

Lineární prostory nad \mathbb{R}

Odpřednesenou látku naleznete v kapitolách 1.1–1.4 skript *Abstraktní a konkrétní lineární algebra*.

Co je definice?

Co je hypotéza?

Co je (matematická) věta? Lemma? Tvrzení?

Co je důkaz?

Více např. v textech

- ① J. Velebil, *Velmi jemný úvod do matematické logiky*
- ② J. Velebil, *Sbírka problémů z lineární algebry*

Neformálně

Lineární prostor (nad \mathbb{R}) je kolekce **jakýchkoli** objektů (těm budeme říkat **vektory**), které mezi sebou můžeme sčítat a každý z nich můžeme vynásobit **skalárem** (v našem případě prvkem \mathbb{R}). Sčítání vektorů a násobení skalárem se musí **řídit jistými zákonitostmi**.

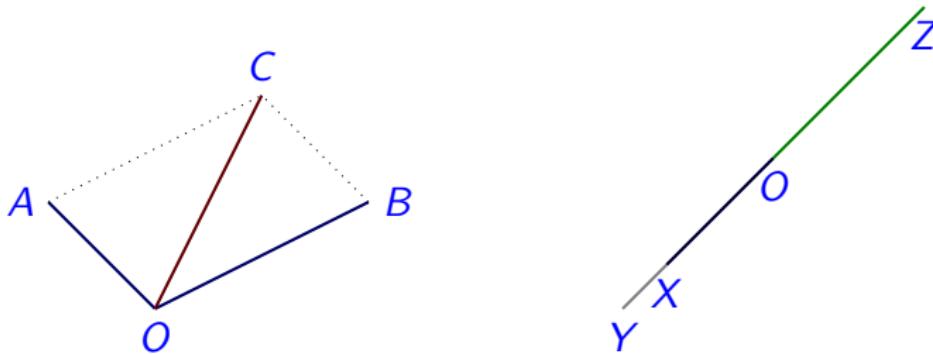
Příklady

- ① Vektory v rovině (fyzikální, případně geometrická intuice).
- ② Reálné polynomy (značení: $\mathbb{R}[x]$).
- ③ n -tice reálných čísel (značení: \mathbb{R}^n , $n \geq 0$).^a
- ④ Komplexní čísla (značení: \mathbb{C}).
- ⑤ Řada dalších příkladů...

^aDůležité: Prvky \mathbb{R}^n budeme psát jako n -tice **do sloupců**.

Příklad (orientované úsečky v rovině)

Dvě operace:



sčítání: $OC = OA + OB$

násobení skalárem: $OY = \sqrt{2} \cdot OX$, $OZ = -\sqrt{2} \cdot OX$

Sčítání orientovaných úseček a násobení orientované úsečky reálným skalárem splňují jisté axiomy.

Definice (lineární prostor nad \mathbb{R})

Lineární prostor (nad \mathbb{R}) je množina L spolu se dvěma funkcemi

$$+ : L \times L \rightarrow L, \quad \cdot : \mathbb{R} \times L \rightarrow L$$

pro které platí následující:

1 Vlastnosti sčítání:

- ① Existuje $\vec{o} \in L$ tak, že pro vš. $\vec{x} \in L$ platí: $\vec{x} + \vec{o} = \vec{o} + \vec{x} = \vec{x}$ (**existence nulového vektoru**).
- ② Pro vš. $\vec{x}, \vec{y}, \vec{z} \in L$ platí: $(\vec{x} + \vec{y}) + \vec{z} = \vec{x} + (\vec{y} + \vec{z})$ (**asociativita sčítání vektorů**).
- ③ Pro vš. $\vec{x}, \vec{y} \in L$ platí: $\vec{x} + \vec{y} = \vec{y} + \vec{x}$ (**komutativita sčítání vektorů**).
- ④ Pro vš. $\vec{x} \in L$ existuje právě jeden $\vec{y} \in L$ tak, že $\vec{x} + \vec{y} = \vec{o}$ (**existence opačného vektoru**, značíme $\vec{y} = -\vec{x}$).

Definice (lineární prostor nad \mathbb{R}), pokrač.

② Vlastnosti násobení skalárem:

- ① Pro vš. $\vec{x} \in L$ platí: $1 \cdot \vec{x} = \vec{x}$ (**násobení jednotkovým skalárem**).
- ② Pro vš. $a, b \in \mathbb{R}$ a vš. $\vec{x} \in L$ platí: $a \cdot (b \cdot \vec{x}) = (a \cdot b) \cdot \vec{x}$ (**asociativita násobení skalárem**).

③ Distributivní zákony:

- ① Pro vš. $a, b \in \mathbb{R}$ a vš. $\vec{x} \in L$ platí: $(a + b) \cdot \vec{x} = a \cdot \vec{x} + b \cdot \vec{x}$ (**distributivita součtu skalárů**).
- ② Pro vš. $a \in \mathbb{R}$ a vš. $\vec{x}, \vec{y} \in L$ platí: $a \cdot (\vec{x} + \vec{y}) = a \cdot \vec{x} + a \cdot \vec{y}$ (**distributivita součtu vektorů**).

Poznámka

Axiomy tří typů: chování operace $+$, chování operace \cdot a vzájemný vztah obou operací.

Jednoduché důsledky definice

Ať L je lineární prostor. Potom:

- ① Nulový vektor je jednoznačně určen.
- ② Pro vš. $\vec{x} \in L$ platí: $0 \cdot \vec{x} = \vec{0}$.
- ③ Opačný vektor k $\vec{x} \in L$ je vektor $(-1) \cdot \vec{x}$.
- ④ Pro vš. $a \in \mathbb{R}$ platí: $a \cdot \vec{0} = \vec{0}$.

Důkaz.

- ① Ať existují \vec{o}_1, \vec{o}_2 tak, že pro vš. $\vec{x} \in L$ platí:
 $\vec{x} + \vec{o}_1 = \vec{o}_1 + \vec{x} = \vec{x}$ a $\vec{x} + \vec{o}_2 = \vec{o}_2 + \vec{x} = \vec{x}$. Pak
 $\vec{o}_1 = \vec{o}_1 + \vec{o}_2 = \vec{o}_2$.
- ② Pro vš. $\vec{x} \in L$ platí:
 $\vec{x} = 1 \cdot \vec{x} = (1 + 0) \cdot \vec{x} = 1 \cdot \vec{x} + 0 \cdot \vec{x} = \vec{x} + 0 \cdot \vec{x}$. Tudíž $0 \cdot \vec{x}$ musí být nulový vektor.

Důkaz (pokrač.)

- ③ Platí: $\vec{x} + (-1) \cdot \vec{x} = 1 \cdot \vec{x} + (-1) \cdot \vec{x} = (1 - 1) \cdot \vec{x} = 0 \cdot \vec{x} = \vec{0}$.
- ④ Platí: $a \cdot \vec{0} = a \cdot (0 \cdot \vec{x}) = (a \cdot 0) \cdot \vec{x} = 0 \cdot \vec{x} = \vec{0}$.



Velmi důležitý důsledek definice

Ať L je lineární prostor, $a \in \mathbb{R}$, $\vec{x} \in L$. Pak $a \cdot \vec{x} = \vec{0}$ právě tehdy, když $a = 0$ nebo $\vec{x} = \vec{0}$.

Důkaz.

Díky předchozímu stačí dokázat pouze implikaci zleva doprava.

Ať $a \cdot \vec{x} = \vec{0}$ a $a \neq 0$. Potom existuje a^{-1} . Tudíž

$$\vec{0} = a^{-1} \cdot \vec{0} = a^{-1} \cdot (a \cdot \vec{x}) = (a^{-1} \cdot a) \cdot \vec{x} = 1 \cdot \vec{x} = \vec{x}.$$



Povšimněme si, čeho využívá předchozí tvrzení:

Pro vš. $a \in \mathbb{R}$ platí: a^{-1} existuje, jakmile $a \neq 0$.



Další příklady a protipříklady

- ① $L = (0, +\infty)$. Operace sčítání vektorů: $x \oplus y := x \cdot y$.
Násobení skalárem: $\alpha \odot x := x^\alpha$. Pak L je lineární prostor.
- ② L je jakákoli jednoprvková množina. Pak L (spolu s evidentními operacemi) je lineární prostor. Říkáme mu **triviální lineární prostor**. Nutně: $L = \{\vec{o}\}$.
- ③ $L = \mathbb{R}^2$. Operace: $\begin{pmatrix} a \\ b \end{pmatrix} + \begin{pmatrix} c \\ d \end{pmatrix} := \begin{pmatrix} a+d \\ b+c \end{pmatrix}$,
 $\alpha \cdot \begin{pmatrix} a \\ b \end{pmatrix} := \begin{pmatrix} \alpha a \\ \alpha b \end{pmatrix}$. Nejde o lineární prostor.

Role reálných skalárů

Lze \mathbb{R} nahradit jiným „číselným oborem“?

Se skaláry je třeba umět následující: rozumné sčítání, násobení.

Abstraktní pojem: skaláry musí tvořit strukturu \mathbb{F} , které se říká **těleso**.

To vede k pojmu **lineární prostor nad tělesem \mathbb{F}** . Více v příští přednášce.

Poznámka

Abstrakce v lineární algebře má tedy dva stupně:

- ① Lineární prostor nad \mathbb{R} abstrahuje (například) prostor orientovaných úseček.
- ② Lineární prostor nad \mathbb{F} abstrahuje dále: roli skalárů převezmou prvky tělesa \mathbb{F} .

Jaký nejobecnější výpočet lze v lineárním prostoru vykonat?

- ① Například můžeme sečíst čtyři vektory: $\vec{x} + \vec{y} + \vec{z} + \vec{w}$.
Díky asociativitě sčítání nemusíme psát závorky.
- ② Například můžeme násobek vektoru opět vynásobit: $b \cdot (a \cdot \vec{x})$.
Díky axiomům jde opět o násobek $(b \cdot a) \cdot \vec{x}$.
- ③ Obecněji, můžeme sčítat konečně mnoho násobků vektorů.
To znamená: je-li dán konečný seznam vektorů $(\vec{x}_1, \dots, \vec{x}_n)$ a
konečný seznam skalárů^a (a_1, \dots, a_n) , lze utvořit lineární
kombinaci

$$a_1 \cdot \vec{x}_1 + a_2 \cdot \vec{x}_2 + a_3 \cdot \vec{x}_3 + \dots + a_n \cdot \vec{x}_n$$

značenou i $\sum_{i=1}^n a_i \cdot \vec{x}_i$ nebo $\sum_{i \in \{1, \dots, n\}} a_i \cdot \vec{x}_i$

^aTěmto skalárům říkáme koeficienty lineární kombinace.

Definice

Seznam (také: **skupina**) vektorů je buď prázdná posloupnost () nebo konečná posloupnost $(\vec{x}_1, \dots, \vec{x}_n)$.

Pozor: je rozdíl mezi seznamem a množinou

$$(\vec{x}_1, \vec{x}_2, \vec{x}_3) \neq (\vec{x}_3, \vec{x}_2, \vec{x}_1) \text{ vs. } \{\vec{x}_1, \vec{x}_2, \vec{x}_3\} = \{\vec{x}_3, \vec{x}_2, \vec{x}_1\}$$

$$(\vec{x}_1, \vec{x}_1, \vec{x}_2) \neq (\vec{x}_1, \vec{x}_2) \text{ vs. } \{\vec{x}_1, \vec{x}_1, \vec{x}_2\} = \{\vec{x}_1, \vec{x}_2\}$$

Definice (lineární kombinace konečného seznamu vektorů)

Pro seznam vektorů tvaru

- ① () definujeme \vec{o} jako jeho (jedinou možnou) **lineární kombinaci** (s prázdným seznamem koeficientů).

- ② $(\vec{x}_1, \dots, \vec{x}_n)$ je vektor $\sum_{i=1}^n a_i \cdot \vec{x}_i$ jeho **lineární kombinace** (se seznamem koeficientů (a_1, \dots, a_n)).

Zobecnění předchozího (zatím jen slogan)

Lineární kombinace seznamu $(\mathbf{a}_1, \dots, \mathbf{a}_k)$ v \mathbb{R}^n vytvářejí „rovný kus“ prostoru \mathbb{R}^n .

Tento „rovný kus“ prostoru \mathbb{R}^n prochází počátkem a má směr $(\mathbf{a}_1, \dots, \mathbf{a}_k)$.

Příští přednášky: těmto „rovným kusům“ v \mathbb{R}^n budeme říkat **lineární podprostory** \mathbb{R}^n .

Pochopitelně, v příštích přednáškách budeme pracovat daleko abstraktněji než v \mathbb{R}^n .

Slogan je reklamní heslo!

Na přednášce budeme zmiňovat řadu sloganů. Slogany mají sloužit k intuitivnímu pochopení. Slogany v žádném případě **nemohou nahradit** přesná znění definic, vět, atd.

Lineární prostory nad \mathbb{F}

Odpřednesenou látku naleznete v kapitolách 1.1–1.4 skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

Lineární prostor nad \mathbb{R} jako zobecnění (například) prostoru orientovaných úseček v rovině.

Dnešní přednáška

- ① Těleso \mathbb{F} jako zobecnění reálných čísel.
- ② Lineární prostor nad \mathbb{F} jako zobecnění pojmu lineární prostor nad \mathbb{R} .
- ③ **Důležité:** povšimneme si, že důkazy typicky nesouvisí s konkrétními operacemi; souvisí s pouze s **algebraickými vlastnostmi** těchto operací.^a

Od příště budeme pracovat s lineárními prostory nad obecným tělesem.

^aDo jisté míry je tak dnešní přednáška „kopií“ přednášky předchozí. Algebra dovolí od příště takovou marnotratnost nedopustit.

Sčítání a násobení reálných čísel

Množina reálných čísel \mathbb{R} je vybavena dvěma funkcemi

$$+ : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}, \quad \cdot : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$$

pro které platí následující:

1 Vlastnosti sčítání:

- ① Existuje $0 \in \mathbb{R}$ tak, že pro vš. $a \in \mathbb{R}$ platí: $a + 0 = 0 + a = a$ (**existence nuly**).
- ② Pro vš. $a, b, c \in \mathbb{R}$ platí: $(a + b) + c = a + (b + c)$ (**asociativita sčítání**).
- ③ Pro vš. $a, b \in \mathbb{R}$ platí: $a + b = b + a$ (**komutativita sčítání**).
- ④ Pro vš. $a \in \mathbb{R}$ existuje právě jedno $b \in \mathbb{R}$ tak, že $a + b = 0$ (**existence opačného čísla**, značíme $b = -a$).

Sčítání a násobení reálných čísel (pokrač.)

② Vlastnosti násobení:

- ① Existuje $1 \in \mathbb{R}$ tak, že pro vš. $a \in \mathbb{R}$ platí: $1 \cdot a = a$ (**existence jednotky**).
- ② Pro vš. $a, b, c \in \mathbb{R}$ platí: $a \cdot (b \cdot c) = (a \cdot b) \cdot c$ (**asociativita násobení**).
- ③ Pro vš. $a, b \in \mathbb{R}$ platí: $a \cdot b = b \cdot a$ (**komutativita násobení**).

③ Provázanost sčítání a násobení:

- ① Pro vš. $a, b, c \in \mathbb{R}$ platí: $a \cdot (b + c) = a \cdot b + a \cdot c$ (**levý distributivní zákon**).
- ② Pro vš. $a, b, c \in \mathbb{R}$ platí: $(b + c) \cdot a = b \cdot a + c \cdot a$ (**pravý distributivní zákon**).

④ Test invertibility: pro vš. $a \in \mathbb{R}$ platí: $a \neq 0$ iff existuje a^{-1} .

Poznámka

Výše uvedené vlastnosti byly podstatné pro zavedení pojmu **lineární prostor nad \mathbb{R}** (viz minulou přednášku).



Příklady: další „standardní“ sčítání a násobení

- ➊ Standardní sčítání a násobení racionálních čísel: obě operace na množině \mathbb{Q} **splňují stejné vlastnosti** jako standardní sčítání a násobení na množině \mathbb{R} .
- ➋ Standardní sčítání a násobení komplexních čísel: obě operace na množině \mathbb{C} **splňují stejné vlastnosti** jako standardní sčítání a násobení na množině \mathbb{R} .
- ➌ Standardní sčítání a násobení celých čísel: obě operace na množině \mathbb{Z} **nesplňují stejné vlastnosti** jako standardní sčítání a násobení na množině \mathbb{R} . **Neplatí test invertibility:** například $2 \neq 0$, ale 2^{-1} v \mathbb{Z} **neexistuje!**^a

^aTest invertibility v \mathbb{R} byl v minulé přednášce podstatný! Množinu \mathbb{Z} tedy jako množinu skalárů nebudeme moci použít.

Příklad: „nestandardní“ sčítání a násobení

- ① Množina $\mathbb{Z}_2 = \{0, 1\}$ s operacemi:

| $+$ | 0 | 1 | \cdot | 0 | 1 |
|-----|---|---|---------|---|---|
| 0 | 0 | 1 | 0 | 0 | 0 |
| 1 | 1 | 0 | 1 | 0 | 1 |

- ② Množina $\mathbb{Z}_3 = \{0, 1, 2\}$ s operacemi:

| $+$ | 0 | 1 | 2 | \cdot | 0 | 1 | 2 |
|-----|---|---|---|---------|---|---|---|
| 0 | 0 | 1 | 2 | 0 | 0 | 0 | 0 |
| 1 | 1 | 2 | 0 | 1 | 0 | 1 | 2 |
| 2 | 2 | 0 | 1 | 2 | 0 | 2 | 1 |

Operace na množinách \mathbb{Z}_2 a \mathbb{Z}_3 splňují stejné vlastnosti jako standardní sčítání a násobení na množině \mathbb{R} .

Slogan pro těleso

Těleso \mathbb{F} je kolekce **jakýchkoli** objektů (těm budeme říkat **prvky tělesa \mathbb{F}**), které mezi sebou můžeme sčítat a násobit. Sčítání a násobení v \mathbb{F} splňují stejné vlastnosti jako standardní sčítání a násobení v \mathbb{R} .

Definice (těleso)

Těleso je množina \mathbb{F} , vybavena dvěma funkcemi

$$+ : \mathbb{F} \times \mathbb{F} \rightarrow \mathbb{F}, \quad \cdot : \mathbb{F} \times \mathbb{F} \rightarrow \mathbb{F}$$

pro které platí následující:

① Vlastnosti sčítání:

- ① Existuje $0 \in \mathbb{F}$ tak, že pro vš. $a \in \mathbb{F}$ platí: $a + 0 = 0 + a = a$ (**existence nuly**).
- ② Pro vš. $a, b, c \in \mathbb{F}$ platí: $(a + b) + c = a + (b + c)$ (**asociativita sčítání**).
- ③ Pro vš. $a, b \in \mathbb{F}$ platí: $a + b = b + a$ (**komutativita sčítání**).
- ④ Pro vš. $a \in \mathbb{F}$ existuje právě jedno $b \in \mathbb{F}$ tak, že $a + b = 0$ (**existence opačného čísla**, značíme $b = -a$).



Definice tělesa (pokrač.)

② Vlastnosti násobení:

- ① Existuje $1 \in \mathbb{F}$ tak, že pro vš. $a \in \mathbb{F}$ platí: $1 \cdot a = a$ (**existence jednotky**).
- ② Pro vš. $a, b, c \in \mathbb{F}$ platí: $a \cdot (b \cdot c) = (a \cdot b) \cdot c$ (**asociativita násobení**).
- ③ Pro vš. $a, b \in \mathbb{F}$ platí: $a \cdot b = b \cdot a$ (**komutativita násobení**).

③ Provázanost sčítání a násobení:

- ① Pro vš. $a, b, c \in \mathbb{F}$ platí: $a \cdot (b + c) = a \cdot b + a \cdot c$ (**levý distributivní zákon**).
- ② Pro vš. $a, b, c \in \mathbb{F}$ platí: $(b + c) \cdot a = b \cdot a + c \cdot a$ (**pravý distributivní zákon**).

- ④ **Test invertibility:** pro vš. $a \in \mathbb{F}$ platí: $a \neq 0$ iff existuje a^{-1} .

Příklady

- ① Množiny \mathbb{Q} , \mathbb{R} , \mathbb{C} se standardním sčítáním a násobením **jsou** tělesa.
- ② Množina \mathbb{Z} se standardním sčítáním a násobením **není** těleso.
- ③ Množiny \mathbb{Z}_2 a \mathbb{Z}_3 **jsou** tělesa (sčítáme a násobíme jako zbytky po dělení 2, resp. 3).

Obecněji: množina $\mathbb{Z}_p = \{0, 1, \dots, p - 1\}$, kde p je **prvočíslo**, je těleso, pokud čísla sčítáme a násobíme jako zbytky po dělení p .

Definice (lineární prostor nad tělesem \mathbb{F})

Lineární prostor nad tělesem \mathbb{F} je množina L spolu se dvěma funkcemi

$$+ : L \times L \rightarrow L, \quad \cdot : \mathbb{F} \times L \rightarrow L$$

pro které platí následující:

1 Vlastnosti sčítání:

- ① Existuje $\vec{o} \in L$ tak, že pro vš. $\vec{x} \in L$ platí: $\vec{x} + \vec{o} = \vec{o} + \vec{x} = \vec{x}$ (**existence nulového vektoru**).
- ② Pro vš. $\vec{x}, \vec{y}, \vec{z} \in L$ platí: $(\vec{x} + \vec{y}) + \vec{z} = \vec{x} + (\vec{y} + \vec{z})$ (**asociativita sčítání vektorů**).
- ③ Pro vš. $\vec{x}, \vec{y} \in L$ platí: $\vec{x} + \vec{y} = \vec{y} + \vec{x}$ (**komutativita sčítání vektorů**).
- ④ Pro vš. $\vec{x} \in L$ existuje právě jeden $\vec{y} \in L$ tak, že $\vec{x} + \vec{y} = \vec{o}$ (**existence opačného vektoru**, značíme $\vec{y} = -\vec{x}$).

Definice (lineární prostor nad tělesem \mathbb{F}), pokrač.

2 Vlastnosti násobení skalárem:

- ① Pro vš. $\vec{x} \in L$ platí: $1 \cdot \vec{x} = \vec{x}$ (násobení jednotkovým skalárem).
- ② Pro vš. $a, b \in \mathbb{F}$ a vš. $\vec{x} \in L$ platí: $a \cdot (b \cdot \vec{x}) = (a \cdot b) \cdot \vec{x}$ (asociativita násobení skalárem).

3 Distributivní zákony:

- ① Pro vš. $a, b \in \mathbb{F}$ a vš. $\vec{x} \in L$ platí: $(a + b) \cdot \vec{x} = a \cdot \vec{x} + b \cdot \vec{x}$ (distributivita součtu skalárů).
- ② Pro vš. $a \in \mathbb{F}$ a vš. $\vec{x}, \vec{y} \in L$ platí: $a \cdot (\vec{x} + \vec{y}) = a \cdot \vec{x} + a \cdot \vec{y}$ (distributivita součtu vektorů).

Poznámka

Axiomy tří typů: chování operace $+$, chování operace \cdot a vzájemný vztah obou operací.

Definice je formálně stejná jako pro lineární prostor nad \mathbb{R} . Jediná změna: těleso \mathbb{R} je nahrazeno obecným tělesem \mathbb{F} .

Příklady lineárních prostorů nad obecným tělesem \mathbb{F}

- 1 Prostory \mathbb{F}^n nad \mathbb{F} , $n \geq 1$. Vektory jsou uspořádané n -tice prvků \mathbb{F} , **psané do sloupce**. Skaláry jsou prvky tělesa \mathbb{F} .

Například: v $(\mathbb{Z}_7)^2$ je vektor $\begin{pmatrix} 2 \\ 0 \end{pmatrix}$, v \mathbb{Q}^3 je vektor $\begin{pmatrix} 2.14 \\ -21.7 \\ 12 \end{pmatrix}$,

v \mathbb{C}^2 je vektor $\begin{pmatrix} 2 - 4i \\ \sqrt{3}i \end{pmatrix}$, atd.

- 2 Prostory $\mathbb{F}[x]$ polynomů v neurčité x s koeficienty z tělesa \mathbb{F} . Skaláry jsou prvky tělesa \mathbb{F} , vektory jsou jednotlivé polynomy. Sčítání a násobení je definováno analogicky jako v $\mathbb{R}[x]$.
Například: v $\mathbb{Z}_3[x]$ platí:

$$(2x + 2) + (x + 2) = 1$$

$$(2x + 2) \cdot (x + 2) = 2x^2 + 1$$

Jednoduché důsledky definice

Ať L je lineární prostor. Potom:

- ① Nulový vektor je jednoznačně určen.
- ② Pro vš. $\vec{x} \in L$ platí: $0 \cdot \vec{x} = \vec{o}$.
- ③ Opačný vektor k $\vec{x} \in L$ je vektor $(-1) \cdot \vec{x}$.
- ④ Pro vš. $a \in \mathbb{R}$ platí: $a \cdot \vec{o} = \vec{o}$.

Důkaz.

- ① Ať existují \vec{o}_1, \vec{o}_2 tak, že pro vš. $\vec{x} \in L$ platí:
 $\vec{x} + \vec{o}_1 = \vec{o}_1 + \vec{x} = \vec{x}$ a $\vec{x} + \vec{o}_2 = \vec{o}_2 + \vec{x} = \vec{x}$. Pak
 $\vec{o}_1 = \vec{o}_1 + \vec{o}_2 = \vec{o}_2$.
- ② Pro vš. $\vec{x} \in L$ platí:
 $\vec{x} = 1 \cdot \vec{x} = (1 + 0) \cdot \vec{x} = 1 \cdot \vec{x} + 0 \cdot \vec{x} = \vec{x} + 0 \cdot \vec{x}$. Tedy $0 \cdot \vec{x}$ musí být nulový vektor.

Důkaz (pokrač.)

- ③ Platí: $\vec{x} + (-1) \cdot \vec{x} = 1 \cdot \vec{x} + (-1) \cdot \vec{x} = (1 - 1) \cdot \vec{x} = 0 \cdot \vec{x} = \vec{o}$.
- ④ Platí: $a \cdot \vec{o} = a \cdot (0 \cdot \vec{o}) = (a \cdot 0) \cdot \vec{o} = 0 \cdot \vec{o} = \vec{o}$.



Velmi důležitý důsledek definice

Ať L je lineární prostor, $a \in \mathbb{F}$, $\vec{x} \in L$. Pak $a \cdot \vec{x} = \vec{o}$ právě tehdy, když $a = 0$ nebo $\vec{x} = \vec{o}$.

Důkaz.

Díky předchozímu stačí dokázat pouze implikaci zleva doprava.

Ať $a \cdot \vec{x} = \vec{o}$ a $a \neq 0$. Potom existuje a^{-1} . Tudíž

$$\vec{o} = a^{-1} \cdot \vec{o} = a^{-1} \cdot (a \cdot \vec{x}) = (a^{-1} \cdot a) \cdot \vec{x} = 1 \cdot \vec{x} = \vec{x}.$$



Povšimněme si:

Důkazy jsou stejné, jako v minulé přednášce!

Jaký nejobecnější výpočet lze v lineárním prostoru vykonat?

- ① Například můžeme sečítat čtyři vektory: $\vec{x} + \vec{y} + \vec{z} + \vec{w}$.
Díky asociativitě sčítání nemusíme psát závorky.
- ② Například můžeme násobek vektoru opět vynásobit: $b \cdot (a \cdot \vec{x})$.
Díky axiomům jde opět o násobek $(b \cdot a) \cdot \vec{x}$.
- ③ Obecněji, můžeme sčítat konečně mnoho násobků vektorů.
To znamená: je-li dán konečný seznam vektorů $(\vec{x}_1, \dots, \vec{x}_n)$ a
konečný seznam skalárů^a (a_1, \dots, a_n) , lze utvořit lineární
kombinaci

$$a_1 \cdot \vec{x}_1 + a_2 \cdot \vec{x}_2 + a_3 \cdot \vec{x}_3 + \dots + a_n \cdot \vec{x}_n$$

značenou i $\sum_{i=1}^n a_i \cdot \vec{x}_i$ nebo $\sum_{i \in \{1, \dots, n\}} a_i \cdot \vec{x}_i$

^aTěmto skalárům říkáme koeficienty lineární kombinace.

Definice

Seznam (také: skupina) vektorů je buď prázdná posloupnost () nebo konečná posloupnost $(\vec{x}_1, \dots, \vec{x}_n)$.

Pozor: je rozdíl mezi seznamem a množinou

$$(\vec{x}_1, \vec{x}_2, \vec{x}_3) \neq (\vec{x}_3, \vec{x}_2, \vec{x}_1) \text{ vs. } \{\vec{x}_1, \vec{x}_2, \vec{x}_3\} = \{\vec{x}_3, \vec{x}_2, \vec{x}_1\}$$

$$(\vec{x}_1, \vec{x}_1, \vec{x}_2) \neq (\vec{x}_1, \vec{x}_2) \text{ vs. } \{\vec{x}_1, \vec{x}_1, \vec{x}_2\} = \{\vec{x}_1, \vec{x}_2\}$$

Definice (lineární kombinace konečného seznamu vektorů)

Pro seznam vektorů tvaru

- ① () definujeme \vec{o} jako jeho (jedinou možnou) lineární kombinaci (s prázdným seznamem koeficientů).

- ② $(\vec{x}_1, \dots, \vec{x}_n)$ je vektor $\sum_{i=1}^n a_i \cdot \vec{x}_i$ jeho lineární kombinace (se seznamem koeficientů (a_1, \dots, a_n)).

Příklad (geometrický význam lineární kombinace)

Pro seznam (\mathbf{a}_1) v \mathbb{R}^2

$$\xrightarrow{\hspace{1cm}} \mathbf{a}_1$$

a seznam (2.5) reálných čísel je

$$\xrightarrow{\hspace{1cm}}_{\mathbf{a}_1} 2.5 \cdot \mathbf{a}_1$$

lineární kombinace.


Všechny možné lineární kombinace vektoru \mathbf{a}_1 vytvářejí v \mathbb{R}^2 přímku procházející počátkem (se směrem \mathbf{a}_1).

Příklad (geometrický význam lineární kombinace)

Pro seznam $(\mathbf{a}_1, \mathbf{a}_2)$ v \mathbb{R}^3



a seznam $(2.1, 1.3)$ reálných čísel je



Všechny možné lineární kombinace seznamu $(\mathbf{a}_1, \mathbf{a}_2)$ vytvářejí v \mathbb{R}^3 rovinu procházející počátkem (se směrem $(\mathbf{a}_1, \mathbf{a}_2)$).

Význam lineárních kombinací (zatím jen slogan)

Ať L je lineární prostor nad \mathbb{F} .

Lineární kombinace seznamu $(\vec{x}_1, \dots, \vec{x}_n)$ v L vytvářejí „rovný kus“ prostoru L .

Tento „rovný kus“ prostoru L prochází počátkem \vec{o} a má „směr“ $(\vec{x}_1, \dots, \vec{x}_n)$.

Příští přednáška: těmto „rovným kusům“ v L budeme říkat **lineární podprostory** L .

Příklad (lineární kombinace a soustavy rovnic)

Existují koeficienty $x, y \in \mathbb{Z}_7$ tak, že v $(\mathbb{Z}_7)^2$ platí rovnost

$$x \cdot \begin{pmatrix} 2 \\ 3 \end{pmatrix} + y \cdot \begin{pmatrix} 6 \\ 1 \end{pmatrix} = \begin{pmatrix} 2 \\ 6 \end{pmatrix} \quad ?$$

Dva pohledy na tento problém:

- ① Hledáme prvky $x, y \in \mathbb{Z}_7$ tak, že platí


$$2x + 6y = 2$$

$$3x + 1y = 6$$


To znamená: koeficienty lineární kombinace jsou řešením jisté soustavy lineárních rovnic nad \mathbb{Z}_7 .

Příklad (lineární kombinace a soustavy rovnic, pokrač.)

- 2 Pro zadané vektory


$$\begin{pmatrix} 2 \\ 6 \end{pmatrix}, \begin{pmatrix} 2 \\ 3 \end{pmatrix}, \begin{pmatrix} 6 \\ 1 \end{pmatrix}$$

hledáme „natažení“ červených vektorů tak, aby modrý vektor byl úhlopříčkou čtyřúhelníka:



Pozor: výše uvedený obrázek je „slogan“! Pracujeme totiž v $(\mathbb{Z}_7)^2$.

Zobecnění předchozího (zatím jen slogan)

Hledáme-li pro pevný seznam $(\mathbf{a}_1, \dots, \mathbf{a}_s)$ a pevný vektor \mathbf{b} v \mathbb{F}^r reálné koeficienty x_1, \dots, x_s tak, aby platila rovnost

$$x_1 \cdot \mathbf{a}_1 + \dots + x_s \cdot \mathbf{a}_s = \mathbf{b}$$

pak lze na tuto úlohu pohlížet dvěma způsoby:

- ① Řešíme soustavu r lineárních rovnic o s neznámých.
- ② Hledáme „natažení“ vektorů $\mathbf{a}_1, \dots, \mathbf{a}_s$ pomocí skalářů x_1, \dots, x_s tak, aby vektor \mathbf{b} tvořil úhlopříčku rovnoběžnostěnu.

Příští přednášky: druhý pohled na tuto úlohu nám dovolí vybudovat elegantní metodu řešení (Gaussovu eliminaci).

Lineární obal a lineární podprostor

Odpřednesenou látku naleznete v kapitolách 1.5 a 1.6 skript
Abstraktní a konkrétní lineární algebra.

Minulá přednáška

- ① Definice lineárního prostoru (nad obecným tělesem).
- ② Lineární kombinace.

Dnešní přednáška

- ① Lineární obal množiny vektorů.
- ② Lineární podprostor lineárního prostoru.

Připomenutí

V lineárním prostoru můžeme zjednodušovat zápis:

- ① Přípomene: $-\vec{x}$ místo $(-1) \cdot \vec{x}$. Jde o **opačný vektor** k vektoru \vec{x} (dokázáno minule).
- ② Přípomene: $\vec{x}_1 + \vec{x}_2 + \cdots + \vec{x}_{n-1} + \vec{x}_n$ místo $(\dots (\vec{x}_1 + \vec{x}_2) + \cdots + \vec{x}_{n-1}) + \vec{x}_n$. Důvod: **asociativita sčítání vektorů**.

Lineární kombinace seznamu $(\vec{x}_1, \dots, \vec{x}_n)$ s koeficienty a_1, \dots, a_n

z tělesa \mathbb{F} je vektor $\sum_{i=1}^n a_i \cdot \vec{x}_i$.

Lineární kombinace prázdného seznamu () je nulový vektor.

Konečné a nekonečné množiny

Připomenutí:^a množina přirozených čísel $\mathbb{N} = \{0, 1, 2, \dots\}$.

- 1 Množina M je **konečná**, když má přesně n prvků, kde n je nějaké přirozené číslo.

To znamená: M je konečná, když bud'

$$M = \emptyset \text{ (množina } M \text{ má 0 prvků),}$$

nebo

$M = \{x_1, \dots, x_n\}$, kde $n \geq 1$ je přirozené číslo (v tom případě má množina M n prvků).

- 2 Množina M je **nekonečná**, když není konečná.

Například \mathbb{N} , \mathbb{Q} , \mathbb{R} , \mathbb{C} jsou nekonečné množiny. Množina $\mathbb{R}[x]$ je nekonečná.

^aDůležité: v této přednášce nula je přirozené číslo.

Definice (lineární obal množiny vektorů)

Ať M je jakákoli množina vektorů lineárního prostoru L . **Lineární obal množiny vektorů** M je množina $\text{span}(M)$, definovaná takto:

$$\vec{x} \in \text{span}(M) \quad \text{právě tehdy, když}^{\text{a}} \quad \vec{x} = \sum_{i=1}^n a_i \cdot \vec{x}_i$$

pro nějaké $n \geq 0$, nějaká $a_1, \dots, a_n \in \mathbb{F}$ a nějaká $\vec{x}_1, \dots, \vec{x}_n \in M$.

^aPozor: prázdná lineární kombinace je rovna vektoru \vec{o} .

Ujasnění si definice $\text{span}(M)$

$\vec{x} \in \text{span}(M)$ právě tehdy, když **existuje** nějaký seznam S vektorů z množiny M tak, že \vec{x} je roven nějaké lineární kombinaci seznamu S .

To jest: $\text{span}(M)$ je množina všech možných lineárních kombinací, které lze z M utvořit.

Příklady (viz minulé přednášky)

① Pro

$$\longrightarrow \mathbf{a}_1$$

v \mathbb{R}^2 je $\text{span}(\{\mathbf{a}_1\})$ přímka procházející počátkem se směrem (\mathbf{a}_1) .

② Pro



v \mathbb{R}^3 je $\text{span}(\{\mathbf{a}_1, \mathbf{a}_2\})$ rovina procházející počátkem se směrem $(\mathbf{a}_1, \mathbf{a}_2)$.

Pozor: pro

$$\mathbf{a}_2 \longleftrightarrow \mathbf{a}_1$$

v \mathbb{R}^3 , lineární obal $\text{span}(\{\mathbf{a}_1, \mathbf{a}_2\})$ **není rovina!** Jde opět o přímku. Jak poznat o co jde? Uvidíme příště.^a

^aToto téma se zove **lineární závislost** a **lineární nezávislost**.

Uzávěrové vlastnosti lineárního obalu

- ① Je-li $M \subseteq N$, potom $\text{span}(M) \subseteq \text{span}(N)$.
- ② Pro vš. M platí: $M \subseteq \text{span}(M)$.
- ③ Pro vš. M platí: $\text{span}(\text{span}(M)) \subseteq \text{span}(M)$.

Důkaz.

Přednáška.



Vysvětlení uzávěrových vlastností (slogan)

Lineárními kombinacemi tvoříme „rovné kusy“ lineárního prostoru (viz minulou přednášku).

Množina $\text{span}(M)$ je tedy „zabalení“ množiny M tak, aby výsledkem byl „co nejmenší rovný kus“, který obsahuje M .

Definice (lineární podprostor)

Ať W je podmnožina lineárního prostoru L . Řekneme, že W je **lineární podprostor** lineárního prostoru L , když platí $\text{span}(W) \subseteq W$.

Slogan pro lineární podprostor

Podprostor je „dobrá“ podmnožina prostoru. Žádnou lineární kombinací nelze z lineárního podprostoru „utéct“.

Tvrzení

- ① $\text{span}(M)$ je vždy lineární podprostor. Jde o nejmenší podprostor, který obsahuje množinu M .
- ② Množina M je lineární podprostor právě tehdy, když $\text{span}(M) = M$.

Důkaz.

Přednáška.

Tvrzení

Ať L je lineární prostor. Podmnožina $W \subseteq L$ je lineárním podprostorem prostoru L právě tehdy, když platí:

- ① $\vec{0}$ je prvkem W (**uzavřenosť W na nulový vektor**).
- ② $\vec{x} + \vec{y}$ je prvkem W , pro každé $\vec{x}, \vec{y} \in W$ (**uzavřenosť W na součet vektorů**).
- ③ $a \cdot \vec{x}$ je prvkem W , pro každé $a \in \mathbb{F}$ a každé $\vec{x} \in W$ (**uzavřenosť W na skalárni násobek**).

Důkaz.

Přednáška.



Další slogan pro lineární podprostor

Lineární podprostor vždy obsahuje nulový vektor a „vydrží“ operace součtu a skalárniho násobku.

Důležité

Ať W je lineární podprostor lineárního prostoru L . Potom množina W sama o sobě je lineárním prostorem, pokud sčítání vektorů ve W a násobení vektoru skalárem ve W definujeme **stejně** jako v prostoru L .

