

Monissa käytännön ongelmissa ei matriisiyhtälölle  $Ax = b$  saada ratkaisua, mutta approksimaatio on silti käyttökelpoinen.

### Määritelmä

*Jos  $A$  on  $m \times n$  matriisi ja  $b \in \mathbf{R}^m$ , niin yhtälön  $Ax = b$  paras pienimmän neliösumman (pns) ratkaisu on  $\hat{x} \in \mathbf{R}^n$  siten, että*

$$\|b - A\hat{x}\| \leq \|b - Ax\|, \quad \forall x \in \mathbf{R}^n$$

Ratkaisu tähän lähtee huomiosta, että  $Ax$  on aina vektori  $A$ :n sarakevektoreiden virittämässä aliavaruudessa. Näistä vektoreista pitää siis valita optimaalinen  $A\hat{x}$  eli se, joka on lähinnä  $b$ :ta. Tällaisella vektorilla täytyy olla se ominaisuus, että vektorin  $b - A\hat{x}$ :n on oltava kohtisuorassa sarakeavaruutta vastaan. Niinpä on vaadittava, että  $A^T(b - A\hat{x}) = 0$ , josta saadaan

## Lause

*Yhtälön  $Ax = b$  pns ratkaisu  $\hat{x}$  on täsmälleen normaaliyhtälön  $A^T A \hat{x} = A^T b$  ratkaisu.*

# Pienimmän neliösumman ratkaisu 2

## Lause

*Yhtälön  $Ax = b$  pns ratkaisu  $\hat{x}$  on täsmälleen normaaliyhtälön  $A^T A \hat{x} = A^T b$  ratkaisu.*

**Esimerkki:** Yhtälön  $Ax = b$ , jossa

$$A = \begin{pmatrix} 4 & 0 \\ 0 & 2 \\ 1 & 1 \end{pmatrix}, \quad b = \begin{pmatrix} 2 \\ 0 \\ 11 \end{pmatrix}$$

pns ratkaisua  $\hat{x}$  varten lasketaan

$$A^T b = \begin{pmatrix} 19 \\ 11 \end{pmatrix}, \quad A^T A = \begin{pmatrix} 17 & 1 \\ 1 & 5 \end{pmatrix}, \quad \text{josta } (A^T A)^{-1} = \frac{1}{84} \begin{pmatrix} 5 & -1 \\ -1 & 17 \end{pmatrix}.$$

Näillä ratkaistaan  $A^T A \hat{x} = A^T b$  ja saadaan

$$\hat{x} = (A^T A)^{-1} A^T b = \begin{pmatrix} 1 \\ 2 \end{pmatrix}.$$

## Lause

*Pns ratkaisu  $\hat{x}$  on yksikäsitteinen joss  $A^T A$  on kääntövä.*

## Lause

*Symmetrisen matriisin ( $A^T = A$ ) eri ominaisarvoihin liittyvät ominaisvektorit ovat kohtisuorassa.*

**Tod.:** Olkoon  $\lambda_1 \neq \lambda_2$  ja  $v_i$ ,  $i = 1, 2$  vastaavat ominaisvektorit. Silloin pätee  $\lambda_1 v_1 \cdot v_2 = (\lambda_1 v_1)^T v_2 = (A v_1)^T v_2 = (v_1^T A^T) v_2 = v_1^T (A v_2) = v_1^T (\lambda_2 v_2) = \lambda_2 v_1 \cdot v_2$  eli  $(\lambda_1 - \lambda_2) v_1 \cdot v_2 = 0$ , josta seuraa kohtisuoruus. QED

Jos ortonormaaleja ominaisvektoreita on riittävästi, voidaan niistä muodostaa (sarakkeina) diagonalisointiin  $A = PDP^{-1}$  tarvittava kannanmuuttomatriisi  $P$ . Tällön sanotaan, että matriisi  $A$  on **ortogonaalisesti diagonalisoituva** ja pätee siis  $A = PDP^T$ . Jos näin on, pätee  $A^T = (PDP^T)^T = P^{TT} D^T P^T = PDP^T = A$  eli  $A$  on symmetrinen! Itse asiassa käänteinenkin pätee:

