

## Määritelmä

Neliömatriisit  $A$  ja  $B$  ovat **similaareja** toistensa suhteen,  $A \sim B$ , jos on olemassa kääntyvä matriisi  $P$ , jolle pätee  $A = PBP^{-1}$ .

## Lause

Jos matriisit ovat similaarit, on niillä sama karakteristinen polynomi ja siten samat ominaisarvot monikertoineen.

**Tod.** Jos  $B = P^{-1}AP$ , niin

$$B - \lambda I = P^{-1}AP - \lambda P^{-1}P = P^{-1}(A - \lambda I)P.$$

Siten

$$\begin{aligned} \det(B - \lambda I) &= \det(P^{-1}(A - \lambda I)P) \\ &= \det(P^{-1}) \det(A - \lambda I) \det(P) = \det(A - \lambda I) \end{aligned}$$

eli molemmat karakteristiset polynomit ovat samat.

QED

**Esimerkkejä, 1.:** Similaareilla matriiseilla on sama determinantti:

$$\begin{aligned}\det A &= \det (PBP^{-1}) = \det P \det B \det (P^{-1}) \\ &= \det P \det B (\det P)^{-1} = \det B .\end{aligned}$$

**2.:**  $n \times n$  matriisin  $A$  **jälki** (engl. trace) on päädiagonaalisumma:

$$\text{Tr}(A) = a_{11} + \dots + a_{nn} .$$

Voidaan osoittaa, että

$$\text{Tr}(A) = \lambda_1 + \dots + \lambda_n .$$

Koska spektri säilyy similariteetissä, tarkoittaa tämä sitä, että myös jälki on muuttumaton similariteetissä.

**3.:** Lause ei yleisty ekvivalenssiksi. Esimerkiksi matriiseilla

$$\begin{pmatrix} 2 & 1 \\ 0 & 2 \end{pmatrix} \text{ ja } \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix}$$

on sama karakteristinen polynomi,  $(2 - \lambda)^2$ , ja siten sama spektri, mutta ne eivät ole similaareja. Miksi?

Matriisin  $A$  diagonalisointi tarkoittaa sellaisen diagonaalimatriisin määräämistä, joka on similaari  $A$ :n kanssa:  $A = PDP^{-1}$ . Jos tämä onnistuu, on siitä paljon etua; esimerkiksi  $A^k = PD^kP^{-1}$ ,  $k \geq 0$ .

## Lause

*$n \times n$  matriisi  $A$  on diagonalisoituva joss  $A$ :lla on  $n$  lineaarisesti riippumatonta ominaisvektoria. Nämä ominaisvektorit muodostavat matriisin  $P$  sarakevektorit ja  $A$ :n ominaisarvot antavat  $D$ :n alkiot vastaavassa järjestyksessä.*

Matriisin  $A$  diagonalisointi tarkoittaa sellaisen diagonaalimatriisin määräämistä, joka on similaari  $A$ :n kanssa:  $A = PDP^{-1}$ . Jos tämä onnistuu, on siitä paljon etua; esimerkiksi  $A^k = PD^kP^{-1}$ ,  $k \geq 0$ .

## Lause

*$n \times n$  matriisi  $A$  on diagonalisoituva joss  $A$ :lla on  $n$  lineaarisesti riippumatonta ominaisvektoria. Nämä ominaisvektorit muodostavat matriisin  $P$  sarakevektorit ja  $A$ :n ominaisarvot antavat  $D$ :n alkiot vastaavassa järjestyksessä.*

### Esimerkki 1:

Matriisin  $A = \begin{pmatrix} 1 & 3 & 3 \\ -3 & -5 & -3 \\ 3 & 3 & 1 \end{pmatrix}$  karakteristinen polynomi on  $-(\lambda - 1)(\lambda + 2)^2$ , joten ominaisarvot ovat 1 ja  $-2$  (kaksinkertainen). Edelliselle voidaan laskea ominaisvektori  $(1, -1, 1)^T$ , jälkimmäiselle  $(-1, 1, 0)^T$  ja  $(-1, 0, 1)^T$ , jotka ovat lineaarisesti riippumattomia.