Obrácené tvrzení ale neplatí: například $W = \left\{ \begin{pmatrix} x \\ 1 \end{pmatrix} \mid x \in \mathbb{R} \right\}$ **není** lineárním podprostorem \mathbb{R}^2 . Ale množina W spolu s operacemi

$$\begin{pmatrix} x \\ 1 \end{pmatrix} \oplus \begin{pmatrix} x' \\ 1 \end{pmatrix} = \begin{pmatrix} x + x' \\ 1 \end{pmatrix} \quad a \odot \begin{pmatrix} x \\ 1 \end{pmatrix} = \begin{pmatrix} a \cdot x \\ 1 \end{pmatrix}$$

tvoří lineární prostor nad \mathbb{R} .

Příklady

- ① Každý lineární prostor je sám svým podprostorem.
- ② Množina $\{\vec{o}\}$ je vždy lineárním podprostorem.^a
- ③ \mathbb{R}^3 je lineární prostor (operace jsou definovány po složkách).

① $W_1 = \left\{ \begin{pmatrix} x \\ y \\ z \end{pmatrix} \in \mathbb{R}^3 \mid z = 0 \right\}$ je lineárním podprostorem \mathbb{R}^3 .

② $W_2 = \left\{ \begin{pmatrix} x \\ y \\ z \end{pmatrix} \in \mathbb{R}^3 \mid z = 1 \right\}$ není lineárním podprostorem \mathbb{R}^3 .

Pozor! Na množině W_2 lze definovat strukturu lineárního prostoru (cvičení).

^aTomuto podprostoru říkáme triviální podprostor.

Příklady (pokrač.)

- ④ Označme jako $\mathbb{R}^{\leq 3}[x]$ množinu všech reálných polynomů stupně maximálně 3 a jako $\mathbb{R}^{\leq 136}[x]$ množinu všech reálných polynomů stupně maximálně 136.

Potom $\mathbb{R}^{\leq 3}[x]$ je lineární podprostor lineárního prostoru $\mathbb{R}^{\leq 136}[x]$.

Obecněji: At' \mathbb{F} je těleso. Označme jako $\mathbb{F}^{\leq n}[x]$ množinu všech polynomů nad \mathbb{F} stupně maximálně n , $n \geq 0$.

Jakmile $n \leq m$, je $\mathbb{F}^{\leq n}[x]$ lineární podprostor lineárního prostoru $\mathbb{F}^{\leq m}[x]$.

- ⑤ Pro každé $n \geq 0$ je $\mathbb{F}^{\leq n}[x]$ lineární podprostor lineárního prostoru $\mathbb{F}[x]$.

Vlastnosti lineárních podprostorů

Ať L je lineární prostor.

- ① Průnik libovolného systému $\{W_i \mid i \in I\}$ podprostorů prostoru L je lineárním podprostorem prostoru L .
- ② Sjednocení systému $\{W_i \mid i \in I\}$ lineárních podprostorů prostoru L obecně lineárním podprostorem prostoru L není.

Důkaz.

Přednáška.



Definice (spojení lineárních podprostorů)

Ať $\{W_i \mid i \in I\}$ je systém lineárních podprostorů prostoru L .

Lineárnímu podprostoru $\text{span}(\bigcup_{i \in I} W_i)$ prostoru L říkáme **spojení** podprostorů W_i , $i \in I$, a značíme jej^a

$$\bigvee_{i \in I} W_i$$

^aV případě dvou podprostorů používáme i značení $W_1 \vee W_2$.



Klasifikace lineárních podprostorů prostoru \mathbb{R}^3

Všechny podprostory \mathbb{R}^3 jsou buď

- ① Jednoprvková množina obsahující pouze počátek.

nebo

- ② Každá přímka procházející počátkem.

nebo

- ③ Každá rovina procházející počátkem.

nebo

- ④ Celá množina \mathbb{R}^3 .

Důkaz.

V každém z uvedených bodů je lineární podprostor prostoru \mathbb{R}^3 .
To, že žádné jiné lineární podprostory prostoru \mathbb{R}^3 neexistují,
ukážeme později.^a



^aBudeme k tomu potřebovat pojem **dimenze**.



Lineární závislost a nezávislost

Odpřednesenou látku naleznete v kapitole 3.1 skript
Abstraktní a konkrétní lineární algebra.

Minulé přednášky

- ① Lineární kombinace.
- ② Definice lineárního obalu.
- ③ Definice lineárního podprostoru.

Dnešní přednáška

- ① Lineární závislost/nezávislost seznamu a množiny vektorů v lineárním prostoru.

Připomenutí

- ① Pro



v \mathbb{R}^3 je $\text{span}(\{\mathbf{a}_1, \mathbf{a}_2\})$ rovina procházející počátkem se směrem $(\mathbf{a}_1, \mathbf{a}_2)$.

- ② Pro



v \mathbb{R}^3 , lineární obal $\text{span}(\{\mathbf{a}_1, \mathbf{a}_2\})$ rovina není.

V množině $\{\mathbf{a}_1, \mathbf{a}_2\}$ je (například) vektor \mathbf{a}_2 „zbytečný“ vzhledem k tvorbě lineárních kombinací.^a

Platí totiž $\text{span}(\{\mathbf{a}_1, \mathbf{a}_2\}) = \text{span}(\{\mathbf{a}_1\})$.

^aZa chvíli budeme říkat, že množina $\{\mathbf{a}_1, \mathbf{a}_2\}$ je lineárně závislá.

Definice

Lineární kombinace $a_1 \cdot \vec{x}_1 + \cdots + a_n \cdot \vec{x}_n$ je **triviální**, pokud $a_1 = a_2 = \cdots = a_n = 0$.

V opačném případě je lineární kombinace $a_1 \cdot \vec{x}_1 + \cdots + a_n \cdot \vec{x}_n$ **netriviální**.

Poznámky

- ① Triviální lineární kombinace je **vždy** rovna nulovému vektoru: rovnost $0 \cdot \vec{x}_1 + \cdots + 0 \cdot \vec{x}_n = \vec{0}$ platí, protože $0 \cdot \vec{x} = \vec{0}$, pro jakýkoli vektor \vec{x} (dokázáno minule).
- ② I netriviální lineární kombinace může být rovna nulovému vektoru: například $\vec{x} - \vec{x} = \vec{0}$, pro jakýkoli vektor \vec{x} .
- ③ Lineární kombinaci, která dává nulový vektor, také říkáme **nulová kombinace**.^a

^a**Pozor:** triviální kombinace je **vždy** nulová. Nulová kombinace **nemusí** být triviální.

Definice (lineární nezávislost seznamu vektorů)

Řekneme, že seznam S vektorů je **lineárně nezávislý**, pokud platí jedna z podmínek:

- ① Seznam S je prázdný.
- ② Seznam S je tvaru $(\vec{x}_1, \dots, \vec{x}_n)$ a platí: kdykoli $a_1 \cdot \vec{x}_1 + \dots + a_n \cdot \vec{x}_n = \vec{o}$, pak $a_1 = a_2 = \dots = a_n = 0$.

Řekneme, že seznam S je **lineárně závislý**, pokud není lineárně nezávislý.

Příklady

- ① Prázdný seznam () je **vždy** lineárně nezávislý.
- ② Seznam (\vec{o}) je **vždy** lineárně závislý.
- ③ Seznam, ve kterém se opakuje vektor, je **vždy** lineárně závislý.

Příklad

Nulová lineární kombinace $x_1 \cdot \mathbf{a}_1 + \dots + x_s \cdot \mathbf{a}_s = \mathbf{0}$ v \mathbb{F}^r , kde

$$\mathbf{a}_1 = \begin{pmatrix} a_{11} \\ a_{21} \\ \vdots \\ a_{r1} \end{pmatrix}, \dots, \mathbf{a}_s = \begin{pmatrix} a_{1s} \\ a_{2s} \\ \vdots \\ a_{rs} \end{pmatrix}$$

kóduje soustavu r lineárních rovnic

$$x_1 a_{11} + x_2 a_{12} + \dots + x_s a_{1s} = 0$$

$$x_1 a_{21} + x_2 a_{22} + \dots + x_s a_{2s} = 0$$

⋮

$$x_1 a_{r1} + x_2 a_{r2} + \dots + x_s a_{rs} = 0$$

o s neznámých nad \mathbb{F} .

Seznam $(\mathbf{a}_1, \dots, \mathbf{a}_s)$ je lineárně nezávislý právě tehdy, když tato soustava má pouze **triviální** řešení $x_1 = x_2 = \dots = x_s = 0$.



Definice (lineární nezávislost množiny vektorů)

Ať M je množina vektorů v lineárním prostoru L . Řekneme, že M je **lineárně nezávislá**, pokud platí jedna z následujících podmínek:

- ① Množina M je prázdná.
- ② $M = \{\vec{x}_1, \dots, \vec{x}_n\}$ je neprázdná konečná množina a navíc platí: kdykoli $a_1 \cdot \vec{x}_1 + \dots + a_n \cdot \vec{x}_n = \vec{0}$, pak $a_1 = a_2 = \dots = a_n = 0$.
- ③ M je nekonečná množina a každá její konečná podmnožina je lineárně nezávislá.

Řekneme, že množina M je **lineárně závislá**, pokud není lineárně nezávislá.

Praktický test lineární nezávislosti neprázdné množiny M

Musí platit následující implikace:

Ať $a_1 \cdot \vec{x}_1 + \dots + a_n \cdot \vec{x}_n = \vec{0}$, kde $n > 0$ je přirozené číslo, vektory $\vec{x}_1, \dots, \vec{x}_n$ jsou z M a skaláry a_1, \dots, a_n jsou z \mathbb{F} .
Potom $a_1 = a_2 = \dots = a_n = 0$.



Příklady

- ① $\{\vec{o}\}$ je lineárně závislá množina v jakémkoli lineárním prostoru L .

Obecněji: at' $\vec{o} \in M$, potom M je lineárně závislá množina.

- ② Množina $\left\{ \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \right\}$ je lineárně nezávislá množina v \mathbb{R}^3 .

Obecněji: definujte pro $i = 1, \dots, n$, vektor $\mathbf{e}_i \in \mathbb{R}^n$ jako n -tici mající na i -té posici 1 a všude jinde 0. Potom $\{\mathbf{e}_1, \dots, \mathbf{e}_n\}$ je lineárně nezávislá množina v \mathbb{R}^n .

- ③ Nekonečná množina $\{1, x, x^2, x^3, \dots\}$ je lineárně nezávislá množina v prostoru polynomů $\mathbb{R}[x]$.

Příklady (pokrač.)

- ④ Množina $\left\{ \begin{pmatrix} 1 \\ -7 \\ 3 \end{pmatrix}, \begin{pmatrix} -1 \\ 2 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ 8 \\ -9 \end{pmatrix} \right\}$ je lineárně závislá množina v \mathbb{R}^3 .

Důvod:

$$2 \cdot \begin{pmatrix} 1 \\ -7 \\ 3 \end{pmatrix} + 3 \cdot \begin{pmatrix} -1 \\ 2 \\ 1 \end{pmatrix} + 1 \cdot \begin{pmatrix} 1 \\ 8 \\ -9 \end{pmatrix} = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$$

Tvrzení

Ať M je lineárně nezávislá množina vektorů v lineárním prostoru L .
Jakmile $N \subseteq M$, je i N lineárně nezávislá množina vektorů.

Důkaz.

Přednáška.



Slogan

Ubereme-li z lineárně nezávislé množiny vektorů nějaké vektory, je výsledná množina opět lineárně nezávislá.

Tvrzení

Ať M je lineárně závislá množina vektorů v lineárním prostoru L . Jakmile N je množina vektorů z L a platí $M \subseteq N$, je i N lineárně závislá množina vektorů.

Důkaz.

Přednáška.



Slogan

Přidáme-li do lineárně závislé množiny vektorů nějaké vektory, je výsledná množina opět lineárně závislá.

Věta (charakterisace lineárně nezávislých množin)

Pro množinu M vektorů z lineárního prostoru L jsou následující podmínky ekvivalentní:


- ① Množina M je lineárně nezávislá.
- ② Pro každý vektor $\vec{x} \notin \text{span}(M)$ je množina $M \cup \{\vec{x}\}$ lineárně nezávislá.

Důkaz.

Přednáška.



Ilustrační obrázek



Věta (charakterisace lineárně závislých množin)

Pro množinu M vektorů z lineárního prostoru L jsou následující podmínky ekvivalentní:


- ① Množina M je lineárně závislá.
- ② Existuje $\vec{v} \in M$ tak, že $\text{span}(M \setminus \{\vec{v}\}) = \text{span}(M)$.

Důkaz.

Přednáška.



Ilustrační obrázek



Báze a dimenze

Odpřednesenou látku naleznete v kapitolách 3.1–3.3 a 3.6 skript *Abstraktní a konkrétní lineární algebra*.

Minulé přednášky

- ① Lineární kombinace, lineární závislost/nezávislost.
- ② Lineární obal seznamu/množiny vektorů.

Dnešní přednáška

- ① Báze lineárního (pod)prostoru.

Intuitivní význam: **báze je výběr systému souřadnicových os.**

- ② Dimenze lineárního (pod)prostoru.

Intuitivní význam: **dimenze je počet souřadnicových os.**

Připomenutí

Množina M je **konečná**, pokud bud' $M = \emptyset$ nebo $M = \{x_1, \dots, x_n\}$ pro nějaké přirozené číslo $n \geq 1$. Množina M je **nekonečná**, když není konečná.

Definice (množina generátorů)

Ať W je lineární podprostor prostoru L . Řekneme, že množina G **generuje** W , když platí $\text{span}(G) = W$. (Říkáme také: G je **množina generátorů** podprostoru W .)

Definice (konečně generovaný podprostor)

Řekneme, že lineární podprostor W prostoru L je **konečně generovaný**, když existuje konečná množina jeho generátorů. (To jest, když platí $\text{span}(G) = W$ pro nějakou **konečnou** množinu G .)

Příklady

- ① Pro každý prostor L platí: L je množina generátorů prostoru L .

Množina generátorů L prostoru L obecně není konečná a je vždy lineárně závislá (například: \mathbb{R}^2 je nekonečná lineárně závislá množina generátorů prostoru \mathbb{R}^2).

- ② Jak \emptyset , tak $\{\vec{o}\}$ jsou konečné množiny generátorů triviálního prostoru $\{\vec{o}\}$. Důvody: $\text{span}(\emptyset) = \{\vec{o}\}$ (minulé přednášky) a $\text{span}(\{\vec{o}\}) = \{\vec{o}\}$.

Všimněme si:

- ① \emptyset je lineárně nezávislá množina generátorů prostoru $\{\vec{o}\}$.
- ② $\{\vec{o}\}$ je lineárně závislá množina generátorů prostoru $\{\vec{o}\}$.

- ③ Konečná množina $G = \left\{ \begin{pmatrix} -1 \\ -1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \end{pmatrix} \right\}$ generuje „osu prvního a třetího kvadrantu“ prostoru \mathbb{R}^2 . Množina G je lineárně závislá.

Definice (základ)

Lineárně nezávislé množině B , která generuje prostor L , říkáme **báze prostoru L** . Je-li B konečná, pak seznamu prvků B říkáme **uspořádaná báze**.

Slogan pro bázi

Báze prostoru je „nejúspornější“ množina generátorů.

Příklady

- ① \emptyset je báze triviálního prostoru $\{\vec{o}\}$.
- ② Každá z množin $\left\{ \begin{pmatrix} 1 \\ 2 \end{pmatrix}, \begin{pmatrix} 3 \\ -4 \end{pmatrix} \right\}$, $\left\{ \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \end{pmatrix} \right\}$ tvoří bázi prostoru \mathbb{R}^2 .
- ③ Množina $\{1, x, x^2, x^3, \dots\}$ tvoří bázi prostoru $\mathbb{R}[x]$ všech reálných polynomů.

Příklad (kanonická báze prostoru \mathbb{F}^n , $n \geq 1$)


Ať \mathbb{F} je jakékoli těleso. Označme jako $K_n = (\mathbf{e}_1, \dots, \mathbf{e}_n)$ následující **seznam** vektorů v \mathbb{F}^n , $n \geq 1$:

\mathbf{e}_i má jedničku na i -té pozici, všude jinde nuly.

Potom K_n je **uspořádaná** báze prostoru \mathbb{F}^n .

Této uspořádané bázi K_n říkáme **kanonická báze prostoru \mathbb{F}^n** .
(Také: **standardní báze**.)

Příklad: kanonická báze K_3 v \mathbb{R}^3 .



$$\mathbf{e}_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix} \quad \mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} \quad \mathbf{e}_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$$

Příklad: Fourierova báze pro $n = 4$ (varianta této báze je používána v JPEG)

Pro $w = e^{\frac{2\pi i}{4}} = i$, je **seznam** $(\vec{f}_0, \vec{f}_1, \vec{f}_2, \vec{f}_3)$, kde

$$\vec{f}_0 = \begin{pmatrix} w^0 \\ w^0 \\ w^0 \\ w^0 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}, \quad \vec{f}_1 = \begin{pmatrix} w^0 \\ w^1 \\ w^2 \\ w^3 \end{pmatrix} = \begin{pmatrix} 1 \\ i \\ -1 \\ -i \end{pmatrix}$$

$$\vec{f}_2 = \begin{pmatrix} w^0 \\ w^2 \\ w^4 \\ w^6 \end{pmatrix} = \begin{pmatrix} 1 \\ -1 \\ 1 \\ -1 \end{pmatrix}, \quad \vec{f}_3 = \begin{pmatrix} w^0 \\ w^3 \\ w^6 \\ w^9 \end{pmatrix} = \begin{pmatrix} 1 \\ -i \\ -1 \\ i \end{pmatrix}$$

uspořádaná báze lineárního prostoru \mathbb{C}^4 nad tělesem \mathbb{C} .

Tvrzení (Existence báze pro konečně generované prostory)

Každý konečně generovaný prostor L má konečnou bázi.

Navíc: všechny možné báze prostoru L mají stejný počet prvků.

Myšlenka důkazu

První tvrzení: víme, že $\text{span}(G) = L$, kde G je konečná. Lze postupovat dvěma způsoby:

- (I) „Přidávat“ do prázdné množiny „důležité“ vektory z G .
- (II) „Ubírat“ z G „zbytečné“ vektory.

Detailey: přednáška.

Druhé tvrzení: Exchange Lemma (viz skripta, Lemma 3.2.10 a cvičení).

Definice (prostor konečné dimenze)

Lineární prostor L má **dimensi** n (značíme: $\dim(L) = n$), když existuje báze B prostoru L , která má n prvků,^a kde n je přirozené číslo.

^aA tudíž, podle předchozího, **všechny** báze prostoru L mají n prvků.

Příklady

- ① Platí: $\dim(\mathbb{R}^n) = n$, $n \geq 0$.
- ② Obecněji: pro **jakékoli** těleso \mathbb{F} platí $\dim(\mathbb{F}^n) = n$, $n \geq 0$.
- ③ Platí: $\dim(\{\vec{o}\}) = 0$.
- ④ Prostor $\mathbb{R}[x]$ všech reálných polynomů **nemá** konečnou dimensi.
- ⑤ Podprostor $\mathbb{R}^{\leq 3}[x]$ (polynomy stupně nejvýše 3) prostoru $\mathbb{R}[x]$ má dimensi 4. Uspořádaná báze je např. $(x^3, x^2, x, 1)$.

Poznámka

Ať $\dim(L) = n$ a ať M je podmnožina L , která má m prvků.

- ① Je-li M lineárně nezávislá, pak $m \leq n$.
- ② Ať $m = n$. M je lineárně nezávislá právě tehdy, když platí $\text{span}(M) = L$.

Důsledek (klasifikace lineárních podprostorů \mathbb{R}^3)

Lineární podprostory prostoru \mathbb{R}^3 jsou přesně tvaru $\text{span}(M)$, kde M (zaměření podprostoru) je lineárně nezávislá podmnožina \mathbb{R}^3 :

- ① Počátek $\{\vec{0}\}$ (když M má nula prvků).
- ② Přímky procházející počátkem (když M má jeden prvek).
- ③ Roviny procházející počátkem (když M má dva prvky).
- ④ Celé \mathbb{R}^3 (když M má tři prvky).

Zobecnění: klasifikace^a lineárních podprostorů prostoru \mathbb{R}^n (dokonce na lineární podprostory prostoru \mathbb{F}^n).

^aTo je náročnější na představu, ale geometrický význam je podobný jako pro lineární podprostory prostoru \mathbb{R}^3 .

Připomenutí (Téma 2A)

Podprostoru $\text{span}(W_1 \cup W_2)$ říkáme **spojení podprostorů** W_1 a W_2 .
Značení: $W_1 \vee W_2$.

Věta (rovnost dvou lineárních podprostorů)

Ať W_1, W_2 jsou lineární podprostory prostoru L konečné dimenze.
Potom $W_1 = W_2$ právě tehdy, když platí rovnost
 $\dim(W_1) = \dim(W_2) = \dim(W_1 \vee W_2)$.^a

^aDůkaz: domácí cvičení. Postupujte následovně:

- ① Ať $W_1 = W_2$. Potom $W_1 \vee W_2 = W_1$. Tudíž platí rovnost
 $\dim(W_1) = \dim(W_2) = \dim(W_1 \vee W_2)$.
- ② Ať $\dim(W_1) = \dim(W_2) = \dim(W_1 \vee W_2)$. Protože $W_1 \subseteq W_1 \vee W_2$ a oba podprostory mají stejnou dimensi, platí $W_1 = W_1 \vee W_2$.
Rovnost $W_2 = W_1 \vee W_2$ se dokáže analogicky.
Celkově: $W_1 = W_1 \vee W_2 = W_2$, hotovo.

Důsledek (důležitý pro Frobeniovu větu, téma 6A)


Ať W je lineární podprostor prostoru L konečné dimenze. Pro vektor \vec{v} jsou následující podmínky ekvivalentní:^a

- ① $\vec{v} \in W$
- ② $\dim(W) = \dim(W \vee \text{span}(\vec{v}))$

^aDůkaz: domácí cvičení. Postupujte následovně:


- ① Dokažte: $\vec{v} \in W$ iff $\text{span}(\vec{v}) \subseteq W$ iff $W = W \vee \text{span}(\vec{v})$.
- ② Použijte větu z předchozí stránky: $W = W \vee \text{span}(\vec{v})$ iff $\dim(W) = \dim(W \vee \text{span}(\vec{v})) = \dim(\underbrace{W \vee (W \vee \text{span}(\vec{v}))}_{=W \vee \text{span}(\vec{v})})$.

Měl by pomocí obrázek situace, kdy $\vec{v} \notin W$:



Připomenutí (princip inkluse a exkluse)

Ať A a B jsou konečné množiny.



Označíme-li počet prvků množin A , B , $A \cap B$ a $A \cup B$ jako $\text{card}(A)$, $\text{card}(B)$, $\text{card}(A \cap B)$ a $\text{card}(A \cup B)$, potom platí rovnost

$$\text{card}(A \cup B) + \text{card}(A \cap B) = \text{card}(A) + \text{card}(B)$$

Věta (o dimensi spojení a průniku)

Ať je L lineární prostor konečné dimenze. Potom, pro libovolné lineární podprostupy W_1, W_2 , platí rovnost

$$\dim(W_1 \vee W_2) + \dim(W_1 \cap W_2) = \dim(W_1) + \dim(W_2).$$

Důkaz.

Přednáška.



Slogan pro větu o dimensi spojení a průniku

Jde o „princip inkluse a exkluse“ pro lineární prostory konečné dimenze. Dimenze hraje roli počtu prvků.^a

^aZnovu upozorňujeme: slogan je reklamní heslo, nikoli skutečnost.

Věta (za předpokladu (AC))

Každý lineární prostor L má bázi.

Důkaz.

Náročný: nebudeme dokazovat. 

Poznámka

Předpoklad (AC). Zkratka (AC) znamená **Axiom of Choice**, česky: axiom výběru.

Jedná se o tvrzení: kartézský součin libovolného systému neprázdných množin je neprázdná množina.^a

Tvrzení (AC) je nezávislé na základních axiomech teorie množin. Srovnejte s axiomem o rovnoběžkách z geometrie.

^aVe **skriptech** je použita ekvivalentní formulace (AC), tzv. **Zornovo Lemma**.

Pozor: stejný prostor nad různými tělesy má různé vlastnosti

- ① Množina \mathbb{C} všech komplexních čísel je
 - ① lineární prostor dimenze 1 nad tělesem \mathbb{C} ,
 - ② lineární prostor dimenze 2 nad tělesem \mathbb{R} .
- ② Množina \mathbb{R} všech reálných čísel je
 - ① lineární prostor dimenze 1 nad tělesem \mathbb{R} ,
 - ② lineární prostor nekonečné dimenze nad tělesem \mathbb{Q} .^a

^aNepovinné: takzvaná Hamelova báze reálných čísel, viz Příklad 3.6.5 skript.

Důsledek: měli bychom vždy psát, nad jakým tělesem o lineárním prostoru mluvíme!

Souřadnice vzhledem k uspořádané bázi a komutativní diagramy

Odpřednesenou látku naleznete v kapitolách 3.1–3.3 a 2.2 skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

- ① Báze lineárního (pod)prostoru.

Intuitivní význam: **báze je výběr systému souřadnicových os.**

- ② Dimenze lineárního (pod)prostoru.

Intuitivní význam: **dimenze je počet souřadnicových os.**

Dnešní přednáška

- ① Souřadnice vektoru vzhledem k **uspořádané** bázi.

Intuitivní význam: **souřadnice vektoru udávají „úseky“ vektoru na jednotlivých souřadnicových osách.**

- ② Ukážeme **velmi užitečný** pohled na zobrazení (funkce): kalkulus komutativních diagramů.

Věta (existence souřadnic vzhledem k uspořádané bázi)

Ať seznam $B = (\vec{b}_1, \dots, \vec{b}_n)$ tvoří bázi lineárního prostoru L . Pro každý vektor \vec{x} v L existuje jediný seznam (a_1, \dots, a_n) prvků \mathbb{F} tak, že $\vec{x} = a_1 \cdot \vec{b}_1 + \dots + a_n \cdot \vec{b}_n$.

Důkaz.

Přednáška.



Definice (souřadnice vzhledem k uspořádané bázi)



Seznamu (a_1, \dots, a_n) z předchozí věty říkáme **souřadnice vektoru \vec{x} vzhledem k uspořádané bázi $B = (\vec{b}_1, \dots, \vec{b}_n)$** . Značení:^a

$$\mathbf{coord}_B(\vec{x}) = \begin{pmatrix} a_1 \\ \vdots \\ a_n \end{pmatrix}.$$

^aTj, souřadnice vektoru \vec{x} chápeme jako další vektor: vektor souřadnic v \mathbb{F}^n .

Příklad (souřadnice stejného vektoru k různým bázím)

Seznamy $K_2 = (\begin{pmatrix} 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \end{pmatrix})$, $B = (\begin{pmatrix} 2 \\ 1 \end{pmatrix}, \begin{pmatrix} 2 \\ 2 \end{pmatrix})$ jsou uspořádané báze prostoru \mathbb{R}^2 . (Seznam K_2 je kanonická báze prostoru \mathbb{R}^2 .)



$$\mathbf{coord}_{K_2} \begin{pmatrix} 2 \\ 3 \end{pmatrix} = \begin{pmatrix} 2 \\ 3 \end{pmatrix}$$

$$\begin{pmatrix} 2 \\ 3 \end{pmatrix} = 2 \cdot \begin{pmatrix} 1 \\ 0 \end{pmatrix} + 3 \cdot \begin{pmatrix} 0 \\ 1 \end{pmatrix}$$

$$\mathbf{coord}_B \begin{pmatrix} 2 \\ 3 \end{pmatrix} = \begin{pmatrix} -1 \\ 2 \end{pmatrix}$$

$$\begin{pmatrix} 2 \\ 3 \end{pmatrix} = -1 \cdot \begin{pmatrix} 2 \\ 1 \end{pmatrix} + 2 \cdot \begin{pmatrix} 2 \\ 2 \end{pmatrix}$$

Důležitá vlastnost kanonické báze

Připomenutí: prostor \mathbb{F}^n nad \mathbb{F} má kanonickou bázi

$K_n = (\mathbf{e}_1, \dots, \mathbf{e}_n)$, kde

$$\mathbf{e}_1 = \begin{pmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix}, \mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{pmatrix}, \dots, \mathbf{e}_n = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 1 \end{pmatrix}$$

Ať $\mathbf{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ je vektor v \mathbb{F}^n . Potom $\mathbf{coord}_{K_n}(\mathbf{x}) = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$.

Příklad (souřadnice stejného vektoru k různým bázím)

Seznamy

$$B_1 = (1, x, x^2) \quad B_2 = (x^2, x, 1)$$

jsou uspořádané báze lineárního prostoru $\mathbb{R}^{\leq 2}[x]$ reálných polynomů stupně nejvýše 2.

Platí:

$$\mathbf{coord}_{B_1}(3x^2 - 2x + 4) = \begin{pmatrix} 4 \\ -2 \\ 3 \end{pmatrix}$$

$$\mathbf{coord}_{B_2}(3x^2 - 2x + 4) = \begin{pmatrix} 3 \\ -2 \\ 4 \end{pmatrix}$$

$$3x^2 - 2x + 4 = 4 \cdot 1 + (-2) \cdot x + 3 \cdot x^2, \quad 3x^2 - 2x + 4 = 3 \cdot x^2 + (-2) \cdot x + 4 \cdot 1$$

Tvrzení (linearita výpočtu souřadnic)

Ať B je (jakákoli) konečná uspořádaná báze lineárního prostoru L .
Potom pro zobrazení $\vec{x} \mapsto \mathbf{coord}_B(\vec{x})$ platí:^a

- ① $\mathbf{coord}_B(\vec{x} + \vec{y}) = \mathbf{coord}_B(\vec{x}) + \mathbf{coord}_B(\vec{y}).$
- ② $\mathbf{coord}_B(a \cdot \vec{x}) = a \cdot \mathbf{coord}_B(\vec{x}).$

^aTyto dvě vlastnosti jsou velmi důležité. Příště je budeme studovat abstraktně (vedou k pojmu lineárního zobrazení).

Důkaz.

Přednáška.



Důsledek: důležitá vlastnost každé uspořádané báze

Ať $B = (\vec{b}_1, \dots, \vec{b}_n)$ je jakákoli uspořádaná báze prostoru L .

Potom platí:

$$\mathbf{coord}_B(\vec{b}_1) = \begin{pmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{pmatrix}, \mathbf{coord}_B(\vec{b}_2) = \begin{pmatrix} 0 \\ 1 \\ \vdots \\ 0 \end{pmatrix}, \dots, \mathbf{coord}_B(\vec{b}_n) = \begin{pmatrix} 0 \\ 0 \\ \vdots \\ 1 \end{pmatrix}$$

Obecně platí:

$$\mathbf{coord}_B\left(\sum_{i=1}^n a_i \cdot \vec{b}_i\right) = \sum_{i=1}^n a_i \cdot \mathbf{coord}_B(\vec{b}_i) = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_n \end{pmatrix}$$

Několik připomenutí

- ① Zadat zobrazení (také: funkci) $f : X \rightarrow Y$ znamená: pro každé $x \in X$ zadat právě jedno $y \in Y$. Toto y značíme $f(x)$ (funkční hodnota v x).
Přeme^a i $x \mapsto f(x)$, $f : x \mapsto f(x)$.
- ② Pro zobrazení $f : X \rightarrow Y$, $g : Y \rightarrow Z$ značíme $g \cdot f : X \rightarrow Z$ složené zobrazení $x \mapsto g(f(x))$.

^aDůležité je rozlišovat: šipka $f : X \rightarrow Y$ versus šipka s patkou $x \mapsto f(x)$.

Poznámky

- Slova *funkce* a *zobrazení* znamenají totéž.
- Skládání zobrazení značíme **stejně** jako násobení (tj. tečkou). Uvidíme později, že skládání zobrazení skutečně **je** jistý druh násobení.

Několik připomenutí (pokrač.)

- ③ Přesná definice zobrazení $f : A \rightarrow B$ zní:


Zobrazení $f : A \rightarrow B$ je podmnožina $A \times B$ taková, že pro všechna $a \in A$ existuje právě jedno $b \in B$ tak, že $(a, b) \in f$.

Potom lze dokázat:

- ① Pro libovolnou množinu B existuje právě jedno zobrazení $f : \emptyset \rightarrow B$.
- ② Pro libovolnou množinu A existuje právě jedno zobrazení $f : A \rightarrow \{b\}$.
- ③ Je-li A neprázdná množina, pak neexistuje zobrazení $f : A \rightarrow \emptyset$.


Několik připomenutí (pokrač.)

④ Komutativní trojúhelník:



znamená $h = g \cdot f$, tj. $h(x) = g(f(x))$ pro všechna $x \in X$.



⑤ Komutativní čtverec:



znamená $h \cdot f = k \cdot g$, tj. $h(f(x)) = k(g(x))$ pro všechna $x \in A$.

Několik připomenutí (pokrač.)

⑥ „Slepování“ komutativních diagramů:^a





^aDůležité: projděte si podrobně Příklady 2.2.1–2.2.3 skript.

Několik připomenutí (pokrač.)

7 „Trhání“ komutativních diagramů:^a

Jestliže je komutativní,



komutativní být nemusí.

^aDůležité: projděte si podrobně Příklady 2.2.1–2.2.3 skript.

Několik připomenutí (pokrač.)

- ⑧ Zobrazení $f : X \rightarrow Y$ je **prosté** (také: **injektivní** nebo **injekce**), když z rovnosti $f(x_1) = f(x_2)$ plyne $x_1 = x_2$.
- ⑨ Zobrazení $f : X \rightarrow Y$ je **na** (také: **surjektivní** nebo **surjekce**), když pro každé $y \in Y$ existuje x tak, že $f(x) = y$.
- ⑩ Zobrazení $f : X \rightarrow Y$ je **bijekce** (také: **vzájemně jednoznačné**), když f je injekce a surjekce současně.

Známá fakta

- ① Identita na X , tj. $\text{id}_X : X \rightarrow X$, kde $\text{id}_X : x \mapsto x$, je bijekce.
- ② Platí $h \cdot (g \cdot f) = (h \cdot g) \cdot f$ a $\text{id}_Y \cdot f = f = f \cdot \text{id}_X$, kdykoli je skládání definováno.
- ③ Složení injekcí je injekce, složení surjekcí je surjekce, složení bijekcí je bijekce.
- ④ $f : X \rightarrow Y$ je bijekce právě tehdy, když existuje jednoznačně určené^a $g : Y \rightarrow X$ tak, že $g \cdot f = \text{id}_X$ a $f \cdot g = \text{id}_Y$.

^aTomuto jednoznačně určenému zobrazení se říká **inverse** zobrazení f a značí se také f^{-1} .

Lineární zobrazení

Odpřednesenou látku naleznete v kapitolách 2.1, 2.2 a 4 skript *Abstraktní a konkrétní lineární algebra*.

Minulé přednášky

- ① Báze lineárního prostoru a souřadnice vektoru vzhledem ke konečné uspořádané bázi.

Dnešní přednáška

- ① Lineární zobrazení $f : L_1 \longrightarrow L_2$ zobecňuje zobrazení $\vec{x} \mapsto \mathbf{coord}_B(\vec{x})$, dané konečnou uspořádanou bází B .
- ② Zavedeme pojem matice lineárního zobrazení z \mathbb{F}^s do \mathbb{F}^r (vzhledem ke kanonickým bázím).

Velmi důležité připomenutí

Vektory z prostoru \mathbb{F}^n píšeme jako sloupce.

Definice (lineární zobrazení)

Ať L_1, L_2 jsou lineární prostory nad \mathbb{F} . Zobrazení $\mathbf{f} : L_1 \rightarrow L_2$, pro které platí $\mathbf{f}(\vec{x} + \vec{x}') = \mathbf{f}(\vec{x}) + \mathbf{f}(\vec{x}')$ a $\mathbf{f}(a \cdot \vec{x}) = a \cdot \mathbf{f}(\vec{x})$ pro vš. a z \mathbb{F} , pro vš. \vec{x}, \vec{x}' z L_1 , říkáme **lineární zobrazení** z L_1 do L_2 .

Příklady

- ① Ať L má uspořádanou bázi B o n prvcích. Zobrazení $\mathbf{coord}_B : L \rightarrow \mathbb{F}^n$ je lineární (minulá přednáška).
- ② Řada dalších...

Poznámka (princip superposice)

$\mathbf{f} : L_1 \rightarrow L_2$ je lineární právě tehdy, když platí rovnost

$$\mathbf{f}\left(\sum_{i=1}^n a_i \cdot \vec{x}_i\right) = \sum_{i=1}^n a_i \cdot \mathbf{f}(\vec{x}_i)$$

pro vš. a_i z \mathbb{F} a vš. \vec{x}_i z L_1 .

Tvrzení (základní algebraické vlastnosti lineárních zobrazení)

- ① Složení lineárních zobrazení je lineární. Identita je lineární zobrazení.
- ② Jsou-li $\mathbf{f} : L_1 \rightarrow L_2$ a $\mathbf{g} : L_1 \rightarrow L_2$ lineární zobrazení, pak i zobrazení
 - ① $\mathbf{f} + \mathbf{g}$ je lineární, kde $(\mathbf{f} + \mathbf{g})(\vec{x}) = \mathbf{f}(\vec{x}) + \mathbf{g}(\vec{x})$.
 - ② $a \cdot \mathbf{f}$ je lineární (a je skalár z \mathbb{F}), kde $(a \cdot \mathbf{f})(\vec{x}) = a \cdot \mathbf{f}(\vec{x})$.

Důkaz.

Přednáška.



Důsledek (lineární prostor lineárních zobrazení)

Pro pevné lineární prostory L_1 a L_2 nad \mathbb{F} je množina všech lineárních zobrazení z L_1 do L_2 lineární prostor nad \mathbb{F} . Tento prostor značíme $\text{Lin}(L_1, L_2)$.

Věta (lineární zobrazení je určeno hodnotami na bázi)

Ať B je báze^a lineárního prostoru L_1 , ať L_2 je libovolný lineární prostor. Pak zadat

- ① libovolné zobrazení $h : B \rightarrow L_2$,

je totéž jako zadat

- ② lineární zobrazení $f : L_1 \rightarrow L_2$.

^aPřipomenutí (téma 3A): každý lineární prostor má bázi.

Důkaz.

Pro prostory konečné dimenze: princip superposice.

Pro obecné prostory: mírně složitější.



Příklad (popis libovolného lineárního zobrazení $f : \mathbb{F}^s \rightarrow \mathbb{F}^r$)

Připomenutí: $K_s = (\mathbf{e}_1, \dots, \mathbf{e}_s)$ je kanonická báze prostoru \mathbb{F}^s .

Zadat lineární zobrazení $f : \mathbb{F}^s \rightarrow \mathbb{F}^r$ znamená zadat seznam s (ne nutně různých) hodnot

$$f(\mathbf{e}_1) = \mathbf{a}_1 = \begin{pmatrix} a_{11} \\ a_{21} \\ a_{31} \\ \vdots \\ a_{r1} \end{pmatrix}, f(\mathbf{e}_2) = \mathbf{a}_2 = \begin{pmatrix} a_{12} \\ a_{22} \\ a_{32} \\ \vdots \\ a_{r2} \end{pmatrix}, \dots, f(\mathbf{e}_s) = \mathbf{a}_s = \begin{pmatrix} a_{1s} \\ a_{2s} \\ a_{3s} \\ \vdots \\ a_{rs} \end{pmatrix}$$

v lineárním prostoru \mathbb{F}^r .

