $k(m + n + 1)$  date și vom obține o aproximare a imaginii inițiale, suficient de bună pentru scopul nostru. Spre exemplu o aproximare de rang 100 a unei imagini cu  $1000 \times 1000$  pixeli are nevoie doar de  $100(1000 + 1000 + 1) = 200.100$  date, astfel rezultă o compresie cu o rată de compresie de aproape 5 : 1.

Mai jos aveți câteva aproximări ale versiunii alb-negru a imaginii de la începutul capitolului:

Reconstrucție folosind matricea întreagă




Reconstrucție folosind o aproximare de rang 100



Reconstrucție folosind o aproximare de rang 10



Reconstrucție folosind o aproximare de rang 3



Mai jos aveti un cod Matlab care genereaza astfel de aproximari ale imaginii tigrlului:

```
% Read the picture of the tiger, and convert to black and white.
tiger = rgb2gray(imread('tiger.jpg'));

% Downsample, just to avoid dealing with high-res images.
tiger = im2double(imresize(tiger, 0.5));

% Compute SVD of this tiger
[U, S, V] = svd(tiger);

% Plot the magnitude of the singular values (log scale)
sigmas = diag(S);
figure; plot(log10(sigmas)); title('Singular Values (Log10 Scale)');
figure; plot(cumsum(sigmas) / sum(sigmas)); title('Cumulative Percent of Total
Sigmas');

% Show full-rank tiger
figure; subplot(4, 2, 1), imshow(tiger), title('Full-Rank Tiger');

% Compute low-rank approximations of the tiger, and show them
ranks = [200, 100, 50, 30, 20, 10, 3];
for i = 1:length(ranks)
    % Keep largest singular values, and nullify others.
    approx_sigmas = sigmas; approx_sigmas(ranks(i):end) = 0;


    % Form the singular value matrix, padded as necessary
    ns = length(sigmas);
    approx_S = S; approx_S(1:ns, 1:ns) = diag(approx_sigmas);

    % Compute low-rank approximation by multiplying out component matrices.
    approx_tiger = U * approx_S * V';

    % Plot approximation
    subplot(4, 2, i + 1), imshow(approx_tiger), title(sprintf('Rank %d Tiger',
ranks(i)));
end
```

### *Amprente digitale*

In 1924 FBI a inceput sa colecteze amprente digitale si acum are mai mult de 100 de milioane de astfel de amprente in fisierele sale. Pentru a reduce costul de depozitare, FBI a inceput sa lucreze cu Laboratorul National din Los Alamos, precum si cu alte grupuri, pentru a gasi metode de comprimare ale fisiereleor, care contineau amprente in forma electronica. In figura alaturata avem amprenta originala si reconstructia ei, dintr-un fisier comprimat la o rata 26 : 1, prin metoda descompunerii valorilor singulare.



Original

Reconstructie

### ■ *Sinteza teorie*

- orice matrice  $A \in \mathcal{M}_{m \times n}(\mathbb{R})$  poate fi descompusa sub forma

$$A = \left( u_1 \mid u_2 \mid \dots \mid u_r \right) \begin{pmatrix} \sigma_1 & 0 & \dots & 0 \\ 0 & \sigma_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma_r \end{pmatrix} \begin{pmatrix} v_1^t \\ v_2^t \\ \vdots \\ v_r^t \end{pmatrix}$$

unde  $u_i$  si  $v_i$  sunt vectori coloana iar  $\sigma_i > 0$  sunt numere reale pozitive numite **valori singulare** ale matricei.

