

"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 scanata si apoi stocata ca o matrice A atasand fiecarui pixel o valoare numerica in functie de nivelul de gri al acestuia.. Daca folosim 256 nivele diferite de gri (0= alb, 255 = negru), atunci elementele matricei ar fi numere intregi cuprinse intre 0 si 255. Imaginea poate fi recuperata din matricea A afisand pixelii colorati in functie de nivelele lor de gri. Daca matricea este de tip $m \times n$ atunci am putea sa stocam toate cele $m \cdot n$ date individual. O alternativa consta in gasirea unei descompuneri a matricei pentru care sa fie nevoie de mai putine date. Spre exemplu, daca 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 $\mathbf{u}_i \in \mathcal{M}_{1 \times m}(\mathbb{R})$, $\mathbf{v}_i \in \mathcal{M}_{1 \times n}(\mathbb{R})$ si $\sigma_i > 0$, atunci nu trebuie sa stocam decat rm date pentru cei r de u_i , rn date pentru cei r de v_i si r date pentru cei r de σ_i . In concluzie $r+rm+rn = r(m+n+1)$ date. Ce nu e suficient de evident la aceasta descompunere este ca fiecare termen este de fapt o matrice $m \times n$. Tinand cont de modul in care am modelat matematic stocarea fotografiei alb-negru o astfel de matrice adauga cateva nuante de gri fiecarui pixel al imaginii urmand ca toate impreuna sa realizeze reconstructia totala a acesteia. Sa presupunem acum ca unii dintre acesti σ_i sunt foarte mici atunci eliminand termenii corespunzatori lor vom obtine ceea ce numim o **aproximatie de rang k** a lui A :

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

In acest fel am putea stoca doar aceste $k(m + n + 1)$ date si vom obtine o aproximare a imaginii intiale, suficient de buna pentru scopul nostru. Spre exemplu o aproximare de rang 100 a unei imagini cu 1000×1000 pixeli are nevoie doar de $100(1000 + 1000 + 1) = 200.100$ date, astfel rezulta o compresie cu o rata de compresie de aproape 5 : 1.

Mai jos aveti cateva aproximari ale versiunii alb-negru a imaginii de la inceputul capitolului:

