

## Seminar 5

# Descompunerea valorilor singulare și aplicațiile sale

Descompunerea valorilor singulare (DVS) este una dintre cele mai puternice metode în algebra liniară. Probleme importante precum calculul rangului unei matrice, determinarea bazelor ortogonale pentru subspații liniare, calculul proiecțiilor ortogonale pe subspații liniare, problema celor mai mici pătrate sunt rezolvate cel mai bine folosind DVS. Acest seminar este dedicat metodelor numerice de descompunere a valorilor singulare și aplicațiilor lor.

### 5.1 Preliminarii

Descompunerea valorilor singulare a unei matrice  $\forall A \in \mathbb{R}^{m \times n}$  este definită astfel: există două matrice ortogonale  $U \in \mathbb{R}^{m \times m}$  și  $V \in \mathbb{R}^{n \times n}$  astfel încât

$$U^T A V = \Sigma = \begin{bmatrix} \Sigma_1 & 0 \\ 0 & 0 \end{bmatrix},$$

unde

$$\Sigma_1 = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_r) \in \mathbb{R}^{r \times r},$$

cu

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

Numerele reale pozitive  $\sigma_i$ ,  $i = 1 : r$  și  $\sigma_i = 0$ ,  $i = r + 1 : \min(m, n)$  sunt numite *valori singulare* ale lui  $A$  și sunt *totdeauna* ordonate descrescător.

Se poate arăta (vezi cursul) că valorile singulare nenule sunt rădăcinile pătrate ale valorilor proprii nenule ale matricelor simetrice și pozitiv semi-definite  $B = A^T A$  și  $C = A A^T$ , i.e. dacă valorile proprii sunt ordonate descrescător atunci,  $\sigma_i(A) = \sqrt{\lambda_i(A^T A)} = \sqrt{\lambda_i(A A^T)}$ ,  $i = 1 : r$ .

În concluzie, calculul DVS este un proces infinit care poate fi trunchiat când aproximarea este considerată acceptabilă. Pentru detalii asupra algoritmului DVS vezi cursul.

Cele mai importante aplicații ale DVS ale unei matrice date  $A \in \mathbb{R}^{m \times n}$  sunt:

- Rangul lui  $A$  este numărul  $r$  al valorilor sale singulare nenule. Pentru conceptul de *rang numeric* consultă cursul.
- Cea mai mare valoare singulară a lui  $A$  este norma spectrală a lui  $A$ , i.e.  $\sigma_1 = \|A\|_2 = \max\|Ax\|_2 = \|x\| = 1$ . Alte norme matriceale, conservate de către transformările ortogonale (cum este norma Frobenius), pot fi exprimate cu ajutorul valorilor singulare.
- Dacă  $r = \text{rang}A$  și notăm  $U_1 = U(:, 1 : r)$ ,  $U_2 = U(:, r + 1 : m)$ ,  $V_1 = V(:, 1 : r)$  și  $V_2 = V(:, r + 1 : n)$  atunci
  - coloanele lui  $U_1$  formează o bază ortogonală pentru subspațiul liniar  $\text{Im}A \subset \mathbb{R}^m$ ;
  - coloanele lui  $U_2$  formează o bază ortogonală pentru subspațiul liniar  $\text{Ker}A^T \subset \mathbb{R}^m$ ;
  - coloanele lui  $V_1$  formează o bază ortogonală pentru subspațiul liniar  $\text{Im}A^T \subset \mathbb{R}^n$ ;
  - coloanele lui  $V_2$  formează o bază ortogonală pentru subspațiul liniar  $\text{Ker}A \subset \mathbb{R}^n$ .
- Cum este cunoscut, dacă coloanele unei matrice  $W$  formează o bază ortogonală pentru un subspațiu liniar  $\mathcal{S}$ , atunci  $P = WW^T$  este o matrice proiecție ortogonală pe  $\mathcal{S}$ .  
În concluzie, folosind DVS putem construi proiecții ortogonale pe subspațiile liniare  $\text{Im}A, \text{Ker}A^T \subset \mathbb{R}^m, \text{Im}A^T, \text{Ker}A \subset \mathbb{R}^n$ .
- Rezolvarea problemei generale a celor mai mici pătrate, i.e. aflarea pseudosoluției de normă eucidiană minimă a sistemului  $Ax = b$

$$\|x^*\| = \min_{\|x\|} \|b - Ax\|$$

pentru un vector dat  $b \in \mathbb{R}^m$ . Calculul soluției sistemului problemei generale celor mai mici pătrate este

$$x^* = A^\# b = V \Sigma^\# U^T b = \sum_{k=1}^r \frac{v_k u_k^T b}{\sigma_k},$$

unde  $u_k, v_k$  sunt coloanele corespunzătoare ale lui  $U$  și  $V$ .

- Rezolvarea altor probleme de optimizare (vezi [3], [6]).
- Calculul pseudoinversei Moore-Penrose a lui  $A$ :

$$A^\# = V \Sigma^\# U^T = \sum_{k=1}^r \frac{v_k u_k^T}{\sigma_k}.$$

**Observație.** Valorile singulare ale unei matrice sunt perfect condiționate numeric. Poate fi atătat (vezi [3],[5],[6]) că

$$|\sigma_k(A + E) - \sigma_k(A)| \leq \sigma_1(E) = \|E\|_2$$

unde matricea  $E$  este o perturbație a lui  $A$ , i.e. valorile singulare sunt modificate cât norma spectrală a perturbației  $E$ . Deci, dacă perturbația este mică, variația valorilor singulare va fi mică. Acesta este motivarea afirmației că DVS este *cea mai bună metodă* de a rezolva toate probleme numerice menționate mai sus.

## 5.2 Probleme rezolvate

### 5.2.1 Proprietățile DVS

**Problema 5.1** Fie  $A \in \mathbb{R}^{m \times n}$  o matrice dată și  $P \in \mathbb{R}^{m \times m}$ ,  $Q \in \mathbb{R}^{n \times n}$  două matrice ortogonale.

**a.** Demonstrați că matricele  $B = A^T$  și  $C = PAQ$  au aceleași valori singulare cu matricea  $A$ . Dacă  $A = U\Sigma V^T$  este DVS al lui  $A$  scrieți DVS ale matricelor  $B$  și  $C$ .

**b.** Demonstrați că matricea  $D = \alpha A$ , unde  $\alpha \in \mathbb{R}$ , are valorile singulare  $\sigma_i(D) = |\alpha|\sigma_i(A)$  și scrieți DVS ale lui  $D$ .

**Soluție. a.** Transpusa lui  $A = U\Sigma V^T$  este  $B = A^T = V\Sigma^T U^T$ , întrucât DVS lui  $B$  este  $B = U_B \Sigma_B V_B^T$ , unde  $U_B = V$ ,  $V_B = U$  sunt ortogonale și  $\Sigma_B = \Sigma^T$  este diagonală. Dar  $\Sigma_B$  și  $\Sigma$  au aceeași diagonală, deci  $\sigma(B) = \sigma(A)$ . Similar,  $C = PAQ = PU\Sigma V^T Q = U_C \Sigma V_C^T$ , unde  $U_C = PU$ ,  $V_C = Q^T V$ , sunt ortogonale, este DVS lui  $C$ . Bineînțeles,  $\sigma(C) = \sigma(A)$ .

**b.** Dacă  $\alpha = 0$ , atunci  $D = 0$  are toate valorile singulare egale cu zero și DVS lui  $D$  este e.g.  $D$  (luând  $U_D = I_m$  și  $V_D = I_n$ ). Dacă  $\alpha \neq 0$ , atunci  $D = \alpha A = \frac{\alpha}{|\alpha|} U |\alpha| \Sigma V^T = U_D \Sigma_D V_D^T$ , unde  $U_D = \frac{\alpha}{|\alpha|} U$  și  $V_D = V$  sunt ortogonale (verifică!) și  $\Sigma_D = |\alpha| \Sigma$  este diagonală cu termeni diagonali pozitivi descrescători  $\sigma_i(D) = |\alpha|\sigma_i(A)$ .