## Lause

*Neliömatriisi on ortogonaalisesti diagonalisoituva joss se on symmetrinen.*

# Symmetristen matriisien ominaisuuksia 2

**Esimerkki:** Matriisin

$$A = \begin{pmatrix} 3 & -2 & 4 \\ -2 & 6 & 2 \\ 4 & 2 & 3 \end{pmatrix}$$

karacteristinen yhtälö on  $-(\lambda - 7)^2(\lambda + 2)$  eli "Ortogonaalisuuslause" edellä ei välittömästi anna ortogonaalista matriisiä  $P$ . Arvoa  $\lambda = -2$  vastaava ominaisvektori  $v_3 = (-1, -\frac{1}{2}, 1)^T$  on kohtisuorassa molempia  $\lambda = 7$  vastaavia ominaisvektoreita  $v_1 = (1, 0, 1)^T$  ja  $v_2 = (-\frac{1}{2}, 1, 0)^T$  vastaan. Mutta jälkimmäiset eivät ole keskenään kohtisuorassa. Korjataan tämä Gram-Schmidtillä:

$$z_2 = v_2 - \frac{v_1 \cdot v_2}{v_1 \cdot v_1} v_1 = \begin{pmatrix} -\frac{1}{4} \\ 1 \\ \frac{1}{4} \end{pmatrix}.$$

Nyt  $\{v_1, z_2, v_3\}$  on  $\mathbf{R}^3$ :n ortogonaalikanta. Normalisoimalla kukin vektoreista ja muodostamalla niistä ortogonaalisen muunnosmatriisin  $P$  sarakkeet saadaan

$$P = \begin{pmatrix} \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{18}} & -\frac{2}{3} \\ 0 & \frac{4}{\sqrt{18}} & -\frac{1}{3} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{18}} & \frac{2}{3} \end{pmatrix} \quad \text{ja} \quad D = \begin{pmatrix} 7 & 0 & 0 \\ 0 & 7 & 0 \\ 0 & 0 & -2 \end{pmatrix},$$

joille siis pätee  $A = PDP^T$ .

Jos pätee  $A = PDP^T$ , jossa ortogonaalisen  $P$ :n sarakkeina ovat  $A$ :n normeeratut ominaisvektorit  $\{u_i\}$  ja  $D$ :n diagonaalina ominaisarvot  $\{\lambda_1, \dots, \lambda_n\}$  (eli  $A$ :n **spektri**), saadaan

$$\begin{aligned} A = PDP^T &= (u_1 | \dots | u_n) \begin{pmatrix} \lambda_1 & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & \lambda_n \end{pmatrix} \begin{pmatrix} u_1^T \\ \vdots \\ u_n^T \end{pmatrix} \\ &= (\lambda_1 u_1 | \dots | \lambda_n u_n) \begin{pmatrix} u_1^T \\ \vdots \\ u_n^T \end{pmatrix} = \lambda_1 u_1 u_1^T + \dots + \lambda_n u_n u_n^T. \end{aligned}$$

Tämä on  $A$ :n **spektraalihajotelma**.  $n \times n$  matriisit  $u_i u_i^T$  ovat rangia 1 olevia **projektiomatriiseja**:  $(u_i u_i^T)x$  on vektorin  $x$  ortogonaaliprojektio vektorin  $u_i$  virittämälle 1-ulotteiselle aliavaruudelle. Jos osa ominaisarvoista on hyvin pieniä, kertoo spektraalihajotelma pelkistetysti, mitkä projektiot kuvaavat  $A$ :n.

**Esimerkki:** Symmetrisen matriisin

$$A = \begin{pmatrix} -3 & -3 & -3 \\ -3 & 1 & -1 \\ -3 & -1 & 1 \end{pmatrix}$$

ominaisarvot ovat  $\lambda_1 = -6$ ,  $\lambda_2 = 3$  ja  $\lambda_3 = 2$ . Vastaavat ominaisvektorit ovat  $(2, 1, 1)^T$ ,  $(-1, 1, 1)^T$  ja  $(0, -1, 1)^T$ . Normalisoimalla nämä saadaan

$$u_1 = \left( \frac{2}{\sqrt{6}}, \frac{1}{\sqrt{6}}, \frac{1}{\sqrt{6}} \right)^T, \quad u_2 = \left( -\frac{1}{\sqrt{3}}, \frac{1}{\sqrt{3}}, \frac{1}{\sqrt{3}} \right)^T \quad \text{ja} \quad u_3 = \left( 0, -\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}} \right)^T.$$