- descompunerea de mai sus este echivalenta cu

$$A = \sigma_1 \mathbf{u}_1 \cdot \mathbf{v}_1^t + \sigma_2 \mathbf{u}_2 \cdot \mathbf{v}_2^t + \dots + \sigma_r \mathbf{u}_r \cdot \mathbf{v}_r^t$$

si poarta numele de **decompunerea valorilor singulare**



### *Remarca*

Numarul  $r$  al valorilor singulare este de fapt **rangul matricei  $A$** . Mai mult, daca asezam valorile singulare intr-o ordine descrescatoare

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_r > 0$$

atunci aceste valori ne dau de fapt distantele de la matricea  $A$  la multimile matricelor de rang mai mic

$$\sigma_{k+1} = \min_{rang(B)=k} dist(A, B), \quad k < r = rang(A)$$

Aceasta relatie se interpreteaza in felul urmatoar: distanta de la  $A$  la cea mai "apropiata" matrice de rang  $k$  este  $\sigma_{k+1}$ . Distanța dintre doua matrice se calculeaza cu formula

$$dist(A, B) = \max_{\|u\|=1} \|(A - B)u\|$$

unde  $u$  este un vector coloana si norma lui  $\|u\|$  este cea obisnuita. De remarcat ca spatiul matricelor este un spatiu metric, pe care putem defini distante extrem de utile in probleme de aproximare.

### ■ *Algoritmul de obtinere a descompunerii SVD*

- valorile singulare  $\sigma_1, \sigma_2, \dots, \sigma_r$  se afla cu formulele

$$\sigma_1 = \sqrt{\lambda_1}, \sigma_2 = \sqrt{\lambda_2}, \dots, \sigma_r = \sqrt{\lambda_r}$$

unde  $\lambda_1, \lambda_2, \dots, \lambda_r$  sunt **valorile proprii nenule** ale matricei  $A^t A$ .

- vectorii  $v_1, v_2, \dots, v_r$  sunt **vectori proprii ortonormati** corespunzatori valorilor proprii  $\lambda_1, \lambda_2, \dots, \lambda_r$

$\implies$  daca avem o **valoare proprie multipla** se aplica procedeul Gram-Schmidt pentru a obtine vectori proprii ortonormati corespunzatori acesteia

⇒ pentru **valorile proprii simple** (ordine de multiplicitate 1) se imparte la norma sa un vector propriu corespunzator

- vectorii  $u$  se obtin cu formulele

$$u_i = \frac{1}{\sigma_i} Av_i, \quad i = \overline{1, r}$$



### Remarca

De retinut ca matricea  $A^t A$  este simetrica si orice matrice simetrica este dia-gonalizabila iar matricea care o diagonalizeaza poate fi aleasa cu coloane reprezentate de catre vectori ortonormati. Mai mult orice valoare proprie a lui  $A^t A$  va fi pozitiva. Asadar algoritmul de mai sus va functiona intotdeauna si nu se pune problema ca dimensiunile subspatiilor proprii sa nu coincida cu multiplicatatile algebrice corespunzatoare.

### Forme patratice

- daca  $\bar{x} \in \mathbb{R}^n$  este un vector linie si  $A \in \mathcal{M}_n(\mathbb{R})$  este o matrice **simetrica**, numim expresia

$$q_A(\bar{x}) = \bar{x} \cdot A \cdot \bar{x}^t$$

forma patratice asociata lui  $A$ , adica

$$q_A(x_1, x_2, \dots, x_n) = \sum_{i=1}^n a_{ii}^2 x_i^2 + \sum_{i,j=1}^n a_{ij} x_i x_j, \quad \bar{x} = (x_1, x_2, \dots, x_n)$$

- o forma patratice  $q_A$  este **pozitiv definita**  $\iff q_A(\bar{x}) > 0, \quad \forall \bar{x} \in \mathbb{R}^n$   
 $\iff A$  este pozitiv definita  $\iff$  toti **minorii principali sunt strict pozitivi**
- o forma patratice  $q_A$  este **negativ definita**  $\iff q_A(\bar{x}) < 0, \quad \forall \bar{x} \in \mathbb{R}^n$   
 $\iff A$  este negativ definita  $\iff$  **minorii principali alterneaza ca semn si primul este strict negativ**
- daca  $P$  este matricea care diagonalizeaza pe  $A$  (adica  $A = PDP^{-1}$ ) atunci prin transformarea  $\bar{x}^t = P\bar{y}^t$  forma patratice devine

$$q_D(\bar{y}) = \lambda_1 y_1^2 + \lambda_2 y_2^2 + \dots + \lambda_n y_n^2$$

- o forma patratice este pozitiv definita  $\iff$  toate valorile proprii sunt **strict pozitive**
- o forma patratice este negativ definita  $\iff$  toate valorile proprii sunt **strict negative**