Tomuto seznamu říkáme **matice** (o r řádcích a s sloupcích).

Definice (matice)

Matici \mathbf{A} nad \mathbb{F} o r řádcích a s sloupcích je tabulka^a

$$\begin{pmatrix} a_{11} & a_{12} & \dots & a_{1s} \\ a_{21} & a_{22} & \dots & a_{2s} \\ \vdots & & & \\ a_{r1} & a_{r2} & \dots & a_{rs} \end{pmatrix}$$

^aBudeme také používat **položkový zápis** $\mathbf{A} = (a_{ij})_{i=1,\dots,r, j=1,\dots,s}$ nebo **sloupcový zápis** $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_s)$.

Nebudeme používat: matici typu $r \times s$, rozměrů $r \times s$, atd., případně ještě horší značení $n \times m$. (Nebo $m \times n$?) ☺

Poznámka

Matici $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_s)$ o r řádcích a s sloupcích **budeme ztotožňovat** s lineárním zobrazením

$$\mathbf{A} : \mathbf{e}_j \mapsto \mathbf{a}_j, \quad j = 1, \dots, s$$


z prostoru \mathbb{F}^s do prostoru \mathbb{F}^r , a budeme psát $\mathbf{A} : \mathbb{F}^s \longrightarrow \mathbb{F}^r$.



Příklad (matice základních lineárních transformací v \mathbb{R}^2)

Kanonická báze $K_2 = (\mathbf{e}_1, \mathbf{e}_2)$ v \mathbb{R}^2 . Matice některých lineárních zobrazení z \mathbb{R}^2 do \mathbb{R}^2 (vzhledem ke K_2) jsou:

- ① Projekce na osu x je ztotožněna s maticí $\mathbf{P}_x = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}$.




Analogicky: projekce na osu y je ztotožněna s maticí $\mathbf{P}_y = \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix}$.

Příklad (matice základních lineárních transformací v \mathbb{R}^2 , pokrač.)

- ② Rotace (o úhel α) je ztotožněna s maticí

$$\mathbf{R}_\alpha = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}.$$



- ③ Změna měřítka ($a \neq 0$ a $b \neq 0$) je ztotožněna s maticí

$$\begin{pmatrix} a & 0 \\ 0 & b \end{pmatrix}. \text{ Pro } a = 1, b = -1 \text{ dostaneme reflexi: } \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}.$$

Příklad (matice základních lineárních transformací v \mathbb{R}^2 , pokrač.)

- ④ Zkosení^a (také: shear) je ztotožněno s maticí

$$\mathbf{S}_{a,b} = \begin{pmatrix} 1 & b \\ a & 1 \end{pmatrix}$$

kde $a, b \in \mathbb{R}$.

^aSpeciální typy zkosení (nad obecným tělesem) budou hrát důležitou roli při řešení soustav rovnic.

Co už nyní víme?

Například diagram

$$\mathbb{R}^2 \xrightarrow{\mathbf{R}_\alpha} \mathbb{R}^2 \xrightarrow{\mathbf{P}_x} \mathbb{R}^2$$

znamená následující: **nejprve** otočte o úhel α , **potom** proved' te projekci na osu x .

Značit se to musí $\mathbf{P}_x \cdot \mathbf{R}_\alpha$ (jde o **skládání** lineárních zobrazení). Co ale „násobení tabulek“ znamená? Odpověď: **jde o novou matici**.

Jak novou matici najít?

$$\mathbf{e}_j \mapsto j\text{-tý sloupec matice } \mathbf{R}_\alpha \mapsto ???$$

- ① Násobení (skládání) matic: **příští přednáška** (téma 4B).
- ② Zbytek dnešní přednášky: **jak obecná matice $\mathbf{A} : \mathbb{F}^s \longrightarrow \mathbb{F}^r$ „zachází“ s obecným vektorem z prostoru \mathbb{F}^s ?**

Tvrzení (výpočet hodnoty matice A v obecném vektoru x)

Pro matici $A : \mathbb{F}^s \rightarrow \mathbb{F}^r$ se sloupcovým zápisem $(\mathbf{a}_1, \dots, \mathbf{a}_s)$ a pro

vektor $x = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_s \end{pmatrix}$ platí

$$A : x \mapsto \sum_{j=1}^s x_j \cdot \mathbf{a}_j$$

Důkaz.

Protože $A : e_j \mapsto \mathbf{a}_j$, tak $A : \sum_{j=1}^s x_j \cdot e_j \mapsto \sum_{j=1}^s x_j \cdot \mathbf{a}_j$. ■

Značení (násobení matice vektorem)

Vektor $\sum_{j=1}^s x_j \cdot \mathbf{a}_j$ značíme $A \cdot x$.

Příklad (rotace vektoru v \mathbb{R}^2)

Rotace (o úhel α): $\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$. Potom součin

$$\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = x_1 \cdot \begin{pmatrix} \cos \alpha \\ \sin \alpha \end{pmatrix} + x_2 \cdot \begin{pmatrix} -\sin \alpha \\ \cos \alpha \end{pmatrix} = \begin{pmatrix} x_1 \cos \alpha - x_2 \sin \alpha \\ x_1 \sin \alpha + x_2 \cos \alpha \end{pmatrix}$$

dává výsledek otočení vektoru $\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$ o úhel α .

Například pro $\alpha = \frac{\pi}{4}$:

$$\begin{pmatrix} \frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} & \frac{\sqrt{2}}{2} \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} x_1 \frac{\sqrt{2}}{2} - x_2 \frac{\sqrt{2}}{2} \\ x_1 \frac{\sqrt{2}}{2} + x_2 \frac{\sqrt{2}}{2} \end{pmatrix} = \frac{\sqrt{2}}{2} \cdot \begin{pmatrix} x_1 - x_2 \\ x_1 + x_2 \end{pmatrix}$$

Poznámka (další význam zápisu $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$)

Zápis $\mathbf{A} \cdot \mathbf{x}$ pro \mathbf{x} v \mathbb{F}^s , kóduje **hodnotu** lineárního zobrazení $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$ v bodě \mathbf{x} .

Zvolme **pevné** \mathbf{b} v \mathbb{F}^r . Hledejme **všechna** \mathbf{x} v \mathbb{F}^s taková, že $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$. Na tento problém se lze dívat dvěma způsoby:

- ① Hledáme **vzor** bodu \mathbf{b} při lineárním zobrazení $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$.
- ② Řešíme **soustavu lineárních rovnic**.

Počet sloupců matice \mathbf{A} je počet neznámých, počet řádků matice \mathbf{A} je počet rovnic v soustavě.

Příklad

$$\begin{pmatrix} 1 & 0 & -3 & 4 \\ 2 & 7 & 6 & 3 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix} = \begin{pmatrix} 24 \\ 8 \end{pmatrix} \text{ je } \begin{array}{l} x_1 \\ 2x_1 + 7x_2 + 6x_3 + 3x_4 = 8 \end{array} \begin{array}{l} -3x_3 + 4x_4 = 24 \end{array}$$

Algebra matic

Odpřednesenou látku najeznete v kapitolách 2.1, 2.2 a 4 skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

- ① Pojem **lineárního zobrazení** z \mathbb{F}^s do \mathbb{F}^r a jeho maticový zápis (vzhledem ke kanonickým bázím).

Dnešní přednáška

- ① Zavedeme základní **algebraické operace s maticemi**.
- ② V příští přednášce vše zobecníme pro prostory **konečných dimensí**; zavedeme pojem **matice lineárního zobrazení** (vzhledem k pevně zvoleným bázím).

Velmi důležité připomenutí

Vektory z prostoru \mathbb{F}^n píšeme jako sloupce.

Již víme: $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$ je lineární prostor nad \mathbb{F} .

Jak se operace v $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$ projeví na „manipulaci s tabulkami“?

Použijeme sloupcový zápis matic.

Pro $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_s)$ a $\mathbf{B} = (\mathbf{b}_1, \dots, \mathbf{b}_s)$ a skalár a z \mathbb{F} je:

- ① $\mathbf{A} + \mathbf{B} : \mathbb{F}^s \longrightarrow \mathbb{F}^r$ matice se sloupcovým zápisem
 $(\mathbf{a}_1 + \mathbf{b}_1, \dots, \mathbf{a}_s + \mathbf{b}_s)$. Zápis $\mathbf{A} + \mathbf{B}$ čteme součet matic \mathbf{A} a \mathbf{B} .
- ② $a \cdot \mathbf{A} : \mathbb{F}^s \longrightarrow \mathbb{F}^r$ je matice se sloupcovým zápisem
 $(a \cdot \mathbf{a}_1, \dots, a \cdot \mathbf{a}_s)$. Zápis $a \cdot \mathbf{A}$ čteme součin skaláru a a matice \mathbf{A} .

Nulový vektor^a v lineárním prostoru $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$ je matice

$\mathbf{0}_{s,r} = \underbrace{(\mathbf{o}, \dots, \mathbf{o})}_{s\text{-krát}}$, kde \mathbf{o} je nulový vektor v \mathbb{F}^r .

^aŘíkáme také: nulová matice.

Příklad: výpočty v $\text{Lin}(\mathbb{R}^3, \mathbb{R}^2)$

① Příklad součtu:

$$\begin{pmatrix} 5 & 3 & 6 \\ -1 & 0 & 7 \end{pmatrix} + \begin{pmatrix} 2 & 5 & -2 \\ 1 & 4 & 3 \end{pmatrix} = \begin{pmatrix} 7 & 8 & 4 \\ 0 & 4 & 10 \end{pmatrix}$$

② Příklad skalárního násobku:

$$(-2) \cdot \begin{pmatrix} -3 & 1 & 2 \\ 2 & 6 & 4 \end{pmatrix} = \begin{pmatrix} 6 & -2 & -4 \\ -4 & -12 & -8 \end{pmatrix}$$

③ Nulový vektor v $\text{v Lin}(\mathbb{R}^3, \mathbb{R}^2)$ je:

$$\mathbf{0}_{3,2} = \begin{pmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \end{pmatrix}$$

Poznámky k součtu matic a ke skalárnímu násobku matic

Sčítání matic a skalární násobení skalárem jsou operace v lineárním prostoru $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$. Přirozená čísla s a r jsou **pevná**. Proto:

- ① Sčítat můžeme pouze matice **stejných** rozměrů. Pro matice různých rozměrů **není sčítání definováno**.

Sloupcový zápis součtu

$$(\mathbf{a}_1, \dots, \mathbf{a}_s) + (\mathbf{b}_1, \dots, \mathbf{b}_s) = (\mathbf{a}_1 + \mathbf{b}_1, \dots, \mathbf{a}_s + \mathbf{b}_s)$$

dává okamžitě „položkový návod“: chcete-li sečíst dvě matice stejných rozměrů, sečtěte položky na odpovídajících posicích.

- ② Sloupcový zápis skalárního násobku

$$a \cdot (\mathbf{a}_1, \dots, \mathbf{a}_s) = (a \cdot \mathbf{a}_1, \dots, a \cdot \mathbf{a}_s)$$

dává okamžitě „položkový návod“: chcete-li matici vynásobit skalárem, vynásobte tímto skalárem každou položku matice.

Vlastnosti součtu matic a skalárního násobku matic

Protože $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$ je lineární prostor nad \mathbb{F} , platí:

- ① $\mathbf{A} + \mathbf{O}_{s,r} = \mathbf{O}_{s,r} + \mathbf{A} = \mathbf{A}$, pro vš. \mathbf{A} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$.
- ② $\mathbf{A} + \mathbf{B} = \mathbf{B} + \mathbf{A}$, pro vš. \mathbf{A}, \mathbf{B} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$.
- ③ $\mathbf{A} + (\mathbf{B} + \mathbf{C}) = (\mathbf{A} + \mathbf{B}) + \mathbf{C}$, pro vš. $\mathbf{A}, \mathbf{B}, \mathbf{C}$ z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$.
- ④ Pro každé \mathbf{A} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$ existuje právě jedno^a \mathbf{B} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$ tak, že $\mathbf{A} + \mathbf{B} = \mathbf{O}_{s,r}$.
- ⑤ $1 \cdot \mathbf{A} = \mathbf{A}$ pro vš. \mathbf{A} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$.
- ⑥ $a \cdot (b \cdot \mathbf{A}) = (a \cdot b) \cdot \mathbf{A}$ pro vš. $a, b \in \mathbb{F}$ a vš. \mathbf{A} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$.
- ⑦ $a \cdot (\mathbf{A} + \mathbf{B}) = a \cdot \mathbf{A} + a \cdot \mathbf{B}$ pro vš. $a \in \mathbb{F}$ a pro vš. \mathbf{A}, \mathbf{B} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$.
- ⑧ $(a + b) \cdot \mathbf{A} = a \cdot \mathbf{A} + b \cdot \mathbf{A}$ pro vš. $a, b \in \mathbb{F}$ a pro vš. \mathbf{A} z $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$.

^aTomuto jednoznačně určenému \mathbf{B} říkáme **opačná** matice k matici \mathbf{A} a značíme ji $-\mathbf{A}$.



Připomenutí značení (téma 4A)

Matici \mathbf{A} se sloupcovým zápisem $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_s)$ je lineární zobrazení z \mathbb{F}^s do \mathbb{F}^r , dané předpisem

$$\mathbf{e}_j \mapsto \mathbf{a}_j, \quad j = 1, \dots, s$$

Princip superposice dává

$$\sum_{j=1}^s x_j \cdot \mathbf{e}_j \mapsto \sum_{j=1}^s x_j \cdot \mathbf{a}_j$$

Pro $\mathbf{x} = \sum_{j=1}^s x_j \cdot \mathbf{e}_j$ značíme $\sum_{j=1}^s x_j \cdot \mathbf{a}_j$ jako $\mathbf{A} \cdot \mathbf{x}$.

Proto

$$\mathbf{A} : \mathbf{x} \mapsto \mathbf{A} \cdot \mathbf{x}$$

Definice (součin matic)

Pro situaci^a

$$\begin{array}{ccccc} \mathbb{F}^s & \xrightarrow{\mathbf{A}} & \mathbb{F}^p & \xrightarrow{\mathbf{B}} & \mathbb{F}^r \\ \mathbf{e}_j & \longmapsto & \mathbf{a}_j & \longmapsto & \mathbf{B} \cdot \mathbf{a}_j \end{array}$$

je $\mathbf{B} \cdot \mathbf{A}$ matice, ^b jejíž j -tý sloupec je $\mathbf{B} \cdot \mathbf{a}_j$, kde \mathbf{a}_j je j -tý sloupec matice \mathbf{A} . Ve sloupcovém zápisu tedy platí $\mathbf{B} \cdot \mathbf{A} = (\mathbf{B} \cdot \mathbf{a}_1, \dots, \mathbf{B} \cdot \mathbf{a}_s)$.

Matici $\mathbf{B} \cdot \mathbf{A}$ říkáme **součin matic** \mathbf{B} a \mathbf{A} .

^aDiagram okamžitě dává **rozměrovou zkoušku** pro součin matic $\mathbf{B} \cdot \mathbf{A}$: počet řádků matice \mathbf{A} musí být roven počtu sloupců matice \mathbf{B} . **Jindy součin matic ne definujeme, protože by skládání nedávalo smysl.**

^bPoložkový zápis součinu $\mathbf{B} \cdot \mathbf{A}$: pro $\mathbf{A} = (a_{kj})_{k=1,\dots,p, j=1,\dots,s}$ a $\mathbf{B} = (b_{ik})_{i=1,\dots,r, k=1,\dots,p}$ je $\mathbf{B} \cdot \mathbf{A}$ matice s položkami $(c_{ij})_{i=1,\dots,r, j=1,\dots,s}$, kde

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



Příklad (matice složených lineárních transformací v \mathbb{R}^2)

Projekce na osu x : $\begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}$, rotace (o úhel α): $\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$.

Součin matic

$$\begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ 0 & 0 \end{pmatrix}$$

je matice lineárního zobrazení „**nejprve** otočte o úhel α , **potom** spočtěte projekci na osu x “.

Součin matic

$$\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} \cdot \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} \cos \alpha & 0 \\ \sin \alpha & 0 \end{pmatrix}$$

je matice lineárního zobrazení „**nejprve** spočtěte projekci na osu x , **potom** otočte o úhel α “.

Příklad (reflexe podle osy, která svírá úhel α s osou x)

Jde o složené zobrazení: nejdříve rotace o úhel $-\alpha$, potom reflexe, nakonec rotace o úhel α .

$$\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} \cdot \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix} \cdot \begin{pmatrix} \cos(-\alpha) & -\sin(-\alpha) \\ \sin(-\alpha) & \cos(-\alpha) \end{pmatrix} =$$

$$\begin{pmatrix} \cos 2\alpha & \sin 2\alpha \\ \sin 2\alpha & -\cos 2\alpha \end{pmatrix}$$

Poznámka

Analogicky lze vytvořit matice základních lineárních transformací v \mathbb{R}^n , $n \geq 3$. Aplikace: matematická analýza, fyzika, grafika.^a

^aDůležité: projděte si podrobně Příklady 4.1.6 a 4.2.9 skript.

Vlastnosti operací s maticemi

- ① Pro součin platí asociativní zákon $\mathbf{C} \cdot (\mathbf{B} \cdot \mathbf{A}) = (\mathbf{C} \cdot \mathbf{B}) \cdot \mathbf{A}$, kdykoli jsou jednotlivé součiny definovány.
- ② Obecně neplatí komutativní zákon $\mathbf{B} \cdot \mathbf{A} = \mathbf{A} \cdot \mathbf{B}$ (i když jsou oba součiny definovány).
- ③ Pro každé n definujeme jednotkovou matici^a $\mathbf{E}_n : \mathbb{F}^n \rightarrow \mathbb{F}^n$ takto: $\mathbf{E}_n = (\mathbf{e}_1, \dots, \mathbf{e}_n)$, kde $\mathbf{e}_1, \dots, \mathbf{e}_n$ jsou vektory kanonické báze \mathbb{F}^n .

Potom pro každou matici $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$ platí:

$$\mathbf{E}_r \cdot \mathbf{A} = \mathbf{A} = \mathbf{A} \cdot \mathbf{E}_s.$$

^a Matice \mathbf{E}_n je maticí identického lineárního zobrazení $\mathbf{id} : \mathbb{F}^n \rightarrow \mathbb{F}^n$.

Důkaz.

Okamžitě z vlastností lineárních zobrazení.

Příklad (popis obrazu projekce na osu x v \mathbb{R}^2)

Ať $\mathbf{P}_x : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je projekce na osu x , ztotožněná s maticí

$$\mathbf{P}_x = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}.$$

Zajímá nás, zda vektor $\mathbf{b} = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$ je projekcí nějakého vektoru

$\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$. To lze zjistit algebrou matic:

$$\mathbf{P}_x \cdot \mathbf{x} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ 0 \end{pmatrix} \neq \begin{pmatrix} 1 \\ 2 \end{pmatrix} = \mathbf{b}$$

Žádný vektor \mathbf{x} , jehož projekce na osu x je vektor \mathbf{b} , neexistuje.

To ale znamená: soustava rovnic $\mathbf{P}_x \cdot \mathbf{x} = \mathbf{b}$ nemá řešení!

Příklad (popis vzoru projekce na osu x v \mathbb{R}^2)

Ať $\mathbf{P}_x : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je projekce na osu x , ztotožněná s maticí

$$\mathbf{P}_x = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}.$$

Pro vektor $\mathbf{b} = \begin{pmatrix} 3 \\ 0 \end{pmatrix}$ nás zajímají všechny vektory $\mathbf{x} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$, které se na \mathbf{b} projekcí zobrazí. To lze zjistit algebrou matic:

$$\mathbf{P}_x \cdot \mathbf{x} = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ 0 \end{pmatrix} = \begin{pmatrix} 3 \\ 0 \end{pmatrix} = \mathbf{b}$$

Řešením soustavy rovnic $\mathbf{P}_x \cdot \mathbf{x} = \mathbf{b}$ je množina všech vektorů \mathbf{x} tvaru $\begin{pmatrix} 3 \\ x_2 \end{pmatrix}$, kde x_2 je libovolné reálné číslo.^a


^a Řešení lze napsat i ve tvaru $\begin{pmatrix} 3 \\ 0 \end{pmatrix} + \text{span}(\begin{pmatrix} 0 \\ 1 \end{pmatrix})$. Jak uvidíme, tento druhý způsob zápisu řešení bude mít mnohé výhody.

Příklad (projekce na osu x v \mathbb{R}^2 není invertibilní)

Ať $\mathbf{P}_x : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je projekce na osu x , ztotožněná s maticí

$$\mathbf{P}_x = \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix}.$$

Existují matice $\mathbf{A} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ a $\mathbf{B} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ takové, že



Intuice: žádné takové matice neexistují, protože matice jsou lineární zobrazení.

Jak intuici dokázat? Algebrou matic!

Příklad (projekce na osu $x v \mathbb{R}^2$ není invertibilní, pokrač.)

Ptáme se, zda existují matice $\mathbf{A} = \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix}$, $\mathbf{B} = \begin{pmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{pmatrix}$ takové, že platí rovnosti

$$\begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad \text{a} \quad \begin{pmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{pmatrix} \cdot \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

Takové matice neexistují, protože

$$\begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{pmatrix} = \begin{pmatrix} a_{11} & a_{12} \\ 0 & 0 \end{pmatrix} \neq \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

$$\begin{pmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{pmatrix} \cdot \begin{pmatrix} 1 & 0 \\ 0 & 0 \end{pmatrix} = \begin{pmatrix} b_{11} & 0 \\ b_{21} & 0 \end{pmatrix} \neq \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

Důsledek

Nenulovost čtvercové matice \mathbf{A} typu $n \times n$ nezaručuje existenci matic \mathbf{X} a \mathbf{Y} , které by řešily rovnice $\mathbf{A} \cdot \mathbf{X} = \mathbf{E}_n$ a $\mathbf{Y} \cdot \mathbf{A} = \mathbf{E}_n$.

Proč nás to zajímá?

Otázka řešitelnosti obecných maticových rovnic $\mathbf{A} \cdot \mathbf{X} = \mathbf{B}$ a $\mathbf{Y} \cdot \mathbf{A} = \mathbf{C}$ je důležitá. Proč?

Jde o zobecnění řešení soustav lineárních rovnic.

Lineární zobrazení, část 2

Odpřednesenou látku naleznete v kapitolách 2.3, 3.4 a 9.1 skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

- 1 Matice $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_s)$ (sloupcový zápis matice, každý sloupec \mathbf{a}_j je vektor z \mathbb{F}^r) je **ztotožněna** s lineárním zobrazením $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$, $\mathbf{e}_j \mapsto \mathbf{a}_j$.


Operace s maticemi odpovídají operacím s lineárními zobrazeními.

Dnešní přednáška

- 1 Pojmy **jádro**, **obraz**, **defekt** a **hodnost** lineárního zobrazení.
Tyto pojmy umožní jemnější klasifikaci lineárních zobrazení.
- 2 Pojem matice **obecného** lineárního zobrazení $\mathbf{f} : L_1 \rightarrow L_2$ vzhledem k **obecným** uspořádaným bázím. Prostory L_1 a L_2 musí mít konečnou dimensi.

Připomenutí (téma 4A a 3B)

- ① Até L_1, L_2 jsou lineární prostory nad \mathbb{F} . Zobrazení $\mathbf{f} : L_1 \rightarrow L_2$, pro které platí $\mathbf{f}(\vec{x} + \vec{x}') = \mathbf{f}(\vec{x}) + \mathbf{f}(\vec{x}')$ a $\mathbf{f}(a \cdot \vec{x}) = a \cdot \mathbf{f}(\vec{x})$ pro vš. a z \mathbb{F} a vš. \vec{x}, \vec{x}' z L_1 , říkáme **lineární zobrazení** z L_1 do L_2 .
- ② Zápis $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$ znamená^a $\mathbf{A} : \mathbf{e}_j \mapsto j$ -tý sloupec \mathbf{A} .
 Tudíž platí $\mathbf{x} \mapsto \mathbf{A} \cdot \mathbf{x}$, pro všechna \mathbf{x} z \mathbb{F}^s .
- ③ Trojúhelník



je komutativní.

^aV terminologii dnešní přednášky: $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$ je maticí zobrazení $\mathbf{A} : \mathbf{e}_j \mapsto j$ -tý sloupec \mathbf{A} vzhledem ke kanonické bázi. Ale nepředbíhejme 😊

Definice (speciální vlastnosti lineárních zobrazení)

Lineárnímu zobrazení $f : L_1 \rightarrow L_2$ říkáme:

- ① **monomorfismus**, je-li f injektivní (také: prosté) zobrazení.
- ② **epimorfismus**, je-li f surjektivní (také: na) zobrazení.
- ③ **isomorfismus**, je-li f bijektivní (také: prosté a na) zobrazení.^a

^aEkvivalentně: k zobrazení f existuje inversní zobrazení f^{-1} a toto inversní zobrazení je opět lineární.

Tvrzení

Složení monomorfismů/epimorfismů/isomorfismů je monomorfismus/epimorfismus/isomorfismus. Identita je isomorfismus.

Důkaz.


Přednáška.

Definice (obraz a jádro)

Ať $f : L_1 \rightarrow L_2$ je lineární zobrazení. Množině

$\ker(f) = \{\vec{x} \mid f(\vec{x}) = \vec{o}\}$ říkáme **jádro** f , množině

$\text{im}(f) = \{f(\vec{x}) \mid \vec{x} \text{ z } L_1\}$ říkáme **obraz** f .



Slogany (tj. reklamní hesla, nikoli skutečnost)

Jádro f říká, jak moc je f monomorfismus.

Obraz f říká, jak moc je f epimorfismus.

Tvrzení

Ať $f : L_1 \rightarrow L_2$ je lineární zobrazení. Pak $\ker(f)$ je podprostor L_1 , $\text{im}(f)$ je podprostor L_2 .^a

^aObecněji: $\{f(\vec{w}) \mid \vec{w} \in W\}$ je podprostor L_2 , pro jakýkoli podprostor W prostoru L_1 .

Důkaz.

Přednáška.



Definice (defekt a hodnost lineárního zobrazení)


Ať $f : L_1 \rightarrow L_2$ je lineární zobrazení, ať prostor L_1 má konečnou dimensi. Číslu $\text{def}(f) = \dim(\ker(f))$ říkáme **defekt** lineárního zobrazení f a číslu $\text{rank}(f) = \dim(\text{im}(f))$ říkáme **hodnost** (také: **rank**) lineárního zobrazení f .

Tvrzení (Věta o dimensi jádra a obrazu)

Ať $f : L_1 \rightarrow L_2$ je lineární zobrazení, ať prostor L_1 má konečnou dimensi. Pak $\text{def}(f) + \text{rank}(f) = \dim(L_1)$.

Důkaz.

Bez důkazu (důkaz je například ve [skriptech](#), Věta 3.3.6).



$$\text{def}(f) = \dim(\ker(f))$$

$$\text{rank}(f) = \dim(\text{im}(f))$$

Tvrzení (charakterisace monomorfismů)

Ať $f : L_1 \rightarrow L_2$ je lineární zobrazení, ať prostor L_1 má konečnou dimensi. Pak je ekvivalentní:

- ① f je monomorfismus.
- ② $\text{def}(f) = 0$.
- ③ f respektuje lineární nezávislost (tj. obraz lineárně nezávislé množiny je opět lineárně nezávislá množina).

Důkaz.

Přednáška.



Důsledek (monomorfismy a soustavy rovnic)

$A : \mathbb{F}^s \rightarrow \mathbb{F}^r$ je monomorfismus právě tehdy, když **soustava**
 $A \cdot x = o$ má pouze triviální řešení.

Tvrzení (charakterisace isomorfismů)

Ať $f : L_1 \rightarrow L_2$ je lineární zobrazení, ať prostor L_1 má konečnou dimensi. Pak je ekvivalentní:

- ① f je isomorfismus.
- ② f je monomorfismus a epimorfismus současně.
- ③ $\text{def}(f) = 0$ a $\text{im}(f) = L_2$ současně.
- ④ $\text{def}(f) = 0$ a $\dim(L_1) = \dim(L_2)$.
- ⑤ f respektuje lineární nezávislost (tj. obraz lineárně nezávislé množiny je opět lineárně nezávislá množina) a každá rovnice $f(\vec{x}) = \vec{b}$ má alespoň jedno řešení.

Důkaz.

Přednáška.



Důsledek (isomorfismy a soustavy rovnic)

A : $\mathbb{F}^s \rightarrow \mathbb{F}^r$ je isomorfismus právě tehdy, když $s = r$ a každá soustava $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$ má právě jedno řešení.

Definice (regulární a singulární matice)

Matrice $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ typu je **regulární** (také: **invertibilní**, také: **isomorfismus**), pokud existuje jednoznačně určená matice \mathbf{A}^{-1} taková, že platí rovnosti $\mathbf{A}^{-1} \cdot \mathbf{A} = \mathbf{E}_n = \mathbf{A} \cdot \mathbf{A}^{-1}$. Matici \mathbf{A}^{-1} říkáme **inverse** matice \mathbf{A} .

Matrice $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ je **singulární**, pokud není regulární.

Příklad (rotace o úhel α v \mathbb{R}^2 je isomorfismus)

$$\mathbf{R}_\alpha = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$$

je regulární (invertibilní) matice.^a

^aInversním zobrazením rotace o úhel α je rotace o úhel $-\alpha$.

Důsledek (isomorfismy prostorů konečné dimenze)

Ať $\dim(L_1) = \dim(L_2) = n$. Potom je, pro lineární zobrazení $f : L_1 \rightarrow L_2$, ekvivalentní:

- ① f je monomorfismus.
- ② f je epimorfismus.
- ③ f je isomorfismus.

Příklad (důležité a užitečné: Lagrangeova interpolace)


Ať a_1, \dots, a_n jsou navzájem různá reálná čísla. Lineární zobrazení

$$\text{ev}_{(a_1, \dots, a_n)} : \mathbb{R}^{\leq n-1}[x] \rightarrow \mathbb{R}^n, \quad p(x) \mapsto \begin{pmatrix} p(a_1) \\ p(a_2) \\ \vdots \\ p(a_n) \end{pmatrix}$$

je monomorfismus, tudíž isomorfismus.

Příklad (Lagrangeova interpolace, pokrač.)

$\text{ev}_{(a_1, \dots, a_n)}$ je izomorfismus: pro každou n -tici $\begin{pmatrix} b_1 \\ \vdots \\ b_n \end{pmatrix}$ v \mathbb{R}^n existuje jediný polynom^a $p_{(b_1, \dots, b_n)}(x)$ v prostoru $\mathbb{R}^{\leq n-1}[x]$ tak, že platí $p_{(b_1, \dots, b_n)}(a_i) = b_i$ pro všechna $i = 1, \dots, n$.



^aŘíká se mu Lagrangeův interpolační polynom, viz skripta, Příklad 3.3.9.

Tvrzení (důležité)

Ať $B = (\vec{b}_1, \dots, \vec{b}_n)$ je uspořádaná báze prostoru L . Potom výpočet souřadnic v bázi B

$$\mathbf{coord}_B : L \rightarrow \mathbb{F}^n, \quad \vec{x} \mapsto \mathbf{coord}_B(\vec{x})$$

je isomorfismus.

Důkaz.

Přednáška.



Poznámka (důležitá)

Protože isomorfní lineární prostory se z abstraktního hlediska nijak neliší, vidíme: až na isomorfismus neexistují jiné konečně dimensionální lineární prostory nad \mathbb{F} než prostory tvaru \mathbb{F}^n .

Definice (matice lineárního zobrazení)

Ať $\mathbf{f} : L_1 \rightarrow L_2$ je lineární zobrazení, ať $B = (\vec{b}_1, \dots, \vec{b}_s)$ a $C = (\vec{c}_1, \dots, \vec{c}_r)$ jsou uspořádané báze prostorů L_1 a L_2 . **Matice zobrazení** \mathbf{f} (vzhledem k B a C) je taková matice \mathbf{A}_f , pro kterou platí

$$\begin{array}{ccc} \mathbb{F}^s & \xrightarrow{x \mapsto \mathbf{A}_f \cdot x} & \mathbb{F}^r \\ \text{coord}_B \uparrow & & \uparrow \text{coord}_C \\ L_1 & \xrightarrow[\mathbf{f}]{} & L_2 \end{array}$$

neboli:

$$\text{coord}_B(\vec{x}) \longmapsto \mathbf{A}_f \cdot \text{coord}_B(\vec{x}) = \text{coord}_C(\mathbf{f}(\vec{x}))$$


$$\vec{x} \longmapsto \mathbf{f}(\vec{x})$$

pro každý vektor \vec{x} .

Tvrzení (výpočet matice lineárního zobrazení)

Ať $\mathbf{f} : L_1 \rightarrow L_2$ je lineární zobrazení, ať $B = (\vec{b}_1, \dots, \vec{b}_s)$ a $C = (\vec{c}_1, \dots, \vec{c}_r)$ jsou uspořádané báze prostorů L_1 a L_2 . Potom matice \mathbf{A}_f má r řádků a s sloupců. Navíc j -tý sloupec matice \mathbf{A}_f je tvořen souřadnicemi $\mathbf{coord}_C(\mathbf{f}(\vec{b}_j))$, zapsanými do sloupce.


Důkaz.



Věta (matice složeného zobrazení)

Ať L_1, L_2, L_3 mají uspořádané báze $B = (\vec{b}_1, \dots, \vec{b}_s)$, $C = (\vec{c}_1, \dots, \vec{c}_p)$ a $D = (\vec{d}_1, \dots, \vec{d}_r)$. Ať $\mathbf{f} : L_1 \rightarrow L_2$ a $\mathbf{g} : L_2 \rightarrow L_3$ jsou lineární zobrazení s maticemi \mathbf{A}_f (vzhledem k B a C) a \mathbf{A}_g (vzhledem k C a D). Potom $\mathbf{g} \cdot \mathbf{f} : L_1 \rightarrow L_3$ má matici $\mathbf{A}_g \cdot \mathbf{A}_f$ (vzhledem k B a D).

Důkaz.




Věta (matice isomorfismu)

Ať L_1, L_2 mají uspořádané báze $B = (\vec{b}_1, \dots, \vec{b}_n)$,
 $C = (\vec{c}_1, \dots, \vec{c}_n)$. Ať lineární zobrazení $f : L_1 \rightarrow L_2$ je isomorfismus
 s maticí zobrazení \mathbf{A}_f (vzhledem k B a C). Potom existuje
 jednoznačně určená matice \mathbf{A}_f^{-1} splňující rovnosti
 $\mathbf{A}_f^{-1} \cdot \mathbf{A}_f = \mathbf{E}_n = \mathbf{A}_f \cdot \mathbf{A}_f^{-1}$. Matice \mathbf{A}_f^{-1} je matice $\mathbf{A}_{f^{-1}}$ inversního
 zobrazení f^{-1} (vzhledem k C a B).^a

^aTj. regulární (invertibilní) matice jsou přesně matice isomorfismů.

Důkaz.



Proto $\mathbf{A}_f^{-1} \cdot \mathbf{A}_f = \mathbf{E}_n$. Druhá rovnost analogicky.

Příklad (výpočet matice pro derivování)

$\mathbb{F}^{\leq 3}[x]$ je prostor polynomů stupně ≤ 3 nad tělesem \mathbb{F} . Báze $B = (x^3, x^2, x^1, 1)$. Zobrazení

$$\begin{aligned}\mathbf{der} : \mathbb{F}^{\leq 3}[x] &\rightarrow \mathbb{F}^{\leq 3}[x], \\ (a_3x^3 + a_2x^2 + a_1x + a_0) &\mapsto (3a_3x^2 + 2a_2x + a_1)\end{aligned}$$

je lineární a má následující matici vzhledem k B :

$$\mathbf{A}_{\mathbf{der}} = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 3 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

Matice pro druhou derivaci: spočítáme součin $\mathbf{A}_{\mathbf{der}} \cdot \mathbf{A}_{\mathbf{der}}$, atd.

Příklad (matice zobrazení vzhledem k nekanonické bázi)

Lineární zobrazení $f : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je dáno hodnotami

$$f\left(\begin{pmatrix} 1 \\ -1 \end{pmatrix}\right) = 2 \cdot \begin{pmatrix} 1 \\ -1 \end{pmatrix} \quad \text{a} \quad f\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right) = \frac{1}{3} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

Zobrazení f tedy:

- ① „Prodlužuje“ $2 \times$ měřítka v ose druhého a čtvrtého kvadrantu.
- ② „Zkracuje“ $3 \times$ měřítka v ose prvního a třetího kvadrantu.


Vzhledem k nekanonické bázi $B = (\begin{pmatrix} 1 \\ -1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \end{pmatrix})$ má tedy f matici

$$\mathbf{A}_f = \begin{pmatrix} 2 & 0 \\ 0 & \frac{1}{3} \end{pmatrix}$$

Jak spočítat matici \mathbf{B}_f zobrazení f vzhledem ke kanonické bázi K_2 ?

Příklad (pokrač.)

Myšlenka řešení: hledaná matice \mathbf{B}_f musí splňovat rovnici $\mathbf{B}_f = \mathbf{S} \cdot \mathbf{A}_f \cdot \mathbf{T}$, kde



Jak najít matice \mathbf{S} a \mathbf{T} ? **Jednoduše:** jsou to matice identického zobrazení, navíc evidentně platí $\mathbf{T} = \mathbf{S}^{-1}$.

Příklad (pokrač.)

Platí (díky tomu, co jsme již dokázali)

$$\mathbf{S} = \begin{pmatrix} 1 & 1 \\ -1 & 1 \end{pmatrix} \quad \mathbf{T} = \begin{pmatrix} \frac{1}{2} & -\frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$

a tedy

$$\mathbf{B}_f = \mathbf{S} \cdot \mathbf{A}_f \cdot \mathbf{T} = \begin{pmatrix} 1 & 1 \\ -1 & 1 \end{pmatrix} \cdot \begin{pmatrix} 2 & 0 \\ 0 & \frac{1}{3} \end{pmatrix} \cdot \begin{pmatrix} \frac{1}{2} & -\frac{1}{2} \\ \frac{1}{2} & \frac{1}{2} \end{pmatrix} = \begin{pmatrix} \frac{7}{6} & -\frac{5}{6} \\ -\frac{5}{6} & \frac{7}{6} \end{pmatrix}$$

Příští přednáška (téma 5B)

Konceptuální hledání (analogií) matic \mathbf{T} a \mathbf{S} : takzvané matice transformace souřadnic.

Transformace souřadnic

Odpřednesenou látku naleznete v kapitolách 9.2 a 9.3 skript
Abstraktní a konkrétní lineární algebra.

Minulá přednáška

- ① Lineární zobrazení.
- ② Výpočet souřadnic vzhledem k bázi je lineární zobrazení.
- ③ Matice libovolného lineárního zobrazení mezi lineárními prostory konečné dimenze vzhledem k pevně zvoleným bázím.

Dnešní přednáška

- ① Matice transformace souřadnic v jedné bázi na souřadnice ve druhé bázi. Jde opět o matici jistého lineárního zobrazení.
- ② Uvidíme, že pro stále více problémů je třeba se naučit řešit maticové soustavy.^a


^aŘadu příkladů tedy v této přednášce nedopočítáme až do konce.

Příští přednáška

- ① Koncepcně čistý a geometricky jasný způsob řešení soustav lineárních rovnic, maticových rovnic, atd.


Připomenutí (výpočet matice lineárního zobrazení)

Ať $\mathbf{f} : L_1 \rightarrow L_2$ je lineární zobrazení, ať $B = (\vec{b}_1, \dots, \vec{b}_s)$ a $C = (\vec{c}_1, \dots, \vec{c}_r)$ jsou uspořádané báze prostorů L_1 a L_2 . Potom matice \mathbf{A}_f má r řádků a s sloupců a j -tý sloupec matice \mathbf{A}_f je tvořen souřadnicemi $\text{coord}_C(\mathbf{f}(\vec{b}_j))$, zapsanými do sloupce.