# Diagonalisointi 2

Näistä muodostetaan kannanvaihto- ja diagonaalimatriisit

$$P = \begin{pmatrix} 1 & -1 & -1 \\ -1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix}, \quad D = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -2 & 0 \\ 0 & 0 & -2 \end{pmatrix}.$$

$P$  on ei-singulaari, koska se on täyttä rangia. Näille siis pätee  $A = PDP^{-1}$ .

# Diagonalisointi 2

Näistä muodostetaan kannanvaihto- ja diagonaalimatriisit

$$P = \begin{pmatrix} 1 & -1 & -1 \\ -1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix}, \quad D = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -2 & 0 \\ 0 & 0 & -2 \end{pmatrix}.$$

$P$  on ei-singulaari, koska se on täyttä rangia. Näille siis pätee  $A = PDP^{-1}$ .

**Esimerkki 2:**

Matriisin  $B = \begin{pmatrix} 2 & 4 & 3 \\ -4 & -6 & -3 \\ 3 & 3 & 1 \end{pmatrix}$  karakteristinen yhtälö on sama kuin yllä. Mutta vaikka ominaisarvot ovat samat (monikertoineen), niin ominaisarvoon  $-2$  liittyviä lineaarisesti riippumattomia ominaisvektoreita on vain yksi. Siten  $B$  ei ole diagonalisoituva.

# Diagonalisointi 2

Näistä muodostetaan kannanvaihto- ja diagonaalimatriisit

$$P = \begin{pmatrix} 1 & -1 & -1 \\ -1 & 1 & 0 \\ 1 & 0 & 1 \end{pmatrix}, \quad D = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -2 & 0 \\ 0 & 0 & -2 \end{pmatrix}.$$

$P$  on ei-singulaari, koska se on täyttä rangia. Näille siis pätee  $A = PDP^{-1}$ .

**Esimerkki 2:**

Matriisin  $B = \begin{pmatrix} 2 & 4 & 3 \\ -4 & -6 & -3 \\ 3 & 3 & 1 \end{pmatrix}$  karakteristinen yhtälö on sama kuin yllä. Mutta vaikka ominaisarvot ovat samat (monikertoineen), niin ominaisarvoon  $-2$  liittyviä lineaarisesti riippumattomia ominaisvektoreita on vain yksi. Siten  $B$  ei ole diagonalisoituva.

Lause

*Jos  $n \times n$  matriisilla on  $n$  erillistä ominaisarvoa, on se diagonalisoituva.*

Yleisesti voidaan osoittaa, että jokainen matriisi "melkein diagonalisoituu". Jos  $n \times n$  matriisin  $A$  spektri on  $\{\lambda_1, \dots, \lambda_p\}$  monikerroin  $\{m_1, \dots, m_p\}$ , ( $p \leq n$ ), niin  $A = PJP^{-1}$ , jossa  $J$  on ns. **Jordanin matriisi**. Se on muotoa

$$\begin{pmatrix} J_1 & 0 & \dots \\ 0 & J_2 & \dots \\ \vdots & \vdots & \ddots \end{pmatrix},$$

jossa **Jordanin lohko**  $J_i$  on skalaari  $\lambda_i$ , jos  $m_i = 1$ . Jos taas  $m_i > 1$ , on  $J_i$   $m_i \times m_i$  yläkolmiomatriisi, jonka diagonaali on identtisesti  $\lambda_i$  ja sen viereinen sivudiagonaali on identtisesti 1.  $J_i$  on siis itse asiassa yksinkertainen **nauhamatriisi**, jolla on varsin helppo operoida. Erityisesti  $J$ :n potenssit voidaan laskea vaivattomasti ja siten  $PJP^{-1}$ -esityksen avulla myös  $A^k$ . Näiden avulla taas päästään (myöhemmin kurssilla) käsiksi matriisiekspONENTTIIN  $e^A$ .