Reconstructie folosind matricea intreaga



Reconstructie folosind o aproximare de rang 100



Reconstructie folosind o aproximare de rang 10



Reconstructie folosind o aproximare de rang 3



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

```
% 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 fisierelor, care contin 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

► Sinteză teorie

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

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

unde u_i și 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

$$A = \sigma_1 u_1 \cdot v_1^t + \sigma_2 u_2 \cdot v_2^t + \dots + \sigma_r u_r \cdot v_r^t$$

si poarta numele de **decomponerea 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

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

Aceasta relatie se interpreteaza in felul urmator: distanta de la A la cea mai "apropiata" matrice de rang k este σ_{k+1} . Distanta dintre doua matrice se calculeaza cu formula

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

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

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

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 valoilor proprii $\lambda_1, \lambda_2, \dots, \lambda_r$

⇒ daca avem o **valoare proprie multipla** se aplica procedeul Gram-Schmidt pentru a obtine vectori proprii ortonormati corespunzatori acestieia

⇒ 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 diagonalizabila 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 multiplicitatile algebrice corespunzatoare.

► **Inversa generalizata si aplicatii**

- abordarile matematice, bazate pe metode exacte de calcul, esueaza de obicei in practica, drept care ajungem la metode numerice de aproximare a valorilor dorite

- pentru o matrice oarecare $A \in M_{m \times n}(\mathbb{R})$ cu descompunerea valorilor singulare in forma redusa

$$A = U \cdot \Sigma \cdot V^t$$

inversa generalizata Moore-Penrose este definita ca fiind

$$A^+ = V \cdot \Sigma^+ \cdot U^t$$

unde Σ^+ se afla prin inversarea valorilor singulare de pe diagonala principala

- inversa generalizata are urmatoarele proprietati utile

$$AA^+A = A$$

$$A^+AA^+ = A^+$$

$$\text{proj}_{\text{col}(A)} v = AA^+v \quad \text{si} \quad \text{proj}_{\text{Ker}(A)} v = (I - A^+A)v$$

adica matricele AA^+ si $I - A^+A$ sunt cele care realizeaza proiectarea vectorilor pe subspatiile $\text{col}(A) = \text{Im}(A)$ si $\text{Ker}(A)$



Remarca

Stim sa rezolvam un sistem liniar, scris in forma generala ca $A\bar{x} = \bar{b}$, cat timp $\bar{b} \in \text{col}(A)$, conditie care ne asigura ca sistemul este compatibil. In practica, cand modelam un fenomen prin intermediul unui sistem liniar de ecuatii, elementele matricei coeficientilor A cat si termenii liberi \bar{b} sunt masurate, fiind supuse unor **erori de masurare**. Din acest motiv orice eroare oricat de mica de masurare va duce la obtinerea unui sistem incompatibil. Prin urmare nu este adevarat sa cautam sa rezolvam exact un astfel de sistem liniar, ci mai degraba sa tinem cont de posibilele erori de masurare si sa sa identificam acea solutie \hat{x} care "se potriveste cel mai bine" sistemului gasit. Adica acea solutie pentru care eroarea $\|A\hat{x} - b\|$ sa

fie minima, unde $\|\cdot\|$ este norma unui vector coloana. Se argumenteaza usor ca o astfel de solutie aproximativa este

$$\hat{x} = A^+ \bar{b} + (I - A^+ A)v$$

unde v este un vector coloana oarecare. Solutia \hat{x} se numeste **solutie gasita prin metoda celor mai mici patrate** caci norma anterioara implica o suma de patrate.

- solutia gasita prin metoda celor mai mici patrate este unica daca $A^t A$ este inversabila

► 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 patratica asociata lui A , adica

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

- o forma patratica q_A este **pozitiv definita** $\iff q_A(\bar{x}) > 0, \forall \bar{x} \in \mathbb{R}^n \iff A$ este pozitiv definita \iff toti minorii principali sunt strict pozitivi
- o forma patratica q_A este **negativ definita** $\iff q_A(\bar{x}) < 0, \forall \bar{x} \in \mathbb{R}^n \iff A$ 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 patratica devine

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

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

► Probleme de optimizare si de valori proprii

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


Valoarea maxima este λ_n si este atinsa intr-un vector propriu corespunzator lui λ_n .

Valoarea minima este λ_1 si este atinsa intr-un vector propriu corespunzator lui λ_1 .



Remarca

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



Geometric, problema aflarii minimului si maximului, relativ la conditionarea $\|\bar{x}\| = 1$, 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 $\bar{a} = (a_1, a_2, \dots, a_n)$ un punct critic al lui f . Atunci f are un **punct de minim local** in \bar{a} daca matricea Hessiană:

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

este pozitiv definita. Analog, f are un **punct de maxim local** in \bar{a} daca matricea Hessiană este negativ definita. Daca matricea $H(\bar{a})$ 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 λ_1 si λ_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:

$$\textcolor{red}{u}_1 = \frac{1}{\sqrt{3}} \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{pmatrix} = \begin{pmatrix} \frac{\sqrt{6}}{3} \\ \frac{\sqrt{6}}{6} \\ \frac{\sqrt{6}}{6} \end{pmatrix}$$

respectiv:

$$\textcolor{red}{u}_2 = 1 \cdot \begin{pmatrix} 1 & 1 \\ 0 & 1 \\ 1 & 0 \end{pmatrix} \begin{pmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{pmatrix} = \begin{pmatrix} 0 \\ -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} \end{pmatrix}$$

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 patratica 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 λ_1 este $v_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ si unul corespunzator lui λ_2 este $v_2 = \begin{pmatrix} -1 \\ 1 \end{pmatrix}$. Pentru a putea aplica teorema de extrem conditionat trebuie sa normalizam acestei 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 $(x, y) = (\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}})$
 Minimul conditionat are valoarea 3 se se obtine in punctul $(x, y) = (-\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}})$

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 diagonală.


Problema B.3. Aflati punctele critice ale functiei:

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


si folositi valorile proprii ale Hessianei 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 inscris in elipsa $4x^2 + 9y^2 = 36$ ca in figura. Folositi teoria formelor patratice pentru a afla valorile pozitive ale lui x si y pentru care dreptunghiul inscris are aria maxima.



Problema C.2. Fie matricea $A = \begin{pmatrix} 4 & 11 & 14 \\ 8 & 7 & -2 \end{pmatrix}$, atunci aplicatia liniara in dusă $\bar{x} \rightarrow A\bar{x}$ transforma sfera unitate $\{\bar{x} \in \mathbb{R}^3 : \|\bar{x}\| = 1\}$ din \mathbb{R}^3 intr-o elipsa din \mathbb{R}^2 , la fel ca in figura. Aflati un vector unitate \bar{x} pentru care lungimea $\|A\bar{x}\|$ este maxima si calculati aceasta 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.