Definice (matice transformace souřadnic)

Ať $B = (\vec{b}_1, \dots, \vec{b}_n)$ a $C = (\vec{c}_1, \dots, \vec{c}_n)$ jsou uspořádané báze prostoru L . Matici^a $\mathbf{T}_{B \mapsto C}$, která splňuje



Říkáme matice transformace souřadnic z báze B do báze C (také: matice transformace souřadnic v bázi B na souřadnice v bázi C).

^aVšimněte si značení: v dolním indexu $\mathbf{T}_{B \mapsto C}$ je **šipka s patkou** (základnu B „posíláme“ na základnu C).



Poznámky (základní vlastnosti matice transformace souřadnic)

- ① Platí $\mathbf{T}_{B \mapsto C} \cdot \mathbf{coord}_B(\vec{x}) = \mathbf{coord}_C(\vec{x})$, pro každý vektor \vec{x} v L .
 To plyne přímo z definice matice $\mathbf{T}_{B \mapsto C}$:

$$\begin{array}{ccc} \mathbb{F}^n & \xrightarrow{\mathbf{x} \mapsto \mathbf{T}_{B \mapsto C} \cdot \mathbf{x}} & \mathbb{F}^n \\ \mathbf{coord}_B \uparrow & & \uparrow \mathbf{coord}_C \\ L & \xrightarrow{\text{id}} & L \end{array}$$

- ② Matice $\mathbf{T}_{B \mapsto C}$ je **vždy regulární**. Platí $(\mathbf{T}_{B \mapsto C})^{-1} = \mathbf{T}_{C \mapsto B}$.
 To plyne z toho, že $\mathbf{id} : L \rightarrow L$ je isomorfismus.

Poznámky (základní vlastnosti matice transformace, pokrač.)

- 3 Platí $\mathbf{T}_{B \mapsto B} = \mathbf{E}_n$. To je triviální:

$$\begin{array}{ccc} \mathbb{F}^n & \xrightarrow{x \mapsto x} & \mathbb{F}^n \\ \text{coord}_B \uparrow & & \uparrow \text{coord}_B \\ L & \xrightarrow{\text{id}} & L \end{array}$$

- 4 Platí $\mathbf{T}_{B \mapsto D} = \mathbf{T}_{C \mapsto D} \cdot \mathbf{T}_{B \mapsto C}$. To plyne z vlastností matice složeného zobrazení:

$$\begin{array}{ccccc} & & x \mapsto \mathbf{T}_{C \mapsto D} \cdot \mathbf{T}_{B \mapsto C} \cdot x & & \\ & \overbrace{\mathbb{F}^n \xrightarrow{x \mapsto \mathbf{T}_{B \mapsto C} \cdot x} \mathbb{F}^n \xrightarrow{x \mapsto \mathbf{T}_{C \mapsto D} \cdot x} \mathbb{F}^n} & & & \uparrow \text{coord}_D \\ \text{coord}_B \uparrow & & \uparrow \text{coord}_C & & \\ L & \xrightarrow{\text{id}} & L & \xrightarrow{\text{id}} & L \end{array}$$

Příklad (přepočet souřadnic vzhledem k jiné bázi)

V prostoru $\mathbb{R}^{\leq 3}[x]$ nad \mathbb{R} máme uspořádané báze $B = (x^3, x^2, x, 1)$ a $C = ((x - 1)^3, (x - 1)^2, x - 1, 1)$.

Pro polynom $p(x) = -3x^2 + 6x + 3$ z $\mathbb{R}^{\leq 3}[x]$ hledáme $\mathbf{coord}_C(p(x))$. Víme, že $\mathbf{coord}_C(p(x)) = \mathbf{T}_{B \mapsto C} \cdot \mathbf{coord}_B(p(x))$.

Protože $\mathbf{coord}_B(p(x)) = \begin{pmatrix} 0 \\ -3 \\ 6 \\ 3 \end{pmatrix}$, stačí tedy znát^a matici $\mathbf{T}_{B \mapsto C}$.

$$\mathbf{T}_{B \mapsto C} = (\mathbf{T}_{C \mapsto B})^{-1} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ -3 & 1 & 0 & 0 \\ 3 & -2 & 1 & 0 \\ -1 & 1 & -1 & 1 \end{pmatrix}^{-1}$$

^aUvidíme později, že pro nalezení matice $(\mathbf{T}_{C \mapsto B})^{-1}$ lze využít **blokový tvar Gaussovy eliminace**:

$$(\mathbf{T}_{C \mapsto B} \mid \mathbf{E}_n) \sim \cdots \sim (\mathbf{E}_n \mid (\mathbf{T}_{C \mapsto B})^{-1})$$



Příklad (přepočet souřadnic vzhledem k jiné bázi)

Jsou dány tři konečné báze B , C a D prostoru L . Spočtěte $\mathbf{coord}_B(4 \cdot \vec{x} + 12 \cdot \vec{y} + 3 \cdot \vec{z})$, pokud znáte $\mathbf{coord}_B(\vec{x})$, $\mathbf{coord}_C(\vec{y})$ a $\mathbf{coord}_D(\vec{z})$.

$$\mathbf{coord}_B(4 \cdot \vec{x} + 12 \cdot \vec{y} + 3 \cdot \vec{z}) =$$

$$4 \cdot \mathbf{coord}_B(\vec{x}) + 12 \cdot \mathbf{coord}_B(\vec{y}) + 3 \cdot \mathbf{coord}_B(\vec{z}) =$$

$$4 \cdot \mathbf{coord}_B(\vec{x}) + 12 \cdot \mathbf{T}_{C \mapsto B} \cdot \mathbf{coord}_C(\vec{y}) + 3 \cdot \mathbf{T}_{D \mapsto B} \cdot \mathbf{coord}_D(\vec{z}).$$

Poznámka (konceptuální výpočet $\mathbf{T}_{B \mapsto C}$ v prostoru \mathbb{F}^n)

Ať $B = (\mathbf{b}_1, \dots, \mathbf{b}_n)$ a $C = (\mathbf{c}_1, \dots, \mathbf{c}_n)$ jsou libovolné báze prostoru \mathbb{F}^n .

Připomenutí: kanonická (také: standardní) báze $K_n = (\mathbf{e}_1, \dots, \mathbf{e}_n)$ prostoru \mathbb{F}^n .

① Je snadné nalézt matice $\mathbf{T}_{B \mapsto K_n}$ a $\mathbf{T}_{C \mapsto K_n}$.

- ① Do j -tého sloupce $\mathbf{T}_{B \mapsto K_n}$ napíšeme souřadnice \mathbf{b}_j v kanonické bázi K_n .
- ② Do j -tého sloupce $\mathbf{T}_{C \mapsto K_n}$ napíšeme souřadnice \mathbf{c}_j v kanonické bázi K_n .

② $\mathbf{T}_{B \mapsto C} = \mathbf{T}_{K_n \mapsto C} \cdot \mathbf{T}_{B \mapsto K_n} = (\mathbf{T}_{C \mapsto K_n})^{-1} \cdot \mathbf{T}_{B \mapsto K_n}$.

Stačí tedy vyřešit^a maticovou rovnici $\mathbf{T}_{C \mapsto K_n} \cdot \mathbf{X} = \mathbf{T}_{B \mapsto K_n}$.

^aUvidíme později, že pro nalezení matice $(\mathbf{T}_{C \mapsto K_n})^{-1} \cdot \mathbf{T}_{B \mapsto K_n}$ lze využít blokový tvar Gaussovy eliminace:

$$(\mathbf{T}_{C \mapsto K_n} \mid \mathbf{T}_{B \mapsto K_n}) \sim \cdots \sim (\mathbf{E}_n \mid (\mathbf{T}_{C \mapsto K_n})^{-1} \cdot \mathbf{T}_{B \mapsto K_n})$$



Příklad (nalezení báze, známe-li matici transformace)

$B = \left(\begin{pmatrix} 1 \\ 1 \\ 2 \end{pmatrix}, \begin{pmatrix} -2 \\ 1 \\ -2 \end{pmatrix}, \begin{pmatrix} 2 \\ -1 \\ 1 \end{pmatrix} \right)$ je báze lineárního prostoru \mathbb{R}^3 . Tedy

$$\mathbf{T}_{B \mapsto K_3} = \begin{pmatrix} 1 & -2 & 2 \\ 1 & 1 & -1 \\ 2 & -2 & 1 \end{pmatrix}, \text{ kde } K_3 \text{ je kanonická báze } \mathbb{R}^3.$$

Nalezněte bázi $C = \left(\begin{pmatrix} c_{11} \\ c_{21} \\ c_{31} \end{pmatrix}, \begin{pmatrix} c_{12} \\ c_{22} \\ c_{32} \end{pmatrix}, \begin{pmatrix} c_{13} \\ c_{23} \\ c_{33} \end{pmatrix} \right)$ lineárního prostoru

$$\mathbb{R}^3 \text{ tak, aby platila rovnost } \mathbf{T}_{B \mapsto C} = \begin{pmatrix} -4 & 3 & 1 \\ 11 & 4 & 1 \\ 2 & 10 & 1 \end{pmatrix}.$$

Příklad (pokrač.)

Protože C je báze a protože K_3 je kanonická báze, víme, že platí:

$$\begin{pmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \\ c_{31} & c_{32} & c_{33} \end{pmatrix} = \mathbf{T}_{C \mapsto K_3}$$

Protože platí $\mathbf{T}_{C \mapsto K_3} = \mathbf{T}_{B \mapsto K_3} \cdot \mathbf{T}_{C \mapsto B} = \mathbf{T}_{B \mapsto K_3} \cdot (\mathbf{T}_{B \mapsto C})^{-1}$, dosadíme a spočítáme

$$\begin{pmatrix} c_{11} & c_{12} & c_{13} \\ c_{21} & c_{22} & c_{23} \\ c_{31} & c_{32} & c_{33} \end{pmatrix} = \begin{pmatrix} 1 & -2 & 2 \\ 1 & 1 & -1 \\ 2 & -2 & 1 \end{pmatrix} \cdot \begin{pmatrix} -4 & 3 & 1 \\ 11 & 4 & 1 \\ 2 & 10 & 1 \end{pmatrix}^{-1}$$

Věta (změna matice zobrazení při změně bází)


Ať $\mathbf{f} : L_1 \rightarrow L_2$ je lineární zobrazení, $\dim(L_1) = n$, $\dim(L_2) = m$.

Ať B a B' jsou báze prostoru L_1 a ať C a C' jsou báze prostoru L_2 .

Jestliže \mathbf{A}_f je matice \mathbf{f} vzhledem k B a C , pak součin

$\mathbf{T}_{C \mapsto C'} \cdot \mathbf{A}_f \cdot \mathbf{T}_{B' \mapsto B}$ je matice \mathbf{f} vzhledem k B' a C' .

Důkaz.



Výpočet matice lineárního zobrazení $f : L_1 \rightarrow L_2$ vzhledem k libovolným bázím

Ať $B = (\vec{b}_1, \dots, \vec{b}_n)$ je báze L_1 a $C = (\vec{c}_1, \dots, \vec{c}_m)$ je báze prostoru L_2 .

Předpokládejme, že matice \mathbf{A}_f zobrazení $f : L_1 \rightarrow L_2$ vzhledem k jistým bázím $easy_n = (\vec{d}_1, \dots, \vec{d}_n)$ a $easy_m = (\vec{k}_1, \dots, \vec{k}_m)$ prostorů L_1 a L_2 se **snadno určí**.

- ① Matice transformací souřadnic $\mathbf{T}_{B \mapsto easy_n}$ a $\mathbf{T}_{C \mapsto easy_m}$ se také určí snadno:
 - ① Do j -tého sloupce matice $\mathbf{T}_{B \mapsto easy_n}$ napíšeme souřadnice vektoru \vec{b}_j vzhledem k bázi $easy_n$.
 - ② Do j -tého sloupce matice $\mathbf{T}_{C \mapsto easy_m}$ napíšeme souřadnice vektoru \vec{c}_j vzhledem k bázi $easy_m$.
- ② Platí: $\mathbf{T}_{easy_m \mapsto C} = (\mathbf{T}_{C \mapsto easy_m})^{-1}$.
- ③ Součin matic $\mathbf{T}_{easy_m \mapsto C} \cdot \mathbf{A}_f \cdot \mathbf{T}_{B \mapsto easy_n}$ je matice zobrazení f vzhledem k bázím B a C .

Příklad (matice zobrazení vzhledem k nestandardní bázi)

Nalezněte matici \mathbf{A} zobrazení $\mathbf{der} : \mathbb{R}^{\leq 3}[x] \rightarrow \mathbb{R}^{\leq 3}[x]$ vzhledem k bázi $C = (x^3 + 3x^2, 3x^2 + 4x - 23, x - 1, 42)$.

Víme, že \mathbf{der} má následující matici vzhledem k $B = (x^3, x^2, x, 1)$:

$$\mathbf{A}_{\mathbf{der}} = \begin{pmatrix} 0 & 0 & 0 & 0 \\ 3 & 0 & 0 & 0 \\ 0 & 2 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

Platí:

$$\mathbf{T}_{C \leftrightarrow B} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 3 & 3 & 0 & 0 \\ 0 & 4 & 1 & 0 \\ 0 & -23 & -1 & 42 \end{pmatrix}$$

Tedy: $\mathbf{A} = \mathbf{T}_{B \leftrightarrow C} \cdot \mathbf{A}_{\mathbf{der}} \cdot \mathbf{T}_{C \leftrightarrow B} = (\mathbf{T}_{C \leftrightarrow B})^{-1} \cdot \mathbf{A}_{\mathbf{der}} \cdot \mathbf{T}_{C \leftrightarrow B}$.

Závěrečné poznámky k transformaci souřadnic

- ① Jakoukoli čvercovou regulární matici \mathbf{T} typu $n \times n$ nad \mathbb{F} lze považovat za matici transformace souřadnic $\mathbf{T}_{B \mapsto K_n}$, kde K_n je kanonická báze prostoru \mathbb{F}^n a báze B je tvořena sloupci matice \mathbf{T} .
- ② Je-li \mathbf{A}_f matice zobrazení $f : L_1 \rightarrow L_2$ vzhledem k bázím B a C , pak matice zobrazení f vzhledem k nějakým bázím B' a C' má tvar $\mathbf{S} \cdot \mathbf{A}_f \cdot \mathbf{T}$, pro nějaké regulární matice \mathbf{S} a \mathbf{T} .

Speciální případ: $L_1 = L_2$, $B = C$ a $B' = C'$. Pak matice \mathbf{A}_f přejde na matici tvaru $\mathbf{T}^{-1} \cdot \mathbf{A}_f \cdot \mathbf{T}$, pro nějakou regulární matici \mathbf{T} .

Poznámky (pokrač.)

- ③ Řekneme, že dvě matice \mathbf{A} a \mathbf{B} typu $n \times n$ nad \mathbb{F} jsou si **podobné** (značení: $\mathbf{A} \approx \mathbf{B}$), pokud platí rovnost $\mathbf{B} = \mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T}$, pro nějakou regulární matici \mathbf{T} .

Podobné matice jsou tedy ty, které popisují **stejné lineární zobrazení**, každá matice jej vyjadřuje **v jiné bázi**. To využijeme při hledání vlastních hodnot lineárních zobrazení (později).

Příklad (Připomenutí příkladu z minulé přednášky)

Lineární zobrazení $\mathbf{f} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je dáno hodnotami

$$\mathbf{f}\left(\begin{pmatrix} 1 \\ -1 \end{pmatrix}\right) = 2 \cdot \begin{pmatrix} 1 \\ -1 \end{pmatrix} \quad \text{a} \quad \mathbf{f}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right) = \frac{1}{3} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix}$$

Zobrazení \mathbf{f} tedy:

- ① „Prodlužuje“ $2 \times$ měřítka v ose druhého a čtvrtého kvadrantu.
- ② „Zkracuje“ $3 \times$ měřítka v ose prvního a třetího kvadrantu.



Příklad (pokrač.)

Vzhledem k nekanonické bázi $B = (\begin{pmatrix} 1 \\ -1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \end{pmatrix})$ lineárního prostoru \mathbb{R}^2 má zobrazení f matici

$$\mathbf{A}_f = \begin{pmatrix} 2 & 0 \\ 0 & \frac{1}{3} \end{pmatrix}$$

Vzhledem ke kanonické bázi K_2 lineárního prostoru \mathbb{R}^2 má zobrazení f matici^a

$$\mathbf{B}_f = \begin{pmatrix} \frac{7}{6} & -\frac{5}{6} \\ -\frac{5}{6} & \frac{7}{6} \end{pmatrix}$$

Platí: $\mathbf{A}_f \approx \mathbf{B}_f$.

Matice \mathbf{A}_f je „přehlednější“ než matice \mathbf{B}_f (matice \mathbf{A}_f vypovídá okamžitě o geometrické povaze zobrazení f).

^aMinulá přednáška.

GEM a soustavy lineárních rovnic, část 1

Odpřednesenou látku naleznete v kapitole 6 skript
Abstraktní a konkrétní lineární algebra.

Minulé přednášky

- ① Matice jako (speciální) lineární zobrazení. Obecná lineární zobrazení lze reprezentovat maticí (vzhledem k zadaným bázím).
- ② Algebra matic (sčítání matic, násobení matic skalárem, násobení matic mezi sebou).
- ③ Zápis $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$ kóduje soustavu lineárních rovnic.

Dnešní přednáška

- ① Gaussova eliminační metoda (GEM) jako **universální a systematická metoda** řešení soustav lineárních rovnic (nad \mathbb{F}).

Příští přednáška

- ① Maticové rovnice.
- ② Hledání soustav, které mají zadané řešení.

Připomenutí (maticový zápis soustavy lineárních rovnic)

Zápis $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$, kde \mathbf{A} je matici typu $r \times s$ nad \mathbb{F} , \mathbf{x} je v \mathbb{F}^s a \mathbf{b} je v \mathbb{F}^r , kóduje soustavu lineárních rovnic nad \mathbb{F} .

Terminologie: \mathbf{A} je matici soustavy, \mathbf{b} je pravá strana rovnice, \mathbf{x} je vektor neznámých. Matici $(\mathbf{A} | \mathbf{b})$ (také: $(\mathbf{a}_1, \dots, \mathbf{a}_s | \mathbf{b})$) je rozšířená matici soustavy.

Například

$$\begin{pmatrix} 2 & -4 & 4 \\ 2 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 12 \\ -42 \end{pmatrix}$$

je zápis soustavy

$$\begin{array}{rcrcrcrcl} 2x_1 & - & 4x_2 & + & 4x_3 & = & 12 \\ 2x_1 & & & + & x_3 & = & -42 \end{array}$$

nad \mathbb{R} .


Připomenutí (dva pohledy na řešení soustav)

Pro soustavu

$$\left(\begin{array}{cc|c} 1 & -1 & 4 \\ 2 & 1 & 5 \end{array} \right)$$

nad \mathbb{R} je řešení


- ① Průsečík dvou přímek: $x - y = 4$ a $2x + y = 5$:



Připomenutí (dva pohledy na řešení soustav, pokrač.)


- ② Pravá strana je lineární kombinací sloupců matice soustavy

$$\left(\begin{array}{cc|c} 1 & -1 & 4 \\ 2 & 1 & 5 \end{array} \right)$$




Řešení jsou koeficienty této lineární kombinace.

Výhoda druhého pohledu na řešení soustav



Ize převést iso-
morfismem na



Koeficienty lineární kombinace situace napravo se najdou snadno.

Gaussova eliminační metoda je přesně postupné převádění vhodnými isomorfismy do příjemné polohy!

Ve zbytku přednášky

- 1 Nejprve se zaměříme na problém řešení soustav tvaru $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$.

Konvence: Nebude-li řečeno jinak, je soustava $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$ ve zbytku přednášky soustavou r rovnic o s neznámých nad \mathbb{F} .

Soustavy budeme většinou zapisovat rozšířenou maticí $(\mathbf{A} \mid \mathbf{b})$ nebo $(\mathbf{a}_1, \dots, \mathbf{a}_s \mid \mathbf{b})$.

Zformulujeme a dokážeme důležitý výsledek: **Frobeniovu větu** o řešitelnosti soustav lineárních rovnic.

- 2 Poté vyřešíme obecný problém maticových rovnic $\mathbf{A} \cdot \mathbf{X} = \mathbf{B}$.
- 3 Jako technický prostředek použijeme **Gaussovou eliminační metodu** (zkráceně: **GEM**). GEM převádí matice (a tím i soustavy) na „příjemný“ tvar.

Definice (horní blokový tvar matice)

Matice \mathbf{M} je v **horním blokovém tvaru**, jsou-li splněny následující dvě podmínky:^a

- ① Každý nenulový řádek matice \mathbf{M} je nad jakýmkoli řádkem samých nul.
- ② Každý **pivot** (tj. nenulová položka první zleva) jakéhokoli nenulového řádku matice \mathbf{M} je vždy více napravo než pivot předchozího řádku.

^aPozorování: \mathbf{M} je v horním blokovém tvaru iff $(\mathbf{M} \mid \mathbf{o})$ je v horním blokovém tvaru.

Příklad

$$\left(\begin{array}{ccccccc} 3 & -1 & 4 & 6 & 1 & 5 & 32 \\ 0 & 0 & 6 & 2 & 3 & -4 & -1 \\ 0 & 0 & 0 & 12 & 2 & 8 & 14 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{array} \right)$$

Je v horním blokovém tvaru.

$$\left(\begin{array}{ccccccc} 31 & 10 & 14 & 16 & -23 & 15 & 32 \\ 0 & 0 & 23 & 2 & 3 & -4 & -1 \\ 0 & 0 & 42 & 12 & 2 & 8 & 14 \\ 0 & 0 & 0 & 0 & 0 & 0 & 15 \end{array} \right)$$

Není v horním blokovém tvaru.



Věta (Gaussova eliminační metoda (GEM) nad \mathbb{F})

Jakoukoli matici M nad \mathbb{F} lze konečným počtem tzv. řádkových elementárních úprav převést na horní blokový tvar.

Řádkové elementární úpravy jsou tří typů:

- (I) Přičtení skalárního násobku řádku matice k jinému řádku matice.
- (II) Prohození dvou řádků v matici.
- (III) Vynásobení řádku matice nenulovým skalárem.

Důkaz.

Nebudeme dělat (viz *skripta*, Věta 6.3.10.).



Poznámky

GEM: použití řádkových elementárních úprav dané matice s cílem zapsat danou matici v horním blokovém tvaru. Při dosažení tohoto tvaru říkáme, že **GEM skončila**.



Příklad (Přičtení skalárního násobku řádku k řádku)

Ať $\mathbf{M} = \begin{pmatrix} 2 & 3 & 5 & 8 \\ 4 & 1 & 7 & 3 \\ 5 & 2 & 6 & 4 \end{pmatrix}$ a ať $\mathbf{P} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 3 & 0 & 1 \end{pmatrix}$.

Platí

$$\mathbf{P} \cdot \mathbf{M} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \\ 3 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} 2 & 3 & 5 & 8 \\ 4 & 1 & 7 & 3 \\ 5 & 2 & 6 & 4 \end{pmatrix} = \begin{pmatrix} 2 & 3 & 5 & 8 \\ 4 & 1 & 7 & 3 \\ \textcolor{red}{11} & \textcolor{red}{11} & \textcolor{red}{21} & \textcolor{red}{28} \end{pmatrix} \begin{matrix} R_1 \\ R_2 \\ R_3 + 3R_1 \end{matrix}$$

Tudíž: přičtení skalárního násobku řádku k danému řádku je dáno isomorfismem $\mathbf{P} : \mathbb{R}^3 \rightarrow \mathbb{R}^3$, aplikovaným na čtveřici vektorů $\mathbf{M} = (\mathbf{m}_1, \mathbf{m}_2, \mathbf{m}_3, \mathbf{m}_4) \in \mathbb{R}^3$.

Příklad (prohození dvou řádků v matici)

Ať $\mathbf{M} = \begin{pmatrix} 2 & 3 & 5 & 8 \\ 4 & 1 & 7 & 3 \\ 5 & 2 & 6 & 4 \end{pmatrix}$ a ať $\mathbf{P} = \begin{pmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{pmatrix}$.

Platí

$$\mathbf{P} \cdot \mathbf{M} = \begin{pmatrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 1 & 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} 2 & 3 & 5 & 8 \\ 4 & 1 & 7 & 3 \\ 5 & 2 & 6 & 4 \end{pmatrix} = \begin{pmatrix} 5 & 2 & 6 & 4 \\ 4 & 1 & 7 & 3 \\ 2 & 3 & 5 & 8 \end{pmatrix} \begin{matrix} R_3 \\ R_2 \\ R_1 \end{matrix}$$

Tudíž: prohození dvou řádků je dáno isomorfismem $\mathbf{P} : \mathbb{R}^3 \rightarrow \mathbb{R}^3$, aplikovaným na čtveřici vektorů $\mathbf{M} = (\mathbf{m}_1, \mathbf{m}_2, \mathbf{m}_3, \mathbf{m}_4) \in \mathbb{R}^3$.

Příklad (Vynásobení řádku matice nenulovým skalárem)

$$\text{At } \mathbf{M} = \begin{pmatrix} 2 & 3 & 5 & 8 \\ 4 & 1 & 7 & 3 \\ 5 & 2 & 6 & 4 \end{pmatrix} \text{ a at } \mathbf{P} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -5 & 0 \\ 0 & 0 & 1 \end{pmatrix}.$$

Platí

$$\mathbf{P} \cdot \mathbf{M} = \begin{pmatrix} 1 & 0 & 0 \\ 0 & -5 & 0 \\ 0 & 0 & 1 \end{pmatrix} \cdot \begin{pmatrix} 2 & 3 & 5 & 8 \\ 4 & 1 & 7 & 3 \\ 5 & 2 & 6 & 4 \end{pmatrix} = \begin{pmatrix} 2 & 3 & 5 & 8 \\ \textcolor{red}{-20} & \textcolor{red}{-5} & \textcolor{red}{-35} & \textcolor{red}{-15} \\ 5 & 2 & 6 & 4 \end{pmatrix} \begin{matrix} R_1 \\ -5R_2 \\ R_3 \end{matrix}$$

Tudíž: vynásobení řádku matice nenulovým skalárem je dáno isomorfismem $\mathbf{P} : \mathbb{R}^3 \rightarrow \mathbb{R}^3$, aplikovaným na čtveřici vektorů $\mathbf{M} = (\mathbf{m}_1, \mathbf{m}_2, \mathbf{m}_3, \mathbf{m}_4) \in \mathbb{R}^3$.

Definice (ekvivalentní soustavy)

Řekneme, že soustavy $(\mathbf{A} \mid \mathbf{b})$ a $(\mathbf{A}' \mid \mathbf{b}')$ r rovnic o s neznámých jsou **ekvivalentní^a** (značení: $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{A}' \mid \mathbf{b}')$), když pro každý vektor \mathbf{x} z \mathbb{F}^s platí: $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$ právě tehdy, když $\mathbf{A}' \cdot \mathbf{x} = \mathbf{b}'$.

^aSlogan: Ekvivalentní soustavy **stejných** rozměrů mají stejná řešení.

Tvrzení (základní vlastnosti ekvivalence soustav)

Platí:

- ① $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{A} \mid \mathbf{b})$.
- ② Jestliže $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{A}' \mid \mathbf{b}')$, pak $(\mathbf{A}' \mid \mathbf{b}') \sim (\mathbf{A} \mid \mathbf{b})$.
- ③ Jestliže $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{A}' \mid \mathbf{b}')$ a $(\mathbf{A}' \mid \mathbf{b}') \sim (\mathbf{A}'' \mid \mathbf{b}'')$, pak $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{A}'' \mid \mathbf{b}'')$.

Ať $\mathbf{P} : \mathbb{F}^r \rightarrow \mathbb{F}^r$ je jakýkoli isomorfismus. Potom platí

- ① $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{P} \cdot \mathbf{A} \mid \mathbf{P} \cdot \mathbf{b})$.
- ② $\text{rank}((\mathbf{A} \mid \mathbf{b})) = \text{rank}((\mathbf{P} \cdot \mathbf{A} \mid \mathbf{P} \cdot \mathbf{b}))$.

Důkaz.

Přednáška.



Shrnutí

Ať \mathbf{M} je jakákoli nad \mathbb{F} o r řádcích. Potom platí:

- ① Každá elementární úprava matice \mathbf{M} je dána součinem $\mathbf{P} \cdot \mathbf{M}$ pro vhodný „elementární“ isomorfismus $\mathbf{P} : \mathbb{F}^r \rightarrow \mathbb{F}^r$.
- ② Je-li matice \mathbf{M}' horním blokovým tvarem^a matice \mathbf{M} , pak
 - ① Existuje isomorfismus $\mathbf{P} : \mathbb{F}^r \rightarrow \mathbb{F}^r$ tak, že $\mathbf{M}' = \mathbf{P} \cdot \mathbf{M}$ a $\mathbf{P} = \mathbf{P}_k \cdot \dots \cdot \mathbf{P}_1$, kde k je nějaké přirozené číslo a $\mathbf{P}_1, \dots, \mathbf{P}_k$ jsou „elementární“ isomorfismy.
 - ② Platí $\text{rank}(\mathbf{M}) = \text{rank}(\mathbf{M}')$ a $\text{def}(\mathbf{M}) = \text{def}(\mathbf{M}')$.

Speciálně: pro \mathbf{M} ve tvaru $(\mathbf{A} \mid \mathbf{b})$ lze elementárními úpravami převést každou soustavu na horní blokový tvar $(\mathbf{A}' \mid \mathbf{b}')$. Navíc platí $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{A}' \mid \mathbf{b}')$.

^aDůležité: nikdy jsme neříkali, že při elementárních úpravách lze vyškrvat nulové řádky. Vyškrvat nulové řádky při GEM nebude; matice \mathbf{M} a \mathbf{M}' musí mít stejné rozměry!

Důsledky

- ① Pro každou matici \mathbf{M} platí $\text{rank}(\mathbf{M}) = \text{rank}(\mathbf{M}^T)$, kde \mathbf{M}^T je **transponovaná matice^a** k matici \mathbf{M} .
- ② Hodnost matice \mathbf{M} je rovna počtu nenulových řádků v horním blokovém tvaru po skončení GEM.
- ③ Defekt matice \mathbf{M} je roven počtu sloupců matice \mathbf{M} ménus hodnost matice \mathbf{M} .

^aMatice \mathbf{M}^T má jako své sloupce původní řádky matice \mathbf{M} zapsané ve stejném pořadí. Například pro

$$\mathbf{M} = \begin{pmatrix} 2 & 4 & -1 \\ 3 & 1 & 7 \end{pmatrix}$$

je

$$\mathbf{M}^T = \begin{pmatrix} 2 & 3 \\ 4 & 1 \\ -1 & 7 \end{pmatrix}$$

Věta (Frobenius)

- ① Soustava $(\mathbf{A} \mid \mathbf{b})$ má řešení právě tehdy, když platí rovnost $\text{rank}(\mathbf{A}) = \text{rank}(\mathbf{A} \mid \mathbf{b})$.
- ② Pokud $(\mathbf{A} \mid \mathbf{b})$ má řešení, potom lze říci následující:^a

Zvolme jakékoli \mathbf{p} , splňující rovnost $\mathbf{A} \cdot \mathbf{p} = \mathbf{b}$.

Potom $\mathbf{A} \cdot \mathbf{x}_0 = \mathbf{b}$ platí právě tehdy, když $\mathbf{x}_0 = \mathbf{p} + \mathbf{x}_h$ pro nějaké \mathbf{x}_h z $\ker(\mathbf{A})$.

^aBudeme používat i zkrácený a přehledný zápis: množinu všech řešení lze napsat jako $\mathbf{p} + \ker(\mathbf{A}) = \{\mathbf{p} + \mathbf{x}_h \mid \mathbf{x}_h \in \ker(\mathbf{A})\}$, kde $\mathbf{A} \cdot \mathbf{p} = \mathbf{b}$.

Důkaz.

- ① $(\mathbf{A} \mid \mathbf{b})$ má řešení právě tehdy, když \mathbf{b} je v $\text{im}(\mathbf{A})$. To nastane právě tehdy, když $\text{rank}(\mathbf{A}) = \text{rank}(\mathbf{A} \mid \mathbf{b})$. Viz str 12, téma 3A.
- ② Triviální.

Základní myšlenky řešení soustavy ($\mathbf{A} | \mathbf{b}$)

- ① $\ker(\mathbf{A}) = \{\mathbf{x} \mid \mathbf{A} \cdot \mathbf{x} = \mathbf{0}\}$ je lineární podprostor prostoru \mathbb{F}^s .
Tudíž pro vyřešení $\mathbf{A} \cdot \mathbf{x} = \mathbf{0}$ stačí najít bázi $\ker(\mathbf{A})$. Tato báze má přesně $\text{def}(\mathbf{A})$ prvků.

Jakékoli bázi prostoru $\ker(\mathbf{A})$ budeme říkat **fundamentální systém soustavy** s maticí \mathbf{A} .

- ② Soustavě $(\mathbf{A} | \mathbf{0})$ budeme říkat **homogenní soustava** příslušná k matici \mathbf{A} .

Jakékoli řešení homogenní soustavy je tedy lineární kombinací prvků fundamentálního systému.

- ③ Jakékoli řešení soustavy lze vyjádřit ve tvaru $\mathbf{p} + \mathbf{x}_h$, kde \mathbf{x}_h je v $\ker(\mathbf{A})$ a \mathbf{p} je **jakékoli** řešení původní soustavy (takzvané **partikulární řešení**).

Jak vyřešit homogenní soustavu ($\mathbf{A} | \mathbf{o}$)

- ① GEM: $(\mathbf{A} | \mathbf{o}) \sim (\mathbf{A}' | \mathbf{o})$.
- ② Víme: $\text{rank}(\mathbf{A}) = \text{rank}(\mathbf{A}')$ a matice \mathbf{A}' je v horním blokovém tvaru. Tudíž známe defekt matice \mathbf{A} :
 $d = \text{def}(\mathbf{A}) = s - \text{rank}(\mathbf{A}) = s - \text{rank}(\mathbf{A}')$.
- ③ Báze prostoru $\ker(\mathbf{A})$ musí mít d prvků. Tudíž d hodnot v každém řešení lze zvolit (jde o posice, na kterých nejsou pivoty matice \mathbf{A}'). Touto volbou zajistíme lineární nezávislost. Dalších $s - d$ hodnot lze spočítat z nenulových rovnic v soustavě $(\mathbf{A}' | \mathbf{o})$ zpětným dosazením.

Jak nalézt partikulární řešení soustavy ($\mathbf{A} | \mathbf{b}$)

- ① GEM: $(\mathbf{A} | \mathbf{b}) \sim (\mathbf{A}' | \mathbf{b}')$.
- ② d hodnot v partikulárním řešení lze zvolit (jde o posice, na kterých nejsou pivoty matice \mathbf{A}').
- ③ Zpětné dopočtení z nenulových rovnic soustavy $(\mathbf{A}' | \mathbf{b}')$.



Příklad (ukázka systematického řešení soustavy nad \mathbb{R})

Nad \mathbb{R} vyřešte: $2x_1 + 3x_2 - 4x_3 = 2$ (maticově: $(\begin{array}{ccc|c} 2 & 3 & -4 & 2 \end{array})$).

Pro matici soustavy $\mathbf{A} = (\begin{array}{ccc} 2 & 3 & -4 \end{array})$ platí rovnosti $\text{rank}(\mathbf{A}) = 1$ a $\text{def}(\mathbf{A}) = 2$. Pivot je na první pozici: volit budeme vždy druhou a třetí položku, první položku dopočteme.

- ① Příslušná homogenní rovnice: $(\begin{array}{ccc|c} 2 & 3 & -4 & 0 \end{array})$.

Fundamentální systém: $\left(\begin{array}{c} -\frac{3}{2} \\ 1 \\ 0 \end{array} \right), \left(\begin{array}{c} 2 \\ 0 \\ 1 \end{array} \right)$.

- ② Partikulární řešení pro $(\begin{array}{ccc|c} 2 & 3 & -4 & 2 \end{array})$: $\left(\begin{array}{c} 1 \\ 0 \\ 0 \end{array} \right)$.

- ③ Celkové řešení: $\left(\begin{array}{c} 1 \\ 0 \\ 0 \end{array} \right) + \text{span} \left\{ \left(\begin{array}{c} -\frac{3}{2} \\ 1 \\ 0 \end{array} \right), \left(\begin{array}{c} 4 \\ 0 \\ 1 \end{array} \right) \right\}$.

Příklad (geometrický význam postupu řešení soustavy)

Rovnice $2x_1 + 3x_2 - 4x_3 = 2$ v \mathbb{R}^3 popisuje rovinu ρ v prostoru \mathbb{R}^3 .

Tato rovina ρ je v obecné poloze (rovina ρ neprochází počátkem, protože $2 \neq 0$).

- ① Homogenní rovnice $2x_1 + 3x_2 - 4x_3 = 0$ je paralelní posunutí roviny ρ tak, aby výsledná rovina ρ_h procházela počátkem.
Fundamentální systém $\mathbf{x}_1, \mathbf{x}_2$ je systém souřadnic v rovině ρ_h .
- ② Partikulární řešení rovnice $2x_1 + 3x_2 - 4x_3 = 2$ je libovolný bod \mathbf{p} v původní rovině ρ .
- ③ Zápis $\mathbf{p} + \text{span}\{\mathbf{x}_1, \mathbf{x}_2\}$ obecného řešení vyjadřuje opětovné paralelní posunutí roviny ρ_h zpět do roviny ρ .

Poznámka

Stejnou geometrickou představu je třeba mít pro řešení obecné soustavy $(\mathbf{A} | \mathbf{b})$ nad \mathbb{F} .

Příklad (systematické řešení komplikovanější soustavy nad \mathbb{R})

$$\left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 1 & 1 & 1 & -1 & 5 \\ 2 & 8 & 5 & 3 & 7 \\ 3 & 9 & 6 & 2 & 12 \end{array} \right) \sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & -2 & -1 & -1 & 2 \\ 0 & 2 & 1 & 3 & 1 \\ 0 & 0 & 0 & 2 & 3 \end{array} \right) R_1$$

$$\sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 2 & 3 \\ 0 & 0 & 0 & 2 & 3 \end{array} \right) R_2 - R_1$$

$$\sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 0 & 0 & 2 & 3 \\ 0 & 0 & 0 & 2 & 3 \\ 0 & 0 & 0 & 2 & 3 \end{array} \right) R_3 - 2R_1$$

$$\sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 2 & 3 \\ 0 & 0 & 0 & 2 & 3 \end{array} \right) R_4 - 3R_1$$

$$\sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 2 & 3 \\ 0 & 0 & 0 & 0 & 0 \end{array} \right) R_1$$

$$\sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 1 & \frac{3}{2} \\ 0 & 0 & 0 & 0 & 0 \end{array} \right) R_2$$

$$\sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 1 & \frac{3}{2} \\ 0 & 0 & 0 & 0 & 0 \end{array} \right) R_3 + R_2$$

$$\sim \left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 1 & \frac{3}{2} \\ 0 & 0 & 0 & 0 & 0 \end{array} \right) R_4$$

Důležité: povšimněme si značení řádkových úprav; úpravy budeme vždy takto vyznačovat.

Příklad (pokrač.)

