

# 1 Vektorji in matrike

**1.1** Vektor je urejena  $n$ -terica števil, ki jo običajno zapišemo kot stolpec

$$\vec{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

**1.2** Produkt vektorja  $\vec{x}$  s skalarjem  $\alpha$  je vektor

$$\alpha\vec{x} = \alpha \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} = \begin{bmatrix} \alpha x_1 \\ \vdots \\ \alpha x_n \end{bmatrix}$$

**1.3** Vsota vektorjev  $\vec{x}$  in  $\vec{y}$  je vektor

$$\vec{x} + \vec{y} = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} + \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} x_1 + y_1 \\ \vdots \\ x_n + y_n \end{bmatrix}$$

**1.4** Nicelni vektor  $\vec{0}$  je tisti vektor, za katerega je  $\vec{a} + \vec{0} = \vec{0} + \vec{a} = \vec{a}$  za vsak vektor  $\vec{a}$ . Vse komponente nicelnega vektorja so enake 0. Vsakemu vektorju  $\vec{a}$  pripada nasprotni vektor  $-\vec{a}$ , tako da je  $\vec{a} + (-\vec{a}) = \vec{0}$ . Razlika vektorjev  $\vec{a}$  in  $\vec{b}$  je vsota  $\vec{a} + (-\vec{b})$  in jo navadno zapišemo kot  $\vec{a} - \vec{b}$ .

**Lastnosti vektorske vsote**

- $\vec{a} + \vec{b} = \vec{b} + \vec{a}$  (komutativnost)
- $\vec{a} + (\vec{b} + \vec{c}) = (\vec{a} + \vec{b}) + \vec{c}$  (asociativnost)
- $a(\vec{a} + \vec{b}) = a\vec{a} + a\vec{b}$  (distributivnost)

**1.5** Linearna kombinacija vektorjev  $\vec{x}$  in  $\vec{y}$  je vsota

$$a\vec{x} + b\vec{y}$$

**1.6** Skalarni produkt vektorjev

$$\begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \text{ in } \begin{bmatrix} y_1 \\ \vdots \\ y_n \end{bmatrix} \text{ je stevilo}$$

$$\vec{x} \cdot \vec{y} = x_1y_1 + x_2y_2 + \dots + x_ny_n$$

alternativno:

$$\vec{x} \cdot \vec{y} = \|\vec{x}\| \|\vec{y}\| \cos \phi$$

**Lastnosti skalarnega produkta**

- $\vec{x} \cdot \vec{y} = \vec{y} \cdot \vec{x}$  (komutativnost)
- $\vec{x} \cdot (\vec{y} + \vec{z}) = \vec{x} \cdot \vec{y} + \vec{x} \cdot \vec{z}$  (aditivnost)
- $\vec{x} \cdot (a\vec{y}) = a(\vec{x} \cdot \vec{y}) = (a\vec{x}) \cdot \vec{y}$  (homogenost)
- $\forall \vec{x}$  velja  $\vec{x} \cdot \vec{x} \geq 0$

**1.7** Dolžina vektorja  $\vec{x}$  je

$$\|\vec{x}\| = \sqrt{\vec{x} \cdot \vec{x}}$$

**1.8** Enotski vektor je vektor z dolžino 1.

**1.9** Za poljubna vektorja  $\vec{u}, \vec{v} \in R^n$  velja:

$$|\vec{u} \cdot \vec{v}| \leq \|\vec{u}\| \|\vec{v}\|,$$

enakost velja, v primeru, da sta vektorja vzporedna.

**1.10** Za poljubna vektorja  $\vec{u}, \vec{v} \in R^n$  velja:

$$\|\vec{u} + \vec{v}\| \leq \|\vec{u}\| + \|\vec{v}\|.$$

**1.11** Vektorja  $\vec{x}$  in  $\vec{y}$  sta ortogonalna (pravokotna) natakno takrat, kadar je

$$\vec{x} \cdot \vec{y} = 0$$

**1.12** Če je  $\phi$  kot med vektorjema  $\vec{x}$  in  $\vec{y}$ , potem je

$$\frac{\vec{x} \cdot \vec{y}}{\|\vec{x}\| \|\vec{y}\|} = \cos \phi$$

**1.13** Vektorski produkt:

$$\vec{a} \times \vec{b} = (a_2b_3 - a_3b_2)\mathbf{i} + (a_3b_1 - a_1b_3)\mathbf{j} + (a_1b_2 - a_2b_1)\mathbf{k}$$

**Lastnosti vektorskega produkta**

- $\vec{a} \times (\vec{b} + \vec{c}) = \vec{a} \times \vec{b} + \vec{a} \times \vec{c}$  (aditivnost)
- $\vec{b} \times \vec{a} = -\vec{a} \times \vec{b}$  (!komutativnost)
- $(a\vec{a}) \times \vec{b} = a(\vec{a} \times \vec{b}) = \vec{a} \times (a\vec{b})$  (homogenost)
- $\vec{a} \times \vec{a} = 0$
- $\vec{a} \times \vec{b}$  je  $\perp$  na vektorja  $\vec{a}$  in  $\vec{b}$
- $\|\vec{a} \times \vec{b}\| = \|\vec{a}\| \|\vec{b}\| \sin \phi$
- Dolžina vektorskega produkta je ploscina paralelograma, katerega vektorja oklepata

**1.14** Mesani produkt  $(\vec{a}, \vec{b}, \vec{c})$  vektorjev  $\vec{a}, \vec{b}$  in  $\vec{c}$  v  $R^3$  je skalarni produkt vektorjev  $\vec{a} \times \vec{b}$  in  $\vec{c}$ :

$$(\vec{a}, \vec{b}, \vec{c}) = (\vec{a} \times \vec{b}) \cdot \vec{c}$$

**Lastnosti mesanega produkta**

- $(\vec{a}, \vec{b}, \vec{c}) = (\vec{b}, \vec{c}, \vec{a}) = (\vec{c}, \vec{a}, \vec{b})$
- $(x\vec{a}, \vec{b}, \vec{c}) = x(\vec{a}, \vec{b}, \vec{c})$  (homogenost)
- $(\vec{a}, \vec{u} + \vec{v}, \vec{c}) = (\vec{a}, \vec{u}, \vec{c}) + (\vec{a}, \vec{v}, \vec{c})$
- Absolutna vrednost mesanega produkta  $(\vec{a}, \vec{b}, \vec{c})$  je enaka prostornini paralepipeda

**Premice v  $R^3$**

Premico določata smerni vektor  $\vec{p} = [a, b, c]^T$  in točka  $A(x_0, y_0, z_0)$ .