$A$ :n spektraalihajotelma on siten  $\sum_{i=1}^3 \lambda_i u_i u_i^T$ . Koska  $u_i$  on  $A^k$ :n ominaisarvoon  $\lambda_i^k$  liittyvä ominaisvektori, nähdään, että  $A^k = \sum_{i=1}^3 \lambda_i^k u_i u_i^T$  kaikille  $k = 1, 2, \dots$

Huomaa, että  $\lambda = -6$  on dominoiva ominaisarvo, koska  $6 > |\lambda_i|$ ,  $i = 2, 3$ . Siten

$$\frac{A^k}{(-6)^k} \rightarrow u_1 u_1^T = \begin{pmatrix} \frac{2}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{1}{3} & \frac{1}{6} & \frac{1}{6} \\ \frac{1}{3} & \frac{1}{6} & \frac{1}{6} \end{pmatrix}.$$

eli projektiomatriisi  $u_1 u_1^T$  kuvaa asymptotisesti  $A^k$ :n geometrian “venytystä vaille”.

Entä jos dominoiva ominaisarvo on monikertainen, kuten edeltävän esimerkin matriisilla

$$B = \begin{pmatrix} 3 & -2 & 4 \\ -2 & 6 & 2 \\ 4 & 2 & 3 \end{pmatrix},$$

jossa  $\lambda = 7$  oli kaksinkertainen ja  $-2$  yksinkertainen? Tämäkin tilanne ratkeaa heti spektraaliesityksestä ja voidaan laskea, että

$$\begin{aligned} \frac{B^k}{7^k} &\rightarrow \left( \frac{1}{\sqrt{2}}, 0, \frac{1}{\sqrt{2}} \right)^T \left( \frac{1}{\sqrt{2}}, 0, \frac{1}{\sqrt{2}} \right) + \left( -\frac{1}{\sqrt{18}}, \frac{4}{\sqrt{18}}, \frac{1}{\sqrt{18}} \right)^T \left( -\frac{1}{\sqrt{18}}, \frac{4}{\sqrt{18}}, \frac{1}{\sqrt{18}} \right) \\ &= \begin{pmatrix} \frac{5}{9} & -\frac{2}{9} & \frac{4}{9} \\ -\frac{2}{9} & \frac{8}{9} & \frac{2}{9} \\ \frac{4}{9} & \frac{2}{9} & \frac{5}{9} \end{pmatrix}, \end{aligned}$$

joka ei ole projektiomatriisi, vaikka onkin kahden sellaisen summa.



Symmetrisillä matriiseilla on paljon hyviä ominaisuuksia, joista useat voidaan tiivistää seuraavasti

## Lause

*Symmetrisellä  $n \times n$ -matriisilla  $A$*

- *on  $n$  reaalista ominaisarvoa,*
- *$k$ -kertaista ominaisarvoa vastaava ominaisavaruus on  $k$ -ulotteinen,*
- *erillisiä ominaisarvoja vastaavat ominaisaliavaruudet ovat kohtisuorassa,*
- *on ortogonaalinen diagonalisointi.*

(Osa näistä ominaisuuksista on johdettu edellä, osa taas vaatii huomattavasti lisätyötä/löytyy kirjallisuudesta.)

## Määritelmä

*Neliömuoto  $Q_A(x)$  on kuvaus  $\mathbf{R}^n \rightarrow \mathbf{R}$ , joka määrittyy  $n \times n$  matriisista  $A$ :  $Q_A(x) = x^T Ax$ .*

Koska  $A$  ja  $\frac{1}{2}(A + A^T)$  määrittelevät saman neliömuodon, voidaan keskittyä symmetristen matriisien antamien neliömuotojen analyysiin. Kun  $A$  on selvä, merkitään yksinkertaisesti  $Q(x)$ .  $n \times n$  matriisin neliömuoto on aina toisen asteen polynomi  $n$ :n muuttujan suhteen.