Po skončení GEM

$$\left(\begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 1 & \frac{3}{2} \\ 0 & 0 & 0 & 0 & 0 \end{array} \right)$$

jsou pivoty na čtvrté, druhé a první pozici. Tyto položky v řešení budeme **dopočítávat**, třetí položku řešení budeme **volit**.

Řešení je:

$$\begin{pmatrix} \frac{33}{4} \\ -\frac{7}{4} \\ 0 \\ \frac{3}{2} \end{pmatrix} + a \cdot \begin{pmatrix} -\frac{1}{2} \\ -\frac{1}{2} \\ 1 \\ 0 \end{pmatrix}, \text{ kde } a \in \mathbb{R}.$$

Zkrácený zápis:

$$\begin{pmatrix} \frac{33}{4} \\ -\frac{7}{4} \\ 0 \\ \frac{3}{2} \end{pmatrix} + \text{span}\left(\begin{pmatrix} -\frac{1}{2} \\ -\frac{1}{2} \\ 1 \\ 0 \end{pmatrix}\right).$$

Řešením soustavy je **přímka** v \mathbb{R}^4 .

GEM a soustavy lineárních rovnic, část 2

Odpřednesenou látku naleznete v kapitolách 6 a 7.1
skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

- ① Gaussova eliminační metoda (GEM) jako **universální a systematická metoda** řešení soustav lineárních rovnic (nad \mathbb{F}).

Dnešní přednáška

- ① Lineární maticové rovnice.
- ② Hledání soustav, které mají zadané řešení.

Příklad

Nalezněte všechny matice \mathbf{X} , které splňují rovnost^a

$\mathbf{R}_\alpha \cdot \mathbf{X} = \mathbf{X} \cdot \mathbf{R}_\alpha$, kde $\mathbf{R}_\alpha : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je matice rotace o úhel α , $\alpha \in [0; 2\pi)$.

Rozměrová zkouška: musí platit $\mathbf{X} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$.

Rešeními jsou například matice \mathbf{E}_2 , $\mathbf{O}_{2,2}$ a \mathbf{R}_α .

Jak nalézt všechna řešení? Předvedeme universální metodu.

① Označme $\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \end{pmatrix}$. Potom

$$\mathbf{R}_\alpha \cdot \mathbf{X} = \begin{pmatrix} \cos \alpha \cdot x_{11} - \sin \alpha \cdot x_{21} & \cos \alpha \cdot x_{12} - \sin \alpha \cdot x_{22} \\ \sin \alpha \cdot x_{11} + \cos \alpha \cdot x_{21} & \sin \alpha \cdot x_{12} + \cos \alpha \cdot x_{22} \end{pmatrix} \text{ a}$$

$$\mathbf{X} \cdot \mathbf{R}_\alpha = \begin{pmatrix} \cos \alpha \cdot x_{11} + \sin \alpha \cdot x_{12} & -\sin \alpha \cdot x_{11} + \cos \alpha \cdot x_{12} \\ \cos \alpha \cdot x_{21} + \sin \alpha \cdot x_{22} & -\sin \alpha \cdot x_{21} + \cos \alpha \cdot x_{22} \end{pmatrix}.$$

^aGeometrický význam: hledáme všechny transformace \mathbf{X} roviny, které jsou záměnné s rotací o úhel α .



Příklad (pokrač.)

② Rovnost $\mathbf{R}_\alpha \cdot \mathbf{X} = \mathbf{X} \cdot \mathbf{R}_\alpha$ je ekvivalentní rovnosti

$\mathbf{R}_\alpha \cdot \mathbf{X} - \mathbf{X} \cdot \mathbf{R}_\alpha = \mathbf{O}_{2,2}$. Stačí tedy vyřešit soustavu čtyř rovnic

$$\begin{array}{lclcl} -\sin \alpha \cdot x_{21} & -\sin \alpha \cdot x_{12} & & = & 0 \\ \sin \alpha \cdot x_{11} & & & -\sin \alpha \cdot x_{22} & = 0 \\ \sin \alpha \cdot x_{11} & & & -\sin \alpha \cdot x_{22} & = 0 \\ \sin \alpha \cdot x_{21} & + \sin \alpha \cdot x_{12} & & & = 0 \end{array}$$

V maticovém zápisu (po skončení GEM) máme řešit soustavu

$$\left(\begin{array}{cccc|c} \sin \alpha & 0 & 0 & -\sin \alpha & 0 \\ 0 & \sin \alpha & \sin \alpha & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{array} \right)$$

v závislosti na parametru $\alpha \in [0; 2\pi)$.

Příklad (pokrač.)

- ③ Pro $\sin \alpha = 0$ má soustava tvar

$$\left(\begin{array}{cccc|c} 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{array} \right)$$

a tudíž řešení je tvaru $\mathbf{X} = \begin{pmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \end{pmatrix}$, kde x_{11}, x_{21}, x_{12} a x_{22} jsou libovolná reálná čísla.

Závěr: s rotací o úhel 0 nebo π je záměnná libovolná transformace roviny.

Příklad (pokrač.)

- ④ Pro $\sin \alpha \neq 0$ má soustava tvar

$$\left(\begin{array}{cccc|c} 1 & 0 & 0 & -1 & 0 \\ 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 \end{array} \right)$$

$$\text{a řešení } \text{span}\left(\begin{pmatrix} 0 \\ -1 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 0 \\ 0 \\ 1 \end{pmatrix}\right).$$

Závěr: s rotací \mathbf{R}_α o úhel $\alpha \notin \{0, \pi\}$ jsou záměnné transformace roviny tvaru $\mathbf{X} = a \cdot \begin{pmatrix} 0 & 1 \\ -1 & 0 \end{pmatrix} + b \cdot \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$, kde a, b jsou libovolná reálná čísla.

Poznámky

- ① Předchozí metoda (rozměrová zkouška pro hledanou matici \mathbf{X} a následné řešení velké soustavy rovnic) je **universální** metodou pro řešení maticových rovnic, kde neznámá matice \mathbf{X} vystupuje pouze v první mocnině.

Jak už to u universálních metod bývá: v některých případech je taková metoda zbytečně zdlouhavá.

- ② Předvedeme **speciální** metodu řešení maticových rovnic tvaru^a $\mathbf{A} \cdot \mathbf{X} = \mathbf{B}$.

^aProtože rovnost $\mathbf{X} \cdot \mathbf{A} = \mathbf{B}$ je ekvivalentní rovnosti $\mathbf{A}^T \cdot \mathbf{X}^T = \mathbf{B}^T$, získáme tak i metodu pro řešení rovnic tvaru $\mathbf{X} \cdot \mathbf{A} = \mathbf{B}$. Musíme ovšem obezřetně zacházet s transposicemi matic.

Převod maticové rovnice na více soustav lineárních rovnic

Maticovou rovnici $\mathbf{A} \cdot \mathbf{X} = \mathbf{B}$, kde matice $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$, a matice $\mathbf{B} : \mathbb{F}^p \rightarrow \mathbb{F}^r$, převedeme na p soustav

$$\mathbf{A} \cdot \mathbf{x} = \mathbf{b}_1, \quad \dots, \quad \mathbf{A} \cdot \mathbf{x} = \mathbf{b}_p$$

kde $\mathbf{B} = (\mathbf{b}_1 \ \mathbf{b}_2 \ \dots \ \mathbf{b}_p)$.

- ① Každou takovou soustavu $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}_i$ vyřešíme předešlými postupy.^a
- ② Řešení $\mathbf{A} \cdot \mathbf{X} = \mathbf{B}$ existuje právě tehdy, když každá soustava $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}_i$ má řešení.
- ③ Pokud má každá soustava $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}_i$ řešení, pak „sesazením“ všech řešení $\mathbf{x}_1, \dots, \mathbf{x}_s$ jednotlivých soustav dostaneme řešení původní maticové rovnice: $\mathbf{X} = (\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_p)$.

^aJak uvidíme, lze takový systém soustav řešit **simultánně**.

Příklad

Nad \mathbb{R} vyřešte rovnici $\begin{pmatrix} 1 & 2 & 1 \\ 1 & -3 & 2 \end{pmatrix} \cdot \mathbf{x} = \begin{pmatrix} 2 & 1 \\ 1 & 2 \end{pmatrix}$.

Protože $\mathbf{X} : \mathbb{R}^2 \rightarrow \mathbb{R}^3$, máme řešit dvě soustavy:

$$\begin{pmatrix} 1 & 2 & 1 \\ 1 & -3 & 2 \end{pmatrix} \cdot \mathbf{x} = \begin{pmatrix} 2 \\ 1 \end{pmatrix} \quad \begin{pmatrix} 1 & 2 & 1 \\ 1 & -3 & 2 \end{pmatrix} \cdot \mathbf{x} = \begin{pmatrix} 1 \\ 2 \end{pmatrix}$$

Obě soustavy mají stejnou matici soustavy, lze je tedy řešit simultánně:

① Simultánní GEM:

$$\left(\begin{array}{ccc|cc} 1 & 2 & 1 & 2 & 1 \\ 1 & -3 & 2 & 1 & 2 \end{array} \right) \sim \left(\begin{array}{ccc|cc} 1 & 2 & 1 & 2 & 1 \\ 0 & -5 & 1 & -1 & 1 \end{array} \right) \quad R_1 \quad R_2 - R_1$$

Podle Frobeniovy věty mají obě soustavy řešení.

Příklad (pokrač.)

- ② Zápis $\left(\begin{array}{ccc|cc} 1 & 2 & 1 & 2 & 1 \\ 0 & -5 & 1 & -1 & 1 \end{array} \right)$ kóduje dvě soustavy s řešeními (v pořadí soustav zleva doprava):

$$\left(\begin{array}{c} 3 \\ 0 \\ -1 \end{array} \right) + \text{span} \left(\begin{pmatrix} -7 \\ 1 \\ 5 \end{pmatrix} \right) \quad \left(\begin{array}{c} 0 \\ 0 \\ 1 \end{array} \right) + \text{span} \left(\begin{pmatrix} -7 \\ 1 \\ 5 \end{pmatrix} \right)$$

- ③ „Sesazení řešení dohromady“: celkové řešení je tvaru

$$\mathbf{x} = \begin{pmatrix} 3 - 7a & -7b \\ a & b \\ -1 + 5a & 1 + 5b \end{pmatrix}$$

kde a, b jsou libovolná reálná čísla.

Poznámka

Víme, že pro **regulární** matici $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ má soustava $\mathbf{A} \cdot \mathbf{X} = \mathbf{B}$ jediné řešení, a sice $\mathbf{X} = \mathbf{A}^{-1} \cdot \mathbf{B}$.

Toto jediné řešení lze nalézt postupem, kterému se někdy říká **Gaussova-Jordanova eliminace**: eleminace řádkovými úpravami nekončí po dosažení horní trojúhelníkové matice, ale pokračuje nulováním i nad hlavní diagonálou.

Získáváme tak postup

$$(\mathbf{A} \mid \mathbf{B}) \sim \dots \sim (\mathbf{E}_n \mid \mathbf{A}^{-1} \cdot \mathbf{B})$$

Speciálně: pro regulární $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ lze nalézt \mathbf{A}^{-1} postupem

$$(\mathbf{A} \mid \mathbf{E}_n) \sim \dots \sim (\mathbf{E}_n \mid \mathbf{A}^{-1})$$

Více viz cvičení a **skripta**, Příklad 6.4.12.

Příklad

Nad \mathbb{R} nalezněte (jakoukoli) soustavu tvaru $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$, která má řešení

$$\begin{pmatrix} 3 \\ 2 \\ 6 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix}, \begin{pmatrix} 2 \\ 0 \\ 4 \end{pmatrix}\right)$$

Myšlenky postupu:

- ① Zadané řešení tvoří rovinu v \mathbb{R}^3 , která prochází bodem $\begin{pmatrix} 3 \\ 2 \\ 6 \end{pmatrix}$ a

má „směr“ určený vektory $\begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix}$, $\begin{pmatrix} 2 \\ 0 \\ 4 \end{pmatrix}$.

- ② Tedy: hledanou soustavu očekáváme ve tvaru $(a_1 \ a_2 \ a_3 \mid b)$, neboť $a_1x + a_2y + a_3z = b$.

Jak najít soustavu $(a_1 \ a_2 \ a_3 \mid b)$ systematicky?

Příklad, pokrač.

Podle Frobeniovovy věty je

$$\begin{pmatrix} 3 \\ 2 \\ 6 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix}, \begin{pmatrix} 2 \\ 0 \\ 4 \end{pmatrix}\right)$$

řešením soustavy $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$, kde

- ① Vektory $\begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix}, \begin{pmatrix} 2 \\ 0 \\ 4 \end{pmatrix}$ jsou lineárně nezávislé; tvoří tudíž fundamentální systém soustavy $\mathbf{A} \cdot \mathbf{x} = \mathbf{o}$, kde $\text{def}(\mathbf{A}) = 2$ a \mathbf{A} má tři sloupce. To umožní nalézt $\mathbf{A} = (a_1 \ a_2 \ a_3)$.
- ② Vektor $\begin{pmatrix} 3 \\ 2 \\ 6 \end{pmatrix}$ je partikulární řešení soustavy $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$, neboli $\mathbf{A} \cdot \begin{pmatrix} 3 \\ 2 \\ 6 \end{pmatrix} = \mathbf{b}$. Matici \mathbf{A} známe, můžeme dopočítat $\mathbf{b} = (b)$.

Příklad, pokrač.

③ Nalezení **A**:

① Protože má platit $(a_1 \ a_2 \ a_3) \cdot \begin{pmatrix} 2 \\ 0 \\ 4 \end{pmatrix} = 0$, musí platit

$$(2 \ 0 \ 4) \cdot \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} = 0.$$

② Protože má platit $(a_1 \ a_2 \ a_3) \cdot \begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix} = 0$,

$$\text{musí platit } (1 \ 2 \ 0) \cdot \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} = 0$$

Tudíž $\begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix}$ je fundamentální systém soustavy

$$\left(\begin{array}{ccc|c} 2 & 0 & 4 & 0 \\ 1 & 2 & 0 & 0 \end{array} \right), \text{ neboli (např.) } \begin{pmatrix} a_1 \\ a_2 \\ a_3 \end{pmatrix} = \begin{pmatrix} 2 \\ -1 \\ -1 \end{pmatrix} \text{ a}$$

$$\mathbf{A} = (2 \ -1 \ -1).$$

Příklad, pokrač.

- ④ Nalezení \mathbf{b} . Protože $\mathbf{A} = \begin{pmatrix} 2 & -1 & -1 \end{pmatrix}$ a $\mathbf{A} \cdot \begin{pmatrix} 3 \\ 2 \\ 6 \end{pmatrix} = \mathbf{b}$, je $b = -2$.
- ⑤ Závěr: hledaná soustava je (například) $(2 \ -1 \ -1 \mid -2)$.

Poznámky

- ① Předchozí příklad nalezl obecnou rovnici roviny z jejího parametrického zadání. Postup využíval platnosti Frobeniových vět a základních vlastností matic.
- ② Očekáváme: podobný postup bude fungovat pro nalezení soustavy $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$ nad tělesem \mathbb{F} , která má řešení

$$\mathbf{p} + \text{span}(\mathbf{x}_1, \dots, \mathbf{x}_d)$$


kde vektory $\mathbf{x}_1, \dots, \mathbf{x}_d$ jsou lineárně nezávislé.

Definice

Zápisu $\mathbf{p} + \text{span}(\mathbf{x}_1, \dots, \mathbf{x}_d)$ v \mathbb{F}^s , kde vektory $\mathbf{x}_1, \dots, \mathbf{x}_d$ jsou lineárně nezávislé, říkáme **affinní podprostor dimenze d** v prostoru \mathbb{F}^s .^a Seznamu $(\mathbf{x}_1, \dots, \mathbf{x}_d)$ říkáme **směr** (také: **zaměření**) tohoto podprostoru.

^aTaké: **d -dimensionální plocha** v \mathbb{F}^s .

Ilustrační obrázek



Tvrzení

Ke každému d -dimensionálnímu afinnímu podprostoru $\mathbf{p} + \text{span}(\mathbf{x}_1, \dots, \mathbf{x}_d)$ v \mathbb{F}^s existuje alespoň jedna soustava tvaru $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$, která má $\mathbf{p} + \text{span}(\mathbf{x}_1, \dots, \mathbf{x}_d)$ jako množinu řešení.

Důkaz.

Podrobně na přednášce; hlavní myšlenky jsou:

- ① Musí platit $\mathbf{A} \cdot \mathbf{x}_i = \mathbf{o}$ pro $i = 1, \dots, d$ a $\mathbf{A} \cdot \mathbf{p} = \mathbf{b}$.
- ② Označme $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_d)$. Protože seznam $(\mathbf{x}_1, \dots, \mathbf{x}_d)$ je lineárně nezávislý, platí $d = \text{rank}(\mathbf{X}) = \text{rank}(\mathbf{X}^T)$. Soustava^a $\mathbf{X}^T \cdot \mathbf{a} = \mathbf{o}$ má $s - d$ prvků ve svém fundamentálním systému. Označme tento systém jako $(\mathbf{a}_1, \dots, \mathbf{a}_{s-d})$.
- ③ Známe $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_{s-d})^T$ a dopočteme \mathbf{b} z rovnice $\mathbf{A} \cdot \mathbf{p} = \mathbf{b}$.



^aPozor: matici \mathbf{X}^T známe, neznámá je označena jako \mathbf{a} .

Příklad

Nad \mathbb{R} nalezněte (jakoukoli) soustavu tvaru $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$, která má řešení

$$\begin{pmatrix} 1 \\ 1 \\ -2 \\ 0 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 2 \\ 1 \\ 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 2 \\ 0 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} -1 \\ 2 \\ 0 \\ 0 \\ 1 \end{pmatrix}\right)$$

- ① Označme $\mathbf{X} = \begin{pmatrix} 2 & 1 & -1 \\ 1 & 2 & 2 \\ 1 & 0 & 0 \\ 0 & 1 & 0 \\ 0 & 0 & 1 \end{pmatrix}$, potom $\mathbf{X}^T = \begin{pmatrix} 2 & 1 & 1 & 0 & 0 \\ 1 & 2 & 0 & 1 & 0 \\ -1 & 2 & 0 & 0 & 1 \end{pmatrix}$. Platí

$$3 = \text{rank}(\mathbf{X}) = \text{rank}(\mathbf{X}^T).$$

- ② Matice \mathbf{A} má jako řádky fundamentální systém soustavy $\mathbf{X}^T \cdot \mathbf{a} = \mathbf{0}$. Protože $\text{rank}(\mathbf{X}^T) = 3$, bude mít matice \mathbf{A} dva lineárně nezávislé řádky.

Příklad (pokrač.)

- ③ Fundamentální systém soustavy $\mathbf{X}^T \cdot \mathbf{a} = \mathbf{o}$, neboli homogenní soustavy

$$\left(\begin{array}{ccccc|c} 2 & 1 & 1 & 0 & 0 & 0 \\ 1 & 2 & 0 & 1 & 0 & 0 \\ -1 & 2 & 0 & 0 & 1 & 0 \end{array} \right), \text{ je například } \begin{pmatrix} -1/2 \\ -1/4 \\ 5/4 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 1/2 \\ -1/4 \\ -3/4 \\ 0 \\ 1 \end{pmatrix}.$$

Užitečný trik:^a proto je i $4 \cdot \begin{pmatrix} -1/2 \\ -1/4 \\ 5/4 \\ 1 \\ 0 \end{pmatrix} = \begin{pmatrix} -2 \\ -1 \\ 5 \\ 4 \\ 0 \end{pmatrix}$, $4 \cdot \begin{pmatrix} 1/2 \\ -1/4 \\ -3/4 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 2 \\ -1 \\ -3 \\ 0 \\ 4 \end{pmatrix}$

fundamentální systém soustavy $\mathbf{X}^T \cdot \mathbf{a} = \mathbf{o}$.

Můžeme tedy psát: $\mathbf{A} = \begin{pmatrix} -2 & -1 & 5 & 4 & 0 \\ 2 & -1 & -3 & 0 & 4 \end{pmatrix}$.

^aFundamentální systém tvoří bázi jádra matice soustavy. A nenulové skalární násobky prvků jakékoli báze opět tvoří bázi.

Příklad (pokrač.)

- ④ Dopočteme \mathbf{b} z rovnice $\mathbf{A} \cdot \begin{pmatrix} 1 \\ 1 \\ -2 \\ 0 \\ 2 \end{pmatrix} = \mathbf{b}$.

$$\text{Tudíž } \mathbf{b} = \begin{pmatrix} -2 & -1 & 5 & 4 & 0 \\ 2 & -1 & -3 & 0 & 4 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \\ -2 \\ 0 \\ 2 \end{pmatrix} = \begin{pmatrix} -13 \\ 15 \end{pmatrix}.$$

Odpověď: 3-dimensionální affinní podprostor v \mathbb{R}^5

$$\begin{pmatrix} 1 \\ 1 \\ -2 \\ 0 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 2 \\ 1 \\ 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 2 \\ 0 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} -1 \\ 2 \\ 0 \\ 0 \\ 1 \end{pmatrix}\right)$$

je řešením soustavy $\left(\begin{array}{ccccc|c} -2 & -1 & 5 & 4 & 0 & -13 \\ 2 & -1 & -3 & 0 & 4 & 15 \end{array} \right)$ nad \mathbb{R} .



Závěrečné poznámky

- ① GEM je sice **universální metodou** řešení soustav lineárních rovnic, nad \mathbb{R} (nebo \mathbb{C}) je však **numericky nestabilní**.

V praxi je pro řešení (zvláště velkých) soustav lineárních rovnic nad \mathbb{R} (nebo \mathbb{C}) nutno **použít jiné metody** (například iterační Gaussovou-Seidelovu metodu,^a a jiné). Tyto metody jsou mimo syllabus standardní přednášky z lineární algebry.

- ② Jak řešit soustavy s parametrem? GEM je **universální metodou!** Při řešení soustav s parametrem pomocí GEM musíme být velmi opatrní na provádění elementárních úprav.

Pro soustavy se **čtvercovou** maticí vyvineme později další metodu řešení (kombinaci GEM a **Cramerovy věty**).

- ③ **Nepovinné:** Nad \mathbb{R} lze mít i další geometrický pohled na GEM (tzv. **Householderovy reflexe**).

^aViz Poznámku 6.4.7 **skript**.



Determinant: část 1

Odpřednesenou látku naleznete v kapitolách 8.1 a 8.2 skript *Abstraktní a konkrétní lineární algebra*.

Minulé přednášky

- ① GEM.
- ② Regularita a singularita čtvercových matic.

Dnešní přednáška

- ① Determinant čtvercové matice: **test regularity matice**.
Determinant má ale především **geometrický význam**.
- ② Bude nutné připomenout základní fakta o permutacích.
Použijeme grafickou notaci pro permutace: **strunové diagramy**.
- ③ Základní **metody výpočtu determinantu**: z definice a pomocí GEM.

Příští přednáška


- ① Hlubší poznatky o determinantech.
- ② Aplikace determinantu na řešení čtvercových soustav lineárních rovnic.

Definice (permutace)

Permutace množiny $\{1, 2, \dots, n\}$ je jakákoli bijekce
 $\pi : \{1, 2, \dots, n\} \rightarrow \{1, 2, \dots, n\}$.

Zápisy permutací

- ① Výčtem: $\pi : 1 \mapsto 2, 2 \mapsto 3, 3 \mapsto 4, 4 \mapsto 1$.
- ② Tabulkou: ^a $\pi = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 2 & 3 & 4 & 1 \end{bmatrix}$
- ③ Strunovým diagramem: ^b



Strunový diagram čteme odhora dolů.

^aUpozornění: tato tabulka není matice ve smyslu našeho předmětu.

^bŘešené příklady na strunové diagramy naleznete v kapitole 8.1 skript.

Grafické skládání permutací

Například:

$$\pi = \begin{array}{cccc} 1 & 2 & 3 & 4 \\ \diagdown & \diagdown & \diagdown & \diagdown \\ 1 & 2 & 3 & 4 \end{array} \quad \sigma = \begin{array}{cc} 1 & 2 \\ \diagup & \diagup \\ 1 & 2 \end{array} \quad \begin{array}{cc} 3 & 4 \\ \diagup & \diagup \\ 3 & 4 \end{array}$$

Spočteme nejdříve π a potom σ (směrem shora dolů):

$$\sigma \cdot \pi = \begin{array}{cccc} 1 & 2 & 3 & 4 \\ \diagdown & \diagdown & \diagdown & \diagdown \\ 1 & 2 & 3 & 4 \\ \diagup & \diagup & \diagup & \diagup \\ 1 & 2 & 3 & 4 \end{array} = \begin{array}{cccc} 1 & 2 & 3 & 4 \\ | & | & | & | \\ 1 & 2 & 3 & 4 \\ \diagup & \diagup & \diagup & \diagup \\ 1 & 2 & 3 & 4 \end{array}$$

Definice (symetrická grupa permutací)

Množině všech permutací množiny $\{1, 2, \dots, n\}$, spolu s výše uvedenou operací skládání \cdot , říkáme **symetrická grupa permutací n -prvkové množiny**. Značení: S_n .

Tvrzení (vlastnosti skládání permutací)

Skládání \cdot v S_n je asociativní, má neutrální prvek (říkáme mu **jednotková** (také: **triviální**) **permutace**, značíme id_n), každá permutace má inversi vzhledem ke skládání \cdot (značení a terminologie: π^{-1} je **inversní permutace** k permutaci π).

Důkaz.

Plyne okamžitě z vlastností bijekcí.




Definice (znaménko permutace)

Ať π je permutace množiny $\{1, \dots, n\}$. Znaménko permutace π je číslo $\text{sign } \pi$, které je definováno takto:

$$\text{sign } \pi = \begin{cases} +1, & \text{pokud strunový diagram } \pi \\ & \text{obsahuje sudý počet překřížení strun} \\ & (\text{v tomto případě říkáme, že } \pi \text{ je \textbf{sudá permutace}}), \\ -1, & \text{pokud strunový diagram } \pi \\ & \text{obsahuje lichý počet překřížení strun} \\ & (\text{v tomto případě říkáme, že } \pi \text{ je \textbf{lichá permutace}}). \end{cases}$$

Příklad

Pro permutace



platí: $\text{sign } \pi = -1 = \text{sign}(\pi^{-1})$.



Tvrzení (znaménka speciálních permutací)

- ① Pro identickou permutaci id_n v S_n platí $\text{sign}(\text{id}_n) = 1$.
- ② Pro libovolné permutace σ a π v S_n platí
 $\text{sign}(\sigma \cdot \pi) = (\text{sign } \sigma) \cdot (\text{sign } \pi)$.
- ③ Ať π je permutace v S_n . Pak platí $\text{sign } \pi = \text{sign}(\pi^{-1})$.
- ④ Ať π je permutace v S_n . Označte jako σ permutaci v S_n vzniklou z π prohozením dvou hodnot. Potom
 $\text{sign } \sigma = -\text{sign } \pi$.

Důkaz.

Přednáška (strunové diagramy).



Definice (determinant čtvercové matice)

Pro matici \mathbf{A} typu $n \times n$ nad \mathbb{F} definujeme determinant jako skalár

$$\det(\mathbf{A}) = \sum_{\pi \in S_n} \text{sign } \pi \cdot a_{\pi(1),1} \cdot a_{\pi(2),2} \cdot \dots \cdot a_{\pi(n),n}$$

Často se píše i $|\mathbf{A}|$ místo $\det(\mathbf{A})$.

„Šachový význam“ součinu $a_{\pi(1),1} \cdot a_{\pi(2),2} \cdot \dots \cdot a_{\pi(n),n}$

- ① Ať π je permutace v S_n .

Pokud na políčka $a_{\pi(1),1}, a_{\pi(2),2}, \dots, a_{\pi(n),n}$ rozestavíme věže, pak se navzájem neohrožují.^a

- ② Obráceně: n navzájem se neohrožujících věží na „šachovnici“ $(a_{i,j})$ určuje permutaci π v S_n a tím i jeden součin $a_{\pi(1),1} \cdot a_{\pi(2),2} \cdot \dots \cdot a_{\pi(n),n}$.

^aPřipomenutí: Položka $a_{\pi(j),j}$ matice \mathbf{A} je položka v j -tém sloupci na $\pi(j)$ -tému řádku.



Příklad (Sarrusovo pravidlo pro matice 3×3)

Na množině $\{1, 2, 3\}$ existuje přesně šest následujících permutací:

$$\pi_0 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline | & | & | \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

$$\pi_2 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline \diagdown & \diagdown & \diagdown \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

$$\pi_4 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline \diagup & \diagup & \diagup \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

$$\pi_1 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline \diagup & & | \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

$$\pi_3 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline | & \diagup & | \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$


$$\pi_5 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline \diagup & \diagup & \diagup \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

Tudíž:

$$\left| \begin{array}{ccc} a_{11} & a_{12} & a_{13} \\ a_{21} & a_{22} & a_{23} \\ a_{31} & a_{32} & a_{33} \end{array} \right| = a_{11} \cdot a_{22} \cdot a_{33} + a_{21} \cdot a_{32} \cdot a_{13} + a_{31} \cdot a_{12} \cdot a_{23} - a_{21} \cdot a_{12} \cdot a_{33} - a_{11} \cdot a_{32} \cdot a_{23} - a_{31} \cdot a_{22} \cdot a_{13}$$

Geometrický význam determinantu matice 2×2 nad \mathbb{R}

Determinant $\begin{vmatrix} a_1 & b_1 \\ a_2 & b_2 \end{vmatrix}$ je velikost $P(\mathbf{a}, \mathbf{b})$ orientované plochy




$$\text{kde } \mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} \text{ a } \mathbf{b} = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix}.$$



Geometrie determinantu (pokrač.)


Vlastnosti velikosti $P(\mathbf{a}, \mathbf{b})$ orientované plochy jsou:

- ① $P(\mathbf{e}_1, \mathbf{e}_2) = 1$. Tato rovnost zavádí jednotku plochy a orientaci prostoru \mathbb{R}^2 : při pohybu kolem počátku jsme zvolili směr proti směru hodinových ručiček — první je vektor \mathbf{e}_1 , vektor \mathbf{e}_2 je druhý.



Geometrie determinantu (pokrač.)

- ② $P(\mathbf{a}, \mathbf{b}) = -P(\mathbf{b}, \mathbf{a})$. Tato rovnost vystihuje, jak chápeme orientaci velikosti plochy: změnou pořadí vektorů \mathbf{a}, \mathbf{b} změníme znaménko velikosti plochy.



$$P(\mathbf{a}, \mathbf{b}) = -P(\mathbf{b}, \mathbf{a})$$


Geometrie determinantu (pokrač.)

- ③ Výpočet hodnoty $P(\mathbf{a}, \mathbf{b})$ je **lineární v každé položce**, tj. pro libovolná reálná čísla a_1, a_2, b_1, b_2 a libovolné vektory $\mathbf{a}, \mathbf{b}, \mathbf{a}_1, \mathbf{a}_2, \mathbf{b}_1, \mathbf{b}_2$ platí rovnosti

$$\begin{aligned} P(a_1 \cdot \mathbf{a}_1 + a_2 \cdot \mathbf{a}_2, \mathbf{b}) &= a_1 \cdot P(\mathbf{a}_1, \mathbf{b}) + a_2 \cdot P(\mathbf{a}_2, \mathbf{b}) \\ P(\mathbf{a}, b_1 \cdot \mathbf{b}_1 + b_2 \cdot \mathbf{b}_2) &= b_1 \cdot P(\mathbf{a}, \mathbf{b}_1) + b_2 \cdot P(\mathbf{a}, \mathbf{b}_2) \end{aligned}$$

Důležitý důsledek: platí rovnosti $P(\mathbf{a}, \mathbf{b}) = P(\mathbf{a}, \mathbf{b} + a \cdot \mathbf{a})$ a $P(\mathbf{a}, \mathbf{b}) = P(\mathbf{a} + b \cdot \mathbf{b}, \mathbf{b})$ pro a, b reálná.

Například:



$$P(\mathbf{a}, \mathbf{b}) = P(\mathbf{a}, \mathbf{b} - 2\mathbf{a})$$



Zobecnění (geometrický význam determinantu)

Determinant $\det(\mathbf{A})$ matice $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_n)$ typu $n \times n$ nad \mathbb{F} je **velikost** $V(\mathbf{a}_1, \dots, \mathbf{a}_n)$ orientovaného objemu rovnoběžnostěnu v prostoru \mathbb{F}^n . Rovnoběžnostěn je určen vektory $\mathbf{a}_1, \dots, \mathbf{a}_n$ (v tomto pořadí).

Platí:

- ① $V(\mathbf{e}_1, \dots, \mathbf{e}_n) = 1$.
- ② $V(\mathbf{a}_1, \dots, \mathbf{a}_n) = \text{sign } \pi \cdot V(\mathbf{a}_{\pi(1)}, \dots, \mathbf{a}_{\pi(n)})$, kde π je libovolná permutace v S_n .
- ③ $V(\mathbf{a}_1, \dots, \mathbf{a}_n)$ je lineární v každé souřadnici zvlášť.

Výše uvedené tři vlastnosti funkce

$$V : \underbrace{\mathbb{F}^n \times \cdots \times \mathbb{F}^n}_{n\text{-krát}} \rightarrow \mathbb{F}$$

určují pojem determinantu jednoznačně.

Tvrzení (determinant transponované matice)

Platí: $\det(\mathbf{A}) = \det(\mathbf{A}^T)$.

Důkaz.

$$\begin{aligned}\det(\mathbf{A}) &= \sum_{\pi \in S_n} \text{sign } \pi \cdot a_{\pi(1),1} \cdot a_{\pi(2),2} \cdots \cdot a_{\pi(n),n} \\ &= \sum_{\pi^{-1} \in S_n} \text{sign } \pi^{-1} \cdot a_{1,\pi^{-1}(1)} \cdot a_{2,\pi^{-1}(2)} \cdots \cdot a_{n,\pi^{-1}(n)} \\ &= \sum_{\pi \in S_n} \text{sign } \pi \cdot a_{1,\pi(1)} \cdot a_{2,\pi(2)} \cdots \cdot a_{n,\pi(n)} \\ &= \det(\mathbf{A}^T)\end{aligned}$$

Využili jsme jednoduchého faktu: platí rovnosti
 $\{\pi \mid \pi \in S_n\} = S_n = \{\pi^{-1} \mid \pi \in S_n\}$. ■

Důsledky (výpočet determinantu a GEM)

- ① Prohození dvou řádků mění znaménko determinantu.
- ② Vynásobení jednoho řádku nenulovým skalárem a změní determinant a -krát.
- ③ Přičtení lineární kombinace ostatních řádků k řádku nezmění hodnotu determinantu.

Tvrzení (determinant horní trojúhelníkové matice)

At \mathbf{A} je horní trojúhelníková matice. Potom $\det(\mathbf{A}) =$ součin prvků na hlavní diagonále matice.

Důsledek (opatrný výpočet determinantu pomocí GEM)

$\det(\mathbf{A})$ lze počítat pomocí GEM: je nutné si ovšem poznamenat typy úprav (a tudíž i případné změny hodnoty determinantu).

Příklad (výpočet determinantu pomocí GEM)

$$\begin{array}{c}
 \left| \begin{array}{ccc} 2 & 3 & 1 \\ 3 & 1 & 4 \\ -2 & 16 & 3 \end{array} \right| = -\frac{1}{2} \left| \begin{array}{ccc} 2 & 3 & 1 \\ -6 & -2 & -8 \\ -2 & 16 & 3 \end{array} \right| R_1 -2R_2 = \\
 = -\frac{1}{2} \left| \begin{array}{ccc} 2 & 3 & 1 \\ 0 & 7 & -5 \\ 0 & 19 & 4 \end{array} \right| R_1 R_2 + 3R_1 = \\
 = \frac{1}{2} \cdot \frac{1}{7} \left| \begin{array}{ccc} 2 & 3 & 1 \\ 0 & 7 & -5 \\ 0 & -133 & -28 \end{array} \right| R_1 R_2 -7R_3 = \\
 = \frac{1}{2} \cdot \frac{1}{7} \left| \begin{array}{ccc} 2 & 3 & 1 \\ 0 & 7 & -5 \\ 0 & 0 & -123 \end{array} \right| R_1 R_2 R_3 + 19R_2 = \\
 = \frac{2 \cdot 7 \cdot (-123)}{2 \cdot 7} = -123
 \end{array}$$



Věta (invertibilita matice pomocí determinantu)

Pro matici \mathbf{A} typu $n \times n$ nad \mathbb{F} platí: \mathbf{A} je regulární právě tehdy, když $\det(\mathbf{A}) \neq 0$.

Důkaz.

Bez důkazu (viz např. Důsledek 8.4.4 skript).



Poznámky k výpočtu $\det(\mathbf{A})$

- ① Výpočet z definice: časově náročný. Je zapotřebí se vyznat v S_n (má $n!$ prvků).
- ② Výpočet pomocí GEM: méně náročný (řádově n^3 kroků).
Pozor! Nad \mathbb{R} a \mathbb{C} je GEM **numericky nestabilní**. Navíc (při ručním výpočtu) je zapotřebí GEM provádět opatrně.
- ③ Jiný způsob výpočtu? Ano: rozvoj podle řádku nebo sloupce (rekursivní výpočet). **Příště.**

Jiný způsob zavedení determinantu (nepovinné)

Determinant lze zavést pomocí **vnější mocniny**^a lineárního prostoru, viz kapitolu 5 *skript*.

Výhody tohoto přístupu:

- ① Okamžitý geometrický výhled do pojmu determinant a snadné důkazy vlastností determinantu.
- ② Determinant je možno počítat pro libovolná lineární zobrazení, ne jen pro matice.
- ③ Pojem vnější mocniny vede rychle ke **geometrické algebře**, která umožňuje elegantní a rychlé výpočty v počítačové grafice, viz například knihu

L. Dorst, D. Fontijne, S. Mann, *Geometric algebra for Computer Science*, Elsevier, 2007

^aNa první pohled myšlenka vnější mocniny vypadá velmi divoce. Tato myšlenka je ale velmi přirozená a je stejně stará jako lineární algebra: v roce 1844 s ní přišel **Hermann Grassmann** (1808–1887).

Determinant, část 2

Odpřednesenou látku naleznete v kapitolách 8.3 a 8.4
skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

- ① Definice determinantu čtvercové matice (s použitím permutací).
- ② Základní metody výpočtu determinantu:
 - ① Z definice: nutnost znalosti S_n .
 - ② Pomocí GEM: nutnost opatrného provádění GEM.
- ③ Čtvercová matice \mathbf{A} je regulární právě tehdy, když $\det(\mathbf{A}) \neq 0$.

Dnešní přednáška

- ① Věta o rozvoji determinantu podle sloupce.^a
- ② Hlubší poznatky o determinantu.
- ③ Aplikace determinantu na řešení čtvercových soustav lineárních rovnic (Cramerova věta). Ukážeme geometrický význam Cramerovy věty.

^aVíme: $\det(\mathbf{A}^T) = \det(\mathbf{A})$. Takže determinant půjde rozvíjet i podle řádku.