**Problema 5.2 a.** Demonstrați că norma matriceală Frobenius  $\|\cdot\|_F$ , definită pentru toate matricele  $A \in \mathbb{R}^{m \times n}$  de

$$\|A\|_F = \sqrt{\operatorname{tr}(A^T A)} = \sqrt{\operatorname{tr}(A A^T)} = \sqrt{\sum_{i=1}^m \sum_{j=1}^n a_{ij}^2}$$

și norma matriceală spectrală  $\|\cdot\|_2$ , definită de

$$\|A\|_2 = \max_{\|x\|_2 = 1} \|Ax\|_2,$$

sunt invariante la transformări ortogonale, i.e.

$$\|U^T A\|_F = \|AV\|_F = \|A\|_F \quad \|U^T A\|_2 = \|AV\|_2 = \|A\|_2,$$

unde  $U \in \mathbb{R}^{m \times m}$  și  $V \in \mathbb{R}^{n \times n}$  sunt ortogonale, și exprimați-le în funcție de valorile singulare ale lui  $A$ .

**b.** Demonstrați că

$$\|A\|_2 \leq \|A\|_F \leq \sqrt{\operatorname{rang}(A)} \|A\|_2.$$

**c.** Dacă matricea  $A$  este pătratică și nesingulară, exprimați numerele de condiționare  $\kappa_F = \|A\|_F \cdot \|A^{-1}\|_F$  și  $\kappa_2 = \|A\|_2 \cdot \|A^{-1}\|_2$  în funcție de valorile singulare  $A$ .

**Soluție. a.** Începem prin a demonstra că norma matriceală Frobenius este invariabilă la transformări ortogonale. Avem  $\|U^T A\|_F^2 = \operatorname{tr}(A^T U U^T A) = \operatorname{tr}(A^T A) = \|A\|_F^2$  și  $\|AV\|_F^2 = \operatorname{tr}(AVV^T A^T) = \operatorname{tr}(AA^T) = \|A\|_F^2$ . Dacă  $A = U\Sigma V^T$  este DVS a lui  $A$ , atunci

$$\|A\|_F = \|\Sigma\|_F = \sqrt{\sigma_1^2 + \sigma_1^2 + \dots + \sigma_r^2},$$

unde  $r$  este numărul valorilor singulare nenule ale lui  $A$ .

Deoarece norma vectorială euclidiană este invariantă la transformările ortogonale, i.e.  $\|Qx\|_2 = \|x\|_2$  pentru toate matricele ortogonale  $Q$  și toți vectorii  $x$ , avem pentru norma spectrală

$$\|U^T A\|_2 = \max_{\|x\|_2 = 1} \|U^T Ax\|_2 = \max_{\|x\|_2 = 1} \|Ax\|_2 = \|A\|_2$$

și

$$\|AV\|_2 = \max_{\|x\|_2 = 1} \|AVx\|_2 = \max_{\|w\|_2 = 1} \|Aw\|_2 = \|A\|_2,$$

unde  $w = Vx$ . Pentru a exprima  $\|A\|_2$  în funcție de valorile singulare ale lui  $A$  avem:

$$\begin{aligned} \|A\|_2 &= \max_{\|x\|_2 = 1} \|Ax\|_2 = \max_{\|x\|_2 = 1} \|U\Sigma V^T x\|_2 = \max_{\|w\|_2 = 1} \|\Sigma w\|_2 = \\ &= \max_{\|w\|_2 = 1} \sqrt{\sigma_1^2 w_1^2 + \sigma_2^2 w_2^2 + \dots + \sigma_n^2 w_n^2} = \\ &= \max_{\|w\|_2 = 1} \sqrt{\sigma_1^2(1 - w_2^2 - \dots - w_n^2) + \sigma_2^2 w_2^2 + \dots + \sigma_n^2 w_n^2} = \\ &= \max_{\|w\|_2 = 1} \sqrt{\sigma_1^2 + (\sigma_2^2 - \sigma_1^2)w_2^2 + \dots + (\sigma_n^2 - \sigma_1^2)w_n^2}. \end{aligned}$$

Dar  $\sigma_1 \geq \sigma_i$  pentru toți  $i = 2 : n$ , deci  $\sigma_i^2 - \sigma_1^2 \leq 0$  pentru toți  $i = 2 : n$  și maximul este obținut pentru  $w_i = 0$  pentru toți  $i = 2 : n$ . În concluzie

$$\|A\|_2 = \sigma_1,$$

i.e. norma spectrală a lui  $A$  este cea mai mare valoare singulară a lui  $A$ .

**b.** Rangul  $r = \text{rang}(A)$  al matricei  $A$  este numărul valorilor singulare nenule ale lui  $A$ . Bineînțeles,  $\|A\|_2^2 = \sigma_1^2 \leq \sum_{i=1}^r \sigma_i^2 = \|A\|_F^2$ . Deci  $\|A\|_2 \leq \|A\|_F$ . Deoarece valorile singulare sunt totdeauna ordonate descrescător, avem  $\|A\|_F^2 = \sum_{i=1}^r \sigma_i^2 \leq r\sigma_1^2 = r\|A\|_2^2$ . Deci  $\|A\|_F \leq \sqrt{r}\|A\|_2$ .

*Observație.* Două norme matriceale  $\mu$  și  $\nu$  sunt numite *echivalente* dacă există două numere pozitive  $\kappa_1$  și  $\kappa_2$  astfel încât  $\kappa_1\nu(A) \leq \mu(A) \leq \kappa_2\nu(A)$  pentru toate matricele  $A$ . În concluzie  $\|\cdot\|_2$  și  $\|\cdot\|_F$  sunt două norme matriceale echivalente.

**c.** Dacă matricea  $A$  este pătratică ( $m = n$ ) și nesingulară, atunci  $\text{rang} A = n$ , i.e. toate valorile sale singulare sunt nenule. Deci, dacă  $A = U\Sigma V^T$  este DVS lui  $A$ , atunci  $\Sigma$  este nesingulară și  $A^{-1} = V\Sigma^{-1}U^T$ . Astfel, dacă  $\sigma(A) = \{\sigma_1, \sigma_2, \dots, \sigma_n\}$ , atunci valorile singulare ale lui  $A^{-1}$  sunt  $\sigma(A^{-1}) = \{1/\sigma_n, 1/\sigma_{n-1}, \dots, 1/\sigma_1\}$  (valorile singulare sunt totdeauna ordonate descrescător!). Așadar avem

$$\|A^{-1}\|_F = \sqrt{\frac{1}{\sigma_n^2} + \frac{1}{\sigma_{n-1}^2} + \dots + \frac{1}{\sigma_1^2}} \quad \text{și} \quad \|A^{-1}\|_2 = \frac{1}{\sigma_n}.$$

În concluzie

$$\kappa_F = \|A\|_F \cdot \|A^{-1}\|_F = \sqrt{\sigma_1^2 + \sigma_2^2 + \dots + \sigma_n^2} \cdot \sqrt{\frac{1}{\sigma_n^2} + \frac{1}{\sigma_{n-1}^2} + \dots + \frac{1}{\sigma_1^2}}$$

și

$$\kappa_2 = \|A\|_2 \cdot \|A^{-1}\|_2 = \frac{\sigma_1}{\sigma_n}.$$

**Problema 5.3** Fie  $A \in \mathbb{R}^{n \times n}$  o matrice simetrică, i.e. satisface condiția  $A^T = A$  și fie  $\lambda(A) = \{\lambda_1, \lambda_2, \dots, \lambda_n\}$ , cu  $|\lambda_1| \geq |\lambda_2| \geq \dots \geq |\lambda_n|$  mulțimea valorilor sale proprii. Demonstrați că valorile singulare ale lui  $A$  sunt  $\sigma_i = |\lambda_i|$ ,  $i = 1:n$ .

