

Jyrki Möttönen

Matriisilaskentaa tilastotieteilijöille

Helsingin yliopisto
Sosiaalitieteiden laitos
Kevät 2015

Sisältö

1	Matriisialgebran alkeita	1
1.1	Notaatioita	1
1.2	Matriisien yhteenlasku ja kertolasku	2
1.3	Matriisin transpoosi	4
1.4	Matriisin jälki (trace)	5
1.5	Determinantti	5
1.6	Käänteismatriisi	8
1.7	Harjoituksia	11
2	Vektoriavaruudet	14
2.1	Määritelmät	14
2.2	Lineaarinen riippumattomuus ja riippuvuus	14
2.3	Vektoriavaruuden kannat ja dimensio	15
2.4	Matriisin aste ja lineaarinen riippumattomuus	15
2.5	Projektiomatriisit	15
2.6	Harjoituksia	17
3	Ominaisarvot ja ominaisvektorit	18
3.1	Johdanto	18
3.2	Määritelmät	18
3.3	Ominaisarvojen ja ominaisvektorien perusominaisuuksia	20
3.4	Symmetriset matriisit	22
3.5	Positiivisesti definiitit ja semidefiniitit matriisit	23
3.6	Harjoituksia	24
4	Matriisihajotelmat	25
4.1	Pääakseliesitys	25
4.2	Singulaariarvohajotelma	27
4.3	Harjoituksia	31
5	Ositetut matriisit	32
5.1	Ositetujen matriisien kertolasku	32
5.2	Ositetun matriisin käänteismatriisi	33
5.3	Ositetun matriisin determinantti	36

<i>SISÄLTÖ</i>	iii
5.4 Harjoituksia	36
6 Lineaariset yhtälöryhmät	37
6.1 Lineaarisen yhtälöryhmän ratkaisujen lukumäärä	37
6.2 Lineaarisen yhtälöryhmän ratkaiseminen	38
6.3 Harjoituksia	39
7 Matriisiderivaatat	40
7.1 Muutamia hyödyllisiä matriisiderivaattoja	40
7.2 Harjoituksia	41
Kirjallisuutta	42

Luku 1

Matriisialgebran alkeita

1.1 Notatioita

Matriiseja merkitään yleensä vahvennetuilla isoilla kirjaimilla. Esimerkiksi $m \times n$ matriisi

$$\mathbf{A} = (a_{ij}) = \begin{pmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \cdots & a_{mn} \end{pmatrix}$$

on matriisi, jolla on m riviä ja n saraketta.

Matriisin \mathbf{A} i :nmen rivin j :nmen sarakkeen alkio on $a_{ij} = (\mathbf{A})_{ij}$.

Matriisin \mathbf{A} i :s rivi on $(\mathbf{A})_i$, ja j :s sarake on $(\mathbf{A})_j$.

Pystyvektori on matriisi, jolla on ainoastaan yksi sarake. Esim.

$$\mathbf{b} = \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_n \end{pmatrix}.$$

Vaakavektori on matriisi, jolla on ainoastaan yksi rivi. Esim.

$$(c_1 \ c_2 \ \cdots \ c_n).$$

Tällä kurssilla pystyvektoria merkitään vahvennetulla pienellä kirjaimella. Pystyvektorista saadaan vaakavektori transpoosin avulla (ks. kappale 1.3).

Yksittäistä numeroa kutsutaan *skalaariksi*. Voidaan ajatella myös, että skalaari on 1×1 matriisi.

1.2 Matriisien yhteenlasku ja kertolasku

Määritelmä 1. *Olkoon A ja B $m \times n$ matriiseja. Tällöin matriisien A ja B summa on*

$$A + B = (a_{ij} + b_{ij}).$$

Huom! Yhteenlaskettavat matriisit täytyy olla samankokoisia eli sekä A että B täytyy olla $m \times n$ matriisi.

Määritelmä 2. *Olkoon A $m \times p$ matriisi ja B $p \times n$ matriisi. Tällöin matriisien A ja B tulo on*

$$AB = (c_{ij}),$$

jossa

$$c_{ij} = (A)_i \cdot (B)_{\cdot j} = \sum_{k=1}^p a_{ik} b_{kj}.$$

Huom! Matriisien tulossa vasemmampuoleisella matriisilla täytyy olla sarakkeita yhtä paljon kuin oikeanpuoleisella matriisilla rivejä, jotta operaatio olisi määritelty.

Määritelmä 3. *Skalaarin α ja matriisin A tulo on*

$$\alpha A = A\alpha = (\alpha a_{ij}).$$

Lause 1. *Olkoon α ja β skalaareja ja A , B ja C matriiseja. Tällöin, las-kuoperaatioiden ollessa määriteltyjä,*

(a) $A + B = B + A$

(b) $(A + B) + C = A + (B + C)$

(c) $\alpha(A + B) = \alpha A + \alpha B$

(d) $(\alpha + \beta)A = \alpha A + \beta A$

(e) $A - A = A + (-A) = (0)$

(f) $A(B + C) = AB + AC$

(g) $(A + B)C = AC + BC$

(h) $(AB)C = A(BC)$

Huom! Yleensä $AB \neq BA$ eli skalaaritulon tuttu ominaisuus $\alpha\beta = \beta\alpha$ ei ole yleisesti voimassa matriisien kertolaskussa!!

```
> A<-matrix(c(1,-1,2,3),2,2)
> B<-matrix(c(3,6,2,3),2,2)
> C<-matrix(c(1,2,3,-1),2,2)
> A
      [,1] [,2]
[1,]    1    2
[2,]   -1    3
> B
      [,1] [,2]
[1,]    3    2
[2,]    6    3
> C
      [,1] [,2]
[1,]    1    3
[2,]    2   -1
> A+B
      [,1] [,2]
[1,]    4    4
[2,]    5    6
> 2*(A+B)
      [,1] [,2]
[1,]    8    8
[2,]   10   12
> A%*%B
      [,1] [,2]
[1,]   15    8
[2,]   15    7
> A%*%B%*%C
      [,1] [,2]
[1,]   31   37
[2,]   29   38
> (A%*%B)%*%C
      [,1] [,2]
[1,]   31   37
[2,]   29   38
> A%*%(B%*%C)
      [,1] [,2]
[1,]   31   37
[2,]   29   38
> B%*%C%*%A
      [,1] [,2]
[1,]    0   35
[2,]   -3   69
```

1.3 Matriisin transpoosi

Olkoon \mathbf{A} $m \times n$ matriisi. Tällöin matriisin \mathbf{A} *transpoosi* \mathbf{A}' on matriisi, jonka riveinä ovat matriisin \mathbf{A} sarakkeet ("käännettynä 90 astetta vastapäivään") järjestys säilyttäen. Toisin sanottuna

$$\mathbf{A}' = (a_{ij})' = (a_{ji})$$

Matriisin \mathbf{A} transpoosi on siis $n \times m$ matriisi eli rivien ja sarakkeiden lukumäärät vaihtavat paikkaa.

Lause 2. *Olkoon α ja β skalaareja ja \mathbf{A} ja \mathbf{B} matriiseja. Tällöin, laskuoperaatioiden ollessa määriteltynä,*

$$(a) (\alpha\mathbf{A})' = \alpha\mathbf{A}'.$$

$$(b) (\mathbf{A}')' = \mathbf{A}.$$

$$(c) (\alpha\mathbf{A} + \beta\mathbf{B})' = \alpha\mathbf{A}' + \beta\mathbf{B}'.$$

$$(d) (\mathbf{AB})' = \mathbf{B}'\mathbf{A}'.$$

Esimerkki 1.3.1

Matriisin

$$\mathbf{A} = \begin{pmatrix} 2 & 5 \\ 3 & 7 \\ 4 & 9 \end{pmatrix}$$

transpoosi on

$$\mathbf{A}' = \begin{pmatrix} 2 & 3 & 4 \\ 5 & 7 & 9 \end{pmatrix}.$$

```
> A<-matrix(c(2,3,4,5,7,9),3,2)
```

```
> A
```

```
  [,1] [,2]
```

```
[1,]  2   5
```

```
[2,]  3   7
```

```
[3,]  4   9
```

```
> t(A)
```

```
  [,1] [,2] [,3]
```

```
[1,]  2   3   4
```

```
[2,]  5   7   9
```

Esimerkki 1.3.2

Pystyvektorin

$$\mathbf{b} = \begin{pmatrix} 1 \\ 4 \\ 7 \end{pmatrix}$$

transpoosi on vaakavektori

$$\mathbf{b}' = (1 \quad 4 \quad 7).$$

1.4 Matriisin jälki (trace)

Olkoon $A = (a_{ij})$ $n \times n$ neliömatriisi. Matriisin A jälki (eng. trace) on tällöin

$$\operatorname{tr}(A) = \sum_{i=1}^n a_{ii}.$$

Matriisin jäljen ominaisuuksia:

Lause 3. *Olkoon α skalaari ja A ja B matriiseja. Tällöin, laskuoperaatioiden ollessa määriteltynä,*

(a) $\operatorname{tr}(A') = \operatorname{tr}(A).$

(b) $\operatorname{tr}(\alpha A) = \alpha \operatorname{tr}(A).$

(c) $\operatorname{tr}(A + B) = \operatorname{tr}(A) + \operatorname{tr}(B).$

(d) $\operatorname{tr}(AB) = \operatorname{tr}(BA).$

(e) $\operatorname{tr}(A'A) = 0$, jos ja vain jos $A = (0)$.

1.5 Determinantti

Määritelmä 4. *Olkoon A $m \times m$ neliömatriisi. Tällöin matriisin A determinantti on*

$$\begin{aligned} |\mathbf{A}| = \det(\mathbf{A}) &= \sum (-1)^{f(i_1, \dots, i_m)} a_{1i_1} a_{2i_2} \cdots a_{mi_m} \\ &= \sum (-1)^{f(i_1, \dots, i_m)} a_{i_1 1} a_{i_2 2} \cdots a_{i_m m}, \end{aligned}$$

jossa summaus otetaan yli kaikkien joukon $(1, \dots, m)$ permutaatioiden (i_1, \dots, i_m) ja funktio $f(i_1, \dots, i_m)$ on transpositioiden lukumäärä, joka tarvitaan lukujonon (i_1, \dots, i_m) muuttamiseksi lukujonoksi $(1, \dots, m)$.

Transpositiolla tarkoitetaan kahden lukujonon luvun paikkojen vaihtamista. Esimerkiksi lukujonosta $(2, 3, 1)$ saadaan transpositioiden avulla $(1, 2, 3)$ seuraavasti:

$$(2, 3, 1) \longrightarrow (1, 3, 2) \longrightarrow (1, 2, 3).$$

Tarvittavien transpositioiden lukumäärä ei ole yksikäsitteinen mutta se on aina yksikäsitteisesti joko parillinen tai pariton.

Lause 4. Olkoon \mathbf{A} $m \times m$ neliömatriisi ja olkoon $A_{ij} = (-1)^{i+j}m_{ij}$ matriisin \mathbf{A} alkiota a_{ij} vastaava kofaktori, jossa m_{ij} on determinantti $(m-1) \times (m-1)$ matriisista, joka saadaan poistamalla matriisin \mathbf{A} i :s rivi ja j :s sarake.

(a) Kun $m = 1$ (eli kyseessä on skalaari), niin

$$|\mathbf{A}| = |a_{11}| = a_{11}.$$

(b) Kun $m = 2$, niin

$$|\mathbf{A}| = \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} = a_{11}a_{22} - a_{12}a_{21}.$$

(c) Kun $m \geq 2$, niin

$$|\mathbf{A}| = \sum_{j=1}^m a_{ij}A_{ij},$$

(d) Kun $m \geq 2$, niin

$$|\mathbf{A}| = \sum_{j=1}^m a_{ji}A_{ji},$$

Esimerkki 1.5.1

(a)

$$\begin{vmatrix} 4 & 6 \\ 3 & 7 \end{vmatrix} = 4 \cdot 7 - 6 \cdot 3 = 28 - 18 = 10.$$

```
> A<-matrix(c(4,3,6,7),2,2)
> A
      [,1] [,2]
[1,]    4    6
[2,]    3    7
> det(A)
[1] 10
```

(b)

$$\begin{aligned} \begin{vmatrix} 4 & 6 & 2 \\ 3 & 7 & 1 \\ 5 & 9 & 8 \end{vmatrix} &= 4(-1)^{1+1} \begin{vmatrix} 7 & 1 \\ 9 & 8 \end{vmatrix} + 6(-1)^{1+2} \begin{vmatrix} 3 & 1 \\ 5 & 8 \end{vmatrix} + 2(-1)^{1+3} \begin{vmatrix} 3 & 7 \\ 5 & 9 \end{vmatrix} \\ &= 4 \begin{vmatrix} 7 & 1 \\ 9 & 8 \end{vmatrix} - 6 \begin{vmatrix} 3 & 1 \\ 5 & 8 \end{vmatrix} + 2 \begin{vmatrix} 3 & 7 \\ 5 & 9 \end{vmatrix} \\ &= 4(7 \cdot 8 - 1 \cdot 9) - 6(3 \cdot 8 - 1 \cdot 5) + 2(3 \cdot 9 - 7 \cdot 5) = 58. \end{aligned}$$

```

> A<-matrix(c(4,3,5,6,7,9,2,1,8),3,3)
> A
      [,1] [,2] [,3]
[1,]    4    6    2
[2,]    3    7    1
[3,]    5    9    8
> det(A)
[1] 58