- Parametrična oblika  
 $\vec{r} = \vec{r}_A + t\vec{p}, t \in R$

- Kanonična oblika  $\frac{x-x_0}{a} = \frac{y-y_0}{b} = \frac{z-z_0}{c}$

### Ravnine v $R^3$

Ravnina z normalo  $\vec{n} = [a, b, c]^T$  skozi točko  $A(x_0, y_0, z_0)$  ima enačbo

$$(\vec{r} - \vec{r}_A) \cdot \vec{n} = 0$$

oziroma

$$ax + by + cz = d$$

### Razdalje

Razdalja od točke  $P$  do ravnine, v kateri leži točka  $A$ :

$$\cos \phi = \frac{\vec{n} \cdot (\vec{r}_P - \vec{r}_A)}{|\vec{n}| |\vec{r}_P - \vec{r}_A|} \text{ oz. } d = \frac{|\vec{n} \cdot (\vec{r}_P - \vec{r}_A)|}{|\vec{n}|}$$

Razdalja od točke  $P$  do premice, katera gre skozi točko  $A$ :

$$d = \frac{|\vec{e} \times (\vec{r}_P - \vec{r}_A)|}{|\vec{e}|}$$

### Projekcije vektorjev

Naj bo  $proj_{\vec{a}} \vec{b} = \vec{x}$  projekcija vektorja  $\vec{b}$  na vektor  $\vec{a}$ . Izračunamo jo po sledeci formuli:

$$proj_{\vec{a}} \vec{b} = \frac{\vec{a} \cdot \vec{b}}{\vec{a} \cdot \vec{a}} \vec{a}$$

**1.15** Matrika dimenzije  $m \times n$  je tabela  $m \times n$  števil, urejenih v  $m$  vrstic in  $n$  stolpcev:

$$A^{m \times n} = \begin{bmatrix} x_{11} & x_{12} & x_{13} & \dots & x_{1n} \\ x_{21} & x_{22} & x_{23} & \dots & x_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & x_{m3} & \dots & x_{mn} \end{bmatrix}$$

**1.16** Matrika, katere elementi so enaki nič povsod zunaj glavne diagonale, se imenuje diagonalna matrika. Za diagonalno matriko je  $a_{ij} = 0$ , kadarkoli velja  $i \neq j$

**1.17** Matrika  $A^{n \times n}$  je spodnjetrokotna, kadar so vsi elementi nad glavno diagonalo enaki 0:

$$a_{ij} = 0 \text{ kadar je } i < j$$

**1.18** Matrika  $A^{n \times n}$  je zgornjetrokotna, kadar so vsi elementi pod glavno diagonalo enaki 0:

$$a_{ij} = 0 \text{ kadar je } i > j$$

**1.19** Matrika je trikotna, ce je zgornjetrokotna ali spodnjetrokotna.

**1.20** Dve matriki  $A$  in  $B$  sta enaki natanko takrat, kadar imata enaki dimenziji in kadar so na istih mestih v obeh matrikah enaki elementi:

$$A^{m \times n} = B^{p \times q} \implies m = p \text{ in } n = q, \\ a_{ij} = b_{ij} \text{ za vsak } i = 1, \dots, m \text{ in } j = 1, \dots, n$$

**1.21** Produkt matrike s skalarjem dobimo tako, da vsak element matrike pomnozimo s skalarjem

$$aA^{m \times n} = \begin{bmatrix} ax_{11} & ax_{12} & ax_{13} & \dots & ax_{1n} \\ ax_{21} & ax_{22} & ax_{23} & \dots & ax_{2n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ ax_{m1} & ax_{m2} & ax_{m3} & \dots & ax_{mn} \end{bmatrix}$$

**1.22** Vsoto dveh matrik enake dimenzije dobimo tako, da seštejemo istolezne elemente obeh matrik:

$$A + B = \begin{bmatrix} a_{11} + b_{11} & a_{12} + b_{12} & \dots & a_{1n} + b_{1n} \\ a_{21} + b_{21} & a_{22} + b_{22} & \dots & a_{2n} + b_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} + b_{m1} & a_{m2} + b_{m3} & \dots & a_{mn} + b_{mn} \end{bmatrix}$$

### Osnovne matricne operacije

- $A + B = B + A$  (komutativnost)
- $(A + B) + C = A + (B + C)$  (asociativnost)
- $a(A + B) = aA + aB$  (množenje s skalarjem)
- $A + (-A) = 0$
- $x(yA) = (xy)A$  in  $1 \cdot A = A$

**1.23** Transponirana matrika k matriki  $A$  reda  $m \times n$  je matrika reda  $n \times m$

$$A = \begin{bmatrix} x_{11} & x_{12} & \dots & x_{1n} \\ x_{21} & x_{22} & \dots & x_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & \dots & x_{mn} \end{bmatrix} \\ A^T = \begin{bmatrix} x_{11} & x_{21} & \dots & x_{m1} \\ x_{12} & x_{22} & \dots & x_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ x_{1n} & x_{2n} & \dots & x_{mn} \end{bmatrix}$$

### Lastnosti transponiranja matrik

- $(A + B)^T = A^T + B^T$
- $(A \cdot B)^T = B^T \cdot A^T$
- $(xA)^T = xA^T$
- $(A^T)^T = A$

**1.24** Produkt matrike  $A$  in vektorja  $\vec{x}$  je linearna kombinacija stolpcev matrike  $A$ , utezi linearne kombinacije so komponente vektorja  $\vec{x}$ :

$$A\vec{x} = \begin{bmatrix} \vec{u} & \vec{v} & \vec{w} \end{bmatrix} \cdot \begin{bmatrix} a \\ b \\ c \end{bmatrix} = a\vec{u} + b\vec{v} + c\vec{w}$$

**1.25** Produkt vrstice  $\vec{y}$  z matriko  $A$  je linearna kombinacija vrstic matrike  $A$ , koeficienti linearne kombinacije so komponente vrstice  $\vec{y}$ :

$$\vec{y} \cdot A = [y_1, y_2, y_3] \cdot \begin{bmatrix} \vec{u} \\ \vec{v} \\ \vec{w} \end{bmatrix} = \begin{bmatrix} y_1\vec{u} \\ y_2\vec{v} \\ y_3\vec{w} \end{bmatrix}$$

**1.26** Produkt matrik  $A$  in  $B$  je matrika, katere stolpci so zaporedoma produkti matrike  $A$  s stolpci matrike  $B$ :

$$AB = A [b_1, b_2, \dots, b_n] = [Ab_1, Ab_2, \dots, Ab_n]$$

**1.27** Element  $c_{ij}$  v  $i$ -ti vrstici in  $j$ -tem stolpcu produkta  $C = AB$  je skalarni produkt  $i$ -te vrstice  $A$  in  $j$ -tega stolpca matrike  $B$

$$c_{ij} = \sum_{k=1}^n a_{ik} b_{kj}$$

**1.28** Produkt matrik  $A$  in  $B$  je matrika, katere vrstice so zaporedoma produkti vrstic matrike  $A$  z matriko  $B$ :

$$[i\text{-ta vrstica } A] B = [i\text{-ta vrstica } AB]$$

### Lastnosti matricnega produkta

- $AB \neq BA$  (!komutativnost)
- $(xA)B = x(AB) = A(xB)$  (homogenost)
- $C(A + B) = CA + CB$  (distributivnost)
- $A(BC) = (AB)C$  (asociativnost)
- $(AB)^T = B^T A^T$

V splošnem; komutativnost matricnega množenja velja samo, ko sta matriki diagonalizabilni.