Připomenutí

Determinant $\det(\mathbf{A})$ čtvercové matice $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_n)$ je **lineární v každém sloupci**. Speciálně: protože $\mathbf{a}_j = \sum_{i=1}^n a_{ij} \cdot \mathbf{e}_i$ (kde \mathbf{a}_j je j -tý sloupec matice \mathbf{A}), platí rovnost:^a

$$\det(\mathbf{A}) = \sum_{i=1}^n a_{ij} \cdot \underbrace{\det(\mathbf{a}_1, \dots, \mathbf{a}_{j-1}, \mathbf{e}_i, \mathbf{a}_{j+1}, \dots, \mathbf{a}_n)}_{\text{Značení: } A_{ij}}.$$

Například (zvolili jsme $j = 2$, tj. rozvíjíme podle druhého sloupce):

$$\left| \begin{array}{ccc} -2 & 4 & 5 \\ 3 & 6 & 7 \\ 7 & -2 & 5 \end{array} \right| = 4 \cdot \underbrace{\left| \begin{array}{ccc} -2 & 1 & 5 \\ 3 & 0 & 7 \\ 7 & 0 & 5 \end{array} \right|}_{A_{12}} + 6 \cdot \underbrace{\left| \begin{array}{ccc} -2 & 0 & 5 \\ 3 & 1 & 7 \\ 7 & 0 & 5 \end{array} \right|}_{A_{22}} - 2 \cdot \underbrace{\left| \begin{array}{ccc} -2 & 0 & 5 \\ 3 & 0 & 7 \\ 7 & 1 & 5 \end{array} \right|}_{A_{32}}$$

^aTéto rovnosti se říká (Laplaceův) **rozvoj determinantu podle j -tého sloupce**.

Definice

Determinantu $A_{ij} = \det(\mathbf{a}_1, \dots, \mathbf{a}_{j-1}, \mathbf{e}_i, \mathbf{a}_{j+1}, \dots, \mathbf{a}_n)$ říkáme algebraický doplněk posice (i, j) v matici $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_n)$.

Věta (praktický výpočet algebraického doplňku)

At' \mathbf{A} je matice typu $n \times n$ nad \mathbb{F} , $n \geq 2$. Označme jako \mathbf{A}_{ij} matici typu $(n-1) \times (n-1)$ vzniklou z matice \mathbf{A} vynescháním i -tého řádku a j -tého sloupce. Potom^a $A_{ij} = (-1)^{i+j} \cdot \det(\mathbf{A}_{ij})$.

^aPozor: nezapomeňte na znaménko posice (i, j) : $A_{ij} = (-1)^{i+j} \cdot \det(\mathbf{A}_{ij})$.

Důkaz.

Bez důkazu (viz např. Lemma 8.3.4 ve skriptech). ■

Pozorování

Rozvoj determinantu podle sloupce umožňuje rekursivní výpočet determinantu! Důvod: pro \mathbf{A} typu $n \times n$ jsou algebraické doplněky jednotlivých posic determinanty matic typu $(n-1) \times (n-1)$.



Příklad (determinant rozvojem podle třetího sloupce)

$$\left| \begin{array}{cccc} 1 & 2 & 0 & 1 \\ 2 & 7 & 6 & 3 \\ 5 & 2 & 0 & 3 \\ 3 & 2 & 5 & 1 \end{array} \right| = 0 \cdot (-1)^{1+3} \cdot \underbrace{\left| \begin{array}{ccc} 2 & 7 & 3 \\ 5 & 2 & 3 \\ 3 & 2 & 1 \end{array} \right|}_{A_{13}}$$

$$+ 6 \cdot (-1)^{2+3} \cdot \underbrace{\left| \begin{array}{ccc} 1 & 2 & 1 \\ 5 & 2 & 3 \\ 3 & 2 & 1 \end{array} \right|}_{A_{23}}$$

$$+ 0 \cdot (-1)^{3+3} \cdot \underbrace{\left| \begin{array}{ccc} 1 & 2 & 1 \\ 2 & 7 & 3 \\ 3 & 2 & 1 \end{array} \right|}_{A_{33}}$$

$$+ 5 \cdot (-1)^{4+3} \cdot \underbrace{\left| \begin{array}{ccc} 1 & 2 & 1 \\ 2 & 7 & 3 \\ 5 & 2 & 3 \end{array} \right|}_{A_{43}}$$



Poznámky k výpočtu determinantu rozvojem podle sloupce

- ① Protože $\det(\mathbf{A}) = \det(\mathbf{A}^T)$, lze determinant počítat i rozvojem podle řádku.
- ② Rekursivní výpočet determinantu (tj. výpočet rozvojem podle sloupce nebo řádku) má složitost $n!$ — je tudíž obecně výpočetně pomalý.
- ③ Výpočet determinantu rozvojem je vhodný pro řídké matice (matice, obsahující hodně nul).

Definice (adjungovaná matice)

Pro matici \mathbf{A} typu $n \times n$ je její adjungovaná matice $\text{adj}(\mathbf{A})$ transponovaná matice algebraických doplňků posic v matici \mathbf{A} .

Příklad (nad \mathbb{R})

Pro $\mathbf{A} = \begin{pmatrix} 2 & 7 \\ 5 & 3 \end{pmatrix}$ je $\text{adj}(\mathbf{A}) = \begin{pmatrix} 3 & -7 \\ -5 & 2 \end{pmatrix}$.

Věta (inverse matice pomocí algebraických doplňků)

Ať \mathbf{A} je matice typu $n \times n$ nad \mathbb{F} , $n \geq 2$. Potom platí rovnosti:

$$\mathbf{A} \cdot \text{adj}(\mathbf{A}) = \det(\mathbf{A}) \cdot \mathbf{E}_n = \text{adj}(\mathbf{A}) \cdot \mathbf{A}$$

Pro regulární \mathbf{A} tedy platí $\mathbf{A}^{-1} = \det(\mathbf{A})^{-1} \cdot \text{adj}(\mathbf{A})$.

Důkaz.

- ① Každý prvek na hlavní diagonále matice $\mathbf{A} \cdot \text{adj}(\mathbf{A})$ má hodnotu $\det(\mathbf{A})$. To plyne z rozvoje determinantu podle sloupce.
- ② Každý prvek mimo hlavní diagonálu matice $\mathbf{A} \cdot \text{adj}(\mathbf{A})$ má hodnotu 0. To plyne z rozvoje determinantu, aplikovaného na matici se dvěma stejnými řádky.

Tudíž $\mathbf{A} \cdot \text{adj}(\mathbf{A}) = \det(\mathbf{A}) \cdot \mathbf{E}_n$. Druhá rovnost se dokáže analogicky.

Příklad (inverse pomocí adjungované matice)

Pro $\mathbf{A} = \begin{pmatrix} 1 & 2 & 3 \\ 2 & 4 & 7 \\ 4 & 2 & 1 \end{pmatrix}$ nad \mathbb{R} je $\det(\mathbf{A}) = 6$. Víme, že **inverse** matice \mathbf{A} **existuje**.

- ① Matice algebraických doplňků posic v matici \mathbf{A} je $\begin{pmatrix} -10 & 26 & -12 \\ 4 & -11 & 6 \\ 2 & -1 & 0 \end{pmatrix}$.

$$\text{Proto } \text{adj}(\mathbf{A}) = \begin{pmatrix} -10 & 26 & -12 \\ 4 & -11 & 6 \\ 2 & -1 & 0 \end{pmatrix}^T = \begin{pmatrix} -10 & 4 & 2 \\ 26 & -11 & -1 \\ -12 & 6 & 0 \end{pmatrix}.$$

- ② Celkově $\mathbf{A}^{-1} = 6^{-1} \cdot \begin{pmatrix} -10 & 4 & 2 \\ 26 & -11 & -1 \\ -12 & 6 & 0 \end{pmatrix}$.

Doporučení (sanity check)

Při výpočtu $\text{adj}(\mathbf{A})$ je možná rozumné **nejprve** spočítat matici algebraických doplňků a **potom** ji transponovat.

Výhodnost a vhodnost výpočtu \mathbf{A}^{-1} pomocí $\text{adj}(\mathbf{A})$

- ① Pro obecné (velké) matice je výpočet **nevýhodný**. Vyžaduje spočítat velké množství determinantů.
- ② Pro **velké a řídké matice** (tj. pro matice obsahující velké množství nulových položek) **může** jít o **výhodný** výpočet.
- ③ Výpočet je **výhodný** pro matice typu 2×2 .

Ať $\mathbf{A} = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$ je regulární (tj., ať $\det(\mathbf{A}) = ad - bc \neq 0$).

Potom

$$\mathbf{A}^{-1} = (ad - bc)^{-1} \cdot \begin{pmatrix} d & -c \\ -b & a \end{pmatrix}^T = (ad - bc)^{-1} \cdot \begin{pmatrix} d & -b \\ -c & a \end{pmatrix}.$$

- ④ **Poznámka:** některé aplikace (například v kryptografii) vyžadují práci s maticemi nad ještě **obecnější** strukturou než je těleso. Pak je výpočet \mathbf{A}^{-1} pomocí $\text{adj}(\mathbf{A})$ často jediná možnost.

Věta (základní strukturální vlastnosti determinantu)


Funkce $\det : \underbrace{\mathbb{F}^n \times \dots \mathbb{F}^n}_{n\text{-krát}} \rightarrow \mathbb{F}$ má následující vlastnosti:

- ① $\det(\mathbf{E}_n) = 1.$
- ② $\det(\mathbf{B} \cdot \mathbf{A}) = \det(\mathbf{B}) \cdot \det(\mathbf{A}).$
- ③ Pro regulární \mathbf{A} je $\det(\mathbf{A}^{-1}) = (\det(\mathbf{A}))^{-1}.$
- ④ $\det(a \cdot \mathbf{A}) = a^n \cdot \det(\mathbf{A}),$ kde a je libovolný skalár.^a

^aPozor: rovnost $\det(\mathbf{A} + \mathbf{B}) = \det(\mathbf{A}) + \det(\mathbf{B})$ obecně neplatí.

Důkaz.

- ① Víme z minulé přednášky.
- ② Bez důkazu (viz např. Tvrzení 8.2.19 ve [skriptech](#)).
- ③ Pro regulární \mathbf{A} platí rovnosti
 $1 = \det(\mathbf{E}_n) = \det(\mathbf{A} \cdot \mathbf{A}^{-1}) = \det(\mathbf{A}) \cdot \det(\mathbf{A}^{-1}).$
Takže $\det(\mathbf{A}^{-1}) = (\det(\mathbf{A}))^{-1}.$
- ④ Plyne z toho, že determinant je v každém sloupci lineární.



Definice (soustava se čtvercovou maticí)

Rovnici $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$, kde \mathbf{A} je matice typu $n \times n$ nad \mathbb{F} , říkáme soustava se čtvercovou maticí.

Tvrzení (řešení čtvercové soustavy s regulární maticí)

Ať $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$ je soustava se čtvercovou maticí. Tato soustava má jediné řešení právě tehdy, když \mathbf{A} je regulární matici. V tomto případě je toto jediné řešení tvaru $\mathbf{A}^{-1} \cdot \mathbf{b}$.

Důkaz.

Regularita matice \mathbf{A} znamená přesně to, že $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ je isomorfismus. To znamená přesně to, že pro každé \mathbf{b} existuje právě jedno \mathbf{x} takové, že $\mathbf{A} : \mathbf{x} \mapsto \mathbf{b}$, neboli $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$. ■

Cramerova věta (také: Cramerovo pravidlo)

Ať $\mathbf{A} \cdot \mathbf{x} = \mathbf{b}$ je soustava se čtvercovou **regulární** maticí nad \mathbb{F} .
Potom j -tá položka jediného řešení $\mathbf{x} = \mathbf{A}^{-1} \cdot \mathbf{b}$ je tvaru

$$x_j = \det(\mathbf{A})^{-1} \cdot \det(\mathbf{a}_1, \dots, \mathbf{a}_{j-1}, \mathbf{b}, \mathbf{a}_{j+1}, \dots, \mathbf{a}_n)$$

Důkaz.

Víme: $\mathbf{x} = \mathbf{A}^{-1} \cdot \mathbf{b} = \det(\mathbf{A})^{-1} \cdot \text{adj}(\mathbf{A}) \cdot \mathbf{b}$. Takže

$$\det(\mathbf{A}) \cdot \mathbf{x} = \text{adj}(\mathbf{A}) \cdot \mathbf{b}$$

Proto $\det(\mathbf{A}) \cdot x_j$ je součin j -tého řádku matice $\text{adj}(\mathbf{A})$ se sloupcem \mathbf{b} .

Ten součin je roven $\det(\mathbf{a}_1, \dots, \mathbf{a}_{j-1}, \mathbf{b}, \mathbf{a}_{j+1}, \dots, \mathbf{a}_n)$. ■

Příklad (použití Cramerovy věty)

Pro soustavu $\begin{pmatrix} 2 & 4 \\ -3 & 5 \end{pmatrix} \left| \begin{array}{c} 1 \\ 6 \end{array} \right.$ nad \mathbb{R} platí $\begin{vmatrix} 2 & 4 \\ -3 & 5 \end{vmatrix} = 22 \neq 0$. Lze tedy použít Cramerovu větu:

- ① První položka jediného řešení je:

$$\frac{\begin{vmatrix} 1 & 4 \\ 6 & 5 \end{vmatrix}}{\begin{vmatrix} 2 & 4 \\ -3 & 5 \end{vmatrix}} = \frac{-19}{22}.$$

- ② Druhá položka jediného řešení je:


$$\frac{\begin{vmatrix} 2 & 1 \\ -3 & 6 \end{vmatrix}}{\begin{vmatrix} 2 & 4 \\ -3 & 5 \end{vmatrix}} = \frac{15}{22}.$$

Jediné řešení: $\begin{pmatrix} \frac{-19}{22} \\ \frac{15}{22} \end{pmatrix}$.

Geometrie Cramerovy věty pro soustavy 2×2 nad \mathbb{R}


Pro regulární soustavu $(\mathbf{a}_1, \mathbf{a}_2 | \mathbf{b})$ platí podle Cramerovy věty

$$\frac{\det(\mathbf{b}, \mathbf{a}_2)}{\det(\mathbf{a}_1, \mathbf{a}_2)} \cdot \mathbf{a}_1 + \frac{\det(\mathbf{a}_1, \mathbf{b})}{\det(\mathbf{a}_1, \mathbf{a}_2)} \cdot \mathbf{a}_2 = \mathbf{b}. \text{ Co to opravdu znamená?}^a$$



Ale $x \cdot \det(\mathbf{a}_1, \mathbf{a}_2) = \det(x \cdot \mathbf{a}_1, \mathbf{a}_2) = \det(\mathbf{b}, \mathbf{a}_2)$, takže platí

$$x = \frac{\det(\mathbf{b}, \mathbf{a}_2)}{\det(\mathbf{a}_1, \mathbf{a}_2)}.$$



Podobnou úvahu lze provést pro $y = \frac{\det(\mathbf{a}_1, \mathbf{b})}{\det(\mathbf{a}_1, \mathbf{a}_2)}$.

^aAnalogicky lze postupovat pro regulární soustavy větších rozměrů a nad libovolným tělesem (musíme ovšem kreslit rovnoběžnostěny).



Příklad (vyřešte nad \mathbb{R} , $p \in \mathbb{R}$ je parametr)

$$(\mathbf{A} | \mathbf{b}) = \left(\begin{array}{ccc|c} 2 & -p & -1 & 3 \\ 1 & -7 & -5 & 0 \\ -1 & 3 & p & -1 \end{array} \right), \det(\mathbf{A}) = (p-2) \cdot (p-17).$$

① $\det(\mathbf{A}) \neq 0$ právě tehdy, když $p \notin \{2, 17\}$.

V tomto případě existuje jediné řešení. Toto jediné řešení lze nalézt pomocí GEM nebo pomocí Cramerovy věty.

Řešení:
$$\begin{pmatrix} \frac{26}{17-p} \\ \frac{3}{17-p} \\ \frac{1}{17-p} \end{pmatrix}, p \notin \{2, 17\}.$$

Příklad (pokrač.)

② $p = 2$. Řešíme soustavu $\left(\begin{array}{ccc|c} 2 & -2 & -1 & 3 \\ 1 & -7 & -5 & 0 \\ -1 & 3 & 2 & -1 \end{array} \right)$.

Řešení: $\begin{pmatrix} \frac{5}{3} \\ 0 \\ \frac{1}{3} \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 3 \\ -4 \end{pmatrix}\right)$, pro $p = 2$.

③ $p = 17$. Řešíme soustavu $\left(\begin{array}{ccc|c} 2 & -17 & -1 & 3 \\ 1 & -7 & -5 & 0 \\ -1 & 3 & 17 & -1 \end{array} \right)$.

Řešení pro $p = 17$ neexistuje (Frobeniova věta).

Doporučení

Pro čtvercové soustavy s parametrem doporučujeme použít kombinaci Cramerovy věty a GEM. Výpočet pak má dvě fáze:

- 1 Cramerova věta pro ty parametry, pro které je matice soustavy regulární.
- 2 GEM pro ty parametry, pro které je matice soustavy singulární.

Vlastní hodnoty a vlastní vektory

Odpřednesenou látku naleznete v kapitolách 10.1, 10.3 a 10.4 skript *Abstraktní a konkrétní lineární algebra*.

Minulé přednášky

- 1 Matice lineárních zobrazení mezi prostory konečných dimensí.
- 2 Matice transformace souřadnic.

Dnešní přednáška

- 1 Budeme studovat obecná lineární zobrazení $\mathbf{f} : L \rightarrow L$, kde L má konečnou dimensi.
Zjistíme, pro které vektory \vec{x} platí $\mathbf{f}(\vec{x}) = \lambda \cdot \vec{x}$ (tzv **homotetie** — to je to nejjednodušší lineární zobrazení z L do L).
- 2 Budeme se snažit změnit bázi L tak, aby ve směrech vektorů nové báze bylo zobrazení $\mathbf{f} : L \rightarrow L$ homotetií (obecně pro každý směr různou). Ne vždy to půjde.

Příští přednáška

- 1 Diagonálisace matic nad \mathbb{R} a nad \mathbb{C} .
- 2 Dvě aplikace diagonálisace: řešení rekurentních rovnic a funkce matic.^a

^aTyto dvě aplikace nebudou zkoušeny!



Příklad (equilibrium stochastických procesů)

Pro matici $\mathbf{A} = \begin{pmatrix} 0.3 & 0.7 \\ 0.8 & 0.2 \end{pmatrix}$ nalezněte alespoň jeden nenulový vektor \mathbf{q} tak, aby platila rovnost^a $\mathbf{A} \cdot \mathbf{q} = \mathbf{q}$.

To je snadné: $\begin{pmatrix} 0.3 & 0.7 \\ 0.8 & 0.2 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$, protože řádkové součty matice \mathbf{A} jsou 1. Tudíž $\mathbf{q} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$.

^a Stejnou (ale komplikovaněji zadanou) úlohu řeší algoritmus PageRank, viz například K. Bryan a A. Leise, *The \$ 25,000,000,000 eigenvector: The linear algebra behind Google*, *SIAM Rev.* 48.3 (2006), 569–581, nebo Dodatek F skript.

Co dělat pro obecnou matici \mathbf{A} ?

Měli jsme štěstí („hezký“ tvar matice \mathbf{A} , takovým maticím se říká řádkově stochastické). Jak ale postupovat pro obecnou matici \mathbf{A} ?

Příklad (equilibrium stochastických procesů, znovu a jinak)

Pro matici $\mathbf{A} = \begin{pmatrix} 0.3 & 0.7 \\ 0.8 & 0.2 \end{pmatrix}$ nalezneme všechna **nenulová** řešení **všech soustav** tvaru $\mathbf{A} \cdot \mathbf{x} = \lambda \cdot \mathbf{x}$, kde $\lambda \in \mathbb{R}$ je **neznámé**.

Přepsáním soustavy $\mathbf{A} \cdot \mathbf{x} = \lambda \cdot \mathbf{x}$ na $(\mathbf{A} - \lambda \cdot \mathbf{E}_2) \cdot \mathbf{x} = \mathbf{o}$ zjistíme, co je třeba udělat:

- ① Matice $\mathbf{A} - \lambda \cdot \mathbf{E}_2$ musí být singulární. Jedině tehdy bude mít rovnice $(\mathbf{A} - \lambda \cdot \mathbf{E}_2) \cdot \mathbf{x} = \mathbf{o}$ nenulové řešení.

To jest: hledáme všechna λ taková, aby $\det(\mathbf{A} - \lambda \cdot \mathbf{E}_2) = 0$.

To znamená vyřešit rovnici $\det(\mathbf{A} - \lambda \cdot \mathbf{E}_2) = 0$.

- ② Pro konkrétní hodnoty λ nalezneme nenulové řešení soustavy $(\mathbf{A} - \lambda \cdot \mathbf{E}_2) \cdot \mathbf{x} = \mathbf{o}$ pomocí GEM.

Příklad (equilibrium stochastických procesů, pokrač.)

$$\det(\mathbf{A} - x \cdot \mathbf{E}_2) = \begin{vmatrix} 0.3 - x & 0.7 \\ 0.8 & 0.2 - x \end{vmatrix} = (0.3 - x) \cdot (0.2 - x) - 0.56 = \\ = x^2 - 0.5x - 0.5 = (x - 1) \cdot (x + 0.5) = 0.$$

Soustava $(\mathbf{A} - x \cdot \mathbf{E}_2) \cdot \mathbf{x} = \mathbf{0}$ pro

- ① $x = 1$ má tvar $\left(\begin{array}{cc|c} -0.7 & 0.7 & 0 \\ 0.8 & -0.8 & 0 \end{array} \right)$ a řešení^a $\text{span}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right)$.

To znamená: $\mathbf{A} \cdot \mathbf{x} = \mathbf{x}$ pro všechna \mathbf{x} ze $\text{span}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right)$.

- ② $x = -0.5$ má tvar $\left(\begin{array}{cc|c} 0.8 & 0.7 & 0 \\ 0.8 & 0.7 & 0 \end{array} \right)$ a řešení^b $\text{span}\left(\begin{pmatrix} -7 \\ 8 \end{pmatrix}\right)$.

To znamená: $\mathbf{A} \cdot \mathbf{x} = -0.5 \cdot \mathbf{x}$ pro všechna \mathbf{x} ze $\text{span}\left(\begin{pmatrix} -7 \\ 8 \end{pmatrix}\right)$.

^aTo jsme již věděli.

^bTo je nová informace.

Příklad (equilibrium stochastických procesů, pokrač.)

Co jsme se vlastně dozvěděli a k čemu je to dobré?

- ① V souřadnicovém systému $B = \left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}, \begin{pmatrix} -7 \\ 8 \end{pmatrix} \right)$ se matice \mathbf{A} stane **diagonální maticí** $D(1; -0.5) = \begin{pmatrix} 1 & 0 \\ 0 & -0.5 \end{pmatrix}$.

Opravdu:

$$\underbrace{\begin{pmatrix} 1 & -7 \\ 1 & 8 \end{pmatrix}}_{\mathbf{T}_{B \mapsto K_2}} \cdot \underbrace{\begin{pmatrix} 1 & 0 \\ 0 & -0.5 \end{pmatrix}}_{D(1; -0.5)} = \begin{pmatrix} 1 & 3.5 \\ 1 & -4 \end{pmatrix} = \underbrace{\begin{pmatrix} 0.3 & 0.7 \\ 0.8 & 0.2 \end{pmatrix}}_{\mathbf{A}} \cdot \underbrace{\begin{pmatrix} 1 & -7 \\ 1 & 8 \end{pmatrix}}_{\mathbf{T}_{B \mapsto K_2}}$$

tudíž

$$\underbrace{\begin{pmatrix} 1 & 0 \\ 0 & -0.5 \end{pmatrix}}_{D(1; -0.5)} = \underbrace{\begin{pmatrix} 1 & -7 \\ 1 & 8 \end{pmatrix}}_{\mathbf{T}_{K_2 \mapsto B}}^{-1} \cdot \underbrace{\begin{pmatrix} 0.3 & 0.7 \\ 0.8 & 0.2 \end{pmatrix}}_{\mathbf{A}} \cdot \underbrace{\begin{pmatrix} 1 & -7 \\ 1 & 8 \end{pmatrix}}_{\mathbf{T}_{B \mapsto K_2}}$$

Příklad (equilibrium stochastických procesů, pokrač.)

- ② Díky předchozímu vidíme, že zadáme-li rekurentní proces


\mathbf{x}_0 libovolný vektor z \mathbb{R}^2 , $\mathbf{A} \cdot \mathbf{x}_k = \mathbf{x}_{k+1}$, $k \geq 0$,

pak se **posloupnost** vektorů $\mathbf{x}_0, \mathbf{x}_1, \mathbf{x}_2, \dots$ chová následovně:


- ① Je-li \mathbf{x}_0 na přímce $\text{span}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right)$, jde o posloupnost $\mathbf{x}_0, \mathbf{x}_0, \mathbf{x}_0, \dots$
- ② Je-li \mathbf{x}_0 na přímce $\text{span}\left(\begin{pmatrix} -7 \\ 8 \end{pmatrix}\right)$, jde o posloupnost $\mathbf{x}_0, -0.5 \cdot \mathbf{x}_0, (-0.5)^2 \cdot \mathbf{x}_0, (-0.5)^3 \cdot \mathbf{x}_0, \dots$
- ③ Je-li $\mathbf{x}_0 = a \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix} + b \cdot \begin{pmatrix} -7 \\ 8 \end{pmatrix}$, tedy jestliže platí rovnost $\mathbf{coord}_B(\mathbf{x}_0) = \begin{pmatrix} a \\ b \end{pmatrix}$, potom $\mathbf{coord}_B(\mathbf{x}_n) = \begin{pmatrix} a \\ (-0.5)^n \cdot b \end{pmatrix}$.

Diagonalisací matice \mathbf{A} tedy získáváme o rekurentním procesu úplný přehled.


Příklad (equilibrium stochastických procesů, pokrač.)




Příklad (equilibrium stochastických procesů, pokrač.)



Příklad (equilibrium stochastických procesů, pokrač.)



Příklad (equilibrium stochastických procesů, pokrač.)



Shrnutí dosavadních úvah

- ① Pokud pro obecnou matici $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ najdeme bázi B , ve které \mathbf{A} je diagonální maticí, získáme v nové bázi úplný přehled o maticích tvaru \mathbf{A}^k , kde $k \geq 0$.

To je důležité například v následujících oblastech:

- ① Teorie dynamických systémů.
- ② Ekonomie (například tzv. Leontiefův input-output model).
- ③ Složitost rekursivních algoritmů (řešení rekurentních rovnic, viz příští přednášku).
- ④ Geometrie kvadratických útvarů, viz kapitolu 14.1 skript.
- ⑤ Funkce matic, viz příští přednášku.
- ⑥ Atd.

Hledání diagonální matice k matici \mathbf{A} se říká **diagonalisace** matice \mathbf{A} . Ne vždy zadanou matici diagonalisovat půjde.

- ② Problém diagonalisace lze zformulovat (a řešit) pro **obecná** lineární zobrazení $\mathbf{f} : L \rightarrow L$, kde L má konečnou dimensi.

Definice

Pro lineární zobrazení $f : L \rightarrow L$ je λ v \mathbb{F} **vlastní hodnotou** (také: **vlastním číslem**), pokud existuje nenulový vektor \vec{x} , splňující rovnost $f(\vec{x}) = \lambda \cdot \vec{x}$.

Každému takovému nenulovému vektoru \vec{x} říkáme **vlastní vektor** **příslušný hodnotě** λ .

Pozorování

Ať $f : L \rightarrow L$ je lineární zobrazení.

- ① Pro libovolné λ v \mathbb{F} platí: $\{\vec{x} \mid f(\vec{x}) = \lambda \cdot \vec{x}\} = \ker(f - \lambda \cdot \text{id})$.
Tudíž vlastní vektory příslušné hodnotě λ tvoří podprostor L .^a
- ② λ je vlastní hodnota f právě tehdy, když $\text{eigen}(\lambda, f)$ je netriviální prostor.

^aŘíkáme mu **vlastní podprostor** příslušný λ , značíme jej $\text{eigen}(\lambda, f)$. Důvod: vlastní hodnotě se říká **eigenvalue**, vlastnímu vektoru **eigenvector**, vlastnímu podprostoru **eigenspace**. Německy: eigen=vlastní.

Připomenutí (základní vlastnosti podobnosti matic)

Řekneme, že dvě matice \mathbf{A} a \mathbf{B} typu $n \times n$ nad \mathbb{F} jsou si **podobné** (značení: $\mathbf{A} \approx \mathbf{B}$), pokud platí rovnost $\mathbf{B} = \mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T}$, pro nějakou regulární matici \mathbf{T} .

Podobné matice jsou maticemi **stejného** lineárního zobrazení, ale vzhledem k **jiné** bázi.

Platí:

- ① $\mathbf{A} \approx \mathbf{A}$.
- ② Jestliže $\mathbf{A} \approx \mathbf{B}$, potom $\mathbf{B} \approx \mathbf{A}$.
- ③ Jestliže $\mathbf{A} \approx \mathbf{B}$ a $\mathbf{B} \approx \mathbf{C}$, potom $\mathbf{A} \approx \mathbf{C}$.

Definice (charakteristický polynom čtvercové matice)

Ať \mathbf{A} je matice typu $n \times n$ nad \mathbb{F} , $n \geq 1$. Výrazu $\det(\mathbf{A} - x\mathbf{E}_n)$ říkáme **charakteristický polynom** matice \mathbf{A} (značení: $\text{char}_{\mathbf{A}}(x)$).

Poznámky (pro matice typu $n \times n$ nad \mathbb{F})

- ① $\text{char}_{\mathbf{A}}(x)$ je polynom stupně n . Tedy má v \mathbb{F} nanejvýš n kořenů (i s násobnostmi). Pro matici $\mathbf{A} = \begin{pmatrix} 0 & -1 \\ 1 & 0 \end{pmatrix}$ nad \mathbb{R} nemá polynom $\text{char}_{\mathbf{A}}(x)$ v \mathbb{R} žádný kořen.
- ② Jestliže $\mathbf{A} \approx \mathbf{B}$, potom $\text{char}_{\mathbf{A}}(x) = \text{char}_{\mathbf{B}}(x)$.^a
Důvod:

$$\begin{aligned} \det(\mathbf{B} - x\mathbf{E}_n) &= \det(\mathbf{T}^{-1}\mathbf{AT} - x\mathbf{E}_n) = \det(\mathbf{T}^{-1}\mathbf{AT} - \mathbf{T}^{-1}x\mathbf{T}) = \\ &= \det(\mathbf{T}^{-1}(\mathbf{A} - x\mathbf{E}_n)\mathbf{T}) = \det(\mathbf{T}^{-1}) \det(\mathbf{A} - x\mathbf{E}_n) \det(\mathbf{T}) = \\ &= \det(\mathbf{A} - x\mathbf{E}_n). \end{aligned}$$

^a**Pozor:** obrácená implikace neplatí, viz dále.

Tvrzení

Ať $\mathbf{f} : L \rightarrow L$ je lineární zobrazení, $\dim(L) = n$. Označme jako \mathbf{A}_f matici \mathbf{f} vzhledem k jakékoli bázi prostoru L . Potom λ v \mathbb{F} je vlastní hodnotou \mathbf{f} právě tehdy, když $\det(\mathbf{A}_f - \lambda \mathbf{E}_n) = 0$.

Důkaz.

Protože L má dimensi n , je λ vlastní hodnotou \mathbf{f} právě tehdy, když $\text{def}(\mathbf{f} - \lambda \mathbf{id}) > 0$. To nastane právě tehdy, když matice $\mathbf{A}_f - \lambda \mathbf{E}_n$ je singulární. ■

Poznámka

Předchozí tvrzení nezávisí na volbě báze prostoru L a tím pádem nezávisí na volbě matice \mathbf{A}_f .

Připomenutí: změnou báze změníme matici \mathbf{A}_f na matici $\mathbf{T}^{-1} \cdot \mathbf{A}_f \cdot \mathbf{T}$, pro nějakou regulární matici \mathbf{T} .

Příklad (matice mohou mít stejné vlastní hodnoty, ale různé vlastní podprostory)

Ať $\mathbf{A} = \begin{pmatrix} 5 & -2 & 2 \\ -1 & 4 & -1 \\ -4 & 4 & -1 \end{pmatrix}$ je matice nad \mathbb{R} .

Potom $\text{char}_{\mathbf{A}}(x) = -(x - 3)^2 \cdot (x - 2)$.

- ① Pro dvojnásobnou vlastní hodnotu $\lambda = 3$:

$$\text{eigen}(3, \mathbf{A}) = \ker(\mathbf{A} - 3\mathbf{E}_3) = \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix}\right).$$

- ② Pro jednonásobnou vlastní hodnotu $\lambda = 2$:

$$\text{eigen}(2, \mathbf{A}) = \ker(\mathbf{A} - 2\mathbf{E}_3) = \text{span}\left(\begin{pmatrix} -2 \\ 1 \\ 4 \end{pmatrix}\right).$$

Příklad (pokrač.)

Pozor! Pro $\mathbf{B} = \begin{pmatrix} 2 & 4 & -3 \\ -1 & 10 & -6 \\ -1 & 8 & -4 \end{pmatrix}$ je $\text{char}_{\mathbf{B}}(x) = \text{char}_{\mathbf{A}}(x)$. Ale

$\text{eigen}(3, \mathbf{B}) = \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}\right)$ a $\text{eigen}(2, \mathbf{B}) = \text{span}\left(\begin{pmatrix} 0 \\ 3 \\ 4 \end{pmatrix}\right)$.

Tedy: \mathbf{A} a \mathbf{B} mají stejná vlastní čísla (i s násobnostmi), ale různé vlastní podprostory.

Problém diagonalisace

Pro matici \mathbf{A} typu $n \times n$ nad \mathbb{F} chceme rozhodnout, zda $\mathbf{A} \approx \mathbf{D}$, kde $\mathbf{D} = D(\lambda_1; \lambda_2; \dots; \lambda_n)$ je **diagonální matic**

$$\begin{pmatrix} \lambda_1 & 0 & 0 & \dots & 0 \\ 0 & \lambda_2 & 0 & \dots & 0 \\ 0 & 0 & \lambda_3 & \dots & 0 \\ \vdots & & & & \\ 0 & 0 & 0 & \dots & \lambda_n \end{pmatrix}$$

nebo ve sloupcovém zápisu

$$(\lambda_1 \cdot \mathbf{e}_1, \lambda_2 \cdot \mathbf{e}_2, \lambda_3 \cdot \mathbf{e}_3, \dots, \lambda_n \cdot \mathbf{e}_n)$$

Myšlenka nalezení matic \mathbf{T} a \mathbf{D} v rovnici $\mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T} = \mathbf{D}$

Ať $\mathbf{D} = D(\lambda_1; \dots; \lambda_n)$.

- ① Rovnost $\mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T} = \mathbf{D}$ platí právě tehdy, když platí rovnost $\mathbf{A} \cdot \mathbf{T} = \mathbf{T} \cdot \mathbf{D}$ a matice \mathbf{T} je regulární.
- ② Pro regulární matici $\mathbf{T} = (\mathbf{t}_1, \dots, \mathbf{t}_n)$ platí rovnost $\mathbf{A} \cdot \mathbf{T} = \mathbf{T} \cdot \mathbf{D}$ právě tehdy, když platí rovnosti $\mathbf{A} \cdot \mathbf{t}_j = \lambda_j \cdot \mathbf{t}_j$ pro všechna $j = 1, \dots, n$.

Shrnuto: rovnost $\mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T} = D(\lambda_1, \dots, \lambda_n)$ platí právě tehdy, když platí následující dvě podmínky:

- $\mathbf{A} \cdot \mathbf{t}_j = \lambda_j \cdot \mathbf{t}_j$ pro všechna $j = 1, \dots, n$.
To jest: j -tý sloupec \mathbf{t}_j matice \mathbf{T} je vlastní vektor příslušný vlastní hodnotě λ_j matice \mathbf{A} .
- Matice $\mathbf{T} = (\mathbf{t}_1, \dots, \mathbf{t}_n)$ je regulární.

Pozorování

Dva vlastní vektory, příslušející dvěma různým vlastním hodnotám, jsou lineárně nezávislé.

Platí-li

$$\mathbf{A} \cdot \mathbf{t}_{j_1} = \lambda_{j_1} \cdot \mathbf{t}_{j_1} \quad \text{a} \quad \mathbf{A} \cdot \mathbf{t}_{j_2} = \lambda_{j_2} \cdot \mathbf{t}_{j_2}$$

pak z rovnosti $a_1 \cdot \mathbf{t}_{j_1} + a_2 \cdot \mathbf{t}_{j_2} = \mathbf{0}$ plyne

$$\begin{aligned}\mathbf{0} &= (\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot \mathbf{o} \\ &= (\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot (a_1 \cdot \mathbf{t}_{j_1} + a_2 \cdot \mathbf{t}_{j_2}) \\ &= a_1 \cdot \underbrace{(\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot \mathbf{t}_{j_1}}_{\neq \mathbf{0}} + a_2 \cdot \underbrace{(\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot \mathbf{t}_{j_2}}_{=\mathbf{0}}\end{aligned}$$

tedy $a_1 = 0$.

Rovnost $a_2 = 0$ se dokáže analogicky.

Problém

Existuje dostatek lineárně nezávislých vlastních vektorů pro stejnou vlastní hodnotu?

Věta (charakterisace diagonalisovatelných matic nad \mathbb{F})

Pro matici \mathbf{A} typu $n \times n$ nad \mathbb{F} jsou následující podmínky ekvivalentní:

- ① \mathbf{A} je diagonalisovatelná, tj $\mathbf{A} \approx \mathbf{D}$ pro nějakou diagonální matici \mathbf{D} .
- ② Charakteristický polynom $\text{char}_{\mathbf{A}}(x)$ lze v \mathbb{F} rozložit na součin lineárních faktorů a platí: násobnost λ jako kořene $\text{char}_{\mathbf{A}}(x)$ je rovna $\dim(\text{eigen}(\lambda, \mathbf{A}))$.^a

^aNásobnosti λ jako kořene $\text{char}_{\mathbf{A}}(x)$ se někdy říká **algebraická násobnost** λ , číslu $\dim(\text{eigen}(\lambda, \mathbf{A}))$ se někdy říká **geometrická násobnost** λ .

Důkaz.

Bez důkazu (nemáme vybudovanou teorii polynomů nad obecným tělesem \mathbb{F}). Pro zájemce: Věta 10.4.8 skript. ■

Příklad (nad \mathbb{R})

Matrice $\mathbf{A} = \begin{pmatrix} 5 & -2 & 2 \\ -1 & 4 & -1 \\ -4 & 4 & -1 \end{pmatrix}$ a $\mathbf{B} = \begin{pmatrix} 2 & 4 & -3 \\ -1 & 10 & -6 \\ -1 & 8 & -4 \end{pmatrix}$ splňují:

- ① $\text{char}_{\mathbf{A}}(x) = \text{char}_{\mathbf{B}}(x) = -(x - 3)^2 \cdot (x - 2)$.
- ② Protože $\dim(\text{eigen}(3, \mathbf{A})) = 2$ a $\dim(\text{eigen}(2, \mathbf{A})) = 1$, platí $\mathbf{A} \approx \mathbf{D}$ pro nějakou diagonální matici \mathbf{D} .
- ③ Protože $\dim(\text{eigen}(3, \mathbf{B})) = 1$ a $\dim(\text{eigen}(2, \mathbf{B})) = 1$, neplatí $\mathbf{B} \approx \mathbf{D}$ pro žádnou diagonální matici \mathbf{D} .

Ukázali jsme (mimo jiné): $\mathbf{A} \not\approx \mathbf{B}$, přestože $\text{char}_{\mathbf{A}}(x) = \text{char}_{\mathbf{B}}(x)$.

Příklad

Pro matici $\mathbf{A} = \begin{pmatrix} 5 & -2 & 2 \\ -1 & 4 & -1 \\ -4 & 4 & -1 \end{pmatrix}$ nad \mathbb{R} platí $\text{char}_{\mathbf{A}}(x) = -(x-3)^2 \cdot (x-2)$

a $\mathbf{D} = \mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T}$, kde $\mathbf{D} = \begin{pmatrix} 3 & 0 & 0 \\ 0 & 3 & 0 \\ 0 & 0 & 2 \end{pmatrix}$ a $\mathbf{T} = \begin{pmatrix} 1 & -1 & -2 \\ 1 & 0 & 1 \\ 0 & 1 & 4 \end{pmatrix}$.