## Määritelmä

*Neliömuoto  $Q_A(x)$  on kuvaus  $\mathbf{R}^n \rightarrow \mathbf{R}$ , joka määrittyy  $n \times n$  matriisista  $A$ :  $Q_A(x) = x^T Ax$ .*

Koska  $A$  ja  $\frac{1}{2}(A + A^T)$  määrittelevät saman neliömuodon, voidaan keskittyä symmetristen matriisien antamien neliömuotojen analyysiin. Kun  $A$  on selvä, merkitään yksinkertaisesti  $Q(x)$ .  $n \times n$  matriisin neliömuoto on aina toisen asteen polynomi  $n$ :n muuttujan suhteen.

**Esimerkki:** Matriisi

$$A = \begin{pmatrix} 3 & -2 \\ -2 & 7 \end{pmatrix}$$

määrittää neliömuodon

$$Q_A(x) = (x_1, x_2) \begin{pmatrix} 3 & -2 \\ -2 & 7 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 3x_1^2 - 4x_1x_2 + 7x_2^2.$$

Kääntyvä  $n \times n$  matriisi  $P$  voidaan tulkita koordinaatiston muunnosmatriisiksi  $\mathbf{R}^n$ :lla:  $x = Py$ . Jos siirrytään alkuperäisistä  $x$ -koordinaateista  $y$ -koordinaatteihin, muuntuu neliömuodon esitys

$$Q(x) = x^T Ax = (Py)^T A(Py) = y^T (P^T AP)y \quad (1)$$

eli uudessa kannassa matriisi on  $P^T AP$ . Koska kuitenkin  $A$  voidaan aina olettaa symmetriseksi ja symmetriset matriisit ovat ortogonaalisesti diagonalisoituvia, on nyt tarjolla ortogonaalinen koordinaatistonmuunnos. Sitä vastaten  $Q$  saa yksinkertaisimman mahdollisen esityksen, **pääkselimuodon**:

$$Q(y) = y^T Dy = \sum_{i=1}^n \lambda_i y_i^2. \quad (2)$$

Geometrisesti (1) ja (2) ovat tietenkin täsmälleen samoja kuvauksia  $Q : \mathbf{R}^n \rightarrow \mathbf{R}$ , esitettynä vain eri koordinaateissa!

Neliömuodon geometria on hahmottuu pääakselimuodosta helposti. Yksinkertaisimmillaan, tasossa, yhtälö  $x^T Ax = vakio$  määrittää joko ellipsin, hyperbelin, suoraparin, pisteen tai on tyhjä joukko. Käyrän orientaatio selviää välittömästi (kohtisuorista) ominaisvektoreista, jotka antavat akselien suunnat.

## Esimerkki:

$$Q(x) = 5x_1^2 - 4x_1x_2 + 5x_2^2 = 48 \iff (x_1, x_2) \begin{pmatrix} 5 & -2 \\ -2 & 5 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 48.$$

Matriisin ominaisarvot ovat 3 ja 7, joita vastaavat ortonormaalit ominaisvektorit ovat  $u_1 = \left(\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}\right)^T$  ja  $u_2 = \left(-\frac{1}{\sqrt{2}}, \frac{1}{\sqrt{2}}\right)^T$ . Siten koordinaatiston muunnos on  $x = Py$ , jossa

$$P = \begin{pmatrix} \frac{1}{\sqrt{2}} & -\frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} & \frac{1}{\sqrt{2}} \end{pmatrix}$$

ja vastaava pääakselimuoto  $y^T Dy = 3y_1^2 + 7y_2^2$ .  $Q = 48$  vastaa ellipsiä, jonka akselit ovat 45 asteen kulmassa alkuperäisten  $\mathbf{R}^2$ :n koordinaattiakselien suhteen.