**Soluție.** Întâi, matricele simetrice au spectre proprii reale și forma lor Schur este diagonală (vezi problema rezolvată 4.7, seminar 4). Acum, fie  $S = Q^T A Q = \Lambda = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$  cu  $Q$  ortogonal și  $|\lambda_1| \geq |\lambda_2| \geq \dots \geq |\lambda_n|$ . Rezultă  $Q^T A^T A Q = Q^T A^T Q Q^T A Q = \Lambda \Lambda = \text{diag}(\lambda_1^2, \lambda_2^2, \dots, \lambda_n^2)$ . În concluzie,  $\sigma_i = \sqrt{\lambda_i(A^T A)} = \sqrt{\lambda_i(A^2)} = \sqrt{\lambda_i^2} = |\lambda_i|$ ,  $i = 1:n$ .

**Problema 5.4** Demonstrați că o matrice patratică are (cel puțin) o valoare singulară zero doar dacă are o valoare proprie zero.

**Soluție.** Fie  $A \in \mathbb{R}^{n \times n}$ . În seminarul 4 am demonstrat că  $\det A = \prod \lambda_i$ . Ținând cont că  $\sigma_i(A) = \sqrt{\lambda_i^2(A^T A)}$  avem  $0 \in \lambda(A) \Leftrightarrow \det A = 0 \Leftrightarrow \det A^T A = 0 \Leftrightarrow 0 \in \sigma(A)$ .

**Problema 5.5** Fie  $Q \in \mathbb{R}^{m \times n}$  o matrice cu coloanele ortogonale, i.e.  $Q^T Q = I_n$ .

a. Cât este  $\|Q\|_2$  ?

b. Fie  $R \in \mathbb{R}^{p \times n}$ ,  $p \geq m - n + 1$  o matrice obținută din  $Q$  prin eliminarea a cel mult  $n - 1$  linii. Demonstrați că  $\|R\|_2 = \|Q\|_2$ .

**Soluție. a.** Deoarece  $Q^T Q = I_n$ , toate valorile singulare ale lui  $Q$  sunt egale cu 1. Rezultă  $\|Q\|_2 = \sigma_1 = 1$ .

**b.** Pentru a arăta că  $\|R\|_2 = 1$ , se observă întâi că permutarea liniilor matricei este o transformare ortogonală și că o transformare ortogonală nu schimbă valorile singulare (vezi problema rezolvată 4.1). Așadar, permutările liniilor nu schimbă norma spectrală. Deci, nu pierdem din generalitate dacă presupunem că rândurile  $k = m - p \leq n - 1$  eliminate din matricea  $Q$  sunt ultimele, i.e. putem scrie  $Q = \begin{bmatrix} R \\ T \end{bmatrix}$ . Fie  $R = UCV^T$  DVS a matricei  $R$ , unde  $C = \text{diag}(c_1, c_2, \dots, c_n)$ , și  $c_1 \geq c_2 \geq \dots \geq c_n \geq 0$  sunt valorile singulare ale lui  $R$ . Dar  $Q^T Q = R^T R + T^T T = I_n$ . Rezultă  $R^T R = I_n - VC^2V^T = V(I_n - C^2)V^T = VS^2V^T$ , unde  $S = \text{diag}(s_1, s_2, \dots, s_n)$ , cu  $s_i = \sqrt{1 - c_i^2}$  valorile singulare ale matricei  $R$  în ordine crescătoare. Deoarece matricea  $T$  are cel mult  $n - 1$  linii, are cel mult  $n - 1$  valori singulare nenule. În concluzie,  $s_1 = 0$ , i.e.  $c_1 = \|R\|_2 = 1$ . Aparent, acesta este un rezultat uimitor: eliminarea unui număr de elemente posibile nenule ai unei matrice nu schimbă norma sa spectrală. Explicația constă în faptul că o asemenea eliminare nu modifică cea mai mare valoare singulară care este norma spectrală.

**Problema 5.6** Demonstrați că orice matrice  $m \times n$  reală este limita unei mulțimi de rang maxim  $m \times n$  real matriceal. Interpretați importanța acestui rezultat pentru practica numerică.

**Soluție.** Fie  $A = U\Sigma V^T$  DVS matricei  $A$ , unde  $\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_p)$ , cu  $p = \min(m, n)$ . Bineînțeles, există mulțimea de numere reale  $(\gamma_i^{(k)})_{k \in \mathbb{N}}$  ca  $\lim_{k \rightarrow \infty} \gamma_i^{(k)} = \sigma_i$  și  $\gamma_i^{(k)} \neq 0$

pentru toți  $i$  și  $k$ . Dacă definim matricele  $\Gamma_k \stackrel{\text{def}}{=} \text{diag}(\gamma_1^{(k)}, \gamma_2^{(k)}, \dots, \gamma_p^{(k)})$ , și  $A_k \stackrel{\text{def}}{=} U \Gamma_k V^T$ , atunci toate matricele  $A_k$  au rang maxim și  $\lim_{k \rightarrow \infty} A_k = A$ . Asta înseamnă că la apropierea de oricare matrice  $m \times n$  (inclusiv matricea  $m \times n$  nulă) există matrice de rang maxim. Astfel, într-un mediu de calcul aproximativ rangul matematic al unei matrice nu are relevanță deoarece erorile de rotunjire pot schimba rangul unei matrice date în rangul maxim. Această observație subliniază importanța conceptului de *rang numeric*.

## 5.2.2 Calculul DVS

**Problema 5.7** Fie  $u \in \mathbb{R}^m$ ,  $v \in \mathbb{R}^n$  doi vectori dați.

- Care este DVS lui  $A = uv^T$ ? Cât este rangul lui  $A$ ?
- Demonstrați că orice matrice de rang 1  $A \in \mathbb{R}^{m \times n}$  poate fi scrisă sub forma  $A = bc^T$ , unde  $b \in \mathbb{R}^m$ ,  $c \in \mathbb{R}^n$ .
- Dacă  $m = n$ , propuneți un algoritm care să calculeze DVS a lui  $A = I_n + uv^T$ . Cât este rangul lui  $A$ ?

**Soluție.** **a.** Dacă  $U_1 \in \mathbb{R}^{m \times m}$ ,  $V_1 \in \mathbb{R}^{n \times n}$  sunt reflectori Householder astfel luați încât  $U_1 u = \|u\|e_1 \in \mathbb{R}^m$  și  $V_1 v = \|v\|e_1 \in \mathbb{R}^n$ , atunci

$$U_1^T A V_1 = \begin{bmatrix} \|u\|\|v\| & 0 \\ 0 & 0 \end{bmatrix} \in \mathbb{R}^{m \times n}$$

este DVS a lui  $A$ . Valorile singulare sunt  $\sigma_1 = \|u\|\|v\|$  și  $\sigma_i = 0$  pentru  $i > 1$ . Bineînțeles,  $\text{rank}(A) = 1$  dacă  $u \neq 0$ ,  $v \neq 0$ , și zero altfel.

**b.** Dacă matricea  $A \in \mathbb{R}^{m \times n}$  are rangul 1, atunci valorile sale singulare sunt  $\sigma_1 \neq 0$  și  $\sigma_i = 0$  pentru  $i > 1$ . În concluzie, din DVS a lui  $A$ , i.e.  $U^T A V = \Sigma = \text{diag}(\sigma_1, 0, \dots, 0)$ , avem

$$A = U \Sigma V^T = U(:, 1) \sigma_1 (V(:, 1))^T = bc^T,$$

unde e.g.  $b = \sigma_1 U(:, 1) \in \mathbb{R}^m$ ,  $c = V(:, 1) \in \mathbb{R}^n$ .