**1.29** Vrstice matrike A z n stolpci naj bodo  $a^1, \dots, a^n$ , stolpci matrike B z n vrsticami pa  $b_1, \dots, b_n$ . Potem je

$$AB = a^1 b_1 + \dots + a^n b_n$$

**1.30** Če delitev na bloke v matriki A ustreza delitvi v matriki B, potem lahko matriki pomnozimo blocno:

$$\begin{bmatrix} A_{11} & A_{12} \\ A_{21} & A_{22} \end{bmatrix} \begin{bmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{bmatrix} = \begin{bmatrix} A_{11}B_{11} + A_{12}B_{21} & A_{11}B_{12} + A_{12}B_{22} \\ A_{21}B_{11} + A_{22}B_{21} & A_{21}B_{12} + A_{22}B_{22} \end{bmatrix}$$

**1.31** Kvadratna matrika  $I_k$  reda  $k \times k$ , ki ima vse diagonalne elemente enake 1, vse ostale elemente pa 0 ima lastnost, da za vsako matriko A reda  $m \times n$  velja  $AI_n = A$  in  $I_m A = A$ . Matrika  $I_k$  se imenuje enotska ali identična matrika.

$$I_k = \begin{bmatrix} 1 & 0 & \dots & 0 \\ 0 & 1 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1 \end{bmatrix}$$

## 2 Sistemi linearnih enačb

**2.1** Kvadratna matrika A je obrnljiva, ce obstaja taka matrika  $A^{-1}$ , da je

$$AA^{-1} = I \text{ in } A^{-1}A = I$$

Matrika  $A^{-1}$  (ce obstaja) se imenuje matriki A inverzna matrika. Matrika, ki ni obrnljiva, je singularna. Matrika NI obrnljiva, kadar je  $\text{rang}(A) < n$ !

**2.2** Kvadratna matrika reda n je obrnljiva natanko tedaj, ko pri gaussovi eliminaciji dobimo n pivotov.

**2.3** Vsaka obrnljiva matrika ima eno samo inverzno matriko.

**2.4** Inverzna matrika inverzne matrike  $A^{-1}$  je matrika A

$$(A^{-1})^{-1} = A$$

**2.5** Ce je matrika A obrnljiva, potem ima sistem enačb  $A\vec{x} = \vec{b}$  edino resitev  $\vec{x} = A^{-1}\vec{b}$

**2.6** Ce obstaja nenicelna resitev  $\vec{x}$  enačbe  $A\vec{x} = \vec{0}$ , matrika A ni obrnljiva (je singularna).

**2.7** Ce sta matriki A in B istega reda obrnljivi, je obrnljiv tudi produkt  $A \cdot B$  in

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

**Pozor!** Pravilo

$$(AB)^p = A^p B^p$$

velja le v primeru, ko matriki A in B komutirata, torej  $AB = BA$ .

**2.8** Inverz transponirane matrike je transponirana matrika inverza

$$(A^T)^{-1} = (A^{-1})^T$$

**2.9** Inverz diagonalne matrike z diagonalnimi elementi  $a_{ii}$  je diagonalna matrika, ki ima na diagonalni elemente  $a_{ii}^{-1}$

$$\begin{bmatrix} a_{11} & & 0 \\ & \ddots & \\ 0 & & a_{nn} \end{bmatrix} = \begin{bmatrix} a_{11}^{-1} & & 0 \\ & \ddots & \\ 0 & & a_{nn}^{-1} \end{bmatrix}$$

**2.10** Za izracun inverza matrike A, uporabimo gaussovo eliminacijo nad matriko  $[A|I]$

$$[A|I] = [I|A^{-1}]$$

**2.11** Matrika A je simetricna  $\Leftrightarrow A^T = A$ . Za elemente  $a_{ij}$  simetricne matrike velja  $a_{ij} = a_{ji}$ . Za simetricno matriko vedno velja, da je kvadratna  $A \in R^{n \times n}$ .

**2.12** Ce je matrika A simetricna in obrnljiva, je tudi  $A^{-1}$  simetricna.

**2.13** Ce je R poljubna (lahko tudi pravokotna) matrika, sta  $R^T R$  in  $R R^T$  simetricni matriki.

## 3 Vektorski prostori

**3.1** Realni vektorski prostor V je množica "vektorjev" skupaj z pravili za

- seštevanje vektorjev,
- množenje vektorja z realnim številom (skalarjem)

Ce sta  $\vec{x}$  in  $\vec{y}$  poljubna vektorja v V, morajo biti v V tudi

- vsota  $\vec{x} + \vec{y}$  in
- produkti  $\alpha \vec{x}$  za vse  $\alpha \in R$

V vektorskem prostoru V morajo biti tudi VSE linearne kombinacije  $\alpha \vec{x} + \beta \vec{y}$

**Pravila za operacije v vektorskih prostorih**

Operaciji seštevanja vektorjev in množenja vektorja s skalarjem v vektorskem prostoru morajo zadoscati naslednjim pravilom:

- $\vec{x} + \vec{y} = \vec{y} + \vec{x}$  (komutativnost)
- $\vec{x} + (\vec{y} + \vec{z}) = (\vec{x} + \vec{y}) + \vec{z}$  (asociativnost)
- obstaja en sam nenicelni vektor  $\vec{0}$ , da velja  $\vec{x} + \vec{0} = \vec{x}$
- za vsak  $\vec{x}$  obstaja natanko en  $-\vec{x}$ , da je  $\vec{x} + (-\vec{x}) = \vec{0}$
- $1 \cdot \vec{x} = \vec{x}$
- $(\alpha\beta)\vec{x} = \alpha(\beta\vec{x})$
- $\alpha(\vec{x} + \vec{y}) = \alpha\vec{x} + \alpha\vec{y}$  (distributivnost)
- $(\alpha + \beta)\vec{x} = \alpha\vec{x} + \beta\vec{x}$

**3.2** Podmnožica U vektorskega prostora V je *vektorski podprostor*, ce je za vsak par vektorjev  $\vec{x}$  in  $\vec{y}$  iz U in vsako realno število  $\alpha$  tudi

- $\vec{x} + \vec{y} \in U$  in
- $\alpha \vec{x} \in U$ .