# Jordanin muodot 2

**Esimerkki 2, jatkoa:** Ominaisarvoon 1 liittyvä ominaisvektori on  $u_3 = (1, -1, 1)^T$  ja arvoon  $-2$   $u_1 = (-1, 1, 0)^T$ . Puuttuva kolmas, lineaarisesti riippumaton, vektori saadaan ratkaistua **yleistettynä ominaisvektorina** yhtälöstä

$$(B - \lambda I) u_2 = u_1,$$

jossa siis nyt  $\lambda = -2$ . Ratkaisu on  $u_2 = (-1, 0, 1)^T$ . Edelleen *Mathematicalla*

```
In[42]:= a = {{2, 4, 3}, {-4, -6, -3}, {3, 3, 1}}
Out[42]:= {{2, 4, 3}, {-4, -6, -3}, {3, 3, 1}}
In[43]:= Eigensystem[a]
Out[43]:= {{-2, -2, 1}, {{-1, 1, 0}, {0, 0, 0}, {1, -1, 1}}}
In[44]:= p = Transpose[{{-1, 1, 0}, {-1, 0, 1}, {1, -1, 1}}]
Out[44]:= {{-1, -1, 1}, {1, 0, -1}, {0, 1, 1}}
In[45]:= MatrixForm[Inverse[p] . a . p]
Out[45]/MatrixForm=

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

```

jossa  $\begin{pmatrix} -2 & 1 \\ 0 & -2 \end{pmatrix}$  on siis ominaisarvoon  $-2$  liittyvä Jordanin lohko.

## Lause

*Olkoon  $\lambda$   $n \times n$  matriisin  $A = [a_{ij}]$  ominaisarvo. Silloin jollekin indeksille  $j \in \{1, 2, \dots, n\}$  pätee  $|\lambda - a_{jj}| \leq \sum_{k=1, k \neq j}^n |a_{jk}|$ .*

**Tod.:** Olkoon  $x$  ominaisarvoa  $\lambda$  vastaava ominaisvektori ja  $x_j$  sen itseisarvoltaan suurin komponentti. Yhtälöryhmän  $(A - \lambda I)x = 0$   $j$ :s rivi on  $\sum_{k=1, k \neq j}^n a_{jk}x_k + (a_{jj} - \lambda)x_j = 0$ . Jakamalla tämä  $x_j$ :lla, soveltamalla kolmioepäyhtälöä, sekä tulosta  $|x_i/x_j| \leq 1$ ,  $\forall i$  kaava seuraa. QED

## Lause

Olkoon  $\lambda$   $n \times n$  matriisin  $A = [a_{ij}]$  ominaisarvo. Silloin jollekin indeksille  $j \in \{1, 2, \dots, n\}$  pätee  $|\lambda - a_{jj}| \leq \sum_{k=1, k \neq j}^n |a_{jk}|$ .

**Tod.:** Olkoon  $x$  ominaisarvoa  $\lambda$  vastaava ominaisvektori ja  $x_j$  sen itseisarvoltaan suurin komponentti. Yhtälöryhmän  $(A - \lambda I)x = 0$   $j$ :s rivi on  $\sum_{k=1, k \neq j}^n a_{jk}x_k + (a_{jj} - \lambda)x_j = 0$ . Jakamalla tämä  $x_j$ :lla, soveltamalla kolmioepäyhtälöä, sekä tulosta  $|x_i/x_j| \leq 1$ ,  $\forall i$  kaava seuraa. QED

**Esimerkki:** Olkoon

$$A = \begin{pmatrix} 0 & \frac{1}{2} & \frac{1}{2} \\ \frac{1}{2} & 5 & 1 \\ \frac{1}{2} & 1 & 1 \end{pmatrix}.$$

Tällöin Lauseen määräämät ns. **Gerschgorinin kiekot** ovat  $|x| \leq 1$ ,  $|x - 5| \leq \frac{3}{2}$  ja  $|x - 1| \leq \frac{3}{2}$ , joissa ominaisarvot siis sijaitsevat.

Lause on siis sitä hyödyllisempi, mitä pienemmät ovat matriisin ei-diagonaalialkiot (pienemmät kiekkojen säteet).