**c.** Dacă  $u = 0$  și/sau  $v = 0$ , atunci  $A = I_n$  și luând  $U = V = I_n$  matricea  $A$  este propriul său DVS cu toate valorile proprii egale cu 1. Presupunând acum că  $u \neq 0$ ,  $v \neq 0$  și rezultă  $\bar{u} = \frac{u}{\|u\|}$  și  $\bar{v} = \frac{v}{\|v\|}$ . Acum putem construi o matrice ortogonală  $W \in \mathbb{R}^{n \times n}$  astfel încât  $W\bar{u} \perp \bar{v}$  (vezi problema rezolvată 3.4 din seminarul 3). Fie  $w = W\bar{u} \in \mathbb{R}^n$  cu, bineînțeles,  $\|w\| = 1$ . Procedând la fel ca în problema rezolvată 3.3 (vezi seminarul 3) putem acum calcula o matrice  $Y \in \mathbb{R}^{n \times (n-2)}$  cu coloane ortogonale (i.e.  $Y^T Y = I_{n-2}$ ) la fel cum matricea  $U = [\bar{v} \ w \ Y]$  să fie ortonormală. Desigur, matricea  $V = [w \ \bar{v} \ Y]$  este de asemenea ortogonală. Atunci

$$\begin{aligned} U^T A V &= U^T (I + uv^T) V = \begin{bmatrix} \bar{v}^T \\ w^T \\ Y^T \end{bmatrix} (I + uv^T) [w \ \bar{v} \ Y] = \\ &= \begin{bmatrix} \bar{v}^T (I + uv^T) w & \bar{v}^T (I + uv^T) \bar{v} & \bar{v}^T (I + uv^T) Y \\ w^T (I + uv^T) w & w^T (I + uv^T) \bar{v} & w^T (I + uv^T) Y \\ Y^T (I + uv^T) w & Y^T (I + uv^T) \bar{v} & Y^T Y \end{bmatrix}. \end{aligned}$$

Dar,  $v^T Y = 0$ ,  $\bar{v}^T Y = 0$ ,  $v^T w = 0$ ,  $Y^T w = 0$ ,  $Y^T Y = I_{n-2}$  și  $w^T w = 1$ ,  $\bar{v}^T \bar{v} = 1$ . În concluzie,  $\alpha = 1 + \bar{v}^T w w^T \bar{v} = 1 + v^T u$  și  $\beta = w^T u v^T \bar{v}$  obținem

$$U^T A V = \begin{bmatrix} 0 & 1 + \bar{v}^T w w^T \bar{v} & 0 \\ 1 & w^T u v^T \bar{v} & 0 \\ 0 & 0 & I_{n-2} \end{bmatrix} = \begin{bmatrix} 0 & \alpha & 0 \\ 1 & \beta & 0 \\ 0 & 0 & I_{n-2} \end{bmatrix}$$

și problema a fost redusă la cazul  $2 \times 2$ . Întradevăr, fie matricea  $2 \times 2$   $B = \begin{bmatrix} 0 & \alpha \\ 1 & \beta \end{bmatrix}$  care are DVS  $U_B^T B V_B = \Sigma_B$ . Atunci

$$\tilde{U}^T A \tilde{V} = \begin{bmatrix} U_B^T & 0 \\ 0 & I_{n-2} \end{bmatrix} U^T A V \begin{bmatrix} V_B & 0 \\ 0 & I_{n-2} \end{bmatrix} = \begin{bmatrix} \Sigma_B & 0 \\ 0 & I_{n-2} \end{bmatrix}$$

este diagonală și dacă  $\sigma_1(B) \geq \sigma_2(B) \geq 1$  este DVS lui  $A$ . În orice caz, valorile singulare ale matricei  $A$  sunt  $\sigma(A) = \sigma(B) \cup \sigma(I_{n-2})$ , i.e.  $n - 2$  valori singulare sunt egale cu 1 și celelalte două sunt cele ale lui  $B$ .

*Observație.* Cu toate că în cazul general valorile singulare ale unei matrice  $A \in \mathbb{R}^{m \times n}$  cu  $\min(m, n) > 4$  nu pot fi calculate într-un număr finit de operații aritmetice, în unele cazuri speciale, ca cel de mai sus, este posibil.

**Problema 5.8** Considerăm o matrice superior bidiagonală  $J \in \mathbb{R}^{n \times n}$  definită de vectorul  $f \in \mathbb{R}^n$ , al elementelor diagonale și de vectorul  $g \in \mathbb{R}^{n-1}$  format din elementele primei supradiagonale diagonalei, i.e.

$$J = \begin{bmatrix} f_1 & g_1 & & & \\ & f_2 & \ddots & & \\ & & \ddots & \ddots & \\ & & & \ddots & g_{n-1} \\ & & & & f_n \end{bmatrix}.$$

Arătați că dacă matricea  $J$  are două valori singulare egale  $\sigma_i = \sigma_{i+1}$ , atunci  $f$  și/sau  $g$  are un element nul.

**Soluție.** Matricea  $T = J^T J$  este tridiagonală, simetrică și pozitiv semidefinită. Deoarece  $\lambda_i(T) = \sigma_i^2(J)$ , matricea  $T$  are (cel puțin) două valori proprii egale. Vom arăta că în aceste condiții matricea  $T$  este reductibilă, i.e. există  $i$  astfel încât  $T(i+1, i) = g_i f_i = 0$ . În concluzie,  $g_i = 0$  și/sau  $f_i = 0$ . Fie  $\lambda \in \lambda(T)$  valoarea proprie dublă a lui  $T$ . Atunci există doi vectori proprii ortogonali  $x$  și  $y$ , asociați valorilor proprii  $\lambda$ , i.e.  $Tx = \lambda x$  și  $Ty = \lambda y$ , cu  $y^T x = 0$ . Presupunem că matricea  $T$  este ireductibilă, i.e.  $T(i+1, i) \neq 0$  pentru toți  $i = 1 : n-1$ .

Considerăm matricea  $S = T - \lambda I_n$  și partiționând-o sub forma  $S = \begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix}$ , unde

$S_{11} = S(1 : n-1, 1) \in \mathbb{R}^{(n-1) \times 1}$  și  $S_{12} = S(1 : n-1, 2 : n) \in \mathbb{R}^{(n-1) \times (n-1)}$  deoarece  $T$  este ireductibilă, blocul  $S_{12}$  este nesingular. Atunci  $x(2:n) = -S_{12}^{-1} S_{11} x(1)$ . Deoarece  $x \neq 0$ , avem  $x(1) \neq 0$ . Similar  $y(2:n) = -S_{12}^{-1} S_{11} y(1)$  cu  $y(1) \neq 0$ . Rezultă că vectorii  $x$  și  $y$  sunt coliniari, ceea ce reprezintă o contradicție cu faptul că sunt ortogonali. În concluzie  $T$  nu poate fi ireductibil. Demonstrația este completă.

**Problema 5.9** Adaptați algoritmul **JQ** pentru o reducere eficientă a unei matrice superior triunghiulare  $A \in \mathbb{R}^{n \times n}$  la forma superior bidiagonală folosind transformări ortogonale de echivalență.

**Soluție.** Să introducem așa numitele rotații *modificate*  $P_{ij}$ ,  $i < j$ , care fac să se anuleze elementul  $x_i$  pentru un vector dat  $x \in \mathbb{R}^n$ , i.e.  $(P_{ij}^T x)(i) = 0$  (în loc să se anuleze elementul  $x_j$  ca pentru rotațiile obișnuite). Este ușor de văzut că scalarii definatori  $c$ ,  $s$  și  $x \leftarrow P_{ij}^T x$  pot fi calculați în acest caz după cum urmează:

1.  $\rho = \sqrt{x_i^2 + x_j^2}$
2.  $c = \frac{x_j}{\rho}$
3.  $s = \frac{x_i}{\rho}$
4.  $x_i \leftarrow 0$
5.  $x_j \leftarrow \rho$ .

Pentru a exploata structura superior triunghiulară a lui  $A$ , vom folosi o secvență de rotații plane modificate ca în următoarea schemă de calcul:

1. pentru  $k = n : -1 : 3$ 
  1. pentru  $i = 1 : k - 2$ 
    1. Se calculează rotația plană modificată  $P_{i,i+1}$  astfel ca  $(P_{i,i+1}^T A)(i, k) = 0$ .
    2.  $A \leftarrow P_{i,i+1}^T A$  % structura este modificată în poziția  $(i + 1, i)$ .
    3. Se calculează rotația plană modificată  $Q_{i,i+1}$  astfel ca  $(AQ_{i,i+1})(i + 1, i) = 0$ .
    4.  $A \leftarrow AQ_{i,i+1}$ .