**3.3** Množica vektorjev U je vektorski podprostor natanko tedaj, ko je vsaka linearna kombinacija vektorjev iz U tudi v U.

**Lastnosti vektorskih podprostorov**

- Vsak vektorski podprostor nujno vsebuje nicelni vektor  $\vec{0}$
- Presek dveh podprostorov vektorskega podprostora je tudi podprostor

**3.4** Stolpčni prostor  $C(A)$  matrike  $A \in R^{m \times n}$  je tisti podprostor vektorskega prostora  $R^m$ , ki vsebuje natanko vse linearne kombinacije stolpcev matrike A.

Izracunamo ga tako, da matriko A transponiramo in izvedemo operacijo gaussove eliminacije nad  $A^T$ . Vrstice katere ostanejo po gaussovi eliminaciji so linearno neodvisni vektorji, kateri tvorijo stolpčni prostor matrike A,  $C(A)$ . *neformalno: linearna ogrinjaca stolpcev matrike (npr. ce imas 5 stolpcev pa lahko 2 zapises kot linearno kombinacijo ostalih 3 bo imel column space 3 elemente)*

**3.5** Sistem linearnih enačb  $A\vec{x} = \vec{b}$  je resljiv natanko tedaj, ko je vektor  $\vec{b} \in C(A)$

**3.6** Naj bo matrika  $A \in R^{m \times n}$ . Množica resitev homogenega sistema linearnih enačb je podprostor v vektorskem prostoru  $R^n$ .

**3.7** Mnozica vseh resitev sistema linearnih enacb  $A\vec{x} = \vec{0}$  se imenuje nicelni prostor matirke A. Označujemo ga z  $N(A)$ .

*neformalno: množica vektorjev, ki se z neko matriko zmnožijo v nicelni vektor. Matriko A samo eliminiras po gaussu in nato dobljene resitve enacis z 0.*

**3.8** Če je matrika A kvadratna in obrnljiva, potem  $N(A)$  vsebuje samo vektor  $\vec{0}$

**3.9** Matrika ima *stopnicasto* obliko, kadar se vsaka od njenih vrstic zacne z vsaj eno niclo vec kot prejsnja vrstica.

**3.10** Prvi element, razlicen od nic v vsaki vrstici, je *pivot*. Stevilo pivotov v matriki se imenuje rang matrike. Rang matrike A zapisemo kot  $rang(A)$ .

**3.11** Rang matrike ni vecji od stevila vrstic in ni vecji od stevila stolpcev matrike.

**3.12**

*Stevilo prostih neznank matrike = st. stolpcev - rang matrike*

**3.13**

1. Visoka in ozka matrika ( $m > n$ ) ima poln stolpicni rang, kadar je  $rang(A) = n$

2. Nizka in siroka matrika ( $m < n$ ) ima poln vrsticni rang, kadar je  $rang(A) = m$

3. Kvadratna matrika ( $n = m$ ) ima poln rang, kadar je  $rang(A) = m = n$

**3.14** Za vsako matriko A s polnim stolpicnim rangom  $r = n \leq m$ , velja:

1. Vsi stolpci A so pivotni stolpci

2. Sistem enacb  $A\vec{x} = \vec{0}$  nima prostih neznank, zato tudi nima posebnih resitev

3. Nicelni prostor  $N(A)$  vsebuje le nicelni vektor  $N(A) = \{\vec{0}\}$

4. Kadar ima sistem enacb  $A\vec{x} = \vec{b}$  resitev(kar ni vedno res!), je resitev ena sama

5. Reducirana vrsticna oblika matrike (A) se da zapisati kot

$$R = \begin{bmatrix} I \\ 0 \end{bmatrix} \begin{bmatrix} n \times n \text{ enotska matrika} \\ m - n \text{ vrstic samih nicel} \end{bmatrix}$$

**3.15** Za vsako matriko A s polnim vrsticnim rangom  $r = m \leq n$  velja:

1. Vse vrstice so pivotne, ni prostih vrstic in U (stopnicasta oblika) in R(reducirana stopnicasta oblika) nimata nicelnih vrstic

2. Sistem enacb  $A\vec{x} = \vec{b}$  je resljiv za vsak vektor  $\vec{b}$

3. Sistem  $A\vec{x} = \vec{b}$  ima  $n - r = n - m$  prostih neznank, zato tudi prav toliko posebnih resitev

4. Stolpicni prostor  $C(A)$  je ves prostor  $R^m$

**3.16** Za vsako kvadratno matriko A polnega ranga ( $rang(A) = m = n$ ) velja:

1. Reducirana vrsticna oblika matrike A je enotska matrika

2. Sistem enacb  $A\vec{x} = \vec{b}$  ima natančno eno resitev za vsak vektor desnih strani  $\vec{b}$

3. Matrika A je obrnljiva

4. Nicelni prostor matrike A je samo nicelni vektor  $N(A) = \{\vec{0}\}$

5. Stolpicni prostor matrike A je cel prostor  $C(A) = R^m$

**3.17** Vektorji  $\vec{x}_1, \dots, \vec{x}_n$  so linearno neodvisni, ce je

$$0\vec{x}_1 + 0\vec{x}_2 + \dots + 0\vec{x}_n$$

edina njihova linearna kombinacija, ki je enaka vektorju  $\vec{0}$ . Vektorji  $\vec{x}_1, \dots, \vec{x}_n$  so linearno odvisni, ce niso linearno neodvisni.

**3.18** Ce so vektorji *odvisni*, lahko vsaj enega izrazimo z ostalimi.

**3.19** Ce je med vektorji  $\vec{u}_1, \dots, \vec{u}_n$  tudi nicelni vektor, so vektorji *linearno odvisni*.

**3.20** Vsaka množica n vektorjev iz  $R^n$  je odvisna, kadar je  $n > m$ .

**3.21** Stolpci matrike A so linearno neodvisni natanko tedaj, ko ima homogena enacba  $A\vec{x} = \vec{0}$  edino resitev  $\vec{x} = \vec{0}$ .

**3.22** Kadar je  $rang(A) = n$ , so stolpci matrike  $A \in R^{m \times n}$  linearno neodvisni. Kadar je pa  $rang(A) < n$ , so stolpci matrike  $A \in R^{m \times n}$  linearno odvisni.

**3.23** Kadar je  $rang(A) = m$ , so vrstice matrike  $A \in R^{m \times n}$  linearno neodvisne. Kadar je pa  $rang(A) < m$ , so vrstice matrike  $A \in R^{m \times n}$  linearno odvisne.

