

## 5.3 SVD

## Huom.

- Vain matriisi  $\Sigma$  on yksikäsitteinen (kun singulaariarvot asetetaan diagonaalille suurimmasta pienimpään), muita voi löytyä useita.
- Luku  $\sigma > 0$  on matriisin  $A$  singulaariarvo, jos on olemassa vektorit  $u$  ja  $v$  siten, että  $Av = \sigma u$  ja  $A^T u = \sigma v$ .
- Jos  $\sigma$  on matriisin  $A$  singulaariarvo, niin  $\sigma^2$  on matriisin  $A^T A$  ominaisarvo.
- SVD on olemassa myös kompleksisille matriiseille, silloin transpoosin  $V^T$  sijaan tarvitaan adjungaatti  $V^*$  (kompleksikonjugaatin transpoosi) ja  $U$  ja  $V$  ovat unitaarisia, eli  $V^{-1} = V^*$ ,  $U^{-1} = U^*$ .

## 5.3 SVD

SVD voidaan laskea seuraavien tietojen perusteella:

- Matriisin  $\Sigma$  diagonaali-alkiot  $\sigma_j$  ovat matriisin  $A^T A$  ominaisarvojen positiiviset neliöjuuret.
- Matriisin  $V$  sarakevektorit  $v_j$  (eli  $V^T$ :n rivit) ovat matriisin  $A^T A$  yksikköpituiset ominaisvektorit.
- Matriisin  $U$  sarakevektorit  $u_j$  ovat matriisin  $AA^T$  yksikköpituiset ominaisvektorit.
- Jos  $\sigma_j \neq 0$ , niin sarakevektori  $u_j = Av_j/\sigma_j$ .

**Huom.** Matriisit  $AA^T \in \mathbb{R}^{m \times m}$  ja  $A^T A \in \mathbb{R}^{n \times n}$  ovat aina symmetrisiä, joten niillä on täysi määrä ortogonaalisia ominaisvektoreita. Koko SVD:n idea perustuu tähän.

## 5.3 SVD

## Esimerkki 11 (Luentoharjoitus)

Etsi matriisin

$$A = \begin{pmatrix} 1 & 2 \\ 3 & 6 \end{pmatrix}$$

singulaariarvohajotelma.

**Ratkaisu:** Matriisin  $A^T A = \begin{pmatrix} 10 & 20 \\ 20 & 40 \end{pmatrix}$  ominaisarvot ovat 50 ja 0, joten singulaariarvot ovat  $\sigma_1 = \sqrt{50}$ ,  $\sigma_2 = 0$ . Matriisin  $A^T A$  yksikköpituiset ominaisvektorit ovat  $v_1 = \begin{pmatrix} 1/\sqrt{5} \\ 2/\sqrt{5} \end{pmatrix}$  ja  $v_2 = \begin{pmatrix} 2/\sqrt{5} \\ -1/\sqrt{5} \end{pmatrix}$ .

## 5.3 SVD

Nyt  $u_1 = Av_1/\sigma_1 = \begin{pmatrix} 5/\sqrt{5} \\ 15/\sqrt{5} \end{pmatrix} \frac{1}{\sqrt{50}} = \begin{pmatrix} 1/\sqrt{10} \\ 3/\sqrt{10} \end{pmatrix}$ . Koska  $\sigma_2 = 0$ , vektoria  $u_2$  ei saada samalla tavalla, vaan se täytyy laskea matriisin  $AA^T$  yksikköpituisena ominaisvektorina:  $AA^T = \begin{pmatrix} 5 & 15 \\ 15 & 45 \end{pmatrix}$ , ja sen ominaisarvoa 0 vastaava yksikköpituisen ominaisvektori on  $u_2 = \begin{pmatrix} 3/\sqrt{10} \\ -1/\sqrt{10} \end{pmatrix}$ . Näin ollen hajotelma on

$$A = U\Sigma V^T = \begin{pmatrix} 1/\sqrt{10} & 3/\sqrt{10} \\ 3/\sqrt{10} & -1/\sqrt{10} \end{pmatrix} \begin{pmatrix} \sqrt{50} & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} 1/\sqrt{5} & 2/\sqrt{5} \\ 2/\sqrt{5} & -1/\sqrt{5} \end{pmatrix}.$$

(Tarkista kertolaskulla!)

## 5.3 SVD

Alkuperäistä  $n \times n$  matriisia voidaan approksimoida SVD:n avulla ottamalla  $k$  ensimmäistä saraketta matriisista  $U$ ,  $k \times k$  osa diagonaalimatriisiin  $\Sigma$  vasemmasta yläkulmasta ja  $k$  ensimmäistä riviä matriisista  $V^T$ , eli ensimmäistä  $k$ :ta singulaariarvoa vastaava osuus.