Matice \mathbf{A} v kanonické bázi odpovídá lineárnímu zobrazení

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} \mapsto \begin{pmatrix} 5x - 2y + 2z \\ -x + 4y - z \\ -4x + 4y - z \end{pmatrix}$$

Vzhledem k bázi $(\begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix}, \begin{pmatrix} -2 \\ 1 \\ 4 \end{pmatrix})$ jde o podstatně jednodušší zobrazení

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} \mapsto \begin{pmatrix} 3x \\ 3y \\ 2z \end{pmatrix}$$

Diagonalisace matic

Odpřednesenou látku naleznete v kapitolách 10.1, 10.3
a 10.4 skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

- ① Pojmy vlastní hodnota a vlastní vektor lineárního zobrazení.
- ② Věta o diagonalisovatelnosti čtvercových matic nad \mathbb{C} .

Dnešní přednáška

- ① Diagonalisovatelnost matic nad \mathbb{C} a nad \mathbb{R} .
- ② Dvě aplikace: řešení rekurentních rovnic a funkce matic.^a

^aTyto dvě aplikace nebudou zkoušeny!

Připomenutí důležité vlastnosti tělesa \mathbb{C}

Každý polynom $p(x)$ v $\mathbb{C}[x]$ stupně n má přesně n kořenů (počítaných i s násobnostmi).^a

^aTéto vlastnosti tělesa \mathbb{C} se říká algebraická uzavřenosť.

- ① Komplexní číslo λ je kořen polynomu $p(x) \in \mathbb{C}[x]$ **násobnosti k** , pokud platí rovnost $p(x) = (x - \lambda)^k \cdot q(x)$ pro $q(x) \in \mathbb{C}[x]$ a $q(\lambda) \neq 0$.
- ② Speciálně: číslo λ má jako kořen $p(x)$ **násobnost nula** právě tehdy, když λ není kořenem polynomu $p(x)$.

Důsledek (téma 8A, tvar věty o diagonalisaci pro $\mathbb{F} = \mathbb{C}$)

Pro čtvercovou matici \mathbf{A} nad \mathbb{C} jsou následující podmínky ekvivalentní:

- ① Matice \mathbf{A} diagonalisovatelná.
- ② Pro každé komplexní číslo λ platí: násobnost λ jako kořene polynomu $\text{char}_{\mathbf{A}}(x)$ je rovna $\dim(\text{eigen}(\lambda, \mathbf{A}))$.

Příklad

Pauliho matice^a jsou následující tři matice nad \mathbb{C} :

$$X = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix} \quad Y = \begin{pmatrix} 0 & -i \\ i & 0 \end{pmatrix} \quad Z = \begin{pmatrix} 1 & 0 \\ 0 & -1 \end{pmatrix}$$

Všechny tyto matice jsou diagonalisovatelné:

- ① Matice Z již diagonální je.

^aJde o důležitý příklad v kvantové mechanice a **kvantovém počítání**. Matice X , Y a Z jsou operátory spinu ve směrech os x , y , z a značívají se též σ_x (také: σ_1) σ_y (také: σ_2) σ_z (také: σ_3)

Užitečná početní cvičení: platí rovnosti

① $\sigma_1^2 = \sigma_2^2 = \sigma_3^2 = -i \cdot \sigma_1\sigma_2\sigma_3 = \mathbf{E}_2$.

② $\{\sigma_j, \sigma_k\} = 2\delta_{jk}\mathbf{E}_2$, kde $\{\sigma_j, \sigma_k\} = \sigma_j\sigma_k + \sigma_k\sigma_j$ je tzv **Poissonova závorka** a δ_{jk} je **Kroneckerův symbol**.

③ $[\sigma_j, \sigma_k] = \sum_{l=1}^3 2i\epsilon_{jkl}\sigma_l$, kde $[\sigma_j, \sigma_k] = \sigma_j\sigma_k - \sigma_k\sigma_j$ je tzv **komutátor** a ϵ_{jkl} je **Levi-Civitův symbol**.



Příklad (pokrač.)

- ② Diagonalisace matice $X = \begin{pmatrix} 0 & 1 \\ 1 & 0 \end{pmatrix}$.

Platí $\text{char}_X(x) = x^2 - 1 = (x - 1) \cdot (x + 1)$.

Vlastní hodnoty a vlastní vektory matice X jsou: $\lambda_1 = 1$,

$$\mathbf{t}_1 = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \text{ a } \lambda_2 = -1, \mathbf{t}_2 = \begin{pmatrix} 1 \\ -1 \end{pmatrix}.$$

Tudíž

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

a operátor X je diagonální v bázi $(\mathbf{t}_1, \mathbf{t}_2)$.

Příklad (pokrač.)

- ③ Diagonalisace matice $Y = \begin{pmatrix} 0 & -i \\ i & 0 \end{pmatrix}$.

Platí $\text{char}_Y(x) = x^2 - 1 = (x - 1) \cdot (x + 1)$.

Vlastní hodnoty a vlastní vektory matice Y jsou: $\lambda_1 = 1$,

$$\mathbf{v}_1 = \begin{pmatrix} -i \\ 1 \end{pmatrix} \text{ a } \lambda_2 = -1, \mathbf{v}_2 = \begin{pmatrix} i \\ 1 \end{pmatrix}.$$

Tudíž

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

a operátor Y je diagonální v bázi $(\mathbf{v}_1, \mathbf{v}_2)$.

Jordanův tvar čtvercové matic

Ať \mathbf{A} je matice typu $n \times n$ nad \mathbb{F} taková, že polynom $\text{char}_{\mathbf{A}}(x)$ lze rozložit na součin lineárních faktorů.^a

Potom lze dokázat, že \mathbf{A} je „téměř diagonalisovatelná“. Přesněji: platí $\mathbf{A} \approx \mathbf{J}$, kde

$$\mathbf{J} = \begin{pmatrix} \mathbf{J}_1 & 0 & 0 & 0 & \dots & 0 \\ 0 & \mathbf{J}_2 & 0 & 0 & \dots & 0 \\ 0 & 0 & \mathbf{J}_3 & 0 & \dots & 0 \\ \vdots & & & & & \\ 0 & 0 & 0 & 0 & \dots & \mathbf{J}_n \end{pmatrix}$$

O Jordanově tvaru budeme mluvit na příští přednášce (téma 9A).

^aTo platí například pro libovolnou matici nad \mathbb{C} .

Jordanův tvar čtvercové matice (pokrač.)

$$\mathbf{J}_i = \begin{pmatrix} \lambda_i & 1 & 0 & 0 & 0 & \dots & 0 \\ 0 & \lambda_i & 1 & 0 & 0 & \dots & 0 \\ 0 & 0 & \lambda_i & 1 & 0 & \dots & 0 \\ \vdots & & & & & & \\ 0 & 0 & 0 & 0 & 0 & \dots & \lambda_i \end{pmatrix}$$

Matici \mathbf{J}_i říkáme **Jordanova buňka**. Na diagonále je vlastní hodnota λ_i matice \mathbf{A} . Rozměr matice \mathbf{J}_i je roven násobnosti vlastní hodnoty λ jako kořene $\text{char}_{\mathbf{A}}(x)$.

Existenci Jordanova tvaru budou věnovány **další přednášky**.

Příklad

Ať $\mathbf{A} = \begin{pmatrix} a & -b \\ b & a \end{pmatrix}$ je regulární matice nad \mathbb{R} . Potom platí:

- ➊ $\text{char}_{\mathbf{A}}(x) = (a - x)^2 + b^2 = x^2 - 2ax + (a^2 + b^2)$.
Diskriminant tohoto výrazu je $-4b^2$.

Matice \mathbf{A} je tedy nad \mathbb{R} diagonalisovatelná **pouze** v případě $b = 0$.

V tomto případě ale \mathbf{A} už je diagonální: $\mathbf{A} = \begin{pmatrix} a & 0 \\ 0 & a \end{pmatrix}$ a musí platit $a \neq 0$, protože \mathbf{A} je regulární.

Matice \mathbf{A} je tedy maticí změny měřítka (změna je stejná na obou souřadnicových osách).

Příklad (pokrač.)

- ② V případě $b \neq 0$ matice $\mathbf{A} = \begin{pmatrix} a & -b \\ b & a \end{pmatrix}$ není nad \mathbb{R} diagonalisovatelná.

Matrice \mathbf{A} (chápaná jako matice nad \mathbb{C}) má vlastní hodnoty

$$\lambda_1 = a + bi \text{ a } \lambda_2 = a - bi, \text{ protože}$$

$$\text{char}_{\mathbf{A}}(x) = x^2 - 2ax + (a^2 + b^2) = (x - (a + ib)) \cdot (x - (a - ib)).$$

Označme $r = |\lambda_1| = |\lambda_2| = \sqrt{a^2 + b^2}$. Dále označme jako α

úhel^a mezi vektory $\begin{pmatrix} 1 \\ 0 \end{pmatrix}$ a $\begin{pmatrix} a \\ b \end{pmatrix}$.

Potom

$$\mathbf{A} = \begin{pmatrix} a & -b \\ b & a \end{pmatrix} = \begin{pmatrix} r & 0 \\ 0 & r \end{pmatrix} \cdot \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$$

To jest: \mathbf{A} je rotace o úhel α , následovaná změnou měřítka.

^aÚhlu α se říká **argument** komplexního čísla $a + bi$. Platí tedy rovnost $a + bi = r \cdot (\cos \alpha + i \sin \alpha) = r \cdot e^{i\alpha}$.



Tvrzení (klasifikace regulárních transformací roviny)

Ať $\mathbf{M} : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ je regulární a ať nemá 2-násobnou vlastní hodnotu. Pak \mathbf{M} je podobná buď

- ① matici $\begin{pmatrix} a & 0 \\ 0 & b \end{pmatrix}$, kde $a \neq b$ jsou z \mathbb{R} a $a \cdot b \neq 0$,

nebo

- ② matici $\begin{pmatrix} r & 0 \\ 0 & r \end{pmatrix} \cdot \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$, kde $r > 0$ a $\alpha \in [0; 2\pi)$.

Slogan

Regulární transformace roviny bez 2-násobných vlastních hodnot jsou **pouze** dvou typů:

- ① Změny měřítka (změna měřítka je na každé souřadnicové ose **jiná**).
- ② Rotace následované změnou měřítka **stejnou** na obou souřadnicových osách.



Důkaz (klasifikace regulárních transformací roviny).

- ① V případě, kdy \mathbf{M} je diagonalisovatelná nad \mathbb{R} , má \mathbf{M} dvě různé reálné vlastní hodnoty a, b . Tudíž $\mathbf{M} \approx \begin{pmatrix} a & 0 \\ 0 & b \end{pmatrix}$, kde $a \cdot b \neq 0$, protože \mathbf{M} je regulární.
- ② V případě, kdy \mathbf{M} nad \mathbb{R} diagonalisovatelná není, má $\text{char}_{\mathbf{M}}(x)$ komplexní kořen $\lambda = a + bi$, kde $b \neq 0$. Označme jako \mathbf{v} komplexní vlastní vektor příslušný vlastní hodnotě λ . Označme jako \mathbf{T} matici se sloupcí $\mathbf{t}_1 = \text{Re}(\mathbf{v})$ (vektor reálných částí položek vektoru \mathbf{v}) a $\mathbf{t}_2 = \text{Im}(\mathbf{v})$ (vektor imaginárních částí položek vektoru \mathbf{v}).

Potom platí rovnost $\mathbf{M} = \mathbf{T} \cdot \begin{pmatrix} a & -b \\ b & a \end{pmatrix} \cdot \mathbf{T}^{-1}$.

Nyní stačí použít předchozí příklad. ■

Výpočet mocnin diagonalisovatelné matice

Pro diagonalisovatelnou matici \mathbf{A} typu $n \times n$ nad \mathbb{F} platí:

$$\mathbf{A} = \mathbf{T}^{-1} \cdot \mathbf{D} \cdot \mathbf{T} \text{ pro nějakou regulární matici } \mathbf{T}.$$

Tudíž: $\mathbf{A}^2 = \mathbf{A} \cdot \mathbf{A} = (\mathbf{T}^{-1} \cdot \mathbf{D} \cdot \mathbf{T}) \cdot (\mathbf{T}^{-1} \cdot \mathbf{D} \cdot \mathbf{T}) = \mathbf{T}^{-1} \cdot \mathbf{D}^2 \cdot \mathbf{T}$.

Obecně: $\mathbf{A}^k = \mathbf{T}^{-1} \cdot \mathbf{D}^k \cdot \mathbf{T}$, pro všechna přirozená čísla $k \geq 0$.

Protože mocniny diagonální matice lze počítat velmi rychle, lze rychle počítat i mocniny diagonalisovatelných matic.

Ukážeme dvě aplikace umocňování:

- ① Řešení lineárních homogenních rekurentních rovnic.
To je důležité při analýze složitosti rekursivních algoritmů.
- ② Základní myšlenku funkcí matic.
To je důležité ve fyzice, grafice, kvantovém počítání, ...

Příklad (Fibonacciho posloupnost)

Hledáme posloupnost čísel $F(n)$, splňující **lineární rekurentní rovnici** $F(n+2) = F(n+1) + F(n)$, pro všechna př. č. $n \geq 0$.

Cíl: chceme **explicitní vzorec** pro $F(n)$, $n \geq 0$.

Evidentně: známe-li $F(0)$ a $F(1)$, známe všechna $F(n)$.^a

- ① Vytvoříme **generující matici** $\mathbf{F} = \begin{pmatrix} 0 & 1 \\ 1 & 1 \end{pmatrix}$ pro kterou platí:

$$\mathbf{F} \cdot \begin{pmatrix} F(0) \\ F(1) \end{pmatrix} = \begin{pmatrix} F(1) \\ F(2) \end{pmatrix}, \text{ obecně } \mathbf{F}^n \cdot \begin{pmatrix} F(0) \\ F(1) \end{pmatrix} = \begin{pmatrix} F(n) \\ F(n+1) \end{pmatrix}.$$

- ② Matice \mathbf{F} je diagonalisovatelná nad \mathbb{R} : $\lambda_1 = \frac{1+\sqrt{5}}{2}$, $\lambda_2 = \frac{1-\sqrt{5}}{2}$

$$\mathbf{D} = \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} = \mathbf{T}^{-1} \cdot \mathbf{F} \cdot \mathbf{T}, \quad \mathbf{T} = \begin{pmatrix} 1 & 1 \\ \lambda_1 & \lambda_2 \end{pmatrix}, \quad \mathbf{F}^n = \mathbf{T} \cdot \mathbf{D}^n \cdot \mathbf{T}^{-1}$$

^aPožadavkům $F(0) = x_0$ a $F(1) = x_1$ se říká **počáteční podmínka**. Pro klasickou Fibonacciho posloupnost jde o $F(0) = 1$, $F(1) = 1$.

Příklad (Fibonacciho posloupnost, pokrač.)

$$\begin{aligned}
 ③ \quad & \begin{pmatrix} F(n) \\ F(n+1) \end{pmatrix} = \mathbf{T} \cdot \begin{pmatrix} \lambda_1^n & 0 \\ 0 & \lambda_2^n \end{pmatrix} \cdot \mathbf{T}^{-1} \cdot \begin{pmatrix} F(0) \\ F(1) \end{pmatrix} = \\
 & \begin{pmatrix} 1 & 1 \\ \lambda_1 & \lambda_2 \end{pmatrix} \cdot \begin{pmatrix} \lambda_1^n & 0 \\ 0 & \lambda_2^n \end{pmatrix} \cdot \frac{1}{\lambda_2 - \lambda_1} \cdot \begin{pmatrix} \lambda_2 & -1 \\ -\lambda_1 & 1 \end{pmatrix} \cdot \begin{pmatrix} F(0) \\ F(1) \end{pmatrix} = \\
 & \frac{1}{\lambda_2 - \lambda_1} \cdot \begin{pmatrix} 1 & 1 \\ \lambda_1 & \lambda_2 \end{pmatrix} \cdot \begin{pmatrix} \lambda_1^n & 0 \\ 0 & \lambda_2^n \end{pmatrix} \cdot \begin{pmatrix} \lambda_2 & -1 \\ -\lambda_1 & 1 \end{pmatrix} \cdot \begin{pmatrix} F(0) \\ F(1) \end{pmatrix}
 \end{aligned}$$

Takže: $F(n) = \frac{\lambda_1^n \cdot \lambda_2 - \lambda_2^n \cdot \lambda_1}{\lambda_2 - \lambda_1} \cdot F(0) + \frac{-\lambda_1^n + \lambda_2^n}{\lambda_2 - \lambda_1} \cdot F(1)$

V klasickém případě (tj když $F(0) = F(1) = 1$), je

$$\begin{aligned}
 F(n) &= \frac{\lambda_1^n \cdot \lambda_2 - \lambda_2^n \cdot \lambda_1}{\lambda_2 - \lambda_1} + \frac{-\lambda_1^n + \lambda_2^n}{\lambda_2 - \lambda_1} = \\
 &= \lambda_1^n \cdot \frac{\lambda_2 - 1}{\lambda_2 - \lambda_1} + \lambda_2^n \cdot \frac{1 - \lambda_1}{\lambda_2 - \lambda_1}
 \end{aligned}$$

Poznámky (lineární homogenní rekurence k -tého řádu)

Obdobným způsobem lze řešit jakoukoli **homogenní lineární rekurentní rovnici k -tého řádu**: hledáme posloupnost $X(n)$ prvků \mathbb{F} , které splňují

$$X(n+k) = a_1 X(n+k-1) + a_2 X(n+k-2) + \dots + a_k X(n)$$

pro všechna přirozená čísla $n \geq 0$, kde a_1, \dots, a_k jsou v \mathbb{F} .

Jediné, co potřebujeme, je diagonalisovatelnost generující matice.

- ① Řešení rekurentních rovnic hraje zásadní úlohu při **analýze složitosti rekursivních algoritmů**.
- ② Podobné postupy fungují i pro **lineární homogenní diferenciální rovnice k -tého řádu**. Viz Dodatek O **skript**.

Příklad (exponenciála matice)

Víme, že funkce e^x má Taylorův rozvoj $e^x = \sum_{n=0}^{\infty} \frac{x^n}{n!}$.

Pro čtvercovou diagonalisovatelnou matici $\mathbf{X} = \mathbf{T}^{-1} \cdot \mathbf{D} \cdot \mathbf{T}$ definujeme

$$e^{\mathbf{X}} = \sum_{i=0}^{\infty} \frac{\mathbf{X}^n}{n!} = \sum_{i=0}^{\infty} \frac{\mathbf{T}^{-1} \cdot \mathbf{D}^n \cdot \mathbf{T}}{n!} = \mathbf{T}^{-1} \cdot \underbrace{\left(\sum_{i=0}^{\infty} \frac{\mathbf{D}^n}{n!} \right)}_{= e^{\mathbf{D}}} \cdot \mathbf{T}$$

Konvergenci této řady musíme chápat ve smyslu normy.^a

Lze ukázat, že matice $e^{\mathbf{D}}$ je diagonální, a že platí $e^{\mathbf{D}} = (\delta_{ij} \cdot e^{d_{ij}})$.

^aTo je velmi technický pojem, nebudeme o něm mluvit. Více například v knize Roger A. Horn, Charles J. Johnson, *Matrix analysis*, Cambridge University Press, 2012, nebo v přednášce A0B01PAN (Pokročilá analýza), nebo v kapitole 13.2 *skript*. Analogicky exponenciále lze postupovat pro obecnou funkci $f : \mathbb{R} \rightarrow \mathbb{R}$ (případně $f : \mathbb{C} \rightarrow \mathbb{C}$), která má Taylorův rozvoj.

Jordanův tvar

Odpřednesenou látku naleznete v kapitolách 11.1 a 11.3 skript *Abstraktní a konkrétní lineární algebra*.

Minulé přednášky

- ① Matice některých lineárních zobrazení mezi prostory konečných dimensí lze (**za určitých předpokladů**) diagonalisovat.
- ② Matice některých lineárních zobrazení mezi prostory konečných dimensí **diagonalisovat nelze**.

Dnešní přednáška

- ① Budeme studovat obecná lineární zobrazení $f : L \rightarrow L$, kde L má konečnou dimensi.

Vysvětlíme, co je **Jordanův tvar** zobrazení f .^a

Půjde o tvar: $f = \text{diagonální} + \text{nilpotentní}$.

Nilpotentní = „téměř nulové zobrazení“.

To znamená: Jordanův tvar = „téměř diagonální tvar“.

^a Jde o velmi technickou partii lineární algebry. **Některé důkazy tudíž neuvedeme**. Důkazy všech tvrzení najeznete v Kapitole 11 **skript**.

Zkouška: výpočet Jordanova tvaru **nebude** v písemné části (**mohou** tam ale být nilpotentní matice), u ústní části **mohou** být vyžadovány pouze hlavní myšlenky Jordanova tvaru (viz str 9 tohoto tématu).



Příklad (direktní rozklad rotace v rovině xy)

Pro

$$\begin{pmatrix} \cos \alpha & -\sin \alpha & 0 \\ \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{pmatrix} : \mathbb{R}^3 \rightarrow \mathbb{R}^3$$

je

- ① $\mathbb{R}^3 = \text{span}(\mathbf{e}_1, \mathbf{e}_2) \vee \text{span}(\mathbf{e}_3)$ a $\text{span}(\mathbf{e}_1, \mathbf{e}_2) \cap \text{span}(\mathbf{e}_3) = \{\mathbf{0}\}$. Tento fakt budeme značit $\mathbb{R}^3 = \text{span}(\mathbf{e}_1, \mathbf{e}_2) \oplus \text{span}(\mathbf{e}_3)$ a budeme mluvit o **direktním rozkladu** \mathbb{R}^3 na $\text{span}(\mathbf{e}_1, \mathbf{e}_2)$ a $\text{span}(\mathbf{e}_3)$.
- ② Direktně rozložit lze i celé lineární zobrazení:

$$\begin{pmatrix} \cos \alpha & -\sin \alpha & 0 \\ \sin \alpha & \cos \alpha & 0 \\ 0 & 0 & 1 \end{pmatrix} = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix} \oplus (1)$$

protože podprostory $\text{span}(\mathbf{e}_1, \mathbf{e}_2)$ a $\text{span}(\mathbf{e}_3)$ jsou **invariantní** na dané zobrazení.

Příklad (diagonalisovatelná matice a direktní rozklad)

Ať $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ je diagonalisovatelná matice:

$$D(\lambda_1; \dots; \lambda_n) = \mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T}, \text{ kde } \mathbf{T} = (\mathbf{v}_1, \dots, \mathbf{v}_n).$$

Potom pro $W_i = \text{span}(\mathbf{v}_i)$ platí:

- ① ① $\mathbb{F}^n = W_1 \vee \dots \vee W_n,$
- ② $W_i \cap \bigvee_{j \neq i} W_j = \{\mathbf{0}\}$ pro všechna $i.$

Tato dvě fakta budeme značit $\mathbb{F}^n = W_1 \oplus \dots \oplus W_n$ a budeme říkat, že W_1, \dots, W_n tvoří **direktní rozklad** prostoru \mathbb{F}^n .

- ② Pro každé \mathbf{x} z W_i je \mathbf{Ax} opět z W_i . To jest: každý W_i je **\mathbf{A} -invariantní** podprostor prostoru \mathbb{F}^n .

Můžeme tedy psát: $\mathbf{A} \approx \mathbf{A}_1 \oplus \dots \oplus \mathbf{A}_n$.

Příklad

Ať $\mathbf{A} = \begin{pmatrix} 5 & -2 & 2 \\ -1 & 4 & -1 \\ -4 & 4 & -1 \end{pmatrix}$ je matici nad \mathbb{R} .

Potom $\text{char}_{\mathbf{A}}(x) = -(x - 3)^2 \cdot (x - 2)$.

- 1 Pro dvojnásobnou vlastní hodnotu $\lambda = 3$:

$$\text{eigen}(3, \mathbf{A}) = \ker(\mathbf{A} - 3\mathbf{E}_3) = \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} -1 \\ 0 \\ 1 \end{pmatrix}\right).$$

- 2 Pro jednonásobnou vlastní hodnotu $\lambda = 2$:

$$\text{eigen}(2, \mathbf{A}) = \ker(\mathbf{A} - 2\mathbf{E}_3) = \text{span}\left(\begin{pmatrix} -2 \\ 1 \\ 4 \end{pmatrix}\right).$$

Platí $\mathbb{R}^3 = \text{eigen}(3, \mathbf{A}) \oplus \text{eigen}(2, \mathbf{A})$ a $\mathbf{A} \approx \begin{pmatrix} 3 & 0 \\ 0 & 3 \end{pmatrix} \oplus (2)$.

Příklad (diagonalisovatelná matice a direktní rozklad, pokrač)

Ať $\mathbf{A} : \mathbb{F}^n \rightarrow \mathbb{F}^n$ je diagonalisovatelná matice:

$$D(\lambda_1; \dots; \lambda_n) = \mathbf{T}^{-1} \cdot \mathbf{A} \cdot \mathbf{T}, \text{ kde } \mathbf{T} = (\mathbf{v}_1, \dots, \mathbf{v}_n).$$

Direktní rozklad lze **zlepšit**: pokud

$\text{char}_{\mathbf{A}}(x) = a \cdot (x - \lambda_1)^{m_1} \cdots \cdots (x - \lambda_p)^{m_p}$, potom

$$\mathbb{F}^n = V_1 \oplus \dots \oplus V_p, \quad \mathbf{A} \approx \mathbf{B}_1 \oplus \dots \oplus \mathbf{B}_p$$

To jest: \mathbf{A} -invariantní podprostory V_i můžeme zvolit tak, že $\dim(V_i) = m_i$.

Poznámka

Když \mathbf{A} diagonalisovat nelze? Když $\dim(V_i) < m_i$ pro alespoň jedno i . Budeme muset **vylepšit** pojem invariantního podprostoru.

Příklad (neexistence direktního rozkladu pro nediagonálisovatelnou matici)

Pro $\mathbf{B} = \begin{pmatrix} 2 & 4 & -3 \\ -1 & 10 & -6 \\ -1 & 8 & -4 \end{pmatrix}$ nad \mathbb{R} je $\text{char}_{\mathbf{B}}(x) = -(x-3)^2 \cdot (x-2)$.

Ale $\text{eigen}(3, \mathbf{B}) = \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}\right)$ a $\text{eigen}(2, \mathbf{B}) = \text{span}\left(\begin{pmatrix} 0 \\ 3 \\ 4 \end{pmatrix}\right)$.


To znamená:

- ① Prostory $\text{eigen}(3, \mathbf{B})$ a $\text{eigen}(2, \mathbf{B})$ jsou \mathbf{B} -invariantní.
- ② $\mathbb{R}^3 \neq \text{eigen}(3, \mathbf{B}) \oplus \text{eigen}(2, \mathbf{B})$.

Prostor $\text{eigen}(3, \mathbf{B})$ vlastních vektorů příslušných hodnotě 3 má **malou** dimensi.

Direktní rozklad lineárního prostoru a lineárního zobrazení

Pro $\mathbf{f} : L_1 \rightarrow L_2$, kde $L_1 = W_1 \oplus \dots \oplus W_k$, $L_2 = V_1 \oplus \dots \oplus V_k$ a $\mathbf{f}(\vec{x})$ je z V_i , jakmile \vec{x} je z W_i , píšeme



To znamená: $\mathbf{f}(\vec{x}) = \mathbf{f}_1(\vec{x}_1) + \dots + \mathbf{f}_k(\vec{x}_k)$, kde $\vec{x} = \vec{x}_1 + \dots + \vec{x}_k$.

Cíl této přednášky (hlavní myšlenky Jordanova tvaru)

- ① Pro lineární zobrazení f chceme psát $f = f_{\text{diag}} + f_{\text{nil}}$, kde
 - ① f_{diag} je diagonalisovatelné.
 - ② f_{nil} se „příliš neliší“ od nulového zobrazení \mathbf{o} . Přesněji: $(f_{\text{nil}})^k = \mathbf{o}$ pro nějaké k .
 - ③ $f_{\text{nil}} \cdot f_{\text{diag}} = f_{\text{diag}} \cdot f_{\text{nil}}$.

Tomuto součtu budeme říkat **Jordanův tvar** f .

K čemu je to dobré? Budeme moci počítat mocniny^a

$$f^m = (f_{\text{diag}} + f_{\text{nil}})^m = \sum_{j=0}^k \binom{m}{j} \cdot \underbrace{(f_{\text{diag}})^j}_{\text{snadné}} \cdot \underbrace{(f_{\text{nil}})^{m-j}}_{=\mathbf{o} \text{ pro } m-j \geq k}$$

- ② Namísto Jordanova tvaru lineárního zobrazení hledáme většinou **Jordanův tvar jeho matice**. V určité bázi (které se říká **Jordanova báze**) bude tedy matice mít „**příjemný tvar**“.

^aTo je v nejrůznějších aplikacích velmi důležité.



Cíl této přednášky (pokrač.)

- ③ Většinu výsledků **nedokážeme**, pouze **uveďeme příklady**.

Navíc: **nenučíme se hledat Jordanovu bázi**. Je to velmi technické, více se lze dočíst v Kapitole 11 **skript**.

Značení

Pro lineární zobrazení $\mathbf{f} : L \rightarrow L$ značíme $\mathbf{f}^0 = \mathbf{id}$ a $\mathbf{f}^{k+1} = \mathbf{f} \cdot \mathbf{f}^k$ pro $k \geq 0$.

Definice (nilpotentní zobrazení)

Lineárnímu zobrazení $\mathbf{f} : L \rightarrow L$, pro které existuje k tak, že $\mathbf{f}^k = \mathbf{o}$, říkáme **nilpotentní**. Nejmenšímu takovému k říkáme **index nilpotence** a značíme jej $\text{nil}(\mathbf{f})$.

Příklad (nilpotentní matice)

Matice

$$\mathbf{N} = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix}$$

je nilpotentní, platí $\text{nil}(\mathbf{N}) = 3$.

Pojďme „stopovat“ cestu vektorů kanonické báze při postupné aplikaci matice \mathbf{N} :

$$\mathbf{e}_1 \mapsto \mathbf{0}, \quad \mathbf{e}_2 \mapsto \mathbf{e}_1 \mapsto \mathbf{0}, \quad \mathbf{e}_3 \mapsto \mathbf{e}_2 \mapsto \mathbf{e}_1 \mapsto \mathbf{0}, \quad \mathbf{e}_4 \mapsto \mathbf{0}$$

Všechny čtyři bázové vektory se nakonec zobrazí na nulový vektor, protože matice \mathbf{N} je nilpotentní. Navíc $\text{nil}(\mathbf{N})$ je zjevně rovna největší z délek jednotlivých řetězců, tj. $\text{nil}(\mathbf{N})$ je maximální z čísel 1, 2, 3, 1.

Příklad (nilpotentní matice)

Matice

$$\mathbf{N} = \begin{pmatrix} 0 & 1 & 3 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{pmatrix}$$

nad \mathbb{R} je nilpotentní: její řetězce jsou

$$\begin{array}{lll} \mathbf{e}_1 & \mapsto & \mathbf{0} \\ \mathbf{e}_2 & \mapsto & \mathbf{e}_1 \mapsto \mathbf{0} \\ \mathbf{e}_3 & \mapsto & 3\mathbf{e}_1 + \mathbf{e}_2 \mapsto \mathbf{e}_1 \mapsto \mathbf{0} \end{array}$$

a proto platí $\text{nil}(\mathbf{N}) = 3$.

Definice

Čtvercové matici

$$\begin{pmatrix} 0 & 1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & & & & \vdots \\ 0 & 0 & 0 & \dots & 1 \\ 0 & 0 & 0 & \dots & 0 \end{pmatrix} = (\mathbf{o}, \mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_{n-1})$$

říkáme **Jordanova buňka**.^a

^aBuňka v této definici má rozměry $n \times n$.

Pozorování

Každá Jordanova buňka je nilpotentní matice. Index nilpotence je roven rozměrům buňky.

Nalezení Jordanova tvaru matice $\mathbf{M} : \mathbb{F}^n \rightarrow \mathbb{F}^n$

Postupujeme takto:

- ① Spočteme charakteristický polynom $\text{char}_{\mathbf{M}}(x)$ matice \mathbf{M} .
 - ① Pokud $\text{char}_{\mathbf{M}}(x)$ nelze v $\mathbb{F}[x]$ rozložit na součin kořenových faktorů, výpočet končíme. Jordanův tvar matice \mathbf{M} neexistuje.
 - ② Pokud $\text{char}_{\mathbf{M}}(x) = a \cdot (x - \lambda_1)^{m_1} \cdots (x - \lambda_p)^{m_p}$ v $\mathbb{F}[x]$, Jordanův tvar matice \mathbf{M} existuje a my postupujeme podle dalších bodů.
- ② Jordanův tvar bude mít p Jordanových segmentů $\mathbf{B}_i(\lambda_i)$, $i = 1, \dots, p$. Segment $\mathbf{B}_i(\lambda_i)$ má rozměry $m_i \times m_i$.
- ③ Nalezení i -tého segmentu $\mathbf{B}_i(\lambda_i)$:
 - ① Utvoříme nilpotentní matici $\mathbf{M} - \lambda_i \cdot \mathbf{E}_n$ a nalezneme její Jordanův tvar \mathbf{N}_i .
 - ② Platí $\mathbf{B}_i(\lambda_i) = \mathbf{N}_i + \lambda_i \cdot \mathbf{E}_{m_i}$.
- ④ Z Jordanových segmentů utvoříme Jordanův tvar matice \mathbf{M} jakožto blokově diagonální matici.

Praktický význam Jordanova tvaru matice $\mathbf{M} : \mathbb{F}^n \rightarrow \mathbb{F}^n$

Pokud $\text{char}_{\mathbf{M}}(x) = a \cdot (x - \lambda_1)^{m_1} \cdot \dots \cdot (x - \lambda_p)^{m_p}$ v $\mathbb{F}[x]$, pak platí

$$\mathbf{M} \approx \mathbf{M}_{\text{diag}} + \mathbf{M}_{\text{nil}}$$

kde \mathbf{M}_{diag} je **diagonální**, \mathbf{M}_{nil} je **nilpotentní** a platí rovnost

$$\mathbf{M}_{\text{diag}} \cdot \mathbf{M}_{\text{nil}} = \mathbf{M}_{\text{nil}} \cdot \mathbf{M}_{\text{diag}}$$

To je velmi důležitý výsledek v aplikacích!

Příklad

Připomenutí: pro čtvercovou matici \mathbf{X} nad \mathbb{R} (nebo nad \mathbb{C}) lze definovat

$$\exp(\mathbf{X}) = \sum_{n=0}^{+\infty} \frac{\mathbf{X}^n}{n!}$$

a výsledkem je opět čtvercová matice nad \mathbb{R} (nebo nad \mathbb{C}).

Navíc: pro funkci $t \mapsto \exp(t\mathbf{X})$ **reálné proměnné** platí rovnost

$$\frac{d}{dt} \exp(t\mathbf{X}) = \mathbf{X} \cdot \exp(t\mathbf{X})$$

a to umožňuje **elegantně řešit soustavy lineárních diferenciálních prvního řádu s konstantními koeficienty**, viz Dodatek O **skript**.

Matici $\exp(t\mathbf{X})$ lze snadno spočítat, známe-li Jordanův tvar matice \mathbf{X} .

Příklad

Pro matici

$$\mathbf{M} = \begin{pmatrix} 5 & 4 & 0 & 0 & 4 & 3 \\ 2 & 3 & 1 & 0 & 5 & 1 \\ 0 & -1 & 2 & 0 & 2 & 0 \\ -8 & -8 & -1 & 2 & -12 & -7 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ -8 & -8 & -1 & 0 & -9 & -5 \end{pmatrix}$$

nad \mathbb{R} nalezneme její Jordanův tvar.

- ① Platí $\text{char}_{\mathbf{M}}(x) = (x - 2)^4(x + 1)^2$.

Jordanův tvar \mathbf{M} bude mít **dva Jordanovy segmenty**:

- ① Segment $\mathbf{B}_1(2)$ velikosti 4×4 , protože násobnost 2 jako kořene charakteristické rovnice je 4.
- ② Segment $\mathbf{B}_2(-1)$ velikosti 2×2 , protože násobnost -1 jako kořene charakteristické rovnice je 2.

Příklad (pokrač.)

② Celkově: Jordanův tvar matice \mathbf{M} je

$$\mathbf{M} \approx B_1(2) \oplus B_2(-1) = \left(\begin{array}{ccc|c||cc} 2 & 1 & 0 & 0 & 0 & 0 \\ 0 & 2 & 1 & 0 & 0 & 0 \\ 0 & 0 & 2 & 0 & 0 & 0 \\ \hline 0 & 0 & 0 & 2 & 0 & 0 \\ \hline 0 & 0 & 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & 0 & 0 & -1 \end{array} \right)$$

Příklad (pokrač.)

Například: víme, že platí

$$t\mathbf{M} \approx t \begin{pmatrix} 5 & 4 & 0 & 0 & 4 & 3 \\ 2 & 3 & 1 & 0 & 5 & 1 \\ 0 & -1 & 2 & 0 & 2 & 0 \\ -8 & -8 & -1 & 2 & -12 & -7 \\ 0 & 0 & 0 & 0 & -1 & 0 \\ -8 & -8 & -1 & 0 & -9 & -5 \end{pmatrix} \approx \underbrace{\begin{pmatrix} 2t & 0 & 0 & 0 & 0 & 0 \\ 0 & 2t & 0 & 0 & 0 & 0 \\ 0 & 0 & 2t & 0 & 0 & 0 \\ 0 & 0 & 0 & 2t & 0 & 0 \\ 0 & 0 & 0 & 0 & -t & 0 \\ 0 & 0 & 0 & 0 & 0 & -t \end{pmatrix}}_{=t\mathbf{M}_{\text{diag}}} + \underbrace{\begin{pmatrix} 0 & t & 0 & 0 & 0 & 0 \\ 0 & 0 & t & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}}_{=t\mathbf{M}_{\text{nil}}}$$

pro každé t z \mathbb{R} .

Příklad (pokrač.)

To znamená, že^a

$$\exp(t\mathbf{M}) \approx \exp(t\mathbf{M}_{\text{diag}} + t\mathbf{M}_{\text{nil}}) = \exp(t\mathbf{M}_{\text{diag}}) \cdot \exp(t\mathbf{M}_{\text{nil}})$$

$$= \exp(t\mathbf{M}_{\text{diag}}) \cdot \left(\mathbf{E}_6 + t\mathbf{M}_{\text{nil}} + \frac{t^2}{2}\mathbf{M}_{\text{nil}}^2 \right)$$

$$= \begin{pmatrix} e^{2t} & te^{2t} & \frac{t^2}{2}e^{2t} & 0 & 0 & 0 \\ 0 & e^{2t} & te^{2t} & 0 & 0 & 0 \\ 0 & 0 & e^{2t} & 0 & 0 & 0 \\ 0 & 0 & 0 & e^{2t} & 0 & 0 \\ 0 & 0 & 0 & 0 & e^{-t} & 0 \\ 0 & 0 & 0 & 0 & 0 & e^{-t} \end{pmatrix}$$

^aExponenciála **diagonální** matic se počítá snadno. Exponenciála **nilpotentní** matic se počítá v **konečně krocích**. V našem případě platí $\text{nil}(\mathbf{M}_{\text{nil}}) = 3$, proto $\exp(t\mathbf{M}_{\text{nil}}) = \mathbf{E}_6 + t\mathbf{M}_{\text{nil}} + \frac{t^2}{2}\mathbf{M}_{\text{nil}}^2$.