Când  $n = 4$ , primul pas al ciclului extern "pentru" este exemplificat mai jos:

$$A \leftarrow P_{12}^T A = \begin{bmatrix} \times & \times & \times & \emptyset \\ + & \times & \times & \times \\ & & \times & \times \\ & & & \times \end{bmatrix}, \quad A \leftarrow AQ_{12} = \begin{bmatrix} \times & \times & \times & 0 \\ \emptyset & \times & \times & \times \\ & & \times & \times \\ & & & \times \end{bmatrix},$$

$$A \leftarrow P_{23}^T A = \begin{bmatrix} \times & \times & \times & 0 \\ & \times & \times & \emptyset \\ & + & \times & \times \\ & & & \times \end{bmatrix}, \quad A \leftarrow AQ_{23} = \begin{bmatrix} \times & \times & \times & 0 \\ & \times & \times & 0 \\ & \emptyset & \times & \times \\ & & & \times \end{bmatrix}.$$

unde  $+$  reprezintă zerourile modificate,  $\emptyset$  reprezintă ultimele zerouri introduse și  $0$  reprezintă zerourile introduse la pașii anteriori.

Acum este ușor să transformăm schema de calcul într-un algoritm detaliat.

1. pentru  $k = n : -1 : 3$ 
  1. pentru  $i = 1 : k - 2$ 
    1.  $\rho = \sqrt{a_{ik}^2 + a_{i+1,k}^2}$



2.  $c = \frac{a_{i+1,k}}{\rho}$
3.  $s = \frac{a_{i,k}}{\rho}$
4.  $a_{ik} \leftarrow 0$
5.  $a_{i+1,k} \leftarrow \rho$
6.  $a_{i+1,i} = sa_{ii}$
7. pentru  $j = i + 1 : k - 1$ 
  1.  $\tau = a_{ij}$
  2.  $a_{ij} = ca_{ij} - sa_{i+1,j}$
  3.  $a_{i+1,i} = s\tau + ca_{i+1,j}$
8.  $\rho = \sqrt{a_{ik}^2 + a_{i+1,k}^2}$
9.  $c = \frac{a_{i+1,i}}{\rho}$
10.  $s = \frac{d_{i+1,i+1}}{\rho}$
11.  $a_{i+1,i} \leftarrow 0$
12.  $a_{i+1,i+1} \leftarrow \rho$
13. pentru  $l = 1 : i$ 
  1.  $\tau = a_{li}$
  2.  $a_{li} = a_{li}c + a_{l,i+1}s$
  3.  $a_{l,i+1} = -\tau s + a_{l,i+1}s$ .

Numărul de flopi necesari algoritmului (care nu cumulează și transformările) este  $N_{fl} \approx 2n^3$ , în comparație cu  $N_{fl} \approx 8n^3/3$  flopi necesari algoritmului JQ.

**Problema 5.10** Adaptați algoritmul **JQ** pentru o reducere eficientă a unei matrice tridiagonale  $T \in \mathbb{R}^{n \times n}$  la o formă superior bidiagonală folosind transformări ortogonale de echivalență.

**Soluție.** Să aplicăm întâi o secvență rotații plane pentru a reduce matricea tridiagonală la forma superior triunghiulară (cu numai două supradiagonale nenule), ca în următoarea schemă de calcul:

1. pentru  $k = 1 : n - 1$ 
  1. calculează rotația plană  $P_{k,k+1}$   
ca  $(P_{k,k+1}^T T)(k+1, k) = 0$ .
  2.  $T \leftarrow P_{k,k+1}^T T$ .

Acum, putem adapta soluția bazându-ne pe soluția problemei rezolvate anterior:

1.  $p = n$
2. pentru  $k = n : -1 : 3$ 
  1.  $p = \max\{1, p - 2\}$
  2. pentru  $i = p : k - 2$ 
    1. Se calculează rotația plană modificată  $P_{i,i+1}$  astfel  
ca  $(P_{i,i+1}^T A)(i, k) = 0$ .
    2.  $A \leftarrow P_{i,i+1}^T A$  % structura este modificată în poziția  $(i+1, i)$ .

3. Se calculează rotația plană modificată  $Q_{i,i+1}$  astfel  
ca  $(AQ_{i,i+1})(i+1, i) = 0$ .
4.  $A \leftarrow AQ_{i,i+1}$ .

Observăm că pentru  $k = n$  trebuie să eliminăm doar un element două elemente  $t_{n-3,n-1}$  și  $t_{n-4,n-1}$  deoarece termenul zero  $t_{n-4,n-1}$  a fost modificat prin înmulțire la dreapta cu  $Q_{n-1,n}$  etc. Pentru a ne descurca cu aceasta modificare structurală am introdus variabila întreagă  $p$ . Algoritmul detaliat este:

1. pentru  $k = 1 : n - 1$ 
  1.  $\rho = \sqrt{t_{kk}^2 + t_{k+1,k}^2}$
  2.  $c = \frac{t_{k,k}}{\rho}$
  3.  $s = \frac{-t_{k+1,k}}{\rho}$
  4.  $t_{kk} \leftarrow \rho$
  5.  $t_{k+1,k} \leftarrow 0$
  6.  $\tau = t_{k,k+1}$
  7.  $t_{k,k+1} = ct_{k,k+1} - st_{k+1,k+1}$
  8.  $t_{k+1,k+1} = s\tau + ct_{k+1,k+1}$
  9. dacă  $k < n - 1$ 
    1.  $t_{k,k+2} = -st_{k+1,k+2}$
    2.  $t_{k+1,k+2} = ct_{k+1,k+2}$
2.  $p = n$
3. pentru  $k = n : -1 : 3$ 
  1.  $p = \max\{1, p - 2\}$
  2. pentru  $i = p : k - 2$ 
    1.  $\rho = \sqrt{t_{ik}^2 + t_{i+1,k}^2}$
    2.  $c = \frac{t_{i+1,k}}{\rho}$
    3.  $s = \frac{t_{i,k}}{\rho}$
    4.  $t_{ik} \leftarrow 0$
    5.  $t_{i+1,k} \leftarrow \rho$
    6.  $t_{i+1,i} = st_{ii}$
    7.  $t_{ii} = ct_{ii}$
    8. pentru  $j = i + 1 : k - 1$ 
      1.  $\tau = t_{ij}$
      2.  $t_{ij} = ct_{ij} - st_{i+1,j}$
      3.  $t_{i+1,i} = s\tau + ct_{i+1,j}$
    9.  $\rho = \sqrt{t_{i+1,i}^2 + t_{i+1,i+1}^2}$
    10.  $c = \frac{t_{i+1,i+1}}{\rho}$
    11.  $s = \frac{t_{i+1,i}}{\rho}$
    12.  $t_{i+1,i} \leftarrow 0$
    13.  $t_{i+1,i+1} \leftarrow \rho$
    14.  $q = \max\{1, p - 2\}$

15. pentru  $l = q : i$
1.  $\tau = t_{li}$
  2.  $t_{li} = t_{li}c - t_{l,i+1}s$
  3.  $t_{l,i+1} = \tau s + t_{l,i+1}c$ .

**Problema 5.11** Fie  $A \in \mathbb{R}^{m \times n}$ , cu  $m < n$ , o matrice dată. Scrieți un algoritm eficient pentru calculul matricelor ortogonale  $U \in \mathbb{R}^{m \times m}$ ,  $V \in \mathbb{R}^{n \times n}$  astfel ca  $U^T A V = \begin{bmatrix} B & 0 \end{bmatrix}$  cu  $B \in \mathbb{R}^{m \times m}$  superior bidiagonală.