### Probleme de optimizare

### Teorema de extrem conditionat

Fie  $A \in \mathcal{M}_n(\mathbb{R})$  o matrice simetrica a carui valori proprii sunt:

$$\lambda_1 \leq \lambda_2 \leq \dots \leq \lambda_n$$

Atunci forma patratica  $q_A(\bar{\mathbf{x}})$  atinge o valoare maxima si una minima pe multimea vectorilor  $\bar{\mathbf{x}}$  pentru care  $\|\bar{\mathbf{x}}\| = 1$ .


**Valoarea maxima** este  $\lambda_n$  si este atinsa intr-un vector propriu corespunzator lui  $\lambda_n$ .

**Valoarea minima** este  $\lambda_1$  si este atinsa intr-un vector propriu corespunzator lui  $\lambda_1$ .



### Remarca

Pentru a vizualiza problema, in cazul  $\bar{\mathbf{x}} = (x, y) \in \mathbb{R}^2$ , forma patratica  $q_A$  poate fi reprezentata ca fiind o suprafata  $z = \bar{\mathbf{x}} \cdot A \cdot \bar{\mathbf{x}}^t$  intr-un sistem de axe Oxyz. Acum  $\|\bar{\mathbf{x}}\| = 1$  devine cercul unitate  $x^2 + y^2 = 1$ .



Geometric, problema aflarii minimului si maximului, relativ la conditionarea  $\|\bar{\mathbf{x}}\| = 1$ , se reduce la **aflarea punctului aflat la cota z cea mai mare si respectiv cota z cea mai mica** pe intersectia dintre suprafata si cilindrul drept format de cercul unitate

Fie  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  o functie pentru care derivatele partiale de ordin doi exista si sunt continue. Fie  $\bar{\mathbf{a}} = (a_1, a_2, \dots, a_n)$  un punct critic al lui  $f$ . Atunci  $f$  are un **punct de minim local** in  $\bar{\mathbf{a}}$  daca matricea Hessiana:

$$H(\bar{\mathbf{a}}) = \begin{pmatrix} \frac{\partial^2 f}{\partial x_1 x_1}(\bar{\mathbf{a}}) & \frac{\partial^2 f}{\partial x_1 x_2}(\bar{\mathbf{a}}) & \dots & \frac{\partial^2 f}{\partial x_1 x_n}(\bar{\mathbf{a}}) \\ \frac{\partial^2 f}{\partial x_2 x_1}(\bar{\mathbf{a}}) & \frac{\partial^2 f}{\partial x_2 x_2}(\bar{\mathbf{a}}) & \dots & \frac{\partial^2 f}{\partial x_2 x_n}(\bar{\mathbf{a}}) \\ \vdots & \vdots & \dots & \vdots \\ \frac{\partial^2 f}{\partial x_n x_1}(\bar{\mathbf{a}}) & \frac{\partial^2 f}{\partial x_n x_2}(\bar{\mathbf{a}}) & \dots & \frac{\partial^2 f}{\partial x_n x_n}(\bar{\mathbf{a}}) \end{pmatrix}$$

este pozitiv definita. Analog,  $f$  are un **punct de maxim local** in  $\bar{\mathbf{a}}$  daca matricea Hessiana este negativ definita. Daca matricea  $H(\bar{\mathbf{a}})$  are si valori proprii pozitive si negative atunci avem un **punct sa**.