```

Lause 5. *Olkoon α skalaari ja \mathbf{A} $m \times m$ matriisi. Tällöin*

(a) $|\mathbf{A}'| = |\mathbf{A}|.$

(b) $|\alpha\mathbf{A}| = \alpha^m |\mathbf{A}|.$

(c) *Jos \mathbf{A} on diagonaalimatriisi, niin*

$$|\mathbf{A}| = |\text{diag}(a_{11}, \dots, a_{mm})| = \prod_{i=1}^m a_{ii}.$$

(d) *Jos matriisin \mathbf{A} jollain rivillä (tai sarakeella) kaikki alkiot ovat nolliä, niin $|\mathbf{A}| = 0.$*

(e) *Jos matriisin \mathbf{A} kaksi riviä (tai saraketta) ovat lineaarisesti riippuvia, niin $|\mathbf{A}| = 0.$*

(f) *Matriisin \mathbf{A} kahden rivin (tai sarakkeen) paikkojen vaihtaminen keskenään vaihtaa determinantin $|\mathbf{A}|$ etumerkin.*

(g) *Jos matriisin \mathbf{A} yhden rivin (tai sarakkeen) alkiot kerrotaan vakiolla α , niin determinantti tulee kerrottua myös vakiolla $\alpha.$*

(h) *Matriisin \mathbf{A} determinantti pysyy muuttumattomana, jos matriisin riviin (tai sarakkeeseen) lisätään jonkin toisen rivin (tai sarakkeen) monikerta.*

Lause 6. *Olkoon \mathbf{A} ja \mathbf{B} $m \times m$ neliömatriiseja. Tällöin*

$$|\mathbf{AB}| = |\mathbf{BA}| = |\mathbf{A}||\mathbf{B}|.$$

1.6 Käänteismatriisi

Esimerkki 1.6.1

Halutaan sovittaa aineistoon lineaarinen regressiomalli

$$y_i = x_{i1}\beta_1 + \dots + x_{ip}\beta_p + \epsilon_i,$$

jossa y_i on havaittu arvo, x_{ij} ovat tunnettuja selittävän muuttujan j arvoja, β_j on j :nnen selittävän muuttujan regressiokerroin ja ϵ_j on virhetermi. Edellinen malli voidaan ilmaista matriisien avulla muodossa

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon},$$

jossa $\mathbf{y} = (y_1, \dots, y_n)'$, $\boldsymbol{\beta} = (\beta_1, \dots, \beta_p)'$, $\mathbf{X} = (\mathbf{x}_1 \dots \mathbf{x}_n)'$ ja $\boldsymbol{\epsilon} = (\epsilon_1, \dots, \epsilon_n)'$. Parametrien β_j estimoimiseen käytetään pienimmän neliösumman menetelmää, jolloin halutaan minimoida jäännösneliösumma

$$S(\boldsymbol{\beta}) = \sum_{i=1}^n (y_i - \mathbf{x}_i'\boldsymbol{\beta})^2$$

parametrivektorin $\boldsymbol{\beta}$ suhteen. Derivoimalla $S(\boldsymbol{\beta})$ parametrivektorin $\boldsymbol{\beta}$ suhteen ja asettamalla derivaatta nolllaksi, saadaan ns. normaaliyhtälö

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y}.$$

Jos on olemassa matriisi \mathbf{A} , jolle pätee $\mathbf{A}(\mathbf{X}'\mathbf{X}) = \mathbf{I}_p$, niin kertomalla edellinen yhtälö vasemmalta puolittain matriisilla \mathbf{A} , saadaan

$$\mathbf{A}\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{A}\mathbf{X}'\mathbf{y} \Leftrightarrow \mathbf{I}_p\boldsymbol{\beta} = \mathbf{A}\mathbf{X}'\mathbf{y} \Leftrightarrow \boldsymbol{\beta} = \mathbf{A}\mathbf{X}'\mathbf{y}.$$

Kyseistä matriisiä \mathbf{A} kutsutaan matriisin $\mathbf{B} = \mathbf{X}'\mathbf{X}$ käänteismatriisiksi.

Esimerkki 1.6.2

Halutaan ratkaista yhtälöryhmä

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + a_{13}x_3 = c_1 \\ a_{21}x_1 + a_{22}x_2 + a_{23}x_3 = c_2 \\ a_{31}x_1 + a_{32}x_2 + a_{33}x_3 = c_3 \end{cases}$$

muuttujien x_1 , x_2 , x_3 suhteen. Edellinen yhtälöryhmä voidaan kirjoittaa matriisien avulla seuraavassa muodossa:

$$\mathbf{A}\mathbf{x} = \mathbf{c},$$

jossa

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}, \quad \mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} \quad \text{ja} \quad \mathbf{c} = \begin{pmatrix} c_1 \\ c_2 \\ c_3 \end{pmatrix}.$$

Jos on olemassa matriisi \mathbf{A}^{-1} , jolle pätee $\mathbf{A}^{-1}\mathbf{A} = \mathbf{I}_3$, niin kertomalla edellinen yhtälö vasemmalta puolittain matriisilla \mathbf{A}^{-1} , saadaan

$$\mathbf{A}^{-1}\mathbf{A}\mathbf{x} = \mathbf{A}^{-1}\mathbf{c} \Leftrightarrow \mathbf{I}_3\mathbf{x} = \mathbf{A}^{-1}\mathbf{c} \Leftrightarrow \mathbf{x} = \mathbf{A}^{-1}\mathbf{c}.$$

Määritelmä 5. Neliömatriisi \mathbf{A} on ei-singulaarinen, jos $|\mathbf{A}| \neq 0$ ja singulaarinen, jos $|\mathbf{A}| = 0$.

Olkoon \mathbf{A} ei-singulaarinen $m \times m$ neliömatriisi. Tällöin on olemassa ei-singulaarinen $m \times m$ neliömatriisi \mathbf{A}^{-1} , jolle pätee

$$\mathbf{A}\mathbf{A}^{-1} = \mathbf{A}^{-1}\mathbf{A} = \mathbf{I}_m.$$

Matriisia \mathbf{A}^{-1} kutsutaan matriisin \mathbf{A} käänteismatriisiksi.

Lause 7. Olkoon $\alpha \neq 0$ skalaari ja \mathbf{A} ja \mathbf{B} ei-singulaarisia $m \times m$ neliömatriiseja. Tällöin

(a) $(\alpha\mathbf{A})^{-1} = \alpha^{-1}\mathbf{A}^{-1}$

(b) $(\mathbf{A}')^{-1} = (\mathbf{A}^{-1})'$

(c) $(\mathbf{A}^{-1})^{-1} = \mathbf{A}$

(d) $|\mathbf{A}^{-1}| = |\mathbf{A}|^{-1}$

(e) Jos $\mathbf{A} = \text{diag}(a_{11}, \dots, a_{mm})$, niin $\mathbf{A}^{-1} = \text{diag}(a_{11}^{-1}, \dots, a_{mm}^{-1})$

(f) Jos $\mathbf{A} = \mathbf{A}'$, niin $\mathbf{A}^{-1} = (\mathbf{A}^{-1})'$

(g) $(\mathbf{A}\mathbf{B})^{-1} = \mathbf{B}^{-1}\mathbf{A}^{-1}$

Käänteismatriisi voidaan laskea determinantin tapaan kofaktorien avulla seuraavasti:

$$\mathbf{A}^{-1} = |\mathbf{A}|^{-1} \begin{pmatrix} A_{11} & A_{21} & \cdots & A_{m1} \\ A_{12} & A_{22} & \cdots & A_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ A_{1m} & A_{2m} & \cdots & A_{mm} \end{pmatrix}.$$

Esimerkki 1.6.3

Matriisin

$$\mathbf{A} = \begin{pmatrix} 1 & 2 \\ 10 & 5 \end{pmatrix}$$

käänteismatriisi on

$$\mathbf{A}^{-1} = \frac{1}{1 \cdot 5 - 2 \cdot 10} \begin{pmatrix} 5 & -2 \\ -10 & 1 \end{pmatrix} = -\frac{1}{15} \begin{pmatrix} 5 & -2 \\ -10 & 1 \end{pmatrix} = \begin{pmatrix} -1/3 & 2/15 \\ 2/3 & -1/15 \end{pmatrix}.$$

```

> A<-matrix(c(1,10,2,5),2,2)
> A
      [,1] [,2]
[1,]    1    2
[2,]   10    5
> invA<-solve(A)
> invA
      [,1]      [,2]
[1,] -0.3333333  0.13333333
[2,]  0.6666667 -0.06666667
> -15*invA
      [,1] [,2]
[1,]    5  -2
[2,]  -10   1
> invA%*%A
      [,1]      [,2]
[1,]  1.0000000e+00 2.775558e-17
[2,] -2.775558e-17 1.0000000e+00

```

Esimerkki 1.6.4

Olkoon

$$A = \begin{pmatrix} 1 & 2 & 3 \\ 10 & 5 & 6 \\ 7 & 8 & 9 \end{pmatrix}.$$

Tällöin

$$|A| = 1 \begin{vmatrix} 5 & 6 \\ 8 & 9 \end{vmatrix} - 2 \begin{vmatrix} 10 & 6 \\ 7 & 9 \end{vmatrix} + 3 \begin{vmatrix} 10 & 5 \\ 7 & 8 \end{vmatrix} = 1(-3) - 2 \cdot 48 + 3 \cdot 45 = 36$$

ja

$$A^{-1} = \frac{1}{36} \begin{pmatrix} \begin{vmatrix} 5 & 6 \\ 8 & 9 \end{vmatrix} & -\begin{vmatrix} 2 & 3 \\ 8 & 9 \end{vmatrix} & \begin{vmatrix} 2 & 3 \\ 5 & 6 \end{vmatrix} \\ -\begin{vmatrix} 10 & 6 \\ 7 & 9 \end{vmatrix} & \begin{vmatrix} 1 & 3 \\ 7 & 9 \end{vmatrix} & -\begin{vmatrix} 1 & 3 \\ 10 & 6 \end{vmatrix} \\ \begin{vmatrix} 10 & 5 \\ 7 & 8 \end{vmatrix} & -\begin{vmatrix} 1 & 2 \\ 7 & 8 \end{vmatrix} & \begin{vmatrix} 1 & 2 \\ 10 & 5 \end{vmatrix} \end{pmatrix} = \frac{1}{36} \begin{pmatrix} -3 & 6 & -3 \\ -48 & -12 & 24 \\ 45 & 6 & -15 \end{pmatrix}.$$

```

> A<-matrix(c(1,10,7,2,5,8,3,6,9),3,3)
> A
      [,1] [,2] [,3]
[1,]    1    2    3

```

```

[2,] 10 5 6
[3,] 7 8 9
> det(A)
[1] 36
> invA<-solve(A)
> invA
           [,1]      [,2]      [,3]
[1,] -0.08333333  0.1666667 -0.08333333
[2,] -1.33333333 -0.3333333  0.66666667
[3,]  1.25000000  0.1666667 -0.41666667
> invA%*%A
           [,1]      [,2]      [,3]
[1,]  1.000000e+00  3.885781e-16  4.163336e-16
[2,] -7.771561e-16  1.000000e+00 -9.992007e-16
[3,]  1.665335e-16  2.498002e-16  1.000000e+00
> det(A)*invA
           [,1] [,2] [,3]
[1,]   -3    6   -3
[2,]  -48  -12   24
[3,]   45    6  -15

```

1.7 Harjoituksia

1.1

Olkoon

$$\mathbf{A} = \begin{pmatrix} 2 & 4 & 3 \\ 8 & 1 & 4 \end{pmatrix}, \mathbf{B} = \begin{pmatrix} 3 & 4 \\ 1 & 2 \\ 8 & 3 \end{pmatrix} \text{ ja } \mathbf{C} = \begin{pmatrix} 5 & 1 & 2 \\ 6 & 7 & 5 \end{pmatrix}.$$

Laske seuraavat summat

- (a) $\mathbf{A} + \mathbf{B}$
- (b) $\mathbf{A} + \mathbf{C}$
- (c) $\mathbf{B} + \mathbf{C}$

1.2

Olkoon

$$\mathbf{A} = \begin{pmatrix} 2 & 4 & 3 \\ 8 & 1 & 4 \end{pmatrix}, \mathbf{B} = \begin{pmatrix} 3 & 4 \\ 1 & 2 \\ 8 & 3 \end{pmatrix}, \mathbf{C} = \begin{pmatrix} 5 & 1 & 2 \\ 6 & 7 & 5 \end{pmatrix} \text{ ja } \mathbf{D} = \begin{pmatrix} 5 & 1 & 2 \\ 6 & 7 & 5 \\ 2 & 8 & 1 \end{pmatrix}.$$

Laske seuraavat matriisitulot

- (a) \mathbf{AB}
- (b) \mathbf{AC}
- (c) \mathbf{BC}
- (c) \mathbf{AD}

1.3

Olkoon

$$\mathbf{A} = \begin{pmatrix} 2 & 4 & 3 \\ 8 & 1 & 4 \end{pmatrix}, \mathbf{B} = \begin{pmatrix} 3 & 4 \\ 1 & 2 \\ 8 & 3 \end{pmatrix} \text{ ja } \mathbf{D} = \begin{pmatrix} 5 & 1 & 2 \\ 6 & 7 & 5 \\ 2 & 8 & 1 \end{pmatrix}.$$