**Soluție.** Aplicăm algoritmul **JQ** pentru a reduce matricea  $A$  la o formă superior bidiagonală obținem:

$$A \leftarrow U^T A V = \begin{bmatrix} B & C \end{bmatrix}, \quad C = \begin{bmatrix} 0 & 0 & \dots & 0 \\ 0 & 0 & \dots & 0 \\ \vdots & \vdots & \dots & \vdots \\ 0 & 0 & \dots & 0 \\ x & 0 & \dots & 0 \end{bmatrix}$$

Pentru ca termenii nenuli să dispară  $(m, n+1)$  aplicăm în partea dreaptă o secvență de rotații plane  $A \leftarrow A P_{m,m+1} P_{m-1,m+1} \dots P_{1,m+1}$  care mută termenii nenuli în sus pe coloana  $m+1$  până când sunt eliminați, ca în exemplul următor cu  $m = 3$ ,  $n = 5$ :

$$A = \begin{bmatrix} \times & \times & & & \\ & \times & \times & & \\ & & \times & + & \\ & & & & \\ & & & & \end{bmatrix}, \quad A \leftarrow A P_{34} = \begin{bmatrix} \times & \times & & & \\ & \times & \times & + & \\ & & \times & \emptyset & \\ & & & & \\ & & & & \end{bmatrix},$$

$$A \leftarrow A P_{24} = \begin{bmatrix} \times & \times & + & & \\ & \times & \times & \emptyset & \\ & & \times & & \\ & & & & \\ & & & & \end{bmatrix}, \quad A \leftarrow A P_{34} = \begin{bmatrix} \times & \times & & \emptyset & \\ & \times & \times & & \\ & & \times & & \\ & & & & \\ & & & & \end{bmatrix}.$$

Schema de calcul este:

1.  $A \leftarrow B = \mathbf{JQ}(A)$
2. pentru  $k = m : -1 : 1$ 
  1. Se calculează rotația plană  $P_{i,m+1}$  astfel ca  $(A P_{i,m+1})(i, m+1) = 0$ .
  2.  $A \leftarrow A P_{i,m+1}$

și algoritmul detaliat:

1.  $A \leftarrow B = \mathbf{JQ}(A)$
2. pentru  $k = m : -1 : 1$ 
  1.  $\rho = \sqrt{a_{ii}^2 + a_{i,m+1}^2}$
  2.  $c = a_{ii}/\rho$
  3.  $s = a_{i,m+1}/\rho$
  4.  $a_{ii} = \rho$
  5.  $a_{i,m+1} = 0$
  6. dacă  $i > 1$ 
    1.  $a_{i-1,m+1} = a_{i-1,i}s$
    2.  $a_{i-1,i} = a_{i-1,i}c$ .

Efortul de calcul cel mai mare este în executarea procedurii **JQ**.

### 5.2.3 Aplicațiile SVD

**Problema 5.12** Considerăm matricele  $A \in \mathbb{R}^{m \times m}$ ,  $B \in \mathbb{R}^{n \times n}$ ,  $C, D \in \mathbb{R}^{m \times n}$  și sistemul matriceal:

$$\begin{cases} AX - YB = C \\ XB^T - A^T Y = D \end{cases}$$

**a.** Arătați că sistemul matriceal de mai sus are o soluție unică  $(X, Y) \in \mathbb{R}^{m \times n} \times \mathbb{R}^{m \times n}$  dacă și numai dacă  $\sigma(A) \cap \sigma(B) = \emptyset$ .

**b.** Presupunând condiția de mai sus satisfăcută, scrieți un algoritm care să calculeze soluția  $(X, Y)$ .

**Soluție.** **a.** Fie descompunerea valorilor singulare ale lui  $A$  și  $B$ : unde  $A = U_A \Sigma_A V_A^T$ ,  $B = U_B \Sigma_B V_B^T$ . Folosindu-le sistemul matriceal devine:

$$\begin{cases} U_A \Sigma_A V_A^T X - Y U_B \Sigma_B V_B^T = C \\ X V_B \Sigma_B^T U_B^T - V_A \Sigma_A^T U_A^T Y = D \end{cases},$$

sau

$$\begin{cases} \Sigma_A \tilde{X} - \tilde{Y} \Sigma_B = \tilde{C} \\ \tilde{X} \Sigma_B^T - \Sigma_A^T \tilde{Y} = \tilde{D} \end{cases},$$

unde

$$\tilde{X} = V_A^T X V_B, \quad \tilde{Y} = U_A^T Y U_B, \quad \tilde{C} = U_A^T C V_B, \quad \tilde{D} = V_A^T D U_B.$$

Bineînțeles sistemul matriceal inițial are o soluție unică dacă și numai dacă sistemul transformat are o soluție unică. Dar sistemul matriceal transformat poate fi scris ca un set de  $mn$  sisteme liniare de două ecuații cu două necunoscute, luând ecuațiile scalare  $(ij)$  din cele două ecuații matricele:

$$\begin{bmatrix} \sigma_i^{(A)} & -\sigma_j^{(B)} \\ \sigma_j^{(B)} & -\sigma_i^{(A)} \end{bmatrix} \begin{bmatrix} \tilde{x}_{ij} \\ \tilde{y}_{ij} \end{bmatrix} = \begin{bmatrix} \tilde{c}_{ij} \\ \tilde{d}_{ij} \end{bmatrix},$$

unde  $\sigma_i^{(A)}$ ,  $i = 1 : m$  sunt valorile singulare ale lui  $A$  și  $\sigma_j^{(B)}$ ,  $j = 1 : n$  sunt valorile singulare ale lui  $B$ . Fiecare dintre aceste sisteme are o soluție unică  $(x_{ij}, y_{ij})$  dacă și numai dacă

matricea  $\begin{bmatrix} \sigma_i^{(A)} & -\sigma_j^{(B)} \\ \sigma_j^{(B)} & -\sigma_i^{(A)} \end{bmatrix}$  este nesingulară, i.e.  $\sigma_i^{(A)} \neq \sigma_j^{(B)}$  (deoarece valorile singulare sunt numere reale pozitive). Toate  $i$  și  $j$  aceste condiții sunt echivalente cu  $\sigma(A) \cap \sigma(B) = \emptyset$ .

**b.** Pentru a rezolva sistemul matriceal putem proceda ca mai sus. Dacă **dvs** este metoda pentru a calcula DVS unei matrice date, atunci putem folosi următoarea schemă de calcul:

1.  $[U_A, \Sigma_A, V_A] = \mathbf{svd}(A)$
2.  $[U_B, \Sigma_B, V_B] = \mathbf{svd}(B)$
3.  $\tilde{C} = U_A^T C V_B$
4.  $\tilde{D} = V_A^T D U_B$
5. pentru  $i = 1 : m$ 
  1. pentru  $j = 1 : n$

1. rezolvă sistemul liniar 
$$\begin{bmatrix} \sigma_i^{(A)} & -\sigma_j^{(B)} \\ \sigma_j^{(B)} & -\sigma_i^{(A)} \end{bmatrix} \begin{bmatrix} \tilde{x}_{ij} \\ \tilde{y}_{ij} \end{bmatrix} = \begin{bmatrix} \tilde{c}_{ij} \\ \tilde{d}_{ij} \end{bmatrix}.$$
6.  $X = V_A \tilde{X} V_B^T$   
7.  $Y = U_A \tilde{Y} U_B^T$ .

Detaliile sunt lăsate pentru studenți.

**Problema 5.13** Considerăm matricea  $A \in \mathbb{R}^{m \times n}$  și vectorul  $b \in \mathbb{R}^m$ .

- a. Arătați că pentru  $\alpha > 0$  problema de minimizare

$$\min_{x \in \mathbb{R}^n} \{ \|b - Ax\|^2 + \alpha \|x\|^2 \}$$

admite o soluție unică  $x_\alpha^*$ .