**3.24** Vrsticni prostor matrike A je podprostor v  $R^n$ , ki ga razpenjajo vrstice matrike A.

**3.25** Vrsticni prostor matrike A je  $C(A^T)$ , stolpicni prostor matrike  $A^T$ .

**3.26** Baza vektorskega prostora je množica vektorjev, ki

1. je linearno neodvisna in

2. napenja cel prostor.

**3.27** Vsak vektor iz vektorskega prostora lahko na en sam način izrazimo kot linearno kombinacijo baznih vektorjev.

**3.28** Vektorji  $\vec{x}_1, \dots, \vec{x}_n$  so baza prostora  $R^n$  natanko tedaj, kadar je matrika, sestavljena iz stolpcev  $\vec{x}_1, \dots, \vec{x}_n$ , obrnljiva.

**3.29** Prostor  $R^n$  ima za  $n > 0$  neskončno mnogo razlicnih baz.

**3.30** Ce sta množici vektorjev  $\vec{v}_1, \dots, \vec{v}_m$  in  $\vec{u}_1, \dots, \vec{u}_n$  obe bazi istega vektorskega prostora, potem je  $m = n \implies$  vse baze istega vektorskega prostora imajo isto stevilo vektorjev.

**3.31** Dimenzija vektorskega prostora je stevilo baznih vektorjev.

**3.32** Dimenziji stolpicnega prostora  $C(A)$  in vrsticnega prostora  $C(A^T)$  sta enaki rangu matrike A

$$\dim(C(A)) = \dim(C(A^T)) = rang(A).$$

**3.33** Dimenzija nicelnega prostora  $N(A)$  matrike A z n stolpci in ranga r je enaka  $\dim(N(A)) = n - r$ .

**3.34** Stolpicni prostor  $C(A)$  in vrsticni prostor  $C(A^T)$  imata oba dimenzijo r. Dimenzija nicelnega prostora  $N(A)$  je  $n - r$ , Dimenzija levega nicelnega prostora  $N(A^T)$  pa je  $m - r$ .

**3.35** Vsako matriko ranga 1 lahko zapisemo kot produkt(stolpcnega) vektorja z vrsticnim vektorjem  $A = \vec{u}\vec{v}^T$ .

## 4 Linearne preslikave

**4.1** Preslikava  $A : U \rightarrow V$  je linearna, ce velja

1. aditivnost:  $A(\vec{u}_1 + \vec{u}_2) = A\vec{u}_1 + A\vec{u}_2$  za vse  $\vec{u}_1, \vec{u}_2 \in U$ ,

2. homogenost:  $A(\alpha\vec{u}) = \alpha(A\vec{u})$  za vse  $\alpha \in R$  in  $\vec{u} \in U$ .

Oziroma v enem koraku:

$$A(\alpha\vec{u}_1 + \beta\vec{u}_2) = \alpha A(\vec{u}_1) + \beta A(\vec{u}_2).$$

**Pozor!** Preslikava ni linearna, ce  $A(\vec{0}) \neq \vec{0}$ .

**4.2** Preslikava  $A : U \rightarrow V$  je linearna natanko tedaj, ko velja

$$A(\alpha_1\vec{u}_1 + \alpha_2\vec{u}_2) = \alpha_1 A\vec{u}_1 + \alpha_2 A\vec{u}_2$$

za vse  $\alpha_1, \alpha_2 \in R$  in vse  $\vec{u}_1, \vec{u}_2 \in U$ .

**4.3** Če je  $A$  linearna preslikava, je  $A\vec{0} = \vec{0}$ .

**4.4** Naj bo  $A : U \rightarrow V$  linearna preslikava in  $\sum_{i=1}^k \alpha_i \vec{u}_i$  linearna kombinacija vektorjev. Potem je  $A(\sum_{i=1}^k \alpha_i \vec{u}_i) = \sum_{i=1}^k \alpha_i A\vec{u}_i$ .

**4.5** Naj bo  $\beta = \{\vec{u}_1, \dots, \vec{u}_n\}$  baza za vektorski prostor  $U$ . Potem je linearna preslikava  $A : U \rightarrow V$  natanko določena, če poznamo slike baznih vektorjev.

**4.6** Naj bo  $\beta = \{\vec{u}_1, \dots, \vec{u}_n\}$  baza za  $U$  in  $\{\vec{v}_1, \dots, \vec{v}_n\}$ . Potem obstaja natanko ena linearna preslikava  $A : U \rightarrow V$ , za katero je  $A\vec{u}_i = \vec{v}_i$  za  $i = 1, 2, \dots, n$ .

**4.7** Naj bo  $A : U \rightarrow V$  linearna preslikava. Potem množico

$$\ker A = \{\vec{u} \in U; A\vec{u} = \vec{0}\}$$

imenujemo *jedro* linearne preslikave. Ker je  $A\vec{0} = \vec{0}$ , je  $\vec{0} \in \ker A$  za vse  $A$ . Zato je jedro vedno neprazna množica. Če je matrika  $A$  *enotska preslikava* za  $\phi$ , potem velja

$$\ker \phi = N(A).$$

**4.8** Jedro linearne preslikave  $A : U \rightarrow V$  je vektorski podprostor v  $U$ .

**4.9** Množico

$$\text{im } A = \{\vec{v} \in V; \text{obstaja tak } \vec{u} \in U, \text{ da je } \vec{v} = A\vec{u}\}$$

imenujemo *slika* linearne preslikave  $A : U \rightarrow V$ . Če je matrika  $A$  *enotska preslikava* za  $\phi$ , potem velja

$$\text{im } \phi = C(A).$$

**4.10** Če je  $A : U \rightarrow V$  linearna preslikava, potem je njena slika *im*  $A$  vektorski podprostor v  $V$ .

**4.11** Če je  $A : U \rightarrow V$  linearna preslikava, in je rang matrike te preslikave v standardni bazi poln, potem lahko sklepamo, da ima ta preslikava **trivialno jedro**.

## 5 Ortogonalnost

**5.1** Podprostora  $U$  in  $V$  vektorskega prostora sta med seboj ortogonalna, če je vsak vektor  $\vec{u} \in U$  ortogonalen na vsak vektor  $\vec{v} \in V$ .

**5.2** Za vsako matriko  $A \in R^{m \times n}$  velja:

- Nicelni prostor  $N(A)$  in vrstični prostor  $C(A^T)$  sta ortogonalna podprostora  $R^n$
- Levi nicelni prostor  $N(A^T)$  in stolpčni prostor  $C(A)$  sta ortogonalna podprostora prostora  $R^m$ .

**5.3** Ortogonalni komplement  $V^\perp$  podprostora  $V$  vsebuje VSE vektorje, ki so ortogonalni na  $V$ .

**5.4** Naj bo  $A$  matrika dimenzije  $m \times n$ .

- Nicelni prostor  $N(A)$  je ortogonalni komplement vrstičnega prostora  $C(A^T)$  v prostoru  $R^n$
- Levi nicelni prostor  $N(A^T)$  je ortogonalni komplement stolpčnega prostora  $C(A)$  v prostoru  $R^m$ .