Laske

- (a) $\text{tr}(\mathbf{A})$
- (b) $\text{tr}(\mathbf{D})$
- (c) $\text{tr}(\mathbf{BA})$
- (d) $\text{tr}(\mathbf{AB})$

1.4

Olkoon

$$\mathbf{A} = \begin{pmatrix} 5 & 1 \\ 6 & 7 \end{pmatrix}, \mathbf{B} = \begin{pmatrix} 3 & 2 \\ 4 & 3 \end{pmatrix}, \mathbf{C} = \begin{pmatrix} 5 & 1 & 2 \\ 6 & 7 & 5 \\ 2 & 8 & 1 \end{pmatrix} \text{ ja } \mathbf{D} = \begin{pmatrix} 3 & 2 & 1 \\ 4 & 3 & 7 \\ 1 & 4 & 6 \end{pmatrix},$$

$$\mathbf{E} = \begin{pmatrix} 5 & 1 & 0 \\ 6 & 7 & 0 \\ 2 & 8 & 0 \end{pmatrix}, \mathbf{F} = \begin{pmatrix} 5 & 0 & 0 \\ 0 & 7 & 0 \\ 0 & 0 & 9 \end{pmatrix} \text{ ja } \mathbf{G} = \begin{pmatrix} 3 & 2 & 3 \\ 4 & 3 & 4 \\ 1 & 4 & 1 \end{pmatrix}.$$

Laske

- (a) $|\mathbf{A}|$
- (b) $|10\mathbf{A}|$
- (b) $|\mathbf{B}|$
- (c) $|\mathbf{AB}|$
- (d) $|\mathbf{C}|$
- (e) $|\mathbf{D}|$

(f) $|CD|$

(g) $|E|$

(h) $|F|$

(i) $|G|$

1.5

Olkoon

$$\mathbf{A} = \begin{pmatrix} 5 & 1 \\ 6 & 7 \\ 2 & 8 \end{pmatrix} \text{ ja } \mathbf{B} = \begin{pmatrix} 3 & 2 & 1 \\ 4 & 3 & 7 \end{pmatrix}.$$

Laske

(a) $|AB|$

(b) $|BA|$

(c) $|B'A'|$

Luku 2

Vektoriavaruudet

2.1 Määritelmät

Määritelmä 6. Olkoon $\mathbf{x}_1, \dots, \mathbf{x}_n$ $p \times 1$ vektoreita. Vektoreiden $\mathbf{x}_1, \dots, \mathbf{x}_n$ virittämä vektoriavaruus koostuu kaikista niiden muodostamista lineaarikombinaatioista, ts.

$$\{\mathbf{y} : \mathbf{y} = \sum_{i=1}^n \alpha_i \mathbf{x}_i, \alpha_i \in \mathbb{R} \text{ kaikilla } i = 1, \dots, n\}$$

Määritelmä 7. Olkoon \mathbf{X} $n \times p$ matriisi. Tällöin matriisin $\mathbf{X} = (\mathbf{x}_1 \dots \mathbf{x}_p)$ sarakeavaruus $\mathcal{R}(\mathbf{X})$ muodostuu sarakkeiden $\mathbf{x}_1 \dots \mathbf{x}_p$ lineaarikombinaatioista, ts.

$$\mathcal{R}(\mathbf{X}) = \left\{ \mathbf{y} : \mathbf{y} = \sum_{i=1}^p \beta_i \mathbf{x}_i = \mathbf{X}\boldsymbol{\beta}, \boldsymbol{\beta} \in \mathbb{R}^p \right\}$$

Esimerkki 2.1.1

Olkoon

$$\mathbf{x}_1 = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \text{ ja } \mathbf{x}_2 = \begin{pmatrix} 0 \\ 1 \end{pmatrix}.$$

Vektorien \mathbf{x}_1 ja \mathbf{x}_2 virittämä vektoriavaruus on

$$\{\mathbf{y} : \mathbf{y} = \alpha_1 \mathbf{x}_1 + \alpha_2 \mathbf{x}_2, \alpha_1 \in \mathbb{R}, \alpha_2 \in \mathbb{R}\} = \left\{ \mathbf{y} : \mathbf{y} = \begin{pmatrix} \alpha_1 \\ \alpha_2 \end{pmatrix}, \alpha_1 \in \mathbb{R}, \alpha_2 \in \mathbb{R} \right\} = \mathbb{R}^2.$$

2.2 Lineaarinen riippumattomuus ja riippuvuus

Määritelmä 8. Vektorit $\mathbf{x}_1, \dots, \mathbf{x}_n$ ovat lineaarisesti riippumattomia, jos yhtälön

$$\sum_{i=1}^n \alpha_i \mathbf{x}_i = \mathbf{0}$$

ainoa ratkaisu on $\alpha_1 = \dots = \alpha_n = 0$. Jos löytyy myös muita ratkaisuja, niin vektorit ovat lineaarisesti riippuvia.

Lause 8. Vektorit $\mathbf{x}_1, \dots, \mathbf{x}_n$ ovat lineaarisesti riippuvia, jos ja vain jos vähintään yksi vektori pystytään ilmaisemaan muiden vektorien lineaarikombinaationa.

Lause 9. Olkoon \mathbf{X} $m \times m$ matriisi, jonka sarakkeet ovat $\mathbf{x}_1, \dots, \mathbf{x}_m$. Silloin $|\mathbf{X}| \neq 0$ jos ja vain jos vektorit $\mathbf{x}_1, \dots, \mathbf{x}_m$ ovat lineaarisesti riippumattomia.

2.3 Vektoriavaruuden kannat ja dimensio

Määritelmä 9. Vektoriavaruuden S osajoukko $V = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ on vektoriavaruuden S kanta, jos

- (a) V virittää vektoriavaruuden S ja
- (b) V on lineaarisesti riippumaton.

Määritelmä 10. Jos vektoriavaruus S on $\{\mathbf{0}\}$, niin vektoriavaruuden dimensio on $\dim(S) = 0$. Muussa tapauksessa vektoriavaruuden S dimensio on vektoriavaruuden S minkä tahansa kannan vektorien lukumäärä.

2.4 Matriisin aste ja lineaarinen riippumattomuus

Määritelmä 11. Olkoon \mathbf{X} $n \times p$ matriisi. Matriisin \mathbf{X} aste $r(\mathbf{X})$ on \mathbf{X} :n lineaarisesti riippumattomien sarakkeiden lukumäärä tai yhtäpitävästi lineaarisesti riippumattomien rivien lukumäärä.

Lauseesta 9 ja määritelmästä 11 seuraa välittömästi seuraava lause.

Lause 10. Olkoon \mathbf{X} $m \times m$ matriisi. Silloin $|\mathbf{X}| \neq 0$ jos ja vain jos $r(\mathbf{X}) = m$.

Lause 11. Olkoon \mathbf{A} $m \times n$ matriisi. Tällöin

- (a) Jos \mathbf{B} on $n \times p$ matriisi, niin $r(\mathbf{AB}) \leq \min\{r(\mathbf{A}), r(\mathbf{B})\}$.
- (b) $r(\mathbf{A}) = r(\mathbf{A}') = r(\mathbf{AA}') = r(\mathbf{A}'\mathbf{A})$.

2.5 Projektiomatriisit

Määritelmä 12. Olkoon \mathbf{P} symmetrinen ($\mathbf{P}' = \mathbf{P}$) ja idempotentti ($\mathbf{P} = \mathbf{P}^2$) $n \times n$ matriisi. Tällöin sanotaan, että matriisi \mathbf{P} on ortogonaalinen projektio tai lyhyesti projektiomatriisi.

Lause 12. *Olkoon $V = \{\mathbf{x}_1, \dots, \mathbf{x}_p\}$ vektoriavaruuden S kanta, jossa $\mathbf{x}_i \in \mathbb{R}^n$ ja $p \leq n$. Jos matriisin \mathbf{X} sarakkeina ovat kantavektorit $\mathbf{x}_1, \dots, \mathbf{x}_p$, niin vektorin $\mathbf{y} \in \mathbb{R}^n$ projektio vektoriavaruudelle S on $\mathbf{P}\mathbf{y}$, jossa $\mathbf{P} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ on projektiomatriisi.*

Esimerkki 2.5.1

Olkoon

$$\mathbf{X} = \begin{pmatrix} 1 \\ 0 \end{pmatrix},$$

eli matriisi \mathbf{X} on x -akselin kanta. Kun $\mathbf{z} \in \mathbb{R}^2$ projisoidaan x -akselille, niin projektiomatriisina on

$$\mathbf{P} = \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' = \begin{pmatrix} 1 \\ 0 \end{pmatrix} 1^{-1} \begin{pmatrix} 1 & 0 \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}.$$

Jos $\mathbf{z} = \begin{pmatrix} a \\ b \end{pmatrix}$, niin vektorin \mathbf{z} projektio x -akselille on

$$\mathbf{P}\mathbf{z} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \begin{pmatrix} a \\ b \end{pmatrix} = \begin{pmatrix} a \\ 0 \end{pmatrix}$$

eli vektorin \mathbf{z} x -koordinaatti.

Esimerkki 2.5.2

Tarkastellaan jälleen lineaarista regressiomallia (ks. esimerkki 1.6.1). Minimoitava jäännösneliösumma voidaan kirjoittaa matriisimuodossa seuraavalla tavalla:

$$S(\boldsymbol{\beta}) = \|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2,$$

jossa $\|\mathbf{y} - \mathbf{X}\boldsymbol{\beta}\|^2$ on vektorin $\mathbf{y} - \mathbf{X}\boldsymbol{\beta}$ pituuden neliö. Vektorin $\mathbf{z} = \mathbf{y} - \mathbf{X}\boldsymbol{\beta}$ pituus on pienimmillään silloin kun vektori \mathbf{z} on kohtisuorassa matriisin \mathbf{X} sarakeavaruutta vastaan eli halutaan löytää sellainen $\boldsymbol{\beta}$, jolla $\mathbf{X}\boldsymbol{\beta}$ on vektorin \mathbf{y} ortogonaalinen projektio sarakeavaruudelle. Olkoon matriisi \mathbf{X} täyttä sarakeastetta. Tällöin $\{\mathbf{x}_1, \dots, \mathbf{x}_p\}$ on sarakeavaruuden $\mathcal{R}(\mathbf{X})$ kanta ja vektorin $\mathbf{y} \in \mathbb{R}^n$ projektio sarakeavaruudelle $\mathcal{R}(\mathbf{X})$ on lauseen 12 perusteella $\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$. Tällöin siis $\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y}$.

Määritelmä 13. *Olkoon $V = \{\mathbf{x}_1, \dots, \mathbf{x}_n\}$ vektoriavaruuden S kanta. Jos jokainen kantavektori on ortogonaalinen muita kantavektoreita vastaan, niin kantaa kutsutaan ortogonaaliseksi ja jos lisäksi kaikki kantavektorit ovat yksikkövektoreita, niin kantaa kutsutaan ortonormaaliseksi.*

Huom! Jos matriisin \mathbf{X} sarakkeina ovat ortonormaalit vektorit $\mathbf{x}_1, \dots, \mathbf{x}_n$, niin \mathbf{X} on ortogonaalinen matriisi ja

$$\mathbf{X}'\mathbf{X} = \mathbf{I}_n.$$

Lause 13. *Olkoon \mathbf{X} $n \times p$ matriisi, jonka sarakkeina ovat vektoriavaruuden S ortonormaalisen kannan vektorit. Jos $\mathbf{x} \in \mathbb{R}^n$, niin vektorin \mathbf{x} ortogonaalinen projektio vektoriavaruudelle S on $\mathbf{P}\mathbf{x}$, jossa $\mathbf{P} = \mathbf{X}\mathbf{X}'$ on projektiomatriisi.*

2.6 Harjoituksia

Luku 3

Ominaisarvot ja ominaisvektorit

3.1 Johdanto

3.2 Määritelmät

Määritelmä 14. *Olkoon \mathbf{A} $m \times m$ neliömatriisi. Skalaari λ on matriisin \mathbf{A} ominaisarvo (eigenvalue), jos on olemassa vektori $\mathbf{x} \neq \mathbf{0}$ siten, että*

$$(3.1) \quad \mathbf{Ax} = \lambda\mathbf{x}.$$

Yhtälön 3.1 toteuttavat vektorit $\mathbf{x} \neq \mathbf{0}$ ovat ominaisarvoon λ liittyviä ominaisvektoreita (eigenvector).

Yhtälö 3.1 voidaan kirjoittaa yhtäpitävästi muodossa (totea)

$$(3.2) \quad (\mathbf{A} - \lambda\mathbf{I}_m)\mathbf{x} = \mathbf{0}.$$

Jos matriisilla $\mathbf{A} - \lambda\mathbf{I}_m$ olisi käänteismatriisi, niin yhtälö 3.2 voitaisiin kertoa puolittain vasemmalta matriisilla $(\mathbf{A} - \lambda\mathbf{I}_m)^{-1}$, jolloin saataisiin

$$\begin{aligned} (\mathbf{A} - \lambda\mathbf{I}_m)^{-1}(\mathbf{A} - \lambda\mathbf{I}_m)\mathbf{x} &= (\mathbf{A} - \lambda\mathbf{I}_m)^{-1}\mathbf{0} \\ \Leftrightarrow \mathbf{I}_m\mathbf{x} &= \mathbf{0} \\ \Leftrightarrow \mathbf{x} &= \mathbf{0}. \end{aligned}$$

Seuraa ristiriita, koska aikaisemmin on sovittu, että $\mathbf{x} \neq \mathbf{0}$. Tästä seuraa, että matriisilla $\mathbf{A} - \lambda\mathbf{I}_m$ ei ole käänteismatriisia, joten sen determinantin täytyy olla nolla. Matriisin \mathbf{A} ominaisarvot löydetään siis ratkaisemalla *kaarakteristinen yhtälö*

$$(3.3) \quad |\mathbf{A} - \lambda\mathbf{I}_m| = 0.$$

skalaarin λ suhteen. Ominaisarvoa λ vastaava ominaisvektori löydetään sen jälkeen ratkaisemalla yhtälö 3.2 vektorin \mathbf{x} suhteen.