Huom: Singulaariarvot oli valittu suuruusjärjestykseen, suurimmasta pienimpään.

Näin saadaan alkuperäistä matriisia approksimoiva matriisi, "jonka rangi on  $k$ ".

## 5.3 SVD

## Esimerkki 12

Äskeisen esimerkin matriisille saadaan approksimaatio

$$\begin{aligned} & \begin{pmatrix} 1 & 2 \\ 3 & 6 \end{pmatrix} \\ &= \begin{pmatrix} 1/\sqrt{10} & 3/\sqrt{10} \\ 3/\sqrt{10} & -1/\sqrt{10} \end{pmatrix} \begin{pmatrix} \sqrt{50} & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} 1/\sqrt{5} & 2/\sqrt{5} \\ 2/\sqrt{5} & -1/\sqrt{5} \end{pmatrix} \\ &\approx \begin{pmatrix} 1/\sqrt{10} \\ 3/\sqrt{10} \end{pmatrix} (\sqrt{50}) \begin{pmatrix} 1/\sqrt{5} & 2/\sqrt{5} \end{pmatrix} \\ &= \begin{pmatrix} 1/\sqrt{10} \\ 3/\sqrt{10} \end{pmatrix} (\sqrt{10} \quad 2\sqrt{10}) \\ &= \begin{pmatrix} 1 & 2 \\ 3 & 6 \end{pmatrix} \end{aligned}$$

## 5.3 SVD

## Esimerkki 13

Testikuvassa on  $512 \times 512$  pikseliä, eli se voidaan esittää  $512 \times 512$ -matriisilla, pikselin väri antaa arvon ko. alkion matriisissa. Tälle matriisille voidaan tehdä singulaariarvohajotelma, ja approksimoida sitten kuvaa ottamalla hajotelmasta  $k$ :ta ensimmäistä singulaariarvoa vastaava osuus. Huomataan, että vähempikin määrä dataa riittää kuvan esittämiseen tunnisttavasti ja jopa silmämääräisesti riittävän tarkasti.

Seuraavalla sivulla kuvat, kun  $k = 1, 10, 20, 50, 100$  ja  $200$  sekä alkuperäinen kuva.

(a)  $k = 1$ (b)  $k = 10$ (c)  $k = 20$ (d)  $k = 50$ (e)  $k = 100$ (f)  $k = 200$ (g)  $k = 512$ 

## 5.3 SVD

## 5.3 SVD

Kun alkuperäisen  $m \times n$ -matriisin sijaan käytetään SVD:stä  $k$  ensimmäistä singulaariarvoa, tarvittavien lukujen määrä on

$$k + km + kn,$$

eli  $k$  singulaariarvoa, niistä vastaavat  $k$  ensimmäistä sarakevektoria (pituus  $m$ ) matriisista  $U$  ja  $k$  ensimmäistä rivivektoria (pituus  $n$ ) matriisista  $V^T$ .

Neliömatriisille  $n \times n$  tämä tarkoittaa, että jos  $k < n^2/(1 + 2n)$ , niin datan määrä pienenee. Edellä käytetylle kuvalle  $n = 512$ , joten  $k < 255$  vähentää datamäärää.

## 5.3 SVD

## Esimerkki 15

Käydään läpi SVD:hen perustuva hahmontunnistusedemo Matlabilla. Demon ohjeet ovat jaossa Noppa-sivulla, voit kokeilla sitä myöhemmin itsekin.

Huomattiin siis, että SVD:n avulla voidaan poimia datasta olennainen ja päästä turhasta "kohinasta" eroon, pienentäen samalla käsiteltävää datamäärää merkittävästi.

SVD:n muut sovellukset jätämme myöhempiin kursseihin, tämä kurssi päättyy tähän!

## 5.3 SVD

## Esimerkki 14 (Luentoharjoitus)

On saatu seuraava singulaariarvohajotelma:

$$\begin{pmatrix} 0 & 0 & 1 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & -1 \\ 1 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 4 & 0 & 0 & 0 & 0 \\ 0 & 3 & 0 & 0 & 0 \\ 0 & 0 & \sqrt{5} & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{pmatrix} \begin{pmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 \\ 1/\sqrt{5} & 0 & 0 & 0 & 2/\sqrt{5} \\ 0 & 0 & 0 & 1 & 0 \\ -2/\sqrt{5} & 0 & 0 & 0 & 1/\sqrt{5} \end{pmatrix}$$

Approksimoi kyseessä olevaa matriisia kahden ja sitten kolmen singulaariarvon avulla. Mitä saat? Miksi? Laske myös alkuperäinen matriisi.