## Probleme rezolvate

### Problema 1

Aflati valorile singulare ale matricei

$$A = \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix}$$

si apoi determinati descompunerea valorilor singulare.

*Solutie:* Intai aflam valorile singulare care prin definitie sunt valorile proprii ale matricei  $A^t A$ . Avem:

$$A^t A = \begin{pmatrix} 1 & 0 & 1 \\ 1 & 1 & 0 \end{pmatrix} \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}$$

Polinomul caracteristic este:

$$p(\lambda) = \det(A^t A - \lambda I) = \lambda^2 - 4\lambda + 3$$

iar valorile proprii vor fi  $\lambda_1 = 3$  si  $\lambda_2 = 1$ . Deci valorile singulare ale matricei  $A$  sunt:

$$\sigma_1 = \sqrt{\lambda_1} = \sqrt{3}, \quad \sigma_2 = \sqrt{\lambda_2} = 1$$

In continuare aflam subspatiile proprii corespunzatoare lui  $\lambda_1$  si  $\lambda_2$  :

$$S_{\lambda_1} = \{v : (A^t A - \lambda_1 I)v = \bar{0}\} = \left\{ v = \begin{pmatrix} \alpha \\ \alpha \end{pmatrix} : \alpha \in \mathbb{R} \right\}$$

Asadar  $v = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$  este un vector dintr-o baza a acestuia dar avem nevoie de un

vector de norma 1 si prin urmare  $v_1 = \frac{v}{\|v\|} = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix}$  este vectorul

cautat Analog gasim:

$$S_{\lambda_2} = \{v : (A^t A - \lambda_2 I)v = \bar{0}\} = \left\{ v = \begin{pmatrix} \alpha \\ -\alpha \end{pmatrix} : \alpha \in \mathbb{R} \right\}$$

si prin urmare  $v_2 = \frac{v}{\|v\|} = \frac{1}{\sqrt{2}} \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{pmatrix}$  este vectorul cautat.

Pentru a afla  $u_1$  si  $u_2$  aplicam formula  $u_i = \frac{1}{\sigma_i} Av_i$  si gasim:

$$u_1 = \frac{1}{\sqrt{3}} \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix} = \begin{pmatrix} \frac{\sqrt{6}}{3} \\ \frac{\sqrt{6}}{6} \\ \frac{\sqrt{6}}{6} \end{pmatrix}$$

respectiv:

$$u_2 = 1 \cdot \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{pmatrix} = \begin{pmatrix} 0 \\ -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} \end{pmatrix}$$

In final descompunerea cautata este:

$$A = \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} = \begin{pmatrix} \frac{\sqrt{6}}{3} & 0 \\ \frac{\sqrt{6}}{6} & -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{6}}{6} & \frac{\sqrt{2}}{2} \end{pmatrix} \begin{pmatrix} \sqrt{3} & 0 \\ 0 & 1 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \end{pmatrix}$$

### Problema 2

Aflati minimul si maximul formei patratice

$$q(x, y) = 5x^2 + 5y^2 + 4xy$$

atunci cand  $x^2 + y^2 = 1$ .

*Solutie:* Forma patratice poate fi exprimata in forma matriciala ca:

$$q(x, y) = 5x^2 + 5y^2 + 4xy = \begin{pmatrix} x & y \end{pmatrix} \begin{pmatrix} 5 & 2 \\ 2 & 5 \end{pmatrix} \begin{pmatrix} x \\ y \end{pmatrix}$$

Se arata usor ca valorile proprii sunt  $\lambda_1 = 7$  si  $\lambda_2 = 3$ . Un vector propriu corespunzator lui  $\lambda_1$  este  $v_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$  si unul corespunzator lui  $\lambda_2$  este

$v_2 = \begin{pmatrix} -1 \\ 1 \end{pmatrix}$ . Pentru a putea aplica teorema de extrem conditionat trebuie sa normalizam acesti vectori:

$$u_1 = \frac{v_1}{\|v_1\|} = \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix}, \quad u_2 = \frac{v_2}{\|v_2\|} = \begin{pmatrix} -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix}$$