Esimerkki 3.2.1

Lasketaan matriisin $\mathbf{A} = \begin{pmatrix} 4 & 6 \\ 3 & 7 \end{pmatrix}$ ominaisarvot ja ominaisvektorit.

$$\begin{aligned} |\mathbf{A} - \lambda \mathbf{I}_2| = 0 &\Leftrightarrow \left| \begin{pmatrix} 4 & 6 \\ 3 & 7 \end{pmatrix} - \lambda \mathbf{I}_2 \right| = 0 \Leftrightarrow \begin{vmatrix} 4 - \lambda & 6 \\ 3 & 7 - \lambda \end{vmatrix} = 0 \\ &\Leftrightarrow (4 - \lambda)(7 - \lambda) - 6 \cdot 3 = 0 \Leftrightarrow \lambda^2 - 11\lambda + 10 = 0 \\ \lambda &= \frac{11 \pm \sqrt{(-11)^2 - 4 \cdot 1 \cdot 10}}{2 \cdot 1} \Leftrightarrow \lambda = \frac{11 \pm 9}{2} \Leftrightarrow \lambda = 1 \text{ tai } \lambda = 10. \end{aligned}$$

Lasketaan ominaisarvoa $\lambda = 1$ vastaava ominaisvektori.

$$\begin{aligned} (\mathbf{A} - \mathbf{I}_2)\mathbf{x} = \mathbf{0} &\Leftrightarrow \begin{pmatrix} 4 - 1 & 6 \\ 3 & 7 - 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Leftrightarrow \begin{pmatrix} 3 & 6 \\ 3 & 6 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \\ &\Leftrightarrow \begin{pmatrix} 3x_1 + 6x_2 \\ 3x_1 + 6x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Leftrightarrow \frac{1}{3} \begin{pmatrix} 3x_1 + 6x_2 \\ 3x_1 + 6x_2 \end{pmatrix} = \frac{1}{3} \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Leftrightarrow \begin{pmatrix} x_1 + 2x_2 \\ x_1 + 2x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}. \end{aligned}$$

Nähdään, että yhtälön ratkaisuna on vektori

$$\mathbf{x} = \begin{pmatrix} 2a \\ -a \end{pmatrix}, \quad a \neq 0.$$

Ohjelmistot antavat yleensä normalisoidun ominaisvektorin eli ominaisvektorin, jonka pituus on yksi. Koska $|\mathbf{x}| = \sqrt{(2a)^2 + (-a)^2} = \sqrt{5a^2} = a\sqrt{5}$, niin normalisoiduksi ominaisvektoriksi saadaan

$$\mathbf{x} = \begin{pmatrix} 2/\sqrt{5} \\ -1/\sqrt{5} \end{pmatrix} \text{ tai } \mathbf{x} = \begin{pmatrix} -2/\sqrt{5} \\ 1/\sqrt{5} \end{pmatrix}.$$

Lasketaan vielä ominaisarvoa $\lambda = 10$ vastaava ominaisvektori.

$$\begin{aligned} (\mathbf{A} - \mathbf{I}_2)\mathbf{x} = \mathbf{0} &\Leftrightarrow \begin{pmatrix} 4 - 10 & 6 \\ 3 & 7 - 10 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Leftrightarrow \begin{pmatrix} -6 & 6 \\ 3 & -3 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \\ &\Leftrightarrow \begin{pmatrix} -6x_1 + 6x_2 \\ 3x_1 - 3x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix} \Leftrightarrow \begin{pmatrix} x_1 - x_2 \\ x_1 - x_2 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \end{pmatrix}. \end{aligned}$$

Yhtälön ratkaisuna on nyt vektori

$$\mathbf{x} = \begin{pmatrix} a \\ a \end{pmatrix}, \quad a \neq 0,$$

josta saadaan normalisoiduksi ominaisvektoriksi

$$\mathbf{x} = \begin{pmatrix} 1/\sqrt{2} \\ 1/\sqrt{2} \end{pmatrix} \text{ tai } \mathbf{x} = \begin{pmatrix} -1/\sqrt{2} \\ -1/\sqrt{2} \end{pmatrix}.$$

```

> A<-matrix(c(4,3,6,7),2,2)
> A
      [,1] [,2]
[1,]    4    6
[2,]    3    7
> eigen(A)
$values
[1] 10  1

$vectors
      [,1]      [,2]
[1,] -0.7071068 -0.8944272
[2,] -0.7071068  0.4472136

> ev<-eigen(A)
> ev$values
[1] 10  1
> ev$vectors
      [,1]      [,2]
[1,] -0.7071068 -0.8944272
[2,] -0.7071068  0.4472136
> 2/sqrt(5)
[1] 0.8944272
> 1/sqrt(5)
[1] 0.4472136
> 1/sqrt(2)
[1] 0.7071068

```

3.3 Ominaisarvojen ja ominaisvektorien perusominaisuuksia

Lause 14. *Olkoon A neliömatriisi. Tällöin*

- (a) *matriiseilla A' ja A on samat ominaisarvot,*
- (b) *matriisi A on singulaarinen jos ja vain jos vähintään yksi matriisin A ominaisarvoista on nolla,*
- (c) *yläkolmiomatriisin (tai alakolmiomatriisin) A diagonaalialkiot ovat samalla myös matriisin A ominaisarvot,*
- (d) *matriiseilla BAB^{-1} ja A on samat ominaisarvot, jos B on ei-singulaarinen neliömatriisi.*

3.3. OMINAISARVOJEN JA OMINAISVEKTORIEN PERUSOMINAISUUKSIA21

Määritelmä 15. Olkoon \mathbf{A} neliömatriisi. Tällöin matriisin \mathbf{A} k :s potenssi on

$$\mathbf{A}^k = \prod_{i=1}^k \mathbf{A}.$$

Toisin sanoen, $\mathbf{A}^2 = \mathbf{A}\mathbf{A}$, $\mathbf{A}^3 = \mathbf{A}\mathbf{A}\mathbf{A}$, $\mathbf{A}^4 = \mathbf{A}\mathbf{A}\mathbf{A}\mathbf{A}$, \dots .

Lause 15. Olkoon λ matriisin \mathbf{A} ominaisarvo, $c \in \mathbb{R}$ ja $k \in \{1, 2, \dots\}$. Tällöin

(a) λ^k on matriisin \mathbf{A}^k ominaisarvo ja

(b) $c\lambda$ on matriisin $c\mathbf{A}$ ominaisarvo.

Lause 16. Olkoon \mathbf{A} $n \times n$ matriisi, jonka ominaisarvot ovat $\lambda_1, \dots, \lambda_n$. Tällöin

(a) $\sum_{i=1}^n \lambda_i = \text{tr}(\mathbf{A})$ ja

(b) $\prod_{i=1}^n \lambda_i = |\mathbf{A}|$.

Esimerkki 3.3.1

Jatkoa esimerkkiin 3.2.1. Matriisin \mathbf{A} ominaisarvojen summa on $10+1 = 11$, joka on sama kuin matriisin \mathbf{A} jälki $4+7 = 11$. Matriisin \mathbf{A} ominaisarvojen tulo on $10 \cdot 1 = 10$, joka on sama kuin matriisin \mathbf{A} determinantti $|\mathbf{A}| = 4 \cdot 7 - 6 \cdot 3 = 28 - 18 = 10$.

Lause 17. Olkoon \mathbf{A} idempotentti $m \times m$ matriisi, ts. $\mathbf{A}^2 = \mathbf{A}$. Tällöin matriisin \mathbf{A} ominaisarvot ovat ainoastaan nollia tai ykkösiä.

Todistus. Olkoon \mathbf{A} idempotentti matriisi. Tällöin ominaisarvot λ saadaan yhtälöstä

$$(3.4) \quad \mathbf{A}\mathbf{x} = \lambda\mathbf{x}, \quad \mathbf{x} \neq \mathbf{0}.$$

ja lauseen 15 perusteella

$$\mathbf{A}^2\mathbf{x} = \lambda^2\mathbf{x}, \quad \mathbf{x} \neq \mathbf{0},$$

jossa λ on matriisin \mathbf{A} ominaisarvo. Toisaalta, koska \mathbf{A} on idempotentti, niin edellinen yhtälö saadaan muotoon

$$(3.5) \quad \mathbf{A}\mathbf{x} = \lambda^2\mathbf{x}, \quad \mathbf{x} \neq \mathbf{0}.$$

Yhtälöitä 3.4 ja 3.5 vertaamalla huomataan, että

$$\lambda = \lambda^2 \Leftrightarrow \lambda(1 - \lambda) = 0 \Leftrightarrow \lambda = 0 \text{ tai } \lambda = 1.$$

□

3.4 Symmetriset matriisit

Lause 18. *Olkoon \mathbf{A} symmetrinen neliömatriisi. Tällöin*

(a) *matriisin \mathbf{A} kaikki ominaisarvot ovat reaalisia.*

(b) *jokaiselle matriisin \mathbf{A} ominaisarvolle löytyy vastaava reaalinen ominaisvektori.*

Lause 19. *Olkoon \mathbf{A} symmetrinen $n \times n$ neliömatriisi. Tällöin matriisin \mathbf{A} ominaisvektoreista on mahdollista muodostaa ortonormaali joukko $\{\mathbf{x}_1, \dots, \mathbf{x}_n\}$.*

Lause 20. *Olkoon \mathbf{A} symmetrinen $n \times n$ neliömatriisi, jolla on p nollasta eroavaa ominaisarvoa. Tällöin matriisin \mathbf{A} aste on $r(\mathbf{A}) = p$.*

Lause 21. *Olkoon \mathbf{A} symmetrinen $n \times n$ neliömatriisi, jonka ominaisarvot ovat $\lambda_1 \geq \dots \geq \lambda_n$. Jokaisella $n \times 1$ vektorilla $\mathbf{x} \neq \mathbf{0}$,*

$$\lambda_n \leq \frac{\mathbf{x}'\mathbf{A}\mathbf{x}}{\mathbf{x}'\mathbf{x}} \leq \lambda_1,$$

ja

$$\lambda_n = \min_{\mathbf{x} \neq \mathbf{0}} \frac{\mathbf{x}'\mathbf{A}\mathbf{x}}{\mathbf{x}'\mathbf{x}} \quad \text{ja} \quad \lambda_1 = \max_{\mathbf{x} \neq \mathbf{0}} \frac{\mathbf{x}'\mathbf{A}\mathbf{x}}{\mathbf{x}'\mathbf{x}}.$$

Minimi saavutetaan pienintä ominaisarvoa vastaavalla ominaisvektorilla ja maksimi saavutetaan suurinta ominaisarvoa vastaavalla ominaisvektorilla.

Esimerkki 3.4.1

Olkoon $\mathbf{x} = (x_1, \dots, x_n)'$ $n \times 1$ satunnaisvektori, jonka kovarianssimatriisi on $\mathbf{\Omega}$. Halutaan löytää $n \times 1$ vektori \mathbf{a}_1 , jolla satunnaismuuttujan $\mathbf{a}'_1\mathbf{x}$ (eli satunnaismuuttujien x_1, \dots, x_n lineaarikombinaation) varianssi saataisiin mahdollisimman suureksi. Ongelmana on nyt, että satunnaismuuttujan $\mathbf{a}'_1\mathbf{x}$ varianssi

$$\text{Var}(\mathbf{a}'_1\mathbf{x}) = \mathbf{a}'_1 \text{Var}(\mathbf{x})\mathbf{a}_1 = \mathbf{a}'_1\mathbf{\Omega}\mathbf{a}_1,$$

saadaan mielivaltaisen suureksi esimerkiksi asettamalla $\mathbf{a}_1 = \alpha\mathbf{c}$, $\mathbf{c} \neq \mathbf{0}$ ja antamalla kertoimen α kasvaa rajatta. Ratkaisuna on, että maksimoidaan varianssi käyttämällä rajoitetta $\mathbf{a}'_1\mathbf{a}_1 = 1$ eli yhtäpitävästi maksimoidaan osamäärä

$$\frac{\mathbf{a}'_1\mathbf{\Omega}\mathbf{a}_1}{\mathbf{a}'_1\mathbf{a}_1}.$$

Lauseen 21 perusteella maksimointitehtävän ratkaisuna saadaan, että $\mathbf{a}_1 = \mathbf{u}_1$, jossa \mathbf{u}_1 on kovarianssimatriisin $\mathbf{\Omega}$ suurinta ominaisarvoa vastaava normeerattu ominaisvektori. Oletetaan edelleen, että me halutaan löytää yksikkövektori \mathbf{a}_2 , joka on ortogonaalinen vektorille \mathbf{a}_1 ja joka maksimoi muuttujan $\mathbf{a}'_2\mathbf{x}$ varianssin. Voidaan osoittaa, että toiseksi suurinta ominaisarvoa vastaava ominaisvektori maksimoi tällöin varianssin ja toiseksi suurin ominaisarvo antaa varianssin maksimiarvon. Samalla tavalla jatkamalla saadaan ortonormaali vektorijoukko $\{\mathbf{a}_1, \dots, \mathbf{a}_n\}$ ja *pääkomponentit* $(\mathbf{a}'_1\mathbf{x}, \dots, \mathbf{a}'_n\mathbf{x})'$.