# Dominoiva ominaisarvo 1

**Esimerkki:** Tarkastellaan kaksitilaista systeemiä, joka päivittyy satunnaisesti diskreetein välein. Siirtymätodennäköisyys  $p_{ij} = \text{Pr}(j|i)$ ,  $i, j \in \{1, 2\}$  antaa ehdollisen todennäköisyyden siirtymälle tilasta  $i$  tilaan  $j$  yhdessä aikayksikössä. Jos  $t_i$  ja  $t'_i$  ovat tilan  $i$  (absoluuttiset) todennäköisyydet perättäisinä ajanhetkinä, pätee päivitykselle **kokonaistodennäköisyyden laki**:

$$\begin{cases} t'_1 = t_1 p_{11} + t_2 p_{21} \\ t'_2 = t_1 p_{12} + t_2 p_{22} \end{cases} \quad \text{eli} \quad t' = tP, \quad P = \begin{pmatrix} p_{11} & p_{12} \\ p_{21} & p_{22} \end{pmatrix}.$$

Yllä  $t, t'$  ovat vaakavektoreita. Kun tällaisen **Markovin ketjun**, annetaan kehittyä, asymptoottisesti  $tP^n \rightarrow p$ . Vektori  $p$  on systeemin **tasapainotila**. Siten täytyy päteä  $p = pP$  eli  $p$  on matriisin  $P$  **vasen ominaisvektori**, joka liittyy ominaisarvoon 1. Aiemmin on määritelty vain matriisin *oikea* ominaisvektori. Ekvivalenttisesti pystyvektoreilla:  $P^T p^T = p^T$ .

Olkoon nyt  $P = \begin{pmatrix} 0.6 & 0.4 \\ 0.9 & 0.1 \end{pmatrix}$  ja  $P^T$ :n ominaisarvoon 1 liittyvä oikea ominaisvektori  $p^T = (0.692308, 0.307692)^T$ . Toisaalta voidaan laskea vaikkapa

```
In[127]:= MatrixForm [ MatrixPower [ Transpose [ p ], 100 ] ]
```

```
Out[127]/MatrixForm=
```

$$\begin{pmatrix} 0.692308 & 0.692308 \\ 0.307692 & 0.307692 \end{pmatrix}$$

Näyttääkin siltä, että  $(P^T)^n \rightarrow \begin{pmatrix} 0.692308 & 0.692308 \\ 0.307692 & 0.307692 \end{pmatrix}$ , miksi?

# Dominoiva ominaisarvo 2

$P^T$ :n spektri on  $\{1, -0.3\}$  ja vastaavat normalisoidut lineaarisesti riippumattomat oikeat ominaisvektorit ovat  $p^T = (0.692308, 0.307692)^T$  ja  $(-0.5, 0.5)^T$ . Määritellään näistä normaaliin tapaan

$$M = \begin{pmatrix} 0.692308 & -0.5 \\ 0.307692 & 0.5 \end{pmatrix} \quad \text{ja} \quad D = \begin{pmatrix} 1 & 0 \\ 0 & -0.3 \end{pmatrix}.$$

Tällöin  $P^T = MDM^{-1}$  josta edelleen  $(P^T)^n = MD^nM^{-1}$ ,  $\forall n \geq 1$ . Mutta koska tietenkin  $(-0.3)^n \rightarrow 0$ , tämä implikoi välittömästi että

$$(P^T)^n \rightarrow M \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} M^{-1} = \begin{pmatrix} 0.692308 & 0.692308 \\ 0.307692 & 0.307692 \end{pmatrix}.$$

Jos  $q$  on arvoa  $\lambda = 1$  vastaava vasen ominaisvektori eli toteuttaa  $qP^T = q$ , ja se normalisoidaan siten, että  $qp^T = 1$ , saadaan  $q = (1, 1)$  ja nähdään, että yllä viimeisenä oleva matriisi on  $p^T q$ . Se on rangia 1 oleva ns. projektiomatriisi.

Ylläoleva yleistyy huomattavasti: Markov-matriisi ja  $\lambda = 1$  eivät ole välttämättömiä oletuksia. Sen sijaan on oleellista, että  $m \times m$  matriisilla  $A$  on **dominoiva ominaisarvo**  $\lambda_1 > |\lambda_i|$ ,  $\forall i \neq 1$ . Silloin voidaan osoittaa, että  $\frac{A^n}{\lambda_1^n}$  suppenee kohti  $\lambda_1$ :tä vastaavien normeerattujen vasemman ja oikean ominaisvektorin ulkoista tuloa.