## Määritelmä

*Neliömuoto  $Q$  on*

- **positiividefiniitti** jos  $Q(x) > 0, \forall x \neq 0$ ,
- **positiivisemidefiniitti** jos  $Q(x) \geq 0, \forall x$  ja on olemassa  $x \neq 0$  siten että  $Q(x) = 0$ ,
- **negatiividefiniitti** jos  $Q(x) < 0, \forall x \neq 0$ ,
- **negatiivisemidefiniitti** jos  $Q(x) \leq 0, \forall x$  ja on olemassa  $x \neq 0$  siten että  $Q(x) = 0$ ,
- **indefiniitti** jos  $Q$  saa sekä pos. että neg. arvoja.

## Lause

*Neliömuoto  $x^T Ax$ ,  $A$  symmetrinen, on*

- *positiividefiniitti joss  $A$ :n ominaisarvot ovat positiiviset,*
- *positiivisemidefiniitti joss  $A$ :n ominaisarvot ovat ei-negatiiviset ja on olemassa häviävä ominaisarvo,*
- *negatiividefiniitti joss  $A$ :n ominaisarvot ovat negatiiviset,*
- *negatiivisemidefiniitti joss  $A$ :n ominaisarvot ovat ei-positiiviset ja on olemassa häviävä ominaisarvo,*
- *indefiniitti joss  $A$ :lla on sekä pos. että neg. ominaisarvoja.*

**Esimerkki:** Muoto  $Q(x) = 3x_1^2 + 2x_2^2 + x_3^2 + 4x_1x_2 + 4x_2x_3$  "näyttää" positiiviselta, mutta ei ole sitä. Vastaavan symmetrisen matriisin

$$\begin{pmatrix} 3 & 2 & 0 \\ 2 & 2 & 2 \\ 0 & 2 & 1 \end{pmatrix}$$

spektri on  $\{5, 2, -1\}$ .  $Q$  on siis indefiniitti neliömuoto (joka siis saa myös negatiivisia arvoja). Geometrisesti tasa-arvopinnat  $Q = \text{vakio}$  ovat yksi- tai kaksivaippaisia elliptisiä hyperboloideja  $\mathbf{R}^3$ :ssa.



Vaikkei diagonalisointi  $A = PDP^{-1}$  olekaan mahdollinen mielivaltaiselle  $m \times n$  matriisille  $A$ , osoittautuu, että hieman yleisempi hajotelma  $A = QDP^{-1}$  onnistuu. Ensin kuitenkin hiukan neliömuotojen ääriarvoista.

$A^T A$  on symmetrinen  $n \times n$  matriisi, joten se on ortogonaalisesti diagonalisoituva. Olkoot  $\{\mu_1, \dots, \mu_n\}$  sen ominaisarvot ja  $\{v_1, \dots, v_n\}$  ortonormaalit ominaisvektorit. Siten

$$0 \leq \|Av_i\|^2 = (Av_i)^T Av_i = v_i^T A^T Av_i = v_i^T \mu_i v_i = \mu_i. \quad (1)$$

Olkoot nämä arvot laskevassa järjestyksessä  $\mu_i \geq \mu_{i+1}$ . Niiden juuret  $\sigma_i = \sqrt{\mu_i}$  ovat  $A$ :n **singulaariarvot**. Singulaariarvot antavat (1) nojalla vektoreiden  $Av_i$  pituudet.

Huomaa, että  $\|Ax\|^2$  maksimoituu samalla  $x$ :lla kuin  $\|Ax\|$ .

## Lause

Symmetriselle  $B$ , jonka spektri on  $\mu_1 \geq \mu_2 \geq \dots$ ,  $\mu_1 = \max \{x^T Bx \mid \|x\| = 1\}$  ja maksimi saavutetaan  $\mu_1$ :tä vastaavalla yksikköominaisvektorilla.