3.5 Positiivisesti definiitit ja semidefiniitit matriisit

Määritelmä 16. Olkoon \mathbf{x} $m \times 1$ vektori ja \mathbf{A} symmetrinen $m \times m$ matriisi.

- (a) Jos $\mathbf{x}'\mathbf{A}\mathbf{x} > 0$ kaikilla $\mathbf{x} \neq 0$, niin \mathbf{A} on positiivisesti definiitti.
- (b) Jos $\mathbf{x}'\mathbf{A}\mathbf{x} \geq 0$ kaikilla $\mathbf{x} \in \mathbb{R}^m$ ja $\mathbf{x}'\mathbf{A}\mathbf{x} = 0$ jollain $\mathbf{x} \neq 0$, niin \mathbf{A} on positiivisesti semidefiniitti.
- (c) Jos $\mathbf{x}'\mathbf{A}\mathbf{x} < 0$ kaikilla $\mathbf{x} \neq 0$, niin \mathbf{A} on negatiivisesti definiitti.
- (d) Jos $\mathbf{x}'\mathbf{A}\mathbf{x} \leq 0$ kaikilla $\mathbf{x} \in \mathbb{R}^m$ ja $\mathbf{x}'\mathbf{A}\mathbf{x} = 0$ jollain $\mathbf{x} \neq 0$, niin \mathbf{A} on negatiivisesti semidefiniitti.

Esimerkki 3.5.1

Olkoon \mathbf{y} $n \times 1$ satunnaisvektori, jonka kovarianssimatriisi on Σ ja \mathbf{a} tunnettu $n \times 1$ vektori. Tällöin

$$\text{Var}(\mathbf{a}'\mathbf{y}) = \mathbf{a}'\text{Var}(\mathbf{y})\mathbf{a} = \mathbf{a}'\Sigma\mathbf{a}.$$

Huomataan, että satunnaisvektorin kovarianssimatriisi on aina positiivisesti semidefiniitti, koska satunnaismuuttujan varianssi on aina ei-negatiivinen.

Lause 22. Positiivisesti definiitti ja negatiivisesti definiitti matriisi on aina ei-singulaarinen.

Todistus. Jos symmetrinen positiivisesti definiitti $m \times m$ matriisi \mathbf{A} olisi singulaarinen, niin siinä tapauksessa olisi olemassa $m \times m$ vektori $\mathbf{x} \neq \mathbf{0}$ siten, että $\mathbf{A}\mathbf{x} = \mathbf{0}$. Tällöin saataisiin $\mathbf{x}'\mathbf{A}\mathbf{x} = 0$ mikä on ristiriidassa oletuksen $\mathbf{x}'\mathbf{A}\mathbf{x} > 0$ kanssa. Negatiivisesti definiitin matriisin \mathbf{A} ei-singulaarisuus seuraa siitä, että matriisi $-\mathbf{A}$ on positiivisesti definiitti. \square

Lause 23. Olkoon $\lambda_1, \dots, \lambda_m$ symmetrisen $m \times m$ matriisin \mathbf{A} ominaisarvot. Tällöin

- (a) \mathbf{A} on positiivisesti definiitti jos ja vain jos $\lambda_i > 0$ kaikilla $i = 1, \dots, m$.
- (b) \mathbf{A} on positiivisesti semidefiniitti jos ja vain jos $\lambda_i \geq 0$ kaikilla $i = 1, \dots, m$ ja $\lambda_i = 0$ vähintään yhdellä i .

Lause 24. Olkoon \mathbf{A} $m \times n$ matriisi, jonka aste on r . Tällöin matriisilla $\mathbf{A}'\mathbf{A}$ on r positiivista ominaisarvoa. Matriisi $\mathbf{A}'\mathbf{A}$ on positiivisesti definiitti, jos $r = n$ ja positiivisesti semidefiniitti, jos $r < n$.

Lause 25. Olkoon \mathbf{A} $m \times n$ matriisi, jonka aste on r . Tällöin matriisin $\mathbf{A}'\mathbf{A}$ positiiviset ominaisarvot ovat samat kuin matriisin $\mathbf{A}\mathbf{A}'$ positiiviset ominaisarvot.

Esimerkki 3.5.2

Tarkastellaan lineaarista regressiomallia

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon},$$

jossa $\boldsymbol{\beta}$ on $p \times 1$ vektori, $E(\boldsymbol{\epsilon}) = \mathbf{0}$ ja $\text{Var}(\boldsymbol{\epsilon}) = \sigma^2 \mathbf{I}_n$. Parametrivektorin $\boldsymbol{\beta}$ pienimmän neliösumman estimaattori on tunnetusti

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{y},$$

Osoitetaan, että $\mathbf{c}'\hat{\boldsymbol{\beta}}$ on paras lineaarinen harhaton estimaattori suureelle $\mathbf{c}'\boldsymbol{\beta}$, jossa \mathbf{c} on mielivaltainen $p \times 1$ vektori. Satunnaismuuttuja $\mathbf{c}'\hat{\boldsymbol{\beta}}$ on harhaton $\mathbf{c}'\boldsymbol{\beta}$:n estimaattori, sillä

$$E(\mathbf{c}'\hat{\boldsymbol{\beta}}) = \mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'E(\mathbf{y}) = \mathbf{c}'(\mathbf{X}'\mathbf{X})^{-1} \mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{c}'\boldsymbol{\beta},$$

kaikilla $\boldsymbol{\beta} \in \mathbb{R}^p$. Näytetään vielä, että satunnaismuuttujan $\mathbf{c}'\hat{\boldsymbol{\beta}}$ varianssi vähintään yhtä pieni kuin millä tahansa muulla $\mathbf{c}'\boldsymbol{\beta}$:n lineaarisella harhattomalla estimaattorilla. Olkoon $\mathbf{a}'\mathbf{y}$ mielivaltainen $\mathbf{c}'\boldsymbol{\beta}$:n lineaarinen harhaton estimaattori. Tällöin

$$\mathbf{c}'\boldsymbol{\beta} = E(\mathbf{a}'\mathbf{y}) = \mathbf{a}'E(\mathbf{y}) = \mathbf{a}'\mathbf{X}\boldsymbol{\beta},$$

josta seuraa, että

$$\mathbf{c}' = \mathbf{a}'\mathbf{X}.$$

Estimaattorin $\mathbf{c}'\hat{\boldsymbol{\beta}}$ varianssi on

$$\text{Var}(\mathbf{c}'\hat{\boldsymbol{\beta}}) = \mathbf{c}'\text{Var}(\hat{\boldsymbol{\beta}})\mathbf{c} = \mathbf{c}'(\sigma^2(\mathbf{X}'\mathbf{X})^{-1})\mathbf{c} = \sigma^2\mathbf{a}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{a}$$

kun taas estimaattorin $\mathbf{a}'\mathbf{y}$ varianssi on

$$\text{Var}(\mathbf{a}'\mathbf{y}) = \mathbf{a}'\text{Var}(\mathbf{y})\mathbf{a} = \mathbf{a}'(\sigma^2\mathbf{I}_n)\mathbf{a} = \sigma^2\mathbf{a}'\mathbf{a}.$$

Varianssien erotukseksi saadaan nyt

$$\begin{aligned} \text{Var}(\mathbf{a}'\mathbf{y}) - \text{Var}(\mathbf{c}'\hat{\boldsymbol{\beta}}) &= \sigma^2\mathbf{a}'\mathbf{a} - \sigma^2\mathbf{a}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{a} \\ &= \sigma^2\mathbf{a}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{a} \end{aligned}$$

Matriisi $\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ on idempotentti, joten lauseen 17 perusteella sen ominaisarvot ovat pelkästään nollia tai ykkösiä. Edelleen lauseen 23(a) perusteella $\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'$ on positiivisesti semidefiniitti ja näin ollen

$$\text{Var}(\mathbf{a}'\mathbf{y}) - \text{Var}(\mathbf{c}'\hat{\boldsymbol{\beta}}) \geq 0.$$

3.6 Harjoituksia

Luku 4

Matriisihajotelmat

4.1 Pääakseliesitys

Lause 26. *Olkoon A symmetrinen $m \times m$ matriisi, jonka ominaisarvot ovat $\lambda_1, \dots, \lambda_m$ ja $\mathbf{u}_1, \dots, \mathbf{u}_m$ ovat ominaisarvoja vastaavat ortonormaalit ominaisvektorit. Tällöin matriisille A saadaan pääakseliesitys*

$$A = U\Lambda U',$$

jossa $\Lambda = \text{diag}(\lambda_1, \dots, \lambda_m)$ ja $U = (\mathbf{u}_1, \dots, \mathbf{u}_m)$.

Esimerkki 4.1.1

Pääakseliesitystä voidaan käyttää positiivisesti semidefiniitin matriisin A neliöjuurimatriisin $A^{1/2}$ laskemiseen. Neliöjuurimatriisilla $A^{1/2}$ on ominaisuus $A^{1/2}A^{1/2} = A$. Olkoon Λ ja U määritelty lauseen 26 mukaisesti. Olkoon $\Lambda^{1/2} = \text{diag}(\lambda_1^{1/2}, \dots, \lambda_m^{1/2})$ ja $A^{1/2} = U\Lambda^{1/2}U'$. Tällöin saadaan

$$A^{1/2}A^{1/2} = U\Lambda^{1/2}U'U\Lambda^{1/2}U' = U\Lambda^{1/2}\Lambda^{1/2}U' = U\Lambda U' = A.$$

Matriisi $A^{1/2}$ on symmetrinen sillä

$$(A^{1/2})' = (U\Lambda^{1/2}U')' = U\Lambda^{1/2}U' = A^{1/2}.$$

Matriisin $A^{1/2}$ käänteismatriisi $A^{-1/2}$, on vastaavasti $A^{-1/2} = U\Lambda^{-1/2}U'$, jossa $\Lambda^{-1/2} = \text{diag}(\lambda_1^{-1/2}, \dots, \lambda_m^{-1/2})$, sillä

$$A^{-1/2}A^{1/2} = U\Lambda^{-1/2}U'U\Lambda^{1/2}U' = U\Lambda^{-1/2}\Lambda^{1/2}U' = UI_mU' = UU' = I_m.$$

Neliöjuurimatriisin määritelmää voidaan yleistää, jos tingitään symmetrisyysvaatimuksesta. Olkoon $A^{1/2}$ mikä tahansa matriisi, jolle pätee $A = A^{1/2}(A^{1/2})'$. Olkoon Q on mikä tahansa ortogonaalinen $m \times m$ matriisi ja $A^{1/2} = U\Lambda^{1/2}Q'$, niin

$$A^{1/2}(A^{1/2})' = U\Lambda^{1/2}Q'Q\Lambda^{1/2}U' = U\Lambda^{1/2}\Lambda^{1/2}U' = U\Lambda U' = A.$$

Lause 27. *Olkoon \mathbf{A} positiivisesti semidefiniitti matriisi. Tällöin on olemassa alakolmiomatriisi \mathbf{T} , jolla on ei-negatiiviset diagonaalialkiot, siten että*

$$\mathbf{A} = \mathbf{T}\mathbf{T}'.$$

Edelleen, jos \mathbf{A} on positiivisesti definiitti, niin matriisi \mathbf{T} on yksikäsitteinen matriisi, jolla on positiiviset diagonaalialkiot.

Edellisen lauseen hajotelmaa $\mathbf{A} = \mathbf{T}\mathbf{T}'$ kutsutaan matriisin \mathbf{A} Choleskyn hajotelmaksi. Lause 27 ilmoittaa, että positiivisesti definiitille matriisille löytyy aina yksikäsitteinen Choleskyn hajotelma. Jos matriisi on positiivisesti semidefiniitti, niin Choleskyn hajotelma voi olla yksikäsitteinen tai ei-yksikäsitteinen. Harjoituksessa 4 tehtävässä 2 on esimerkki ei-yksikäsitteisestä hajotelmasta. Tarkastellaan nollamatriisia $\mathbf{0}_{n \times n}$. Se on selvästikin positiivisesti semidefiniitti sillä $\mathbf{x}'\mathbf{0}_{n \times n}\mathbf{x} = 0 \geq 0$ kaikilla $\mathbf{x} \in \mathbb{R}^n$ ja $\mathbf{x}'\mathbf{0}_{n \times n}\mathbf{x} = 0$ jollain (itse asiassa kaikilla) $\mathbf{x} \neq \mathbf{0}$. Nollamatriisille saadaan yksikäsitteinen Choleskyn hajotelma $\mathbf{0}_{n \times n} = \mathbf{T}\mathbf{T}'$, jossa $\mathbf{T} = \mathbf{0}_{n \times n}$.