$n \times 1$  matriisit  $u, v \in \mathbf{R}^n$  ovat pystyvektoreja.

## Määritelmä

Skalaari  $u^T v = u \cdot v$  on vektoreiden  $u$  ja  $v$  **sisä- eli pistetulo**.

Pistetulo on liitännäinen, vaihdannainen ja distributiivinen skalaarilla kertomisen suhteen. Selvästi  $u^T u \geq 0$ , josta seuraa

## Määritelmä

Vektorin **normi eli pituus** on  $\|u\| = \sqrt{u^T u}$ .

Tämä määritelmä on itse asiassa täsmälleen Pythagoraan teoreema.

$n \times 1$  matriisit  $u, v \in \mathbf{R}^n$  ovat pystyvektoreja.

## Määritelmä

Skalaari  $u^T v = u \cdot v$  on vektoreiden  $u$  ja  $v$  **sisä- eli pistetulo**.

Pistetulo on liitännäinen, vaihdannainen ja distributiivinen skalaarilla kertomisen suhteen. Selvästi  $u^T u \geq 0$ , josta seuraa

## Määritelmä

Vektorin **normi eli pituus** on  $\|u\| = \sqrt{u^T u}$ .

Tämä määritelmä on itse asiassa täsmälleen Pythagoraan teoreema.

## Määritelmä

Vektorit  $u$  ja  $v$  ovat **kohtisuorassa eli ortogonaaliset** jos  $u^T v = 0$ .

## Määritelmä

Vektorin  $u \in \mathbf{R}^n$  **ortogonaalikomplementti**, merkitään  $u^\perp$ , on joukko  $\{v \in \mathbf{R}^n \mid v \cdot u = 0\}$ . Aliavaruuden  $W \subset \mathbf{R}^n$  **ortogonaalikomplementti**  $W^\perp$  on kaikkien niiden vektoreiden joukko, jotka ovat ortogonaalisia jokaista  $W$ :n nollasta eroavaa alkiota vastaan.

**Esimerkki:** Vektorin  $u \in \mathbf{R}^3$ ,  $u \neq 0$  ortogonaalikomplementti on vektoria vastaan kohtisuora, origon kautta kulkeva taso. Kyseisen tason ortogonaalikomplementti taas on tason normaalivektoreiden joukko (joista  $u$  on eräs).

Voidaan helposti osoittaa, että vektoreille  $u, v \in \mathbf{R}^n$ ,  $u, v \neq 0$  pätee aina  $u \cdot v = \|u\| \|v\| \cos \alpha$ , jossa  $\alpha$  on vektoreiden välinen kulma. Huomaa, että dimensio  $n \geq 2$  on mielivaltainen; kaksi vektoria  $u$  ja  $v$  määräävät korkeintaan kaksiulotteisen aliavaruuden, joten kulma siinä on aina määriteltävissä.



## Määritelmä

*Vektorikokoelma*  $\{u_1, \dots, u_k\} \subset \mathbf{R}^n$ ,  $k \leq n$  on **ortogonaalinen joukko**, jos  $u_i \cdot u_j = 0$ ,  $i \neq j$  ja  $u_j \cdot u_j > 0 \forall i, j$ .

$\mathbf{R}^n$ :n **ortogonaalikanta** on  $n$ :n elementin ortogonaalinen joukko.

Vektori ja mikä tahansa (ei nolla)vektori sen ortogonaalikomplementista muodostavat ortogonaalisen joukon. Jos ortogonaalisessa joukossa on  $k$  elementtiä, virittävät ne  $k$ -ulotteisen aliavaruuden  $\mathbf{R}^n$ :än.

**Esimerkkejä, 1.**  $\mathbf{R}^n$ :n kanoninen ortogonaalikanta muodostuu **alkeisvektoreista**  $e_i = (0, \dots, 1, \dots, 0)$ ,  $i = 1, \dots, n$ , jossa ainoa ei-häviävä alkio on  $i$ :nnessä koordinaatissa.