**Esimerkki:** Olkoon

$$A = \begin{pmatrix} 4 & 11 & 14 \\ 8 & -7 & 2 \end{pmatrix}, \quad \text{joten} \quad A^T A = \begin{pmatrix} 80 & 100 & 40 \\ 100 & 170 & 140 \\ 40 & 140 & 200 \end{pmatrix},$$

jonka ominaisarvot ovat  $\{360, 90, 0\}$ , josta edelleen  $A$ :n singulaariarvot:  $\{6\sqrt{10}, 3\sqrt{10}, 0\}$ .  $A^T A$ :n yksikköominaisvektorit ovat

$$v_1 = \left(\frac{1}{3}, \frac{2}{3}, \frac{2}{3}\right)^T, \quad v_2 = \left(-\frac{2}{3}, -\frac{1}{3}, \frac{2}{3}\right)^T \quad \text{ja} \quad v_3 = \left(\frac{2}{3}, -\frac{2}{3}, \frac{1}{3}\right)^T.$$

$\|Ax\|$  maksimoiduu edellä olevan nojalla  $v_1$ :n suuntaan ja sen maksimiarvo yksikköpallolla on siis  $\|Av_1\| = \sigma_1 = 6\sqrt{10}$ .

Voidaan osoittaa, että  $\|Ax\|$ :n maksimi  $v_1$ :n ortogonaalikomplementissa saavutetaan  $v_2$ :n suuntaan ja on suuruudeltaan  $\sigma_2$ . (Tämä yleistyy edelleen, katso Lay 7.3 Lause 7 ja 7.4 Lause 9.)

# Singulaariarvot 3

Myös  $AA^T$  on symmetrinen ( $m \times m$ ) matriisi, joten se on ortogonaalisesti diagonalisoituva. Olkoot  $\{\lambda_1, \dots, \lambda_m\}$  sen ominaisarvot ja  $\{u_1, \dots, u_m\}$  ortonormaalit ominaisvektorit. Siten  $0 \leq \|A^T u_i\|^2 = (A^T u_i)^T A^T u_i = u_i^T AA^T u_i = u_i^T \lambda_i u_i = \lambda_i$ . (2) Olkoot nämä arvot laskevassa järjestyksessä  $\lambda_i \geq \lambda_{i+1}$ . Koska  $A^T A v_i = \mu_i v_i$ , saadaan kertomalla vasemmalta  $A$ :lla

$$AA^T(Av_i) = \mu_i(Av_i),$$

joten nähdään, että  $\mu_i$  ja  $Av_i$  ovat  $AA^T$ :n ominaisarvo ja -vektori pari. Siten  $AA^T$ :n ja  $A^T A$ :n nollasta eroavat ominaisarvot ovat samat. Jos  $r$  on  $A$ :n rangi, niin

$$\mu_i = \begin{cases} \sigma_i^2 & , i = 1, \dots, r \\ 0 & , i = r + 1, \dots, n \end{cases}$$

josta edelleen

$$Av_i = \begin{cases} \sigma_i u_i & , i = 1, \dots, r \\ 0 & , i = r + 1, \dots, m \end{cases}$$

# Singulaariarvot 4

$\{u_i\}_1^m$  ovat  $A$ :n **vasemmat singulaarivektorit** ja  $\{v_i\}_1^n$  **oikeat singulaarivektorit**. Edellisen nojalla niille voidaan siis kirjoittaa

$$A(v_1 \cdots v_r | v_{r+1} \cdots v_n) = (u_1 \cdots u_r | u_{r+1} \cdots u_m) \Sigma,$$

jossa

$$\Sigma = \begin{pmatrix} D & 0 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \sigma_1 & 0 & \cdots & 0 & 0 & \cdots & 0 \\ 0 & \sigma_2 & \cdots & 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & \sigma_r & 0 & \cdots & 0 \\ 0 & 0 & \cdots & 0 & 0 & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & 0 & 0 & \cdots & 0 \end{pmatrix}$$

on  $m \times n$  matriisi, jonka ainoat nollasta eroavat alkiot ovat singulaariarvot  $r \times r$  diagonaalimatriisissa  $D$ ,  $r \leq \min\{n, m\}$ .

Edellä oleva kehittely on oleellisesti kaikki mitä tarvitaan todistamaan **singulaariarvohajotelma** (engl. singular value decomposition, SVD).