Esimerkki 4.1.2

Olkoon \mathbf{x} $m \times 1$ satunnaisvektori, jolla on odotusarvovektori $\boldsymbol{\mu}$ ja positiivisesti definiitti kovarianssimatriisi $\boldsymbol{\Omega}$. Kovarianssimatriisin neliöjuurimatriisin käänteismatriisia käyttämällä voidaan muodostaa satunnaisvektorin \mathbf{x} lineaarinen transformaatio, jonka kovarianssimatriisi on \mathbf{I}_m . Olkoon matriisin $\boldsymbol{\Omega}$ pääakseliesitys $\boldsymbol{\Omega} = \mathbf{U}\boldsymbol{\Lambda}\mathbf{U}'$ ja $\boldsymbol{\Omega}^{-1/2} = \mathbf{U}\boldsymbol{\Lambda}^{-1/2}\mathbf{U}'$. Lasketaan lineaarisen transformaation $\mathbf{z} = \boldsymbol{\Omega}^{-1/2}\mathbf{x}$ kovarianssimatriisi:

$$\begin{aligned} \text{Var}(\mathbf{z}) &= \text{Var}(\boldsymbol{\Omega}^{-1/2}\mathbf{x}) = \boldsymbol{\Omega}^{-1/2}\text{Var}(\mathbf{x})(\boldsymbol{\Omega}^{-1/2})' \\ &= [\mathbf{U}\boldsymbol{\Lambda}^{-1/2}\mathbf{U}'][\mathbf{U}\boldsymbol{\Lambda}\mathbf{U}'][(\mathbf{U}\boldsymbol{\Lambda}^{-1/2}\mathbf{U}')'] \\ &= \mathbf{U}\boldsymbol{\Lambda}^{-1/2}\mathbf{I}_m\boldsymbol{\Lambda}\mathbf{I}_m\boldsymbol{\Lambda}^{-1/2}\mathbf{U}' = \mathbf{U}\boldsymbol{\Lambda}^{-1/2}\boldsymbol{\Lambda}\boldsymbol{\Lambda}^{-1/2}\mathbf{U}' \\ &= \mathbf{U}\mathbf{I}_m\mathbf{U}' = \mathbf{U}\mathbf{U}' = \mathbf{I}_m. \end{aligned}$$

Toinen tapa on käyttää kovarianssimatriisin $\boldsymbol{\Omega}$ Choleskyn hajotelman käänteismatriisia \mathbf{T}^{-1} . Tällöin

$$\begin{aligned} \text{Var}(\mathbf{z}) &= \text{Var}(\mathbf{T}^{-1}\mathbf{x}) = \mathbf{T}^{-1}\text{Var}(\mathbf{x})(\mathbf{T}^{-1})' \\ &= \mathbf{T}^{-1}\mathbf{T}\mathbf{T}'(\mathbf{T}^{-1})' = \mathbf{T}^{-1}\mathbf{T}\mathbf{T}'(\mathbf{T}')^{-1} = \mathbf{I}_m. \end{aligned}$$

4.2 Singulaariarvohajotelma

Lause 28. Olkoon \mathbf{A} $m \times n$ matriisi, jonka aste on $r > 0$. Tällöin on olemassa ortogonaalinen $m \times m$ matriisi \mathbf{P} ja ortogonaalinen $n \times n$ matriisi \mathbf{Q} , siten että $\mathbf{A} = \mathbf{P}\mathbf{D}\mathbf{Q}'$ ja $\mathbf{D} = \mathbf{P}'\mathbf{A}\mathbf{Q}$, jossa $m \times n$ matriisi \mathbf{D} on

a)

$$\Delta, \text{ jos } r = m = n$$

b)

$$(\Delta \quad \mathbf{0}_{m \times (n-m)}) \text{ jos } r = m < n$$

c)

$$\begin{pmatrix} \Delta \\ \mathbf{0}_{(m-n) \times n} \end{pmatrix} \text{ jos } r = n < m$$

d)

$$\begin{pmatrix} \Delta & \mathbf{0}_{r \times (n-r)} \\ \mathbf{0}_{(m-r) \times r} & \mathbf{0}_{(m-r) \times (n-r)} \end{pmatrix} \text{ jos } r < m, r < n$$

ja Δ on $r \times r$ diagonaalimatriisi, jonka diagonaalialkiot (singulaariarvot) ovat positiivisia. Matriisin Δ^2 diagonaalialkiot ovat matriisien $\mathbf{A}'\mathbf{A}$ ja $\mathbf{A}\mathbf{A}'$ positiiviset ominaisarvot. Matriisin \mathbf{P} sarakkeina ovat matriisin $\mathbf{A}\mathbf{A}'$ ominaisvektorit ja matriisin \mathbf{Q} sarakkeina ovat matriisin $\mathbf{A}'\mathbf{A}$ ominaisvektorit.

Huom! Singulaariarvohajotelman singulaariarvojen lukumäärä antaa yleisen $m \times n$ matriisin asteen. Aikaisemmin todettiin (Lause 20), että *symmetrisellä neliömatriisilla* nolasta eroavien ominaisarvojen lukumäärä ilmoittaa matriisin asteen.

Esimerkki 4.2.1

Olkoon

$$\mathbf{A} = \begin{pmatrix} 2 & 0 & 1 \\ 3 & -1 & 1 \\ -2 & 4 & 1 \\ 1 & 1 & 1 \end{pmatrix}$$

Lasketaan singulaariarvohajotelma R-ohjelmiston funktion `svd` avulla:

```
> A<-matrix(c(2,3,-2,1,0,-1,4,1,1,1,1,1),4,3)
> A
      [,1] [,2] [,3]
[1,]    2    0    1
[2,]    3   -1    1
[3,]   -2    4    1
[4,]    1    1    1
> svdA<-svd(A)
```

```

> svdA
$d
[1] 5.291503e+00 3.464102e+00 1.762781e-16

$u
      [,1] [,2]      [,3]
[1,] -2.672612e-01 -0.5 -0.1262763
[2,] -5.345225e-01 -0.5  0.5540196
[3,]  8.017837e-01 -0.5  0.3272543
[4,]  2.507895e-16 -0.5 -0.7549975

$v
      [,1]      [,2]      [,3]
[1,] -7.071068e-01 -0.5773503 -0.4082483
[2,]  7.071068e-01 -0.5773503 -0.4082483
[3,]  1.919580e-16 -0.5773503  0.8164966

> svdA$u*%diag(svdA$d)*%t(svdA$v)
      [,1]      [,2] [,3]
[1,]    2 -4.292554e-16  1
[2,]    3 -1.000000e+00  1
[3,]   -2  4.000000e+00  1
[4,]    1  1.000000e+00  1

```

Funktio `svd` antaa singulaariarvohajotelman tiivistetyssä muodossa. Itseasiassa sitä voi tiivistää enemmänkin, koska vektorin `svdA$d` on kolmas alkio on nolla (toisinsanottuna singulaariarvoja on kaksi):

```

> svdA$u[,1:2]
      [,1] [,2]
[1,] -2.672612e-01 -0.5
[2,] -5.345225e-01 -0.5
[3,]  8.017837e-01 -0.5
[4,]  2.507895e-16 -0.5
> diag(svdA$d[1:2])
      [,1]      [,2]
[1,] 5.291503 0.000000
[2,] 0.000000 3.464102
> svdA$v[,1:2]
      [,1]      [,2]
[1,] -7.071068e-01 -0.5773503
[2,]  7.071068e-01 -0.5773503
[3,]  1.919580e-16 -0.5773503

```



```

> svdA$u[,1:2]%%diag(svdA$d[1:2])%%t(svdA$v[,1:2])
      [,1]      [,2] [,3]
[1,]    2 -4.383429e-16    1
[2,]    3 -1.000000e+00    1
[3,]   -2  4.000000e+00    1
[4,]    1  1.000000e+00    1

```

Korollari 28.1. *Olkoon A $m \times n$ matriisi, jonka aste on $r > 0$. Tällöin on olemassa $m \times r$ matriisi P_1 ja $n \times r$ matriisi Q_1 , siten että $P_1'P_1 = Q_1'Q_1 = I_r$ ja $A = P_1\Lambda Q_1'$, jossa Λ on $r \times r$ diagonaalimatriisi, jonka diagonaalialkiot ovat positiivisia.*

Edellinen korollari seuraa suoraan Lauseesta 28 osittamalla matriisit P ja Q seuraavalla tavalla:

$$P = (P_1 \ P_2) \quad \text{ja} \quad Q = (Q_1 \ Q_2),$$

jossa P_1 on $m \times r$ matriisi ja Q_1 on $n \times r$ matriisi. Matriisit P_1 ja Q_1 eivät voi olla ortogonaalisia matriiseja kun $m > r$ ja $n > r$. Ortogonaaliset matriisit ovat aina neliömatriiseja. Nyt $P_1P_1' \neq I_m$ ja $Q_1Q_1' \neq I_n$. Matriisin A singulaariarvohajotelma antaa paljon tietoa matriisin rakenteesta:

- Singulaariarvojen lukumäärä r on sama kuin matriisin A aste.
- Matriisin P_1 sarakkeet antavat matriisin A sarakeavaruuden ortonormaalin kannan.
- Matriisin Q_1 sarakkeet antavat matriisin A riviavaruuden ortonormaalin kannan.
- Matriisin P_2 sarakkeet virittävät matriisin A' nolla-avaruuden $N(A') = \{\mathbf{x} : A'\mathbf{x} = \mathbf{0}, \mathbf{x} \in \mathbb{R}^m\}$.
- Matriisin Q_2 sarakkeet virittävät matriisin A nolla-avaruuden $N(A) = \{\mathbf{x} : A\mathbf{x} = \mathbf{0}, \mathbf{x} \in \mathbb{R}^n\}$.

Singulaariarvohajotelmaa voidaan käyttää myös yleistetyn käänteismatriisin laskemiseen. Yleistetty käänteismatriisi määritellään seuraavasti

Määritelmä 17. *Olkoon A $m \times n$ matriisi. Matriisin A yleistetty $n \times m$ käänteismatriisi A^- toteuttaa ehdon*

$$AA^-A = A.$$

Huom! Edellisen ehdon toteuttavia yleistettyjä käänteismatriiseja voi olla ääretön määrä. Yleistetty käänteismatriisi ei ole siis välttämättä yksikäsitteinen. Jos vaaditaan määritelmän 17 ehdon lisäksi, että $A^-AA^- = A^-$, $(AA^-)' = AA^-$ ja $(A^-A)' = A^-A$, niin saadaan yksikäsitteinen Mooren-Penrosen yleistetty käänteismatriisi A^+ .

Lause 29. *Olkoon A $m \times n$ matriisi, jonka aste on $r > 0$ ja jolla on singulaariarvohajotelma*

$$A = P \begin{pmatrix} \Delta & \mathbf{0}_{r \times (n-r)} \\ \mathbf{0}_{(m-r) \times r} & \mathbf{0}_{(m-r) \times (n-r)} \end{pmatrix} Q'.$$

Olkoon

$$B = Q \begin{pmatrix} \Delta^{-1} & E \\ F & G \end{pmatrix} P',$$

jossa E on $r \times (m - r)$ matriisi, F on $(n - r) \times r$ matriisi ja G on $(n - r) \times (m - r)$ matriisi. Tällöin kaikilla valinnoilla E , F ja G , matriisi B on matriisin A yleistetty käänteismatriisi ja mikä tahansa yleistetty käänteismatriisi voidaan ilmaista muodossa B joillain matriiseilla E , F ja G .

Esimerkki 4.2.2

Lasketaan matriisille

$$A = \begin{pmatrix} 3 & 6 \\ 1 & 2 \\ 2 & 4 \end{pmatrix}$$

yleistetty käänteismatriisi.

```
> A<-matrix(c(3,1,2,6,2,4),3,2)
> A
      [,1] [,2]
[1,]    3    6
[2,]    1    2
[3,]    2    4
> P<-eigen(A%*%t(A))$vectors
> Q<-eigen(t(A)%*%A)$vectors
> eigen(t(A)%*%A)$values
[1] 70 0
> eigen(A%*%t(A))$values
[1] 7.000000e+01 4.263256e-14 -2.428613e-15
> Delta<-sqrt(70)
> P
      [,1]      [,2]      [,3]
[1,] 0.8017837 0.5976143 0.0000000
[2,] 0.2672612 -0.3585686 -0.8944272
[3,] 0.5345225 -0.7171372 0.4472136
> Q
      [,1]      [,2]
[1,] 0.4472136 -0.8944272
[2,] 0.8944272 0.4472136
> D<-matrix(0,3,2)
```

```

> D[1,1]<-Delta
> D
      [,1] [,2]
[1,] 8.3666  0
[2,] 0.0000  0
[3,] 0.0000  0
> P%*%D%*%t(Q)
      [,1] [,2]
[1,]  3    6
[2,]  1    2
[3,]  2    4
> invD<-t(D)
> invD[1,1]<-1/invD[1,1]
> invD
      [,1] [,2] [,3]
[1,] 0.1195229  0  0
[2,] 0.0000000  0  0
> B<-Q%*%invD%*%t(P)
> B
      [,1]      [,2]      [,3]
[1,] 0.04285714 0.01428571 0.02857143
[2,] 0.08571429 0.02857143 0.05714286
> A%*%B%*%A
      [,1] [,2]
[1,]  3    6
[2,]  1    2
[3,]  2    4