- b. Acest lucru se întâmplă și pentru  $\alpha \searrow 0$  ?  
c. Scrieți un algoritm eficient pentru a calcula soluția  $x_\alpha^*$ .  
d. Arătați că sistemul liniar

$$(A^T A + \alpha I_n)(A^T A + \beta I_n)y = (\beta - \alpha)A^T b$$

este satisfăcut de  $y \stackrel{\text{not}}{=} x_\alpha^* - x_\beta^*$ .

**Soluție.** a. Folosind DVS  $A = U\Sigma V^T$  și ținând cont că norma euclidiană este invariantă la transformările ortogonale, problema devine echivalentă cu următoarea problemă de minimizare:

$$\begin{aligned} \min_{x \in \mathbb{R}^n} \{ \|b - Ax\|^2 + \alpha \|x\|^2 \} &= \min_{x \in \mathbb{R}^n} \{ \|b - U\Sigma V^T x\|^2 + \alpha \|V^T x\|^2 \} = \\ &= \min_{y \in \mathbb{R}^n} \{ \|d - \Sigma y\|^2 + \alpha \|y\|^2 \}, \end{aligned}$$

unde  $d = U^T b$  și  $y = V^T x$ . Bineînțeles această problemă este simplă și poate fi rezolvată ușor. Pentru aceasta, fie  $r$  rangul lui  $A$ . Avem

$$\begin{aligned} \|d - \Sigma y\|^2 + \alpha \|y\|^2 &= \sum_{i=1}^n ((d_i - \sigma_i y_i)^2 + \alpha y_i^2) = \\ &= \sum_{i=1}^r (d_i^2 - 2d_i \sigma_i y_i + (\sigma_i^2 + \alpha) y_i^2) + \sum_{i=r+1}^n (d_i^2 + \alpha y_i^2) = \\ &= \sum_{i=1}^r \left( \frac{\alpha d_i^2}{\sigma_i^2 + \alpha} - \left( \frac{d_i \sigma_i}{\sqrt{\sigma_i^2 + \alpha}} - \sqrt{\sigma_i^2 + \alpha} y_i \right)^2 \right) + \sum_{i=r+1}^n (d_i^2 + \alpha y_i^2). \end{aligned}$$

În concluzie minimul este atins pentru  $y$  unic dat de

$$y_i = \frac{d_i \sigma_i}{\sigma_i^2 + \alpha}, \quad i = 1 : r, \quad y_i = 0, \quad i = r + 1 : n$$

și valoarea sa este

$$\min_{y \in \mathbb{R}^n} \{\|d - \Sigma y\|^2 + \alpha \|y\|^2\} = \sum_{i=1}^r \frac{\alpha d_i^2}{\sigma_i^2 + \alpha} + \sum_{i=r+1}^n d_i^2.$$

Pentru problema inițială de minimizare soluția este unică și dată de  $x_\alpha^* = Vy = V_1 y(1:r)$ , unde  $V_1 = V(:, 1:r)$ . Observăm că pentru  $\alpha \geq 0$  diagonala matricei  $\Sigma_1^2 + \alpha I_r$  este nesingulară. Avem  $y(1:r) = (\Sigma_1^2 + \alpha I_r)^{-1} \Sigma_1 d(1:r)$ . Dar  $d(1:r) = (U^T b)(1:r) = U_1^T b$ , unde  $U_1 = U(:, 1:r)$ . În concluzie, soluția problemei inițiale de minimizare poate fi scrisă sub forma

$$x_\alpha^* = V_1 (\Sigma_1^2 + \alpha I_r)^{-1} \Sigma_1 U_1^T b.$$

**b.** Când  $\alpha \searrow 0$  obținem

$$x_0^* = V_1 (\Sigma_1^2)^{-1} \Sigma_1 U_1^T b = V_1 \Sigma_1^{-1} U_1^T b = A^\# b,$$

unde  $A^\#$  este pseudoinversa lui  $A$ , i.e.  $x_0^*$  este soluția problemei celor mai mici pătrate pentru sistemul linear  $Ax = b$ .

**c.** Algoritmul pentru calcularea vectorului  $x_\alpha^*$ :

1.  $[U, \Sigma, V] = \mathbf{dvs}(A)$
2.  $d = (U(:, 1:r))^T b$
3. pentru  $i = 1:r$ 
  1.  $d_i = \frac{d_i \sigma_i}{\sigma_i^2 + \alpha}$
4.  $x_\alpha^* = V(:, 1:r)d$ .

Detaliile sunt lăsate pentru studenți.

**d.** Pentru a arăta că

$$(A^T A + \alpha I_n)(A^T A + \beta I_n)(x_\alpha^* - x_\beta^*) = (\beta - \alpha)A^T b$$

observăm întâi că, cu notații uzuale,  $A^T A = V_1 \Sigma_1^2 V_1^T$  și, în concluzie

$$\begin{aligned} (A^T A + \gamma I_n)x_\gamma^* &= (V_1 \Sigma_1^2 V_1^T + \gamma I_n)V_1 (\Sigma_1^2 + \gamma I_r)^{-1} \Sigma_1 U_1^T b = \\ &= V_1 (\Sigma_1^2 + \gamma I_n)(\Sigma_1^2 + \gamma I_r)^{-1} \Sigma_1 U_1^T b = V_1 \Sigma_1 U_1^T b = A^T b \end{aligned}$$

pentru  $\gamma \in \{\alpha, \beta\}$ , deoarece  $V_1^T V_1 = I_r$ . Dar matricele  $A^T A + \alpha I_n$  și  $A^T A + \beta I_n$  comută. Atunci, avem

$$\begin{aligned} (A^T A + \alpha I_n)(A^T A + \beta I_n)x_\alpha^* &= (A^T A + \beta I_n)(A^T A + \alpha I_n)x_\alpha^* = \\ &= (A^T A + \beta I_n)A^T b = A^T A A^T b + \beta A^T b. \end{aligned}$$

Scăzând,

$$(A^T A + \alpha I_n)(A^T A + \beta I_n)x_\beta^* = A^T A A^T b + \alpha A^T b.$$

Înlocuind ultimele două relații obținem rezultatul dorit.

### 5.3 Probleme propuse

**Problema 5.14** Care sunt valorile singulare ale matricelor:

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

**Problema 5.15** Arătați că matricea  $A = \begin{bmatrix} 6 & 3 & 1 \\ 1 & 3 & 3 \\ 3 & -1 & 3 \end{bmatrix}$  este normală, i.e.  $AA^T = A^T A$ , și calculați valorile sale proprii și valorile sale singulare. Verificați că  $\sigma_i = |\lambda_i|$ ,  $i = 1:3$ .

**Problema 5.16 a.** Dați formule explicite pentru a calcula valorile singulare ale matricii  $A = \begin{bmatrix} \alpha & \beta \\ \gamma & \delta \end{bmatrix}$ . Aplicați-le pentru a calcula valorile singulare pentru  $A = \begin{bmatrix} 1 & 2 \\ 3 & 4 \end{bmatrix}$  și  $B = \begin{bmatrix} 1 & 3 \\ 2 & 4 \end{bmatrix}$ .

**b.** Aceeași problemă pentru cazul simetric, i.e. dați formule explicite pentru a calcula valorile singulare ale matricii  $A = \begin{bmatrix} \alpha & \beta \\ \beta & \gamma \end{bmatrix}$ . Aplicați-le pentru a calcula valorile singulare pentru  $A = \begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix}$  și  $B = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}$ .

*Indicație: a.*

$$\sigma_1 = \sqrt{\frac{1}{2} \left( \alpha^2 + \beta^2 + \gamma^2 + \delta^2 + \sqrt{(\alpha^2 - \delta^2)^2 + (\beta^2 - \gamma^2)^2 + 2(\alpha\beta + \gamma\delta)^2 + 2(\alpha\gamma + \beta\delta)^2} \right)},$$

etc.

**Problema 5.17** Arătați că dacă  $A \in \mathbb{R}^{m \times n}$  are rangul  $n$ , atunci  $\|A(A^T A)^{-1} A^T\|_2 = 1$ .