## Lause

*Olkoon  $A$   $m \times n$  matriisi, jonka rangi on  $r$ . Silloin on olemassa  $\Sigma$  kuten edellä ja siinä matriisi  $D$ , jonka diagonaalina ovat  $A$ :n singulaariarvot. Samoin on olemassa  $m \times m$   $U$  ja  $n \times n$   $V$ , molemmat ortogonaalisia, siten että  $A = U\Sigma V^T$ .*

## Huomioita:

1. Matriisit  $U$  ja  $V$  eivät ole yksikäsitteisiä.
2. Jos  $A$  on  $n \times n$  neliömatriisi, ovat  $\Sigma$ ,  $U$  ja  $V$  samaa kokoa ja kaksi viimeistä ortogonaalimatriiseja. Jos  $A$  on vieläpä symmetrinen tiedetään aiemmasta, että se on ortogonaalisesti diagonalisoituva,  $A = PDP^T$ , joten voidaan siis valita  $U = V$ .

**Esimerkki:** Konstruoidaan singulaarihajoitelma edellisen esimerkin matriisille

$$A = \begin{pmatrix} 4 & 11 & 14 \\ 8 & -7 & 2 \end{pmatrix}.$$

Nyt siis  $m = 2$ ,  $n = 3$ .

1. Diagonalisoidaan  $A^T A$  ja ratkaistaan singulaariarvot  $\sigma_i$  kuten edellä:  $\{6\sqrt{10}, 3\sqrt{10}, 0\}$  (siis  $r = 2$ ). Ortonormaalit ominaisvektorit  $v_i$ :

$$v_1 = \left(\frac{1}{3}, \frac{2}{3}, \frac{2}{3}\right)^T, \quad v_2 = \left(-\frac{2}{3}, -\frac{1}{3}, \frac{2}{3}\right)^T \quad \text{ja} \quad v_3 = \left(\frac{2}{3}, -\frac{2}{3}, \frac{1}{3}\right)^T.$$

2. Määritellään  $3 \times 3$  -matriisi  $V = (v_1|v_2|v_3)$  ja edelleen

$$D = \begin{pmatrix} \sigma_1 & 0 \\ 0 & \sigma_2 \end{pmatrix} = \begin{pmatrix} 6\sqrt{10} & 0 \\ 0 & 3\sqrt{10} \end{pmatrix} \quad \text{ja} \quad \Sigma = \begin{pmatrix} 6\sqrt{10} & 0 & 0 \\ 0 & 3\sqrt{10} & 0 \end{pmatrix}.$$

3.  $U$ :n  $r$  ensimmäistä saraketta ovat  $Av_1, \dots, Av_r$  normalisoituna. Nyt  $r = 2$  ja

$$u_1 = \frac{1}{\sigma_1} Av_1 = \frac{1}{6\sqrt{10}} \begin{pmatrix} 18 \\ 6 \end{pmatrix} = \begin{pmatrix} \frac{3}{\sqrt{10}} \\ \frac{1}{\sqrt{10}} \end{pmatrix}$$

$$u_2 = \frac{1}{\sigma_2} Av_2 = \frac{1}{3\sqrt{10}} \begin{pmatrix} 3 \\ -9 \end{pmatrix} = \begin{pmatrix} \frac{1}{\sqrt{10}} \\ -\frac{3}{\sqrt{10}} \end{pmatrix},$$

jotka ovat  $\mathbf{R}^2$ :n kanta ja siten  $U = (u_1|u_2)$ . Siten  $A$ :n singulaariarvohajotelma on

$$U\Sigma V^T = \begin{pmatrix} \frac{3}{\sqrt{10}} & \frac{1}{\sqrt{10}} \\ \frac{1}{\sqrt{10}} & -\frac{3}{\sqrt{10}} \end{pmatrix} \begin{pmatrix} 6\sqrt{10} & 0 & 0 \\ 0 & 3\sqrt{10} & 0 \end{pmatrix} \begin{pmatrix} \frac{1}{3} & \frac{2}{3} & \frac{2}{3} \\ -\frac{2}{3} & -\frac{1}{3} & \frac{2}{3} \\ \frac{2}{3} & -\frac{3}{3} & \frac{1}{3} \end{pmatrix}.$$

NB. Jos kävisi niin, että  $\{Av_i\}$  ei antaisi kantaa kuten yllä, vaan vain  $k < m$  vektoria, niin silloin etsitään ortogonaalikannan loput vektorit tämän joukon ortogonaalikomplementista Gram-Schmidtia ja normalisointia käyttäen.