```

4.3 Harjoituksia

Luku 5

Ositetut matriisit

5.1 Ositettujen matriisien kertolasku

Olkoon A $m \times n$ matriisi, joka on ositettu seuraavasti:

$$A = \begin{pmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{pmatrix},$$

jossa A_{11} on $m_1 \times n_1$ matriisi, A_{12} on $m_1 \times n_2$ matriisi, A_{21} on $m_2 \times n_1$ matriisi ja A_{22} on $m_2 \times n_2$ matriisi. Olkoon lisäksi B $n \times p$ matriisi, joka on ositettu seuraavalla tavalla:

$$B = \begin{pmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{pmatrix},$$

jossa B_{11} on $n_1 \times p_1$ matriisi, B_{12} on $n_1 \times p_2$ matriisi, B_{21} on $n_2 \times p_1$ matriisi ja B_{22} on $n_2 \times p_2$ matriisi. Tällöin matriisien A ja B tulo voidaan ilmaista alimatriisien avulla seuraavasti:

$$AB = \begin{pmatrix} A_{11}B_{11} + A_{12}B_{21} & A_{11}B_{12} + A_{12}B_{22} \\ A_{21}B_{11} + A_{22}B_{21} & A_{21}B_{12} + A_{22}B_{22} \end{pmatrix}.$$

Huom! Ositettujen matriisien kertolasku suoritettiin merkinnällisesti täsmälleen samaan tapaan kuin 2×2 matriiseilla:

$$\begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} \begin{pmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{pmatrix} = \begin{pmatrix} a_{11}b_{11} + a_{12}b_{21} & a_{11}b_{12} + a_{12}b_{22} \\ a_{21}b_{11} + a_{22}b_{21} & a_{21}b_{12} + a_{22}b_{22} \end{pmatrix}$$

Ositettujen matriisien tapauksessa täytyy lisäksi alimatriisien kertolaskut olla määriteltyjä. Edellinen ositettujen matriisien kertolasku voidaan luonnollisesti yleistää ositetuille matriiseille

$$A = \begin{pmatrix} A_{11} & A_{12} & \cdots & A_{1m} \\ A_{21} & A_{22} & \cdots & A_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ A_{r1} & A_{r2} & \cdots & A_{rm} \end{pmatrix} \quad \text{ja} \quad B = \begin{pmatrix} B_{11} & B_{12} & \cdots & B_{1c} \\ B_{21} & B_{22} & \cdots & B_{2c} \\ \vdots & \vdots & \ddots & \vdots \\ B_{m1} & B_{m2} & \cdots & B_{mc} \end{pmatrix}.$$

Kertolasku $\mathbf{A}\mathbf{B}$ suoritetaan nyt samaan tapaan kuin $r \times m$ matriisin ja $m \times c$ matriisin kertolaskussa. Alimatriisien kertolaskut täytyy tietysti tässäkin tapauksessa olla määriteltyjä.

5.2 Ositetun matriisin käänteismatriisi

Tässä kappaleessa tarkastellaan ositettua $m \times m$ matriisia

$$(5.1) \quad \mathbf{A} = \begin{pmatrix} \mathbf{A}_{11} & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{A}_{22} \end{pmatrix},$$

jossa \mathbf{A}_{11} on $m_1 \times m_1$ neliömatriisi, \mathbf{A}_{12} on $m_1 \times m_2$ matriisi, \mathbf{A}_{21} on $m_2 \times m_1$ matriisi ja \mathbf{A}_{22} on $m_2 \times m_2$ neliömatriisi.

Lause 30. *Olkoon \mathbf{A} ei-singulaarinen $m \times m$ matriisi, joka on ositettu kuten kaavassa (5.1) ja olkoon*

$$\mathbf{B} = \mathbf{A}^{-1} = \begin{pmatrix} \mathbf{B}_{11} & \mathbf{B}_{12} \\ \mathbf{B}_{21} & \mathbf{B}_{22} \end{pmatrix},$$

matriisin \mathbf{A} ositettu käänteismatriisi, jossa matriisit \mathbf{B}_{11} , \mathbf{B}_{12} , \mathbf{B}_{21} ja \mathbf{B}_{22} ovat samaa kokoa vastaavien matriisin \mathbf{A} alimatriisien kanssa.

Jos matriisit \mathbf{A}_{11} ja $\mathbf{A}_{22} - \mathbf{A}_{21}\mathbf{A}_{11}^{-1}\mathbf{A}_{12}$ ovat ei-singulaarisia, niin

$$(a) \quad \mathbf{B}_{11} = \mathbf{A}_{11}^{-1} + \mathbf{A}_{11}^{-1}\mathbf{A}_{12}\mathbf{B}_{22}\mathbf{A}_{21}\mathbf{A}_{11}^{-1},$$

$$(b) \quad \mathbf{B}_{22} = (\mathbf{A}_{22} - \mathbf{A}_{21}\mathbf{A}_{11}^{-1}\mathbf{A}_{12})^{-1},$$

$$(c) \quad \mathbf{B}_{12} = -\mathbf{A}_{11}^{-1}\mathbf{A}_{12}\mathbf{B}_{22},$$

$$(d) \quad \mathbf{B}_{21} = -\mathbf{B}_{22}\mathbf{A}_{21}\mathbf{A}_{11}^{-1}$$

Jos matriisit \mathbf{A}_{22} ja $\mathbf{A}_{11} - \mathbf{A}_{12}\mathbf{A}_{22}^{-1}\mathbf{A}_{21}$ ovat ei-singulaarisia, niin

$$(e) \quad \mathbf{B}_{11} = (\mathbf{A}_{11} - \mathbf{A}_{12}\mathbf{A}_{22}^{-1}\mathbf{A}_{21})^{-1},$$

$$(f) \quad \mathbf{B}_{22} = \mathbf{A}_{22}^{-1} + \mathbf{A}_{22}^{-1}\mathbf{A}_{21}\mathbf{B}_{11}\mathbf{A}_{12}\mathbf{A}_{22}^{-1},$$

$$(g) \quad \mathbf{B}_{12} = -\mathbf{B}_{11}\mathbf{A}_{12}\mathbf{A}_{22}^{-1},$$

$$(h) \quad \mathbf{B}_{21} = -\mathbf{A}_{22}^{-1}\mathbf{A}_{21}\mathbf{B}_{11}.$$

Esimerkki 5.2.1

Matriisien \mathbf{A}_{11} ja \mathbf{A}_{22} ei tarvitse olla ei-singulaarisia, jotta ositettu matriisi \mathbf{A} olisi ei-singulaarinen. Tarkastellaan matriisia

$$\mathbf{A} = \begin{pmatrix} \mathbf{O} & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{O} \end{pmatrix},$$

jossa $m_1 = m_2$ ja \mathbf{A}_{12} ja \mathbf{A}_{21} ovat ei-singulaarisia $m_1 \times m_1$ matriiseja. Matriisit \mathbf{A}_{11} ja \mathbf{A}_{22} ovat nyt $m_1 \times m_1$ nollamatriiseja ja siis luonnollisesti myös singulaarisia. Tällöin

$$\mathbf{A}^{-1} = \begin{pmatrix} \mathbf{O} & \mathbf{A}_{21}^{-1} \\ \mathbf{A}_{12}^{-1} & \mathbf{O} \end{pmatrix},$$

sillä

$$\begin{aligned} \begin{pmatrix} \mathbf{O} & \mathbf{A}_{21}^{-1} \\ \mathbf{A}_{12}^{-1} & \mathbf{O} \end{pmatrix} \begin{pmatrix} \mathbf{O} & \mathbf{A}_{12} \\ \mathbf{A}_{21} & \mathbf{O} \end{pmatrix} &= \begin{pmatrix} \mathbf{O}\mathbf{O} + \mathbf{A}_{21}^{-1}\mathbf{A}_{21} & \mathbf{O}\mathbf{A}_{12} + \mathbf{A}_{21}^{-1}\mathbf{O} \\ \mathbf{A}_{12}^{-1}\mathbf{O} + \mathbf{O}\mathbf{A}_{21} & \mathbf{A}_{12}^{-1}\mathbf{A}_{12} + \mathbf{O}\mathbf{O} \end{pmatrix} \\ &= \begin{pmatrix} \mathbf{I}_{m_1} & \mathbf{O} \\ \mathbf{O} & \mathbf{I}_{m_1} \end{pmatrix} = \mathbf{I}_m. \end{aligned}$$

Esimerkki 5.2.2

Tarkastellaan lineaarista regressiomallia

$$(5.2) \quad \mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon},$$

jossa \mathbf{y} on $n \times 1$ vektori, \mathbf{X} on $n \times p$ matriisi, $\boldsymbol{\beta}$ on $p \times 1$ vektori ja $\boldsymbol{\epsilon}$ on $n \times 1$ vektori. Olkoon

$$\mathbf{X} = (\mathbf{X}_1 \quad \mathbf{X}_2) \quad \text{ja} \quad \boldsymbol{\beta} = \begin{pmatrix} \boldsymbol{\beta}_1 \\ \boldsymbol{\beta}_2 \end{pmatrix},$$

jossa \mathbf{X}_1 on $n \times p_1$ matriisi, \mathbf{X}_2 on $n \times p_2$ matriisi, $\boldsymbol{\beta}_1$ on $p_1 \times 1$ vektori ja $\boldsymbol{\beta}_2$ on $p_2 \times 1$ vektori ($p = p_1 + p_2$). Tällöin lineaarinen malli (5.2) voidaan kirjoittaa yhtäpitävästi muodossa

$$(5.3) \quad \mathbf{y} = \mathbf{X}_1\boldsymbol{\beta}_1 + \mathbf{X}_2\boldsymbol{\beta}_2 + \boldsymbol{\epsilon},$$

Oletetaan, että me halutaan verrata lineaarista mallia (5.2) rajoitettuun malliin

$$(5.4) \quad \mathbf{y} = \mathbf{X}_1\boldsymbol{\beta}_1 + \boldsymbol{\epsilon},$$

(eli malliin jossa $\boldsymbol{\beta}_2 = \mathbf{0}$) residuaalineliosummien erotuksen avulla. Jos \mathbf{X} on täyttä sarakeastetta, niin mallien (5.2) ja (5.4) regressiokerroinvektorien pienimmän neliosumman estimaattorit ovat

$$\hat{\boldsymbol{\beta}} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} \quad \text{ja} \quad \hat{\boldsymbol{\beta}}_1 = (\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{y}.$$

ja residuaalineliosummien erotus on

$$\begin{aligned} &(\mathbf{y} - \mathbf{X}_1\hat{\boldsymbol{\beta}}_1)'(\mathbf{y} - \mathbf{X}_1\hat{\boldsymbol{\beta}}_1) - (\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}})'(\mathbf{y} - \mathbf{X}\hat{\boldsymbol{\beta}}) \\ &= \mathbf{y}'(\mathbf{I}_n - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1)\mathbf{y} - \mathbf{y}'(\mathbf{I}_n - \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}')\mathbf{y} \\ &= \mathbf{y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{y}. \end{aligned}$$

Lasketaan seuraavaksi matriisiin

$$\mathbf{X}'\mathbf{X} = \begin{pmatrix} \mathbf{X}'_1 \\ \mathbf{X}'_2 \end{pmatrix} (\mathbf{X}_1 \quad \mathbf{X}_2) = \begin{pmatrix} \mathbf{X}'_1\mathbf{X}_1 & \mathbf{X}'_1\mathbf{X}_2 \\ \mathbf{X}'_2\mathbf{X}_1 & \mathbf{X}'_2\mathbf{X}_2 \end{pmatrix}$$

käänteismatriisi lauseen 30 avulla. Olkoon $\mathbf{A}_{11} = \mathbf{X}'_1\mathbf{X}_1$, $\mathbf{A}_{12} = \mathbf{X}'_1\mathbf{X}_2$, $\mathbf{A}_{21} = \mathbf{X}'_2\mathbf{X}_1$, $\mathbf{A}_{22} = \mathbf{X}'_2\mathbf{X}_2$ ja $\mathbf{X}_{2*} = (\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1)\mathbf{X}_2$. Tällöin

$$\begin{aligned} \mathbf{B}_{22} &= (\mathbf{A}_{22} - \mathbf{A}_{21}\mathbf{A}_{11}^{-1}\mathbf{A}_{12})^{-1} \\ &= (\mathbf{X}'_2\mathbf{X}_2 - \mathbf{X}'_2\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{X}_2)^{-1} \\ &= [\mathbf{X}'_2(\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1)\mathbf{X}_2]^{-1} \\ &= [\mathbf{X}'_2(\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1)'(\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1)\mathbf{X}_2]^{-1} \\ &= (\mathbf{X}'_{2*}\mathbf{X}_{2*})^{-1}, \\ \mathbf{B}_{11} &= \mathbf{A}_{11}^{-1} + \mathbf{A}_{11}^{-1}\mathbf{A}_{12}\mathbf{B}_{22}\mathbf{A}_{21}\mathbf{A}_{11}^{-1} \\ &= (\mathbf{X}'_1\mathbf{X}_1)^{-1} + (\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1} \\ \mathbf{B}_{12} &= -\mathbf{A}_{11}^{-1}\mathbf{A}_{12}\mathbf{B}_{22} \\ &= -(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{X}_2\mathbf{B}_{22} \\ \mathbf{B}_{21} &= -\mathbf{B}_{22}\mathbf{A}_{21}\mathbf{A}_{11}^{-1} \\ &= -\mathbf{B}_{22}\mathbf{X}'_2\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1} \end{aligned}$$

$$\begin{aligned} \mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}' &= (\mathbf{X}_1 \quad \mathbf{X}_2) \begin{pmatrix} \mathbf{B}_{11} & \mathbf{B}_{12} \\ \mathbf{B}_{21} & \mathbf{B}_{22} \end{pmatrix} \begin{pmatrix} \mathbf{X}'_1 \\ \mathbf{X}'_2 \end{pmatrix} \\ &= \mathbf{X}_1\mathbf{B}_{11}\mathbf{X}'_1 + \mathbf{X}_2\mathbf{B}_{21}\mathbf{X}'_1 + \mathbf{X}_1\mathbf{B}_{12}\mathbf{X}'_2 + \mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2 \\ &= \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 + \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 \\ &\quad - \mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 \\ &\quad - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2 \\ &\quad + \mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2 \\ &= \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1[\mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 - \mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2] \\ &\quad + \mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2(\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1) \\ &\quad + \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 \\ &= -\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1[\mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2](\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1) \\ &\quad + \mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2(\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1) \\ &\quad + \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 \\ &= (\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1)[\mathbf{X}_2\mathbf{B}_{22}\mathbf{X}'_2](\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1) \\ &\quad + \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 \\ &= \mathbf{X}_{2*}\mathbf{B}_{22}\mathbf{X}'_{2*} + \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1 \end{aligned}$$

Residuaalineliosummien erotukseksi saadaan nyt

$$\begin{aligned} & \mathbf{y}'\mathbf{X}(\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y} - \mathbf{y}'\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{y} \\ &= \mathbf{y}'\mathbf{X}_{2*}\mathbf{B}_{22}\mathbf{X}'_{2*}\mathbf{y} + \mathbf{y}'\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{y} - \mathbf{y}'\mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1\mathbf{y} \\ &= \mathbf{y}'\mathbf{X}_{2*}(\mathbf{X}'_{2*}\mathbf{X}_{2*})^{-1}\mathbf{X}'_{2*}\mathbf{y}, \end{aligned}$$

jossa $\mathbf{X}_{2*} = (\mathbf{I} - \mathbf{X}_1(\mathbf{X}'_1\mathbf{X}_1)^{-1}\mathbf{X}'_1)\mathbf{X}_2$.