In concluzie:

Maximul conditionat are valoarea 7 si se obtine in punctul  $(x, y) = \left(\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}\right)$

Minimul conditionat are valoarea 3 se se obtine in punctul  $(x, y) = \left(-\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}\right)$



## Probleme propuse

### A. Consolidare cunostinte

**Problema A.1.** Aratati ca daca  $A \in M_{m \times n}(\mathbb{R})$  este o matrice oarecare, atunci  $A^t A$  are valori proprii reale si pozitive.

**Problema A.2.** Pentru orice transformare liniara  $T : \mathbb{R}^n \rightarrow \mathbb{R}^p$  putem schimba sistemul de coordonate in  $\mathbb{R}^n$  si  $\mathbb{R}^p$  astfel incat relativ la noile sisteme de coordonate  $T$  sa fie o scalare neuniforma, cu factori posibil nuli.

Indiciu: teorema generala de descompunere a valorilor singulare

### B. Tehnica de calcul

**Problema B.1.** Aflati descompunerea valorilor singulare pentru matricele:

$$A = \begin{pmatrix} 1 & 0 \\ -2 & -2 \\ 0 & 1 \end{pmatrix}, \quad B = \begin{pmatrix} 3 & 2 & 2 \\ 2 & 3 & -2 \end{pmatrix}$$

$$C = \begin{pmatrix} 0 & 1 & 1 \\ \sqrt{2} & 2 & 0 \\ 0 & 1 & 1 \end{pmatrix}, \quad D = \begin{pmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \end{pmatrix}$$

**Problema B.2.** Sa se determine o baza ortonormata in care transformarea

liniara  $T : \mathbb{R}^3 \rightarrow \mathbb{R}^3$  de matrice  $A = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & \frac{-1}{\sqrt{2}} \\ \frac{1}{2} & \frac{1}{2} & \frac{1}{\sqrt{2}} \\ \frac{-1}{\sqrt{2}} & \frac{1}{\sqrt{2}} & 0 \end{pmatrix}$  are forma diagonala.


**Problema B.3.** Aflati punctele critice ale functiei:

$$f(x, y) = \frac{x^3}{3} + xy^2 - 8xy + 3$$


si folositi valorile proprii ale Hessienei pentru a decide care dintre ele sunt puncte de minim local, maxim local sau puncte sa.

### C. Probleme cu caracter practic-aplicativ

**Problema C.1.** Un dreptunghi este înscris în elipsa  $4x^2 + 9y^2 = 36$  ca în figura. Folosiți teoria formelor patratice pentru a afla valorile pozitive ale lui  $x$  și  $y$  pentru care dreptunghiul înscris are aria maximă.



**Problema C.2.** Fie matricea  $A = \begin{pmatrix} 4 & 11 & 14 \\ 8 & 7 & -2 \end{pmatrix}$ , atunci aplicația liniară indusă  $\bar{x} \rightarrow A\bar{x}$  transformă sfera unitate  $\{\bar{x} \in \mathbb{R}^3 : \|\bar{x}\| = 1\}$  din  $\mathbb{R}^3$  într-o elipsă din  $\mathbb{R}^2$ , la fel ca în figura. Aflați un vector unitate  $\bar{x}$  pentru care lungimea  $\|A\bar{x}\|$  este maximă și calculați această lungime.



## Bibliografie

- [1] H. Anton, C. Rorres. *Elementary Linear Algebra. Applications Version* Ed. Wiley, 2014.
- [2] O. Bundau, A. Juratoni *Exercitii si probleme de algebra liniara*, Ed. Politehnica, 2012.
- [3] C. D. Meyer. *Matrix Analysis and Applied Linear Algebra*, SIAM, 2000.
- [4] D. Lay. *Linear Algebra and its Applications*, Ed. Addison-Wesley, 2012.