**2.** Vektorit  $u_1 = (3, 1, 1)^T$ ,  $u_2 = (-1, 2, 1)^T$  ja  $u_3 = (-\frac{1}{2}, -2, \frac{7}{2})^T$  muodostavat ortogonaalisen kannan  $\mathbf{R}^3$ :en. Voidaan helposti tarkistaa, että  $y = (6, 1, -8)^T = u_1 - 2u_2 - 2u_3$ . Miten tehdä tällainen esitys systemaattisesti annetuille vektoreille?

## Lause

Jos  $\{u_1, \dots, u_p\}$  on ortogonaalinen kanta  $\mathbf{R}^n$ :n aliavaruudelle, niin silloin mielivaltainen aliavaruuden vektori voidaan hajottaa

$$y = \sum_{i=1}^p c_i u_i, \quad \text{jossa} \quad c_i = \frac{y \cdot u_i}{u_i \cdot u_i}.$$

**Tod.:**  $y \cdot u_j = \left(\sum_{i=1}^p c_i u_i\right) \cdot u_j = c_j u_j \cdot u_j.$  QED

Suure  $\frac{y \cdot u}{u \cdot u} u$  on  $y$ :n **ortogonaaliprojektiio** vektorin  $u$  suuntaan.

**Esimerkki** (ed. jatkoa):  $u_1 \cdot u_1 = 11$ ,  $u_2 \cdot u_2 = 6$  ja  $u_3 \cdot u_3 = \frac{33}{2}$ . Koska sisätulot ovat  $y \cdot u_1 = 11$ ,  $y \cdot u_2 = -12$  ja  $y \cdot u_3 = -33$ , seuraavat annetut kertoimet 1,  $-2$  ja  $-2$ .

Jos ortogonaaliselle joukolle pätee  $u_i \cdot u_j = \delta_{ij} = \begin{cases} 0 & , i \neq j \\ 1 & , i = j \end{cases}$ , on kyseessä **ortonormaali** joukko (jolle laskenta on erityisen helppoa!)

## Lause

Olkoon  $\{u_1, u_2, \dots, u_p\}$  kanta  $\mathbf{R}^n$ :n aliavaruudelle  $W$ . Kun määritellään

$$v_1 = u_1$$

$$v_2 = u_2 - \frac{u_2 \cdot v_1}{v_1 \cdot v_1} v_1$$

$$v_3 = u_3 - \frac{u_3 \cdot v_1}{v_1 \cdot v_1} v_1 - \frac{u_3 \cdot v_2}{v_2 \cdot v_2} v_2$$

$$\vdots$$

$$v_p = u_p - \frac{u_p \cdot v_1}{v_1 \cdot v_1} v_1 - \frac{u_p \cdot v_2}{v_2 \cdot v_2} v_2 - \dots - \frac{u_p \cdot v_{p-1}}{v_{p-1} \cdot v_{p-1}} v_{p-1},$$

niin  $\{v_1, v_2, \dots, v_p\}$  muodostaa  $W$ :n ortogonaalisen kannan.

Normalisoimalla  $\left\{ \frac{v_1}{\|v_1\|}, \frac{v_2}{\|v_2\|}, \dots, \frac{v_p}{\|v_p\|} \right\}$  saadaan ortonormaali kanta.

**Esimerkki:** Kokoelma  $\{u_i\}_{i=1}^3 = \{(1, 0, 0)^T, (1, 1, 0)^T, (1, 1, 1)^T\}$  on helppo nähdä lineaarisesti riippumattomaksi. Muodostetaan siitä ortonormaali kanta  $\mathbf{R}^3$ :lle:

$$v_1 = u_1 = (1, 0, 0)^T$$

$$v_2 = (1, 1, 0)^T - (1, 1, 0)^T(1, 0, 0)(1, 0, 0)^T = (0, 1, 0)^T$$

$$v_3 = (1, 1, 1)^T - (1, 1, 1)^T(1, 0, 0)(1, 0, 0)^T - (1, 1, 1)^T(0, 1, 0)(0, 1, 0)^T = (0, 0, 1)^T,$$

jossa vektorit  $v_i$  tulivat (sattumalta) valmiiksi normalisoituneina ja saatiin  $\mathbf{R}^3$ :n kanoninen kanta. Mikäli alkuperäistä joukkoa käsitellään vaikkapa käänteisessä järjestyksessä, saadaan erilainen ortogonaalinen systeemi:

$$w_1 = u_3 = (1, 1, 1)^T$$

$$w_2 = (1, 1, 0)^T - \frac{(1, 1, 0)^T(1, 1, 1)}{(1, 1, 1)^T(1, 1, 1)}(1, 1, 1)^T = \left(\frac{1}{3}, \frac{1}{3}, -\frac{2}{3}\right)^T$$

$$\begin{aligned} w_3 &= (1, 0, 0)^T - \frac{(1, 0, 0)^T(1, 1, 1)}{(1, 1, 1)^T(1, 1, 1)}(1, 1, 1)^T - \frac{(1, 0, 0)^T \left(\frac{1}{3}, \frac{1}{3}, -\frac{2}{3}\right)}{\left(\frac{1}{3}, \frac{1}{3}, -\frac{2}{3}\right)^T \left(\frac{1}{3}, \frac{1}{3}, -\frac{2}{3}\right)} \left(\frac{1}{3}, \frac{1}{3}, -\frac{2}{3}\right)^T \\ &= \left(\frac{1}{2}, -\frac{1}{2}, 0\right)^T, \end{aligned}$$

joka on edelleen normalisoitava, jos halutaan ortonormaali joukko.

## Lause

*Jos neliömatriisin  $U$  sarakkeet ovat ortonormaali joukko, pätee sille  $U^T U = I$ .*

**Proof:**  $U = (u_1 | u_2 | \cdots | u_n)$  ( $u_i$  on pystyvektori), joten identiteetti  $I$  seuraa välittömästi sisätuloista:  $u_i \cdot u_j = \delta_{ij}$ . QED

Lause määrittelee **ortogonaalisen matriisin**. Niillä on erinomaisia ominaisuuksia:

- $U^{-1} = U^T$ ,
- rivit ovat myös ortonormaali joukko,
- $(Ux) \cdot (Uy) = (Ux)^T (Uy) = x^T U^T U y = x^T y = x \cdot y$ , josta erikoistapauksena seuraa, että  $\|Ux\| = \|x\|$ , kuten myös se, että ortogonaalinen matriisi säilyttää vektorien väliset kulmat.

**Esimerkkejä, 1.:**

$$K(\theta) = \begin{pmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{pmatrix},$$

kierto tasossa vastapäivään kulman  $\theta$  verran, on ortogonaalinen transformaatio ja  $K(\theta)$  on ortogonaalinen matriisi jokaiselle  $\theta$ . Muunnoksessa  $x \mapsto K(\theta)x$  vektorin pituus ei muutu. Huomaa, että inverssi on harvinaisen helppo: transponointi tai  $\theta \rightarrow -\theta$ !  $K$ :n ortogonaalinen lähisukulainen on

$$H(\phi) = \begin{pmatrix} \cos(2\phi) & \sin(2\phi) \\ \sin(2\phi) & -\cos(2\phi) \end{pmatrix}.$$

Miten  $H$  kuvaa tasovektorit? Mitä merkitsee se,  $\det K(\theta) = 1$ , mutta  $\det H(\phi) = -1$ ?

## Esimerkkejä, 1.:

$$K(\theta) = \begin{pmatrix} \cos(\theta) & -\sin(\theta) \\ \sin(\theta) & \cos(\theta) \end{pmatrix},$$

kierto tasossa vastapäivään kulman  $\theta$  verran, on ortogonaalinen transformaatio ja  $K(\theta)$  on ortogonaalinen matriisi jokaiselle  $\theta$ . Muunnoksessa  $x \mapsto K(\theta)x$  vektorin pituus ei muutu. Huomaa, että inverssi on harvinaisen helppo: transponointi tai  $\theta \rightarrow -\theta$ !  $K$ :n ortogonaalinen lähisukulainen on

$$H(\phi) = \begin{pmatrix} \cos(2\phi) & \sin(2\phi) \\ \sin(2\phi) & -\cos(2\phi) \end{pmatrix}.$$

Miten  $H$  kuvaa tasovektorit? Mitä merkitsee se,  $\det K(\theta) = 1$ , mutta  $\det H(\phi) = -1$ ?