5.3 Ositetun matriisin determinantti

Lause 31. *Olkoon \mathbf{A} ei-singulaarinen $m \times m$ matriisi, joka on ositettu kuten kaavassa (5.1). Jos $\mathbf{A}_{12} = \mathbf{O}$ tai $\mathbf{A}_{21} = \mathbf{O}$, niin $|\mathbf{A}| = |\mathbf{A}_{11}||\mathbf{A}_{22}|$.*

Lause 32. *Olkoon \mathbf{A} ei-singulaarinen $m \times m$ matriisi, joka on ositettu kuten kaavassa (5.1).*

(a) $|\mathbf{A}| = |\mathbf{A}_{22}||\mathbf{A}_{11} - \mathbf{A}_{12}\mathbf{A}_{22}^{-1}\mathbf{A}_{21}|$, jos \mathbf{A}_{22} on ei-singulaarinen.

(b) $|\mathbf{A}| = |\mathbf{A}_{11}||\mathbf{A}_{22} - \mathbf{A}_{21}\mathbf{A}_{11}^{-1}\mathbf{A}_{12}|$, jos \mathbf{A}_{11} on ei-singulaarinen.

Lause 33. *Olkoon \mathbf{A} $m \times n$ matriisi ja \mathbf{B} $n \times m$ matriisi. Tällöin*

$$|\mathbf{I}_m + \mathbf{A}\mathbf{B}| = |\mathbf{I}_n + \mathbf{B}\mathbf{A}|.$$

Lause 34. *Olkoon \mathbf{A} symmetrinen $m \times m$ matriisi ja olkoon \mathbf{A}_k matriisi, joka saadaan poistamalla matriisista \mathbf{A} viimeiset $m - k$ riviä ja saraketta. Matriisi \mathbf{A} on positiivisesti definiitti, jos ja vain jos $|\mathbf{A}_1| > 0$, $|\mathbf{A}_2| > 0$, ..., $|\mathbf{A}_k| > 0$.*

Esimerkki 5.3.1

Lauseen 34 perusteella matriisi

$$\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{pmatrix}$$

on positiivisesti definiitti jos ja vain jos

$$|\mathbf{A}_1| = a_{11} > 0, \quad |\mathbf{A}_2| = \begin{vmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{vmatrix} > 0 \text{ ja } |\mathbf{A}_3| = |\mathbf{A}| > 0.$$

5.4 Harjoituksia

Luku 6

Lineaariset yhtälöryhmät

6.1 Lineaarisen yhtälöryhmän ratkaisujen lukumäärä

Määritelmä 18. Olkoon \mathbf{A} $m \times n$ matriisi, \mathbf{x} $n \times 1$ vektori ja \mathbf{c} $m \times 1$ vektori. Halutaan ratkaista lineaarinen yhtälöryhmä

$$(6.1) \quad \mathbf{Ax} = \mathbf{c}$$

vektorin \mathbf{x} suhteen. Lineaarinen yhtälöryhmä 6.1 on **konsistentti**, jos sillä on vähintään yksi ratkaisu.

Lause 35. Olkoon \mathbf{A} $m \times n$ matriisi, \mathbf{x} $n \times 1$ vektori ja \mathbf{c} $m \times 1$ vektori. Yhtälöryhmä

$$\mathbf{Ax} = \mathbf{c}$$

on konsistentti, jos ja vain jos $r(\mathbf{B}) = r(\mathbf{A})$, jossa $\mathbf{B} = (\mathbf{A} \ \mathbf{c})$.

Esimerkki 6.1.1

Tarkastellaan lineaarista yhtälöryhmää $\mathbf{Ax} = \mathbf{c}$, jossa

$$\mathbf{A} = \begin{pmatrix} 1 & 2 \\ 2 & 1 \\ 1 & 0 \end{pmatrix} \quad \text{ja} \quad \mathbf{c} = \begin{pmatrix} 1 \\ 5 \\ 3 \end{pmatrix}.$$

Huomataan että matriisin \mathbf{A} aste on 2. Matriisin

$$\mathbf{B} = (\mathbf{A} \ \mathbf{c}) = \begin{pmatrix} 1 & 2 & 1 \\ 2 & 1 & 5 \\ 1 & 0 & 3 \end{pmatrix}$$

determinantti on nolla, joten myös matriisin \mathbf{B} aste on 2. Yhtälöryhmä on siis konsistentti eli sillä on vähintään yksi ratkaisu.

Lause 36. Lineaarinen yhtälöryhmä

$$\mathbf{Ax} = \mathbf{c}$$

on konsistentti, jos ja vain jos matriisilla \mathbf{A} on yleistetty käänteismatriisi \mathbf{A}^- , jolle pätee $\mathbf{AA}^- \mathbf{c} = \mathbf{c}$.

Korollari 36.1. Jos \mathbf{A} on ei-singulaarinen $m \times m$ matriisi ja \mathbf{c} on $m \times 1$ vektori, niin yhtälöryhmä

$$\mathbf{Ax} = \mathbf{c}$$

on konsistentti.

Korollari 36.2. Jos \mathbf{A} on $m \times n$ matriisi, jonka aste on $r(\mathbf{A}) = m$, niin yhtälöryhmä

$$\mathbf{Ax} = \mathbf{c}$$

on konsistentti.

6.2 Lineaarisen yhtälöryhmän ratkaiseminen

Lause 37. Olkoon \mathbf{A} $m \times n$ matriisi, \mathbf{x} $n \times 1$ vektori ja \mathbf{c} $m \times 1$ vektori. Oletetaan, että yhtälöryhmä

$$\mathbf{Ax} = \mathbf{c}$$

on konsistentti ja olkoon \mathbf{A}^- matriisin \mathbf{A} yleistetty käänteismatriisi. Jokaiselle $n \times 1$ vektorille \mathbf{y} ,

$$\mathbf{x}_y = \mathbf{A}^- \mathbf{c} + (\mathbf{I}_n - \mathbf{A}^- \mathbf{A}) \mathbf{y}$$

on yhtälöryhmän ratkaisu ja jokaiselle ratkaisulle \mathbf{x}_* on olemassa vektori \mathbf{y} , jolla $\mathbf{x}_* = \mathbf{x}_y$.

Lause 38. Olkoon \mathbf{A} $m \times n$ matriisi, \mathbf{x} $n \times 1$ vektori ja \mathbf{c} $m \times 1$ vektori. Oletetaan, että yhtälöryhmä

$$\mathbf{Ax} = \mathbf{c}$$

on konsistentti. Ratkaisu $\mathbf{x}_* = \mathbf{A}^- \mathbf{c}$ on yhtälöryhmän yksikäsitteinen ratkaisu, jos ja vain jos $\mathbf{A}^- \mathbf{A} = \mathbf{I}_n$, jossa \mathbf{A}^- on mikä tahansa $m \times n$ matriisin \mathbf{A} yleistetty käänteismatriisi.

Korollari 38.1. Olkoon \mathbf{A} $m \times n$ matriisi, \mathbf{x} $n \times 1$ vektori ja \mathbf{c} $m \times 1$ vektori. Oletetaan, että yhtälöryhmä

$$\mathbf{Ax} = \mathbf{c}$$

on konsistentti. Ratkaisu $\mathbf{x}_* = \mathbf{A}^- \mathbf{c}$ on yhtälöryhmän yksikäsitteinen ratkaisu, jos ja vain jos $r(\mathbf{A}) = n$.

Lause 39. *Olkoon \mathbf{A} $m \times n$ matriisi ja \mathbf{x} $n \times 1$ vektori. Yhtälöryhmällä*

$$\mathbf{Ax} = \mathbf{0}$$

on ei-triviaali ratkaisu $\mathbf{x}_ \neq \mathbf{0}$,*

a) jos ja vain jos $\mathbf{A}^- \mathbf{A} \neq \mathbf{I}_n$.

b) jos ja vain jos $r(\mathbf{A}) < n$.

6.3 Harjoituksia

Luku 7

Matriisiderivaatat

7.1 Muutamia hyödyllisiä matriisiderivaattoja

Olkoon $f(\mathbf{x}) = f(x_1, \dots, x_n)$ skalaarifunktio. Määritellään funktion f derivaatta vektorin \mathbf{x} suhteen seuraavasti:

$$\frac{\partial}{\partial \mathbf{x}} f(\mathbf{x}) = \begin{pmatrix} \frac{\partial}{\partial x_1} f(\mathbf{x}) \\ \frac{\partial}{\partial x_2} f(\mathbf{x}) \\ \vdots \\ \frac{\partial}{\partial x_n} f(\mathbf{x}) \end{pmatrix}$$

Lause 40. *Olkoon $f(\mathbf{x}) = \mathbf{a}'\mathbf{x} = \mathbf{x}'\mathbf{a}$, jossa $\mathbf{x} = (x_1 \dots x_n)'$ ja $\mathbf{a} = (a_1 \dots a_n)'$. Tällöin*

$$\frac{\partial}{\partial \mathbf{x}} f(\mathbf{x}) = \mathbf{a}.$$

Lause 41. *Olkoon $f(\mathbf{x}) = \mathbf{x}'\mathbf{A}\mathbf{x}$, jossa $\mathbf{x} = (x_1 \dots x_n)'$ ja \mathbf{A} on symmetrinen $n \times n$ matriisi. Tällöin*

$$\frac{\partial}{\partial \mathbf{x}} f(\mathbf{x}) = 2\mathbf{A}\mathbf{x}.$$

Esimerkki 7.1.1

Tarkastellaan lineaarista regressiomallia

$$\mathbf{y} = \mathbf{X}\boldsymbol{\beta} + \boldsymbol{\epsilon}.$$

Regressiokerroinvektorin $\boldsymbol{\beta}$ pienimmän neliösumman estimaatti saadaan minimoimalla residuaalineliosumma

$$\begin{aligned} f(\boldsymbol{\beta}) &= (\mathbf{y} - \mathbf{X}\boldsymbol{\beta})'(\mathbf{y} - \mathbf{X}\boldsymbol{\beta}) \\ &= \mathbf{y}'\mathbf{y} - \mathbf{y}'\mathbf{X}\boldsymbol{\beta} - \boldsymbol{\beta}'\mathbf{X}'\mathbf{y} + \boldsymbol{\beta}'\mathbf{X}'\mathbf{X}\boldsymbol{\beta} \end{aligned}$$

vektorin $\boldsymbol{\beta}$ suhteen. Derivoidaan $f(\boldsymbol{\beta})$ vektorin $\boldsymbol{\beta}$ suhteen:

$$\frac{\partial}{\partial \mathbf{x}} f(\mathbf{x}) = \mathbf{0} - \mathbf{X}'\mathbf{y} - \mathbf{X}'\mathbf{y} + 2\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = 2(\mathbf{X}'\mathbf{X}\boldsymbol{\beta} - \mathbf{X}'\mathbf{y}).$$

Kun derivaatta asetetaan nolaksi, niin saadaan normaaliyhtälö

$$\mathbf{X}'\mathbf{X}\boldsymbol{\beta} = \mathbf{X}'\mathbf{y},$$

jolla on yksikäsitteinen ratkaisu

$$\boldsymbol{\beta} = (\mathbf{X}'\mathbf{X})^{-1}\mathbf{X}'\mathbf{y},$$

jos matriisi \mathbf{X} on täyttä sarakeastetta.

7.2 Harjoituksia

Kirjallisuutta

- [1] Abadir, K. M. and Magnus, J. R. (2005). *Matrix Algebra*. New York: Cambridge University Press.
- [2] Basilevsky, A. (2005). *Applied Matrix Algebra in the Statistical Sciences*. New York: Dover.
- [3] Schott, J. R. (2005). *Matrix Analysis for Statistics*, Second Edition. New York: Wiley.
- [4] Searle, S. R. (1982). *Matrix Algebra Useful for Statistics*. New York: Wiley.