**krajše:**

$$N(A) = C(A^T)^\perp \\ N(A^T) = C(A)^\perp$$

tukaj lahko vedno pomnožimo s komplementom, da dobimo npr.

$$N(A)^\perp = C(A^T)$$

**dodatek:**

$$\dim N(A) = \text{st.stolpcev} - \text{rang}(A) \\ \dim N(A^T) = \text{st.vrstic} - \text{rang}(A) \\ \dim C(A) = \dim C(A^T) = \text{rang}(A)$$

**5.5** Za vsak vektor  $\vec{y}$  v stolpčnem prostoru  $C(A)$  obstaja v vrstičnem prostoru  $C(A^T)$  en sam vektor  $\vec{x}$ , da je  $A\vec{x} = \vec{y}$ .

**5.6** Če so stolpci matrike  $A$  linearno neodvisni, je matrika  $A^T A$  obrnljiva.

**5.7** Matrika  $P$  je projekcijska, kadar

- je simetrična:  $P^T = P$  in
- velja  $P^2 = P$ .

**5.8** Če je  $P$  projekcijska matrika, ki projicira na podprostor  $U$ , potem je  $I - P$  projekcijska matrika, ki projicira na  $U^\perp$ , ortogonalni komplement podprostora  $U$ .

**5.9** Vektorji  $\vec{q}_1, \vec{q}_2, \dots, \vec{q}_n$  so ortonormirani kadar so ortogonalni in imajo vsi dolžino 1, torej

$$\vec{q}_i^T \vec{q}_j = \begin{cases} 0 & \text{ko je } i \neq j \text{ pravokotni vektorji} \\ 1 & \text{ko je } i = j \text{ enotski vektorji} \end{cases}$$

za matriko  $Q = [\vec{q}_1, \vec{q}_2, \dots, \vec{q}_n]$  velja  $Q^T Q = I$ .

**5.10** Vektorji  $\vec{q}_1, \dots, \vec{q}_n$  naj bodo ortonormirani v prostoru  $R^m$ . Potem za matriko

$$Q = [\vec{q}_1 \vec{q}_2 \dots \vec{q}_n]$$

velja, da je  $Q^T Q = I_n$  enotska matrika reda  $n$ .

**5.11** Matrika  $Q$  je ortogonalna, kadar je

- kvadratna in
- ima ortonormirane stolpce.

**5.12** Če je  $Q$  ortogonalna matrika, potem je obrnljiva in

$$Q^{-1} = Q^T \\ \dim U^\perp = n - \dim U \\ (U^\perp)^\perp = U$$

**5.13** Množenje z ortogonalno matriko ohranja dolžino vektorjev in kote med njimi. Če je  $Q$  ortogonalna matrika, potem je

$$\|Q\vec{x}\| = \|\vec{x}\| \text{ za vsak vektor } \vec{x} \text{ in} \\ (Q\vec{x})^T Q\vec{y} = \vec{x}^T \vec{y} \text{ za vsak vektor } \vec{x} \text{ in } \vec{y}$$

**5.14** Če sta  $Q_1$  in  $Q_2$  ortogonalni matriki, je tudi produkt  $Q = Q_1 Q_2$  ortogonalna matrika.

**5.15 Gram-Schmidtova** ortogonalizacija. Za vhod uporabimo linearno ogrinjaco linearno neodvisnih vektorjev. Po gram-schmidtovi ortogonalizaciji pa dobimo paroma ortogonalne vektorje. Postopek:

$$\vec{u}_1 = \vec{v}_1 \\ \vec{u}_2 = \vec{v}_2 - \text{proj}_{\vec{u}_1} \vec{v}_2 \\ \vec{u}_3 = \vec{v}_3 - \text{proj}_{\vec{u}_1} \vec{v}_3 - \text{proj}_{\vec{u}_2} \vec{v}_3 \\ \vdots$$

Po tem postopku dobimo paroma ortogonalne vektorje po Gram-Schmidtovi ortogonalizaciji.

**5.16 QR Razcep:** Iz linearno neodvisnih vektorjev  $a_1, \dots, a_n$  z Gram-Schmidtovo ortogonalizacijo dobimo ortonormirane vektorje  $q_1, \dots, q_n$ . Matriki  $A$  in  $Q$  s temi stolpci zadoscajo enačbi  $A = QR$ , kjer je  $R$  zgornjetrikotna matrika.

- Najprej z Gram-Schmidtovo ortogonalizacijo poiscemo linearno neodvisne vektorje matrike  $A$
- Vektorje normiramo in jih zapisemo v matriko  $Q$ .
- Matriko  $R$  dobimo tako, da matriko  $Q^T$  pomnožimo z matriko  $A$

$$R = Q^T A$$

Tako smo prisli do vseh elementov v QR razcepu matrike A.

$$\det(A) = \pm \det(U).$$

Sedaj ko imamo izračunane vse elemente lahko zapisemo se projekcijsko matriko. To je matrika pravokotne projekcije na  $C(Q) = C(A)$ . Njen izračun je preprost:

$$QQ^T = \text{pravokotna projekcija na } C(Q) = C(A)$$

Sedaj lahko to projekcijsko matriko pomnožimo z desne s poljubnim vektorjem in ugotovimo kam se preslika v prostoru  $C(A)$ . V nasprotnem primeru, ce bi pa zeleli imeti projekcijsko matriko, s katero bi radi videli kam se vektor preslika v prostoru  $N(A^T)$ , bi pa od identične matrike odsteli projekcijsko matriko za  $C(Q)$ .

$$I - QQ^T = \text{pravokotna projekcija na } C(A)^\perp = N(A^T)$$

**5.17** Vektorski prostor  $\iota$  je množica vseh neskončnih zaporedij  $\vec{u}$  s koncno dolžino

$$\|\vec{u}\|^2 = \vec{u} \cdot \vec{u} = u_1^2 + u_2^2 + \dots < \infty$$

### 5.18 Predoloceni sistemi

$$A^T A \begin{bmatrix} a \\ b \end{bmatrix} = A^T \vec{f}$$

Kjer je A matrika sistemov linearnih enacb in  $\vec{f}$  vektor pričakovanih resitev po gaussovi eliminaciji zgornje enacbe, dobimo spremenljivke, ki predstavljajo najboljšo aproksimacijo vseh kombinacij rezultatov in vhodnih spremenljivk.