**Problema 5.18** Calculați valorile singulare pentru o matrice ortogonală  $Q \in \mathbb{R}^{n \times n}$ .

**Problema 5.19** Fie  $V \in \mathbb{R}^{m \times k}$  o matrice cu coloanele ortogonale. Matricea  $P = VV^T$  este numită *matrice de proiecție ortogonală* pe subspațiul liniar  $\text{Im}V$ .

**a.** Arătați că matricea  $Q = I - 2P$  este ortogonală.

**b.** Calculați valorile singulare ale unei matrice de proiecție ortogonală.

**Problema 5.20** Fie  $A, B \in \mathbb{R}^{n \times n}$  două matrice pătratice. Am demonstrat că  $AB$  și  $BA$  au aceleași valori proprii. Acest lucru este adevărat și pentru valorile singulare ale matricilor  $AB$  și  $BA$ ?

## 5.4 Bibliografie

1. B. Jora, B. Dumitrescu, C. Oară, NUMERICAL METHODS, UPB, Bucharest, 1995.
2. G.W. Stewart, INTRODUCTION TO MATRIX COMPUTATIONS, Academic Press, 1973.
3. G. Golub, Ch. Van Loan, MATRIX COMPUTATIONS, 3-rd edition, John Hopkins University Press, 1998.
4. G.W. Stewart, MATRIX ALGORITHMS, vol.1: Basic Decompositions, SIAM, 1999.
5. G.W. Stewart, MATRIX ALGORITHMS, vol.2: Eigensystems, SIAM, 2001.
6. B. Dumitrescu, C. Popeea, B. Jora, METODE DE CALCUL NUMERIC MATRICEAL. ALGORITMI FUNDAMENTALI, ALL, București, 1998.



## 5.5 Programe MATLAB

În această secțiune sunt date programele MATLAB pentru implementarea algoritmilor prezentați în acest seminar. Programele au fost testate și pot fi obținute de la autorul lor menționat în comentariile atașate.

```

1: function [A]=JQ_ortogonal(A)
2: %-----
3: % Se da o matrice A(nxm). Algoritmul ofera o metoda eficienta pentu
4: % calculul matricelor ortogonale U (mxm) si V (nxn) cu U_transpus*A*V=[B 0].
5: % B este o matrice superior bidiagonala.
6: % Apelul: A=JQ_ortogonal(A)
7: %
8: % Dumitru Iulia, mai 2006.
9: %-----
10: [n,m]=size(A);
11: B=JQ(A);
12: A=B;
13: for k=m:-1:1
14:     rho=sqrt(A(i,i)*A(i,i)+A(i,m+1)*A(i,m+1));
15:     c=A(i,i)/rho;
16:     s=A(i,m+1)/rho
17:     A(i,i)=rho
18:     A(i,m+1)=0;
19:     if i>1
20:         A(i-1,m+1)=A(i-1,i)*s;
21:         A(i-1,i)=A(i-1,i)*c;
22:     end
23: end
24:

```

```

1: function [T]=JQ_tridiagonal(T);
2: %-----
3: % Se da o matrice patratica, superior tridiagonala T. Algoritmul ofera o
4: % reducere eficienta a matricei A la forma superior bidiagonala, folosind
5: % algoritmul JQ si transformarile ortogonale.
6: % Apelul: T=JQ_tridiagonal(T)
7: %
8: % Dumitru Iulia, mai 2006.
9: %-----
10:
11: [n,m]=size(T);
12:
13: %analizam daca matricea e patratica

```

```

14: if n~=m
15:     error('Matricea nu e patratica');
16: end
17:
18: for i=1:n-2
19:     for j=i+2:n
20:         if T(i,j)~=0
21:             error('Matricea nu e tridiagonala')
22:         end
23:     end
24: end
25: for i=3:n
26:     for j=1:i-2
27:         if T(i,j)~=0
28:             error('Matricea nu e tridiagonala')
29:         end
30:     end
31: end
32:
33: for k=1:n-1
34:     rho=sqrt(T(k,k)*T(k,k)+T(k+1,k)*T(k+1,k));
35:     c=T(k,k)/rho;
36:     s=-T(k+1,k)/rho;
37:     T(k,k) =rho;
38:     T(k+1,k)=0;
39:     rho=T(k,k+1);
40:     T(k,k+1)=c*T(k,k+1)-s*T(k+1,k+1);
41:     T(k+1,k+1)=s*rho+c*T(k+1,k+1);
42:     if k<n-1
43:         T(k,k+2)=-s*T(k+1,k+2);
44:         T(k+1,k+2)=c*T(k+1,k+2);
45:     end
46: end
47: p=n;
48: for k=n:-1:3
49:     max=1;
50:     if max<p-2
51:         max=p-2;
52:     end
53:     p=max;
54:     for i=p:k-2
55:         rho=sqrt(T(i,k)*T(i,k)+T(i+1,k)*T(i+1,k));
56:         c=T(i+1,k)/rho;
57:         s=T(i,k)/rho;
58:         T(i,k) =0;
59:         T(i+1,k)=rho;
60:         T(i+1,i)=s*T(i,i);

```

```

61:         T(i,i)=c*T(i,i);
62:         for j=i+1:k-1
63:             tau=T(i,j);
64:             T(i,j)=c*T(i,j)-s*T(i+1,j);
65:             T(i+1,i)=s*tau + c*T(i+1,j);
66:         end
67:         rho=sqrt(T(i+1,i)*T(i+1,i)+T(i+1,i+1)*T(i+1,i+1));
68:         c=T(i+1,i+1)/rho;
69:         s=T(i+1,i)/rho;
70:         T(i+1,i)=0;
71:         T(i+1,i+1)=rho;
72:         max=1;
73:         if max<p-2
74:             max=p-2;
75:         end
76:         q=max;
77:         for l=q:i
78:             tau=T(l,i);
79:             T(l,i)=T(l,i)*c-T(l,i+1)*s;
80:             T(l,i+1)=tau*s+T(l,i+1)*c;
81:         end
82:     end
83: end

1: function [A]=JQ_trianghiular(A);
2: %-----
3: % Se da o matrice patratica, superior trianghiulara A. Algoritmul ofera o
4: % reducere eficienta a matricei A la forma superior bidiagonala, folosind
5: % algoritmul JQ si transformarile ortogonale.
6: % Apelul: A=JQ_trianghiular(A);
7: %
8: % Dumitru Iulia, mai 2006.
9: %-----
10:
11: [n,m]=size(A);
12:
13: %analizam daca matricea e patratica
14: if n~=m
15:     error('Matricea nu e patratica');
16: end
17:
18: for i=1:n
19:     for j=1:n
20:         if i>j
21:             if A(i,j)~=0
22:                 error('Matricea nu este superior trunghiulara');

```

```

23:         end
24:     end
25: end
26: end
27:
28: for k=n:-1:3
29:     for i=1:k-2
30:         rho=sqrt(A(i,k)*A(i,k)+A(i+1,k)*A(i+1,k));
31:         c=A(i+1,k)/rho;
32:         s=A(i,k)/rho;
33:         A(i,k) =0;
34:         A(i+1,k)=rho;
35:         A(i+1,i)=s*A(i,i);
36:         for j=i+1:k-1
37:             tau=A(i,j);
38:             A(i,j)=c*A(i,j)-s*A(i+1,j);
39:             A(i+1,i)=s*tau + c*A(i+1,j);
40:         end
41:         rho=sqrt(A(i,k)*A(i,k)+A(i+1,k)*A(i+1,k));
42:         c=A(i+1,i)/rho;
43:         s=A(i+1,i+1)/rho;
44:         A(i+1,i)=0;
45:         A(i+1,i+1)=rho;
46:         for l=1:i
47:             tau=A(l,i);
48:             A(l,i)=A(l,i)*c+A(l,i+1)*s;
49:             A(l,i+1)=-tau*s+A(l,i+1)*s;
50:         end
51:     end
52: end

```