2.: Olkoon  $P$   $n \times n$ -matriisi, jonka jokaisessa sarakkeessa ja jokaisella rivillä on yksi ykkönen muiden alkoiden ollessa nollia. Siten matriisin rivit ja sarakkeet ovat aina alkeisvektoreita  $e_i = (0, \dots, 1, \dots, 0) \in \mathbf{R}^n$ . Selvästi  $e_i \cdot e_j = \delta_{ij}$ , joten ortogonaalisuus seuraa välittömästi.

Olkoon  $w = (1, 2, 3, \dots, n)^T$ . On helppo nähdä, että  $Pw$  on pystyvektori, jossa luvut  $1, 2, \dots, n$  ovat uudessa järjestyksessä.  $P$  on esimerkki **permutaatiomatriisista**. Sillä ei ole ilmeistä geometrista tulkintaa, mutta se on hyvin tärkeä kombinatoriikassa.

Esimerkiksi jos  $n = 52$ , on kaikkien tällaisten  $P$ -matriisien joukko kaikkien korttipakan sekoitusten joukko (joita on  $52! \approx 8.0658 \cdot 10^{67}$  kpl...)

Olkoon  $A$   $m \times n$ -matriisi, jolla on lineaarisesti riippumattomat sarakkeet  $\{x_1, x_2, \dots, x_n\}$  eli nämä siis virittävät  $n$ -ulotteisen avaruuden,  $A$ :n sarakeavaruuden. Sarakkeet voidaan ortonormalisoida Gram-Schmidtillä ja muodostaa näistä ortogonaalimatriisi  $Q = (u_1 | \dots | u_n)$ . Siten

$$x_k = \sum_{j=1}^k r_{jk} u_j + \sum_{j=k+1}^n 0 \cdot u_j$$

Saadaan myös  $r_{kk} \geq 0$  valitsemalla kantaan joko  $u_k$  tai  $-u_k$ . Määrittelemällä  $r_k = (r_{1k}, \dots, r_{kk}, 0, \dots, 0)^T$  nähdään, että  $x_k = Qr_k$ ,  $k = 1, \dots, n$ . Asettamalla  $R = (r_1 | \dots | r_n)$  saadaan

### Lause

**QR-hajotelma** on  $A = QR$ , jossa  $Q$ :n sarakkeet ovat ortonormaali kanta  $A$ :n sarakeavaruudelle ja  $R$  on kääntyvä yläkolmiomatriisi, jonka diagonaali on positiivinen.



**Esimerkki:** Matriisiin

$$A = \begin{pmatrix} 1 & 0 & 0 \\ 1 & 1 & 0 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{pmatrix}.$$

sarakkeet voidaan ortonormalisoida Gram-Schmidtin proseduurilla ja saadaan

$$Q = \begin{pmatrix} \frac{1}{2} & -\frac{3}{\sqrt{12}} & 0 \\ \frac{1}{2} & \frac{1}{\sqrt{12}} & -\frac{2}{\sqrt{6}} \\ \frac{1}{2} & \frac{1}{\sqrt{12}} & \frac{1}{\sqrt{6}} \\ \frac{1}{2} & \frac{1}{\sqrt{12}} & \frac{1}{\sqrt{6}} \end{pmatrix}.$$

Koska  $Q$  on ortogonaalinen, pätee  $Q^T A = Q^T Q R = Q^{-1} Q R = R$  josta helposti

$$R = \begin{pmatrix} 2 & \frac{3}{2} & 1 \\ 0 & \frac{3}{\sqrt{12}} & \frac{2}{\sqrt{12}} \\ 0 & 0 & \frac{2}{\sqrt{6}} \end{pmatrix}.$$

QR-hajotelma on tärkeä numeriikan algoritmi ja se on implementoitu moniin matemaattisiin ohjelmistoihin.