## 6 Determinante

**6.1** Determinanta enotske matirke je  $\det(I) = 1$ .

$$\begin{vmatrix} 1 & 0 \\ 0 & 1 \end{vmatrix} = 1 \text{ in } \begin{vmatrix} 1 & & 0 \\ & \ddots & \\ 0 & & 1 \end{vmatrix} = 1.$$

**6.2** Determinanta spremeni predznak, ce med seboj zamenjamo dve vrstici.

**6.3** Determinanta je linearna funkcija vsake vrstice posebej. To pomeni, da se

1. determinanta pomnoži s faktorjem t, ce eno vrstico determinante (vsak element v tej vrstici) pomnožimo s faktorjem t.

$$\begin{vmatrix} ta & tb \\ c & d \end{vmatrix} = t \begin{vmatrix} a & b \\ c & d \end{vmatrix}$$

2. determinanta je vsota dveh determinant, ki se razlikujeta le v eni vrstici, ce je v prvotni determinanti ta vrstica vsota obeh vrstic, ostale vrstice pa so enake v vseh treh determinantah.

$$\begin{vmatrix} a + a' & b + b' \\ c & d \end{vmatrix} = \begin{vmatrix} a & b \\ c & d \end{vmatrix} + \begin{vmatrix} a' & b' \\ c & d \end{vmatrix}$$

**Pozor!** Kadar množimo matriko A s skalarjem t, se vsak element matrike pomnoži s skalarjem. Ko računamo determinanto produkta matirke s skalarjem tA, skalar t izpostavimo iz vsake vrstice posebej, zato je  $\det(tA) = t^n \det(A)$ , kjer je n število vrstic (ali stolpcev) determinante.

**6.4** Matrika, ki ima dve enaki vrstici, ima determinanto enako 0.

**6.5** Ce v matriki od poljubne vrstice odštejemo mnogokratnik neke druge vrstice, se njena determinanta ne spremeni.

**6.6** Naj bo A poljubna kvadratna matirka  $n \times n$  in U njena vrsticno-stopnicasta oblika, ki jo dobimo z *Gaussovo eliminacijo*. Potem je

**6.7** Determinanta, ki ima vrstico samih nicel, je enaka 0.

**6.8** Determinanta trikotne matrike A je produkt diagonalnih elementov:

$$\det(A) = a_{11}a_{22} \dots a_{nn}.$$

**6.9** Determinanta singularne matrike je enaka 0, determinanta obrnljive matrike je različna od 0.

**6.10** Determinanta produkta dveh matrik je enaka produktu determinant obeh matrik:

$$\det(AB) = \det(A)\det(B).$$

**6.11** Determinanta inverzne matrike je enaka

$$\det(A^{-1}) = 1/\det(A)$$

in determinanta potence  $A^n$  matrike A je

$$\det(A^n) = (\det(A))^n$$

ter determinanta transponirane matrike je enaka determinanti originalne matrike, saj ko naredimo razvoj po vrsticah, pridemo do enakih elementov po diagonali.

$$\det(A) = \det(A^T).$$

**6.12** Transponirana matrika  $A^T$  ima isto determinanto kot A.

### 6.13 Recap dovoljenih operacij nad determinanto

1. Ce zamenjamo dve vrstici, se **spremeni** predznak determinante
2. Vrednost determinante se ne spremeni, ce neki vrstici pristejemo poljuben veckratnik katerekoli druge vrstice.
3. Ce vse elemente neke vrstice pomnožimo z istim številom  $\alpha$ , se vrednost determinante pomnoži z  $\alpha$ .

**6.14** Vsaka lastnost, ki velja za vrstice determinante, velja tudi za njene **stolpce**. Med drugim:

- Determinanta spremeni predznak, ce med seboj zamenjamo dva stolpca
- Determinanta je enaka 0, ce sta dva stolpca enaka
- Determinanta je enaka 0, ce so v vsaj enem stolpcu same nicle.

**6.15 (kofaktorska formula)** Ce je A kvadratna matrika reda n, njeno determinanto lahko izračunamo z razvojem po  $i - ti$  vrstici

$$\det(A) = a_{i1}C_{i1} + a_{i2}C_{i2} + \dots + a_{in}C_{in}.$$

Kofaktorje  $C_{ij}$  izračunamo kot  $C_{ij} = (-1)^{i+j}D_{ij}$ , kjer je  $D_{ij}$  determinanta, ki jo dobimo, ce v A izbrisemo i-to vrstico in j-ti stolpec.

**6.16** Inverzna matrika  $A^{-1}$  matrike A je transponirana matrika kofaktorjev, deljena z determinanto |A|:

$$A^{-1} = \frac{C^T}{\det(A)},$$

kjer je C matrika kofaktorjev matrike A.

**6.17** Ploscina paralelograma, dolocenega z vektorjema  $\vec{a}$  in  $\vec{b} \in R^2$  je enaka  $\det([\vec{a}\vec{b}])$ , to je absolutni vrednosti determinante s stolpcema  $\vec{a}$  in  $\vec{b}$ .

**6.18** Mesani produkt vektorjev  $\vec{a}$  in  $\vec{b}$  in  $\vec{c}$  je enak determinanti matrike, ki ima te tri vektorje kot stolpce.

**6.19** Naj bo A matrika  $R^{n \times n}$

$$A \text{ je obrnljiva} \iff \det A \neq 0$$

$$A^{-1} \text{ ne obstaja} \iff \det A = 0$$

## 7 L. vrednosti in vektorji

**7.1** Vektor  $\vec{x} \neq \vec{0}$ , za katerega je  $A\vec{x} = \lambda\vec{x}$  lastni vektor. Stevilo  $\lambda$  je lastna vrednost. **Pozor!** Nicelni vektor  $\vec{0}$  ne more biti lastni vektor. Lahko pa je lastna vrednost enaka 0.

**7.2** Če ima matrika  $A$  lastno vrednost  $\lambda$  in lastni vektor  $\vec{x}$ , potem ima matrika  $A^2$  lastno vrednost  $\lambda^2$  in isti lastni vektor  $\vec{x}$ .

**7.3** Če ima matrika  $A$  lastno vrednost  $\lambda$  in lastni vektor  $\vec{x}$ , potem ima matrika  $A^k$  lastno vrednost  $\lambda^k$  in isti lastni vektor  $\vec{x}$ .

**7.4** Če ima matrika  $A$  lastno vrednost  $\lambda$  in lastni vektor  $\vec{x}$ , potem ima inverzna matrika lastno vrednost  $1/\lambda$  in isti lastni vektor  $\vec{x}$ .

**7.5** Sled kvadratne matrike  $A$  reda  $n$  je vsota njenih diagonalnih elementov.

$$\text{sled}(A) = \sum_{i=1}^n a_{ii} = a_{11} + \dots + a_{nn}.$$

**7.6** Sled matrike je enaka vsoti vseh lastnih vrednosti, steti z njihovo večkratnostjo. Če so  $\lambda_1, \dots, \lambda_n$  lastne vrednosti matrike reda  $n$ , potem je sled enaka vsoti

$$\text{sled}(A) = \sum_{i=1}^n \lambda_i = \lambda_1 + \dots + \lambda_n,$$

determinanta matrike pa produktu lastnih vrednosti

$$\det(A) = \prod_{i=1}^n \lambda_i = \lambda_1 \dots \lambda_n.$$

**7.7** Če ima matrika  $A$  lastno vrednost  $\lambda$ , ki ji pripada lastni vektor  $\vec{x}$ , potem ima matrika  $A + cI$  lastno vrednost  $\lambda + c$  z istim lastnim vektorjem  $\vec{x}$  (velja samo z enotskimi matrikami  $I$ ).

**7.8** Lastne vrednosti trikotne matrike so enake diagonalnim elementom.

**7.9** Denimo, da ima matrika  $A \in R^{n \times n}$   $n$  linearno neodvisnih lastnih vektorjev  $\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n$ . Če jih zložimo kot stolpce v matriko  $S$

$$S = [\vec{x}_1, \vec{x}_2, \dots, \vec{x}_n],$$

potem je  $T = S^{-1}AS$  diagonalna matrika z lastnimi vrednostmi  $\lambda_i, i = 1, \dots, n$  na diagonalni

$$S^{-1}AS = T = \begin{bmatrix} \lambda_1 & & \\ & \ddots & \\ & & \lambda_n \end{bmatrix}.$$

**Pozor!** Lastni vektorji v matriki  $S$  morajo biti v istem vrstnem redu kot lastne vrednosti v matriki  $T$ .

**7.10** Če je  $A = STS^{-1}$ , potem je  $A^k = ST^kS^{-1}$  za vsak  $k \in N$ .

**7.12** Vse lastne vrednosti realne simetrične matrike so realne.

**7.13** Lastni vektorji realne simetrične matrike, ki pripadajo različnim lastnim vrednostim, so med seboj pravokotni.

**7.14 Schurov izrek** Za vsako kvadratno matriko reda  $n$ , ki ima le realne lastne vrednosti, obstaja taka ortogonalna matrika  $Q$ , da je

$$Q^T A Q = T$$

zgornjetrikotna matrika, ki ima lastne vrednosti (lahko so kompleksne) matrike  $A$  na diagonalni.

**7.15 Spektralni izrek** Vsako simetrično matriko  $A$  lahko razcepimo v produkt  $A = Q T Q^T$ , kjer je  $Q$  ortogonalna matrika lastnih vektorjev,  $T$  pa diagonalna z lastnimi vrednostmi matrike  $A$  na diagonalni.

**7.16** Vsako realno simetrično matriko lahko zapisemo kot linearno kombinacijo matrik ranga 1

$$A = \lambda_1 \vec{q}_1 \vec{q}_1^T + \lambda_2 \vec{q}_2 \vec{q}_2^T + \dots + \lambda_n \vec{q}_n \vec{q}_n^T,$$

kjer so  $\vec{q}_i$  stolpci matrike  $Q$  (torej lastni vektorji matrike  $A$ ).

**7.17** Za simetrično nesingularno matriko  $A$  je število pozitivnih pivotov enako številu pozitivnih lastnih vrednosti.

**7.18** Kvadratna matrika je pozitivno definirana, kadar so vse njene lastne vrednosti pozitivne.

**7.19** Kvadratna matrika reda 2 je pozitivno definirana natanko tedaj, kadar sta pozitivni sled in determinanta matrike.

**7.20** Simetrična matrika  $A$  reda  $n$  je pozitivno definirana natanko tedaj, ko je za vsak vektor  $\vec{x} \neq \vec{0} \in R^n$

$$\vec{x}^T A \vec{x} > 0$$

**7.21** Če sta matriki  $A$  in  $B$  pozitivno definitni, je pozitivno definitna tudi njuna vsota  $A + B$ .

**7.22** Matrika  $A$  je pozitivno definitna, kadar so vse njene vodilne glavne poddeterminante pozitivne.

**7.23** Če so stolpci matrike  $R$  linearno neodvisni, je matrika  $A = R^T R$  pozitivno definitna.

**7.24** Za vsako simetrično pozitivno definitno matriko  $A$  obstaja zgornjetrikotna matrika  $R$ , da je  $A = R^T R$ .

**7.25** Simetrična matrika reda  $n$ , ki ima eno od spodnjih lastnosti, ima tudi ostale štiri:

1. Vseh  $n$  pivotov je pozitivnih;
2. Vseh  $n$  vodilnih glavnih determinant je pozitivnih;
3. Vseh  $n$  lastnih vrednosti je pozitivnih;
4. Za vsak  $\vec{x} \neq \vec{0}$  je  $\vec{x}^T A \vec{x} > 0$ ;
5.  $A = R^T R$  za neko matriko  $R$  z linearno neodvisnimi stolpci.

**7.26** Vsako realno  $m \times n$  matriko  $A$  lahko zapisemo kot produkt  $A = U E V^T$ , kjer je matrika  $U$  ortogonalna  $m \times m$ ,  $E$  diagonalna  $m \times n$  in  $V$  ortogonalna  $n \times n$ .

**7.27** Če je matrika  $A$  simetrična in so vsej njeni elementi realni, potem je njen rang enak številu nenicelnih lastnih vrednosti matrike  $A$ .

$$\text{rang}(A) = \text{število } \lambda A$$

**7.28 Diagonalizacija oz podobnost** matrik. Matriki  $A$  in  $B$  sta podobni, ce imata obe iste lastne vrednosti. Diagonalno matriko sestavimo tako, da v njeno diagonalo vpisemo lastne vrednosti. Matriko  $P$  pa sestavimo iz njenih lastnih vektorjev; po stolpcih.

$$A = P D P^{-1} \text{ oz. } D = P^{-1} A P$$

**7.29 Spektralni razcep** Naj bodo vektorji  $\vec{q}_1, \dots, \vec{q}_n$  ONB iz 1. vektorjev matrike  $A$  za l. vrednost  $\lambda_1, \dots, \lambda_n$ , potem lahko matriko  $A$  zapisemo kot:

$$A = \lambda_1 \vec{q}_1 \vec{q}_1^T + \dots + \lambda_n \vec{q}_n \vec{q}_n^T$$

### 7.30 Nekaj lastnosti simetričnih matrik

- Vse lastne vrednosti simetrične matrike so realne. Lastni vektorji realne simetrične matrike, ki pripadajo različnim lastnim vrednostim, so med seboj pravokotni.
- Vsako realno simetrično matriko  $A$  lahko zapisemo kot  $A = Q D Q^T$ , kjer je  $Q$  ortogonalna matrika lastnih vektorjev,  $D$  pa diagonalna matrika, ki ima na diagonalni pripadajoče lastne vrednosti matrike  $A$ .