Abstraktní skalární součin

Odpřednesenou látku naleznete v kapitolách 12.1 a 12.2 skript
Abstraktní a konkrétní lineární algebra.

Dnešní přednáška

- ① V této přednášce (a ve všech přednáškách týkajících se skalárního součinu) se zaměříme na lineární prostory nad \mathbb{R} .^a
- ② Skalární součin zavedeme axiomaticky. Odvodíme geometrický význam skalárního součinu.^b

Axiomatické zavedení skalárního součinu nám umožní převést známé významy z \mathbb{R}^n (kolmost, délka vektoru, atd) do obecných lineárních prostorů se skalárním součinem.

^aVelmi málo řekneme i o lineárních prostorech nad \mathbb{C} . Důvod: fyzika a kvantové počítání.

^bSlogan: skalární součin je míra „odchylky“ dvou vektorů.

Příští přednáška

- ① Popis obecných skalárních součinů v prostorech \mathbb{R}^n .

Definice (reálný skalární součin)

Ať L je lineární prostor nad \mathbb{R} . Funkci $\langle - | - \rangle : L \times L \rightarrow \mathbb{R}$ říkáme **skalární součin**,^a pokud platí následující, pro libovolné vektory \vec{x}, \vec{y} :

- ① **Komutativita:** $\langle \vec{x} | \vec{y} \rangle = \langle \vec{y} | \vec{x} \rangle$.
- ② **Linearita ve druhé souřadnici:** zobrazení $\langle \vec{x} | - \rangle : L \rightarrow \mathbb{R}$ je lineární.
- ③ **Positivní definitnost:** $\langle \vec{x} | \vec{x} \rangle \geq 0$, $\langle \vec{x} | \vec{x} \rangle = 0$ iff $\vec{x} = \vec{o}$.

^aNaše značení pro skalární součin je obvyklé ve fyzice (tzv **bra-ket notation** nebo **Diracova notace**) a má jisté výhody. Značení $\vec{x} \cdot \vec{y}$ pro skalární součin **nebudeme používat!** Důvod: přetížení značky \cdot pro součin.


Poznámka (skalární součin pro prostory nad \mathbb{C})

V případě lineárního prostoru nad \mathbb{C} mluvíme o skalárním součinu, pokud $\langle - | - \rangle : L \times L \rightarrow \mathbb{C}$ je pozitivně definitní, lineární ve druhé souřadnici a **místo komutativity** platí rovnost $\langle \vec{x} | \vec{y} \rangle = \overline{\langle \vec{y} | \vec{x} \rangle}$.

Příklady skalárních součinů

- ① Skalární součin v prostoru orientovaných úseček:

$\langle \vec{x} | \vec{y} \rangle = \|\vec{x}\| \cdot \|\vec{y}\| \cdot \cos \varphi$, kde $\|\vec{x}\|$ a $\|\vec{y}\|$ jsou délky úseček \vec{x} a \vec{y} a φ je úhel, který svírají:^a



Tento skalární součin splňuje všechny tři požadované vlastnosti: je komutativní, lineární ve druhé souřadnici a pozitivně definitní.

^aDůležitá poznámka: v další části přednášky ukážeme, že pro libovolný skalární součin je možné definovat pojmy délky $\|\vec{x}\|$ vektoru \vec{x} (také: normy vektoru \vec{x}) a úhlu φ mezi dvěma vektory tak, že platí rovnost $\langle \vec{x} | \vec{y} \rangle = \|\vec{x}\| \cdot \|\vec{y}\| \cdot \cos \varphi$.

V prostoru s obecným skalárním součinem se tudíž budeme moci „chovat stejně“ jako v klasické geometrii. Bude tak například platit Pythagorova věta, a podobně.



Příklady skalárních součinů (pokrač.)

② Standardní skalární součin v \mathbb{R}^n : $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{y} = \sum_{i=1}^n x_i \cdot y_i$.

③ Standardní skalární součin není jediný skalární součin v \mathbb{R}^n .

Například^a $\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} | \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = x_1 y_1 + x_2 y_1 + x_1 y_2 + 2x_2 y_2$ je skalární součin v \mathbb{R}^2 . (Jde o úmorné, ale užitečné cvičení.)

④ Standardní skalární součin v \mathbb{C}^n : $\langle \mathbf{x} | \mathbf{y} \rangle = \sum_{i=1}^n \overline{x_i} \cdot y_i$.

Pozor! Platí rovnost $\langle \mathbf{x} | \mathbf{y} \rangle = \overline{\langle \mathbf{y} | \mathbf{x} \rangle}$, nikoli $\langle \mathbf{x} | \mathbf{y} \rangle = \langle \mathbf{y} | \mathbf{x} \rangle$.

^aK tomuto skalárnímu součinu se vrátíme koncem této přednášky. Po příští přednášce budeme schopni (téměř) okamžitě uvidět, že jde o skalární součin. Budeme také schopni popsat všechny možné skalární součiny v prostoru \mathbb{R}^n .

Tvrzení (nerovnost Cauchy-Schwarz-Bunyakovski)

$$\text{Platí } |\langle \vec{x} | \vec{y} \rangle| \leq \sqrt{\langle \vec{x} | \vec{x} \rangle} \cdot \sqrt{\langle \vec{y} | \vec{y} \rangle}.$$

Důkaz.

Platí $0 \leq \langle \vec{x} + a\vec{y} | \vec{x} + a\vec{y} \rangle = \underbrace{\langle \vec{x} | \vec{x} \rangle}_C + a \underbrace{2\langle \vec{x} | \vec{y} \rangle}_B + a^2 \underbrace{\langle \vec{y} | \vec{y} \rangle}_A$, pro každé $a \in \mathbb{R}$.

Tudíž $B^2 - 4AC \leq 0$, neboli $B^2 \leq 4AC$. Z toho nerovnost $|\langle \vec{x} | \vec{y} \rangle| \leq \sqrt{\langle \vec{x} | \vec{x} \rangle} \cdot \sqrt{\langle \vec{y} | \vec{y} \rangle}$ plyně okamžitě. ■

Jednoduchý, ale důležitý důsledek: úhel mezi vektory

Pro nenulové \vec{x}, \vec{y} platí $-1 \leq \frac{\langle \vec{x} | \vec{y} \rangle}{\sqrt{\langle \vec{x} | \vec{x} \rangle} \cdot \sqrt{\langle \vec{y} | \vec{y} \rangle}} \leq 1$. Úhlu φ $= \cos \varphi$ pro jediné $\varphi \in [0; \pi]$

říkáme úhel mezi vektory \vec{x} a \vec{y} .

Definice (norma vektoru)

Normu vektoru \vec{x} definujeme^a jako $\|\vec{x}\| = \sqrt{\langle \vec{x} | \vec{x} \rangle}$.

^aNerovnost C-S-B tedy můžeme zapsat jako $|\langle \vec{x} | \vec{y} \rangle| \leq \|\vec{x}\| \cdot \|\vec{y}\|$.

Tvrzení (vlastnosti normy)

Platí:

- ① $\|\vec{x}\| \geq 0$, $\|\vec{x}\| = 0$ iff $\vec{x} = \vec{o}$.
- ② $\|a \cdot \vec{x}\| = |a| \cdot \|\vec{x}\|$.
- ③ **Trojúhelníková nerovnost:** $\|\vec{x} + \vec{y}\| \leq \|\vec{x}\| + \|\vec{y}\|$.

Důkaz.

Jediná netriviální vlastnost je trojúhelníková nerovnost. Upravujte:

$\|\vec{x} + \vec{y}\|^2 = \langle \vec{x} + \vec{y} | \vec{x} + \vec{y} \rangle = \|\vec{x}\|^2 + 2\langle \vec{x} | \vec{y} \rangle + \|\vec{y}\|^2$ a použijte nerovnost Cauchy-Schwarz-Bunyakovski:

$$\|\vec{x}\|^2 + 2\langle \vec{x} | \vec{y} \rangle + \|\vec{y}\|^2 \leq \|\vec{x}\|^2 + 2\|\vec{x}\| \cdot \|\vec{y}\| + \|\vec{y}\|^2 = (\|\vec{x}\| + \|\vec{y}\|)^2.$$

Celkově: $\|\vec{x} + \vec{y}\|^2 \leq (\|\vec{x}\| + \|\vec{y}\|)^2$, tedy $\|\vec{x} + \vec{y}\| \leq \|\vec{x}\| + \|\vec{y}\|$. ■

Důsledek

Pro nenulová \vec{x} , \vec{y} platí rovnost $\langle \vec{x} | \vec{y} \rangle = \|\vec{x}\| \cdot \|\vec{y}\| \cdot \cos \varphi$.

Poznámka

Předchozí důsledek je **stejná** rovnost, která platí pro „klasický“ skalární součin v prostoru orientovaných úseček!

Definice (ortogonalita vektorů)

Pokud $\langle \vec{x} | \vec{y} \rangle = 0$, mluvíme o **ortogonálních** (také: **navzájem kolmých**) vektorech.

Několik poznámek o ortogonalitě

- ① Neřekli jsme, že vektory \vec{x} a \vec{y} jsou na sebe kolmé, pokud svírají úhel $\frac{\pi}{2}$. Taková úvaha platí pouze pro **nenulové** vektory. Chceme ovšem hovořit i o nulovém vektoru, proto jsme definovali kolmost rovností $\langle \vec{x} | \vec{y} \rangle = 0$.

Několik poznámek o ortogonalitě (pokrač.)

② **Pozor:** nulový vektor \vec{o} je kolmý na každý vektor \vec{x} .

Důvod: z definice skalárního součinu víme, že zobrazení

$$\langle \vec{x} | - \rangle : L \rightarrow \mathbb{R}$$

je lineární. Proto $\langle \vec{x} | - \rangle$ musí poslat nulový vektor na nulový vektor, neboli musí platit rovnost

$$\langle \vec{x} | \vec{o} \rangle = 0$$

Obráceně: jestliže \vec{x} je kolmý na každý vektor, pak $\vec{x} = \vec{o}$.

Důvod: podle předpokladu je $\langle \vec{x} | \vec{x} \rangle = 0$. Z definice skalárního součinu plyne, že $\vec{x} = \vec{o}$.

Několik poznámek o ortogonalitě (pokrač.)

- ③ Chceme-li pro nějaký vektor \vec{x} ověřit, že $\langle \vec{x} | \vec{v} \rangle = 0$ pro každý vektor \vec{v} ze $\text{span}(M)$, stačí ověřit, že platí $\langle \vec{x} | \vec{m} \rangle = 0$ pro všechny vektory \vec{m} z M .

Důvod: pro obecný vektor \vec{v} ze $\text{span}(M)$ nastane jedna ze dvou situací:

- ① $\vec{v} = \vec{o}$. Pak $\langle \vec{x} | \vec{v} \rangle = 0$.

- ② $\vec{v} = \sum_{i=1}^n a_i \cdot \vec{m}_i$ pro nějaká a_i z \mathbb{R} a nějaká \vec{m}_i z M . Pak

$$\langle \vec{x} | \vec{v} \rangle = \langle \vec{x} | \sum_{i=1}^n a_i \cdot \vec{m}_i \rangle = \sum_{i=1}^n a_i \cdot \langle \vec{x} | \vec{m}_i \rangle$$

Jestliže tedy je $\langle \vec{x} | \vec{m}_i \rangle = 0$ pro každé i , platí $\langle \vec{x} | \vec{v} \rangle = 0$.

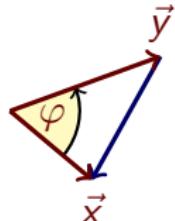
Slogan: ortogonalitu stačí ověřovat pouze pro množinu generátorů podprostoru.

Ortogonalitou se budeme podrobněji zabývat v příštích přednáškách.



Příklady (geometrie prostoru se skalárním součinem)


- ① **Kosinová věta:** Nenulové vektory \vec{x} a \vec{y} určují trojúhelník



$$\text{Platí: } \|\vec{x} - \vec{y}\|^2 = \|\vec{x}\|^2 + \|\vec{y}\|^2 - \underbrace{2 \cdot \langle \vec{x} | \vec{y} \rangle}_{2 \cdot \|\vec{x}\| \cdot \|\vec{y}\| \cdot \cos \varphi}.$$

Případu, kdy $\langle \vec{x} | \vec{y} \rangle = 0$, se říká **Pythagorova věta**.

- ② **Rovnoběžníková rovnost:** Dva nenulové vektory \vec{x} a \vec{y} určují strany rovnoběžníka s úhlopříčkami $\vec{x} - \vec{y}$ a $\vec{x} + \vec{y}$.



$$\text{Platí: } \|\vec{x} - \vec{y}\|^2 + \|\vec{x} + \vec{y}\|^2 = 2(\|\vec{x}\|^2 + \|\vec{y}\|^2).$$

Upravujte:

$$\|\vec{x} - \vec{y}\|^2 + \|\vec{x} + \vec{y}\|^2 = \langle \vec{x} - \vec{y} | \vec{x} - \vec{y} \rangle + \langle \vec{x} + \vec{y} | \vec{x} + \vec{y} \rangle = \dots$$

Poznámky (vztah skalárního součinu, normy a metriky)

Skalární součin indukuje normu a ta indukuje **metriku** (také: **distanci**) na množině L . Jde o funkci $d : L \times L \rightarrow \mathbb{R}$, která splňuje:

- ① $d(\vec{x}, \vec{y}) \geq 0$, rovnost nastává právě tehdy, když $\vec{x} = \vec{y}$.
- ② $d(\vec{x}, \vec{y}) = d(\vec{y}, \vec{x})$.
- ③ $d(\vec{x}, \vec{y}) \leq d(\vec{x}, \vec{z}) + d(\vec{z}, \vec{y})$.

Stačí definovat $d(\vec{x}, \vec{y}) = \|\vec{x} - \vec{y}\|$.

O prostoru L s metrikou d mluvíme jako o **metrickém lineárním prostoru**.

Pro lineární prostory platí: ^a skalární součin \rightsquigarrow norma \rightsquigarrow metrika.

^aObrácené implikace **neplatí**. Například $d(x, y) = \begin{cases} 1, & \text{když } x \neq y, \\ 0, & \text{když } x = y, \end{cases}$ je metrika na \mathbb{R} , která nevznikla z žádné normy na \mathbb{R} (tj $\|x\| = d(0, x)$ **není norma**). Norma $\left\| \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \right\| = |x_1| + |x_2|$ na \mathbb{R}^2 nevznikla z žádného skalárního součinu na \mathbb{R}^2 , protože **nesplňuje rovnoběžníkovou rovnost**.

Poznámka

Předchozí úvahy říkají, že prostory se skalárním součinem se chovají tak, jak jsme zvyklí z klasické geometrie. Další příklad ukazuje, že klasická geometrie nemusí být vždy vhodná.

Příklad (nikoli pozitivně definitní „skalární součin“)

Na \mathbb{R}^4 definujte $\langle \begin{pmatrix} t \\ x \\ y \\ z \end{pmatrix} | \begin{pmatrix} t' \\ x' \\ y' \\ z' \end{pmatrix} \rangle = tt' - xx' - yy' - zz'$. Protože $\langle \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \end{pmatrix} | \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \end{pmatrix} \rangle = -1$, nejde o pozitivně definitní „skalární součin“.

Tento „skalární součin“ je velmi důležitý v **teorii relativity**.

Příslušnému pojmu „vzdálenosti“ vektorů \mathbf{x} a \mathbf{y} v \mathbb{R}^4 se říká **Lorentzova metrika Minkowského časoprostoru**.^a

^aV tomto časoprostoru je rychlosť světla c rovna 1.

Příklad (Lorentzova transformace)

Pohyb podsvětelnou rychlostí v ve směru osy x v Minkowského časoprostoru je lineární zobrazení $\mathbf{L} : \mathbb{R}^4 \rightarrow \mathbb{R}^4$, pro které platí

$$\begin{aligned} t' &= \gamma \cdot (t - vx) \\ x' &= \gamma \cdot (x - vt) \\ y' &= y \\ z' &= z \end{aligned} \quad \text{kde } 0 \leq v < c = 1 \text{ a } \gamma = \frac{1}{\sqrt{1 - v^2}}.$$

Vzhledem ke kanonické bázi \mathbb{R}^4 má zobrazení \mathbf{L} matici

$$\Lambda = \begin{pmatrix} \gamma & -v \cdot \gamma & 0 & 0 \\ -v \cdot \gamma & \gamma & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix} = \begin{pmatrix} \cosh \varphi & -\sinh \varphi & 0 & 0 \\ -\sinh \varphi & \cosh \varphi & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{pmatrix}$$

kde $\varphi = \ln(\gamma(1 + v))$. Pohyb ve směru osy x podsvětelnou rychlostí v v Minkowského časoprostoru lze tedy interpretovat jako rotaci (v rovině dané osami t a x) o úhel φ v hyperbolické geometrii.

Příklad (rotace a standardní skalární součin)

Připomenutí: rotace o úhel α je $\mathbf{R}_\alpha : \mathbb{R}^2 \rightarrow \mathbb{R}^2$, kde^a

$$\mathbf{R}_\alpha = \begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$$

Potom platí:

$$\begin{aligned} \langle \mathbf{R}_\alpha \cdot \mathbf{x} \mid \mathbf{R}_\alpha \cdot \mathbf{y} \rangle &= (\mathbf{R}_\alpha \cdot \mathbf{x})^T \cdot (\mathbf{R}_\alpha \cdot \mathbf{y}) \\ &= \mathbf{x}^T \cdot \mathbf{R}_\alpha^T \cdot \mathbf{R}_\alpha \cdot \mathbf{y} \\ &= \mathbf{x}^T \cdot \mathbf{R}_\alpha^{-1} \cdot \mathbf{R}_\alpha \cdot \mathbf{y} \\ &= \mathbf{x}^T \cdot \mathbf{y} \\ &= \langle \mathbf{x} \mid \mathbf{y} \rangle \end{aligned}$$

Tudíž platí: $\|\mathbf{x}\| = \|\mathbf{R}_\alpha \cdot \mathbf{x}\|$ a $\|\mathbf{x} - \mathbf{y}\| = \|\mathbf{R}_\alpha \cdot \mathbf{x} - \mathbf{R}_\alpha \cdot \mathbf{y}\|$.

Ukázali jsme: **rotace zachovává standardní skalární součin, normu a metriku.**

^aPovšimněme si: $\mathbf{R}_\alpha^T = \mathbf{R}_\alpha^{-1}$.



Tvrzení

Pro matici $\mathbf{A} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ jsou následující podmínky ekvivalentní:

- ① \mathbf{A} zachovává standardní skalární součin v \mathbb{R}^n .
- ② \mathbf{A} je regulární a platí $\mathbf{A}^T = \mathbf{A}^{-1}$.

Důkaz.

Z (1) plyne (2):^a $\delta_{ij} = \langle \mathbf{e}_i | \mathbf{e}_j \rangle = \langle \mathbf{A} \cdot \mathbf{e}_i | \mathbf{A} \cdot \mathbf{e}_j \rangle = \mathbf{e}_i^T \cdot \mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{e}_j$, takže $\mathbf{A}^T \cdot \mathbf{A} = \mathbf{E}_n$.

Ze (2) plyne (1):

$$\langle \mathbf{A} \cdot \mathbf{x} | \mathbf{A} \cdot \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{y} = \mathbf{x}^T \cdot \mathbf{A}^{-1} \cdot \mathbf{A} \cdot \mathbf{y} = \mathbf{x}^T \cdot \mathbf{y} = \langle \mathbf{x} | \mathbf{y} \rangle. \quad \blacksquare$$

^aPřipomenutí: pro Kroneckerův symbol δ platí $\delta_{ij} = 0$ pro $i \neq j$ a $\delta_{ii} = 1$.

Poznámka (základní transformace prostoru \mathbb{R}^2)

Projekce na osy a změna měřítka **nezachovávají** standardní skalární součin! Rotace skalární součin zachovávají (viz předchozí příklad).

Reflexe podle os x a y standardní skalární součin zachovávají.

Příklad (netradiční skalární součin v \mathbb{R}^2)

Pro $\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = x_1y_1 + x_2y_1 + x_1y_2 + 2x_2y_2$ v \mathbb{R}^2 platí rovnost $\left\langle \begin{pmatrix} 1 \\ 0 \end{pmatrix} \mid \begin{pmatrix} -1 \\ 1 \end{pmatrix} \right\rangle = 0$.

To znamená, že náš skalární součin „vidí“ vektory $\begin{pmatrix} 1 \\ 0 \end{pmatrix}, \begin{pmatrix} -1 \\ 1 \end{pmatrix}$ jako **navzájem kolmé**:



To může být velmi praktické. Jak tedy rozpoznat obecný skalární součin? Všimněme si, že náš součin je zadán jistou **maticí G**:

$$\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = (x_1 \quad x_2) \cdot \underbrace{\begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}}_{G} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = x_1y_1 + x_2y_1 + x_1y_2 + 2x_2y_2$$

Co dál?

Budeme chtít pochopit, které matice **G** zadávají skalární součiny v prostoru \mathbb{R}^n .

Uvidíme, že skalární součiny v \mathbb{R}^n přesně odpovídají maticím, kterým říkáme **positivně definitní**.

Charakterisace skalárních součinů v \mathbb{R}^n

Odpřednesenou látku naleznete v kapitolách 12.1, 12.2 a 12.3
skript *Abstraktní a konkrétní lineární algebra*.

Dnešní přednáška

- ① V této přednášce (a ve všech přednáškách týkajících se skalárního součinu) se zaměříme na lineární prostory nad \mathbb{R} .
- ② Charakterisace matic, které zadávají skalární součiny v prostoru \mathbb{R}^n .
- ③ Konstrukce skalárních součinů požadovaných vlastností.

Příští přednášky ke skalárnímu součinu

- ① Ortogonální báze a ortonormální báze.
- ② Ortogonalisační proces a ortonormalisační proces.
- ③ Ortogonální projekce a ortogonální rejekce.

Připomenutí (dva různé skalární součiny v \mathbb{R}^2)

1 Standardní skalární součin:

$$\begin{aligned}\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle &= x_1y_1 + x_2y_2 \\ &= (x_1 \quad x_2) \cdot \underbrace{\begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}}_{\mathbf{E}_2} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}\end{aligned}$$

2 „Nezvyklý“ skalární součin:

$$\begin{aligned}\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle &= x_1y_1 + x_2y_1 + x_1y_2 + 2x_2y_2 \\ &= (x_1 \quad x_2) \cdot \underbrace{\begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}}_{\mathbf{G}} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}\end{aligned}$$

V obou případech je součin zadán jistou maticí typu 2×2 . Je to náhoda?

Co dál?

Ukážeme, že skalární součiny v \mathbb{R}^n odpovídají přesně těm čtvercovým maticím, kterým říkáme positivně definitní.

Definice (positivně definitní matice)

Řekneme, že matice \mathbf{G} typu $n \times n$ nad \mathbb{R} je **positivně definitní**, když existuje matice \mathbf{R} s lineárně nezávislými sloupcí tak, že $\mathbf{G} = \mathbf{R}^T \cdot \mathbf{R}$.

Poznámky

- 1 Protože $\mathbf{G}^T = (\mathbf{R}^T \cdot \mathbf{R})^T = \mathbf{R}^T \cdot \mathbf{R} = \mathbf{G}$, je každá positivně definitní matice \mathbf{G} **symetrická**.

Poznámky (pokrač.)

- ② Positivně definitní matice \mathbf{G} zobecňují kladná reálná čísla: matice \mathbf{R} je „druhá odmocnina“^a matice \mathbf{G} .

Opravdu: Matice $\mathbf{G} = (g)$ typu 1×1 je positivně definitní právě tehdy, když $g > 0$.

① At' $\mathbf{G} = (g) = \mathbf{R}^T \cdot \mathbf{R}$. Pak $\mathbf{R} = \begin{pmatrix} r_1 \\ \vdots \\ r_n \end{pmatrix}$ a platí $g = r_1^2 + \cdots + r_n^2$.

Protože jediný sloupec \mathbf{R} musí být lineárně nezávislý, je $g > 0$.

- ② Je-li $g > 0$, platí $(g) = (\sqrt{g})^T \cdot (\sqrt{g})$. Protože $\sqrt{g} > 0$, je jediný sloupec matice $\mathbf{R} = (\sqrt{g})$ lineárně nezávislý. Matice \mathbf{G} je tudíž positivně definitní.

^aJde jen o **slogan**: matice \mathbf{R} není určena jednoznačně. Například platí

$$(4) = (2)^T \cdot (2) = \begin{pmatrix} 2 \\ 0 \end{pmatrix}^T \cdot \begin{pmatrix} 2 \\ 0 \end{pmatrix}.$$

Věta (charakterisace positivně definitních matic)

Pro matici $\mathbf{G} = (g_{ij})_{i=1,\dots,n,j=1,\dots,n}$ nad \mathbb{R} jsou následující podmínky ekvivalentní:

- ① **\mathbf{G} je pozitivně definitní.**
- ② Matice \mathbf{G} je symetrická a determinanty všech matic $\mathbf{G}_k = (g_{ij})_{i=1,\dots,k,j=1,\dots,k}$, kde $1 \leq k \leq n$, jsou kladné.^a
- ③ Matice \mathbf{G} je symetrická a nerovnost $\mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{x} \geq 0$ platí pro všechna \mathbf{x} z \mathbb{R}^n (rovnost platí pouze pro $\mathbf{x} = \mathbf{0}$).
- ④ Matice \mathbf{G} je symetrická a $\text{char}_{\mathbf{G}}(\lambda)$ má všechny kořeny reálné a kladné.
- ⑤ Existuje **regulární** matice \mathbf{R} tak, že platí $\mathbf{G} = \mathbf{R}^T \cdot \mathbf{R}$.

^aTento test pozitivní definitnosti budete využívat v analýze pro určování lokálních minim funkcí více proměnných.

Důkaz.

Bez důkazu (je těžký, pro zájemce: Tvrzení 12.3.4 skript).



Poznámka o Choleskyho faktorisaci — nepovinné

- ① Připomenutí definice: \mathbf{G} je positivně definitní právě tehdy, když $\mathbf{G} = \mathbf{R}^T \cdot \mathbf{R}$, kde \mathbf{R} má lineárně nezávislé sloupce.
- ② Předchozí věta: \mathbf{G} je positivně definitní právě tehdy, když $\mathbf{G} = \mathbf{R}^T \cdot \mathbf{R}$, kde \mathbf{R} je regulární.
- ③ Zesílení věty: \mathbf{G} je positivně definitní právě tehdy, když $\mathbf{G} = \mathbf{R}^T \cdot \mathbf{R}$, kde \mathbf{R} je regulární v horním blokovém tvaru.

Rovnosti $\mathbf{G} = \mathbf{R}^T \cdot \mathbf{R}$ pro regulární matici \mathbf{R} v horním blokovém tvaru se říká Choleskyho faktorisace matice \mathbf{G} .

Příklad Choleskyho faktorisace:

$$\begin{pmatrix} 1 & 2 & 8 \\ 2 & 8 & 12 \\ 8 & 12 & 27 \end{pmatrix} = \begin{pmatrix} 1 & 2 & 3 \\ 0 & 2 & 3 \\ 0 & 0 & 3 \end{pmatrix}^T \cdot \begin{pmatrix} 1 & 2 & 3 \\ 0 & 2 & 3 \\ 0 & 0 & 3 \end{pmatrix}$$

Choleskyho faktorisaci lze nalézt algoritmem, viz skripta,
Příklad 12.3.6. Tento algoritmus je nepovinný.

Příklady

- ① Protože $\mathbf{E}_n = \mathbf{E}_n^T \cdot \mathbf{E}_n$, je jednotková matice \mathbf{E}_n positivně definitní.

Připomeňme: \mathbf{E}_n zadává standardní skalární součin

$$\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{E}_n \cdot \mathbf{y} = \mathbf{x}^T \cdot \mathbf{y} \quad \forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n.$$

- ② Matice $\mathbf{G} = \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}$ je positivně definitní podle předchozí věty: \mathbf{G} je symetrická a platí nerovnosti $\det(\mathbf{G}_1) = \det(1) > 0$ a $\det(\mathbf{G}_2) = \det(\mathbf{G}) > 0$.

Připomeňme: \mathbf{G} zadává „nezvyklý“ skalární součin

$$\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{y} \quad \forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^2.$$

Příklady (pokrač.)

③ Matice

$$\mathbf{G} = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & -1 & 0 & 0 \\ 0 & 0 & -1 & 0 \\ 0 & 0 & 0 & -1 \end{pmatrix}$$

není positivně definitní podle předchozí věty: platí
 $\det(\mathbf{G}_1) > 0$, $\det(\mathbf{G}_2) < 0$, $\det(\mathbf{G}_3) > 0$, $\det(\mathbf{G}_4) < 0$.

Připomeňme (minulá přednáška): \mathbf{G} zadává „skalární součin“
 $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{y}$ v Minkowského časoprostoru \mathbb{R}^4 .

Věta (obecný tvar skalárního součinu v \mathbb{R}^n)

- ① At' \mathbf{G} je positivně definitní matice typu $n \times n$ nad \mathbb{R} .

Potom maticový součin

$$\mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{y}$$

definuje skalární součin v \mathbb{R}^n .

- ② Každý skalární součin $\langle - | - \rangle$ v \mathbb{R}^n definuje positivně definitní^a matici $\mathbf{G} = (g_{ij})_{i=1,\dots,n, j=1,\dots,n}$, kde $g_{ij} = \langle \mathbf{e}_i | \mathbf{e}_j \rangle$. Potom platí rovnost $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{y}$.

^aMatici \mathbf{G} říkáme metrický tensor (také: Gramova matice) skalárního součinu $\langle - | - \rangle$.

Důkaz.

Přednáška.



Příklad (popis všech skalárních součinů v \mathbb{R}^2)

Matrice $\mathbf{G} = \begin{pmatrix} a & b \\ c & d \end{pmatrix}$ je positivně definitní právě tehdy, když platí:

- ① \mathbf{G} je symetrická matice, tj. když platí $c = b$.
- ② $\det(\mathbf{G}_1) = a > 0$ a $\det(\mathbf{G}_2) = \det(\mathbf{G}) = ad - b^2 > 0$.

To znamená: výraz

$$ax_1y_1 + b(x_1y_2 + x_2y_1) + dx_2y_2$$

zadává skalární součin $\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle$ v \mathbb{R}^2 právě tehdy, když platí nerovnosti $a > 0$ a $ad - b^2 > 0$.

Příklad (jednotková kružnice pro skalární součin v \mathbb{R}^2)

Pro pozitivně definitní^a matici $\mathbf{G} = \begin{pmatrix} a & b \\ b & d \end{pmatrix}$ a příslušný skalární součin $\langle - | - \rangle$ je množina^b

$$\left\{ \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \| \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \| = 1 \right\}$$

jednotková kružnice. Rovnice této kružnice je

$$ax_1^2 + 2bx_1x_2 + dx_2^2 = 1$$

a my ukážeme, že v **bázi vlastních vektorů** matice \mathbf{G} , jde o elipsu.

^aPřipomenutí: platí $a > 0$ a $ad - b^2 > 0$.

^bPřipomenutí: $\| - \|$ je norma vytvořená skalárním součinem

$$\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = (x_1 \quad x_2) \cdot \begin{pmatrix} a & b \\ b & d \end{pmatrix} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}.$$

Příklad (jednotková kružnice, pokrač.)

- ① Positivně definitní matice $\mathbf{G} = \begin{pmatrix} a & b \\ b & d \end{pmatrix}$ má charakteristický polynom $\text{char}_{\mathbf{G}}(x) = x^2 - (a + d)x + (ad - b^2)$ s diskriminantem $D = (a - d)^2 + 4b^2 \geqslant 0$.
- ② V případě $D = (a - d)^2 + 4b^2 = 0$ platí $b = 0$ a $a = d > 0$.

Pak matice \mathbf{G} je diagonální, vlastní vektory jsou \mathbf{e}_1 a \mathbf{e}_2 a v bázi $(\mathbf{e}_1, \mathbf{e}_2)$ má rovnice jednotkové kružnice tvar

$$x_1^2 + x_2^2 = \left(\frac{1}{\sqrt{a}}\right)^2$$

Příklad (jednotková kružnice, pokrač.)

③ V případě $D = (a - d)^2 + 4b^2 > 0$ rozlišíme dva případy:

① $b = 0$. Pak \mathbf{G} je diagonální a $a \neq d$. Vlastní vektory \mathbf{G} jsou \mathbf{e}_1 a \mathbf{e}_2 a v bázi $(\mathbf{e}_1, \mathbf{e}_2)$ má rovnice jednotkové kružnice tvar

$$\left(\frac{x_1}{\sqrt{d}}\right)^2 + \left(\frac{x_2}{\sqrt{a}}\right)^2 = \left(\frac{1}{\sqrt{ad}}\right)^2$$

protože $d > 0$, neboť \mathbf{G} je positivně definitní. Jde tedy o elipsu.

② $b \neq 0$. Matice \mathbf{G} pak má dvě různé kladné vlastní hodnoty

$$\lambda_1 = \frac{a+d+\sqrt{D}}{2} \quad \lambda_2 = \frac{a+d-\sqrt{D}}{2}$$

V bázi $(\mathbf{v}_1, \mathbf{v}_2)$ vlastních vektorů má rovnice jednotkové kružnice tvar

$$\left(\frac{t_1}{\sqrt{\lambda_2}}\right)^2 + \left(\frac{t_2}{\sqrt{\lambda_1}}\right)^2 = \left(\frac{1}{\sqrt{\lambda_1 \lambda_2}}\right)^2$$

Jde tedy o elipsu.

Připomenutí

Minulá přednáška: každý skalární součin vytváří normu.

Je-li $\langle - | - \rangle$ skalární součin na \mathbb{R}^n , pak

- ① vektory \mathbf{x} a \mathbf{y} jsou **ortogonální** (také: **navzájem kolmé**), pokud $\langle \mathbf{x} | \mathbf{y} \rangle = 0$,
- ② **norma** (také: **velikost**) vektoru \mathbf{x} je $\|\mathbf{x}\| = \sqrt{\langle \mathbf{x} | \mathbf{x} \rangle}$,
- ③ vektor \mathbf{x} je **normovaný**, pokud $\|\mathbf{x}\| = 1$.

Tvrzení (kanonická báze \mathbb{R}^n a standardní skalární součin v \mathbb{R}^n)

Pro standardní skalární součin $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{y}$ a kanonickou bázi $(\mathbf{e}_1, \dots, \mathbf{e}_n)$ v \mathbb{R}^n platí:^a $\langle \mathbf{e}_i | \mathbf{e}_j \rangle = \mathbf{e}_i^T \cdot \mathbf{e}_j = \delta_{ij} = \begin{cases} 0, & \text{pro } i \neq j \\ 1, & \text{pro } i = j \end{cases}$

^aTakovým bázim budeme říkat **ortonormální** a obecně je budeme studovat příště. To jest: vektory takové báze jsou na sebe navzájem kolmé a každý vektor takové báze má normu 1.

Věta (každou bázi \mathbb{R}^n lze považovat za ortonormální)

Ať $(\mathbf{b}_1, \dots, \mathbf{b}_n)$ je jakákoli uspořádaná báze \mathbb{R}^n . Potom existuje **jediný** skalární součin $\langle - | - \rangle$ takový, že $\langle \mathbf{b}_i | \mathbf{b}_j \rangle = \delta_{ij}$.

Důkaz.

Označme $B = (\mathbf{b}_1, \dots, \mathbf{b}_n)$, připomenutí (téma 5B):

$\mathbf{T}_{B \mapsto K_n} \cdot \mathbf{e}_i = \mathbf{b}_i$, čili $\mathbf{T}_{K_n \mapsto B} \cdot \mathbf{b}_i = \mathbf{e}_i$, pro vši $i = 1, \dots, n$.

- Existence hledaného skalárního součinu.

Definujte $\mathbf{G} = (\mathbf{T}_{K_n \mapsto B})^T \cdot \mathbf{T}_{K_n \mapsto B}$. Potom matice \mathbf{G} je positivně definitní a platí

$$\begin{aligned}\langle \mathbf{b}_i | \mathbf{b}_j \rangle &= \mathbf{b}_i^T \cdot \mathbf{G} \cdot \mathbf{b}_j \\ &= \underbrace{\mathbf{b}_i^T \cdot (\mathbf{T}_{K_n \mapsto B})^T}_{=(\mathbf{T}_{K_n \mapsto B} \cdot \mathbf{b}_i)^T = \mathbf{e}_i^T} \cdot \underbrace{\mathbf{T}_{K_n \mapsto B} \cdot \mathbf{b}_j}_{=\mathbf{e}_j} \\ &= \mathbf{e}_i^T \cdot \mathbf{e}_j = \delta_{ij}\end{aligned}$$

Důkaz (pokrač.)

- ② Jednoznačnost hledaného skalárního součinu.

Ať $\mathbf{b}_i^T \cdot \mathbf{G}_1 \cdot \mathbf{b}_j = \mathbf{b}_i^T \cdot \mathbf{G}_2 \cdot \mathbf{b}_j = \delta_{ij}$. Ukážeme $\mathbf{G}_1 = \mathbf{G}_2$.

Opravdu: platí $\mathbf{b}_i^T \cdot (\mathbf{G}_1 - \mathbf{G}_2) \cdot \mathbf{b}_j = 0$ pro vš. i, j .

To znamená $(\mathbf{T}_{B \mapsto K_n} \cdot \mathbf{e}_i)^T \cdot (\mathbf{G}_1 - \mathbf{G}_2) \cdot (\mathbf{T}_{B \mapsto K_n} \cdot \mathbf{e}_j) = 0$ pro vš. i, j , neboli $\mathbf{e}_i^T \cdot (\mathbf{T}_{B \mapsto K_n})^T \cdot (\mathbf{G}_1 - \mathbf{G}_2) \cdot \mathbf{T}_{B \mapsto K_n} \cdot \mathbf{e}_j = 0$ pro vš. i, j .

Ukázali jsme rovnost $(\mathbf{T}_{B \mapsto K_n})^T \cdot (\mathbf{G}_1 - \mathbf{G}_2) \cdot \mathbf{T}_{B \mapsto K_n} = \mathbf{0}_{n,n}$.

Protože $\mathbf{T}_{B \mapsto K_n}$ i $(\mathbf{T}_{B \mapsto K_n})^T$ jsou regulární, platí
 $\mathbf{G}_1 - \mathbf{G}_2 = \mathbf{0}_{n,n}$.


Tudíž $\mathbf{G}_1 = \mathbf{G}_2$.



Příklad

Najděte skalární součin v \mathbb{R}^2 takový, aby vektory $\begin{pmatrix} 2 \\ -3 \end{pmatrix}$ a $\begin{pmatrix} 5 \\ -3 \end{pmatrix}$ byly navzájem kolmé a každý měl normu 1.

Obrázek:



Skalární součin nalezneme podle předchozího tvrzení:

① Pro $\mathbf{T}_{B \mapsto K_n} = \begin{pmatrix} 2 & 5 \\ -3 & -3 \end{pmatrix}$ je^a $(\mathbf{T}_{B \mapsto K_n})^{-1} = \frac{1}{9} \cdot \begin{pmatrix} -3 & -5 \\ 3 & 2 \end{pmatrix}$.

Tudíž $\mathbf{G} = ((\mathbf{T}_{B \mapsto K_n})^{-1})^T \cdot (\mathbf{T}_{B \mapsto K_n})^{-1} = \frac{1}{81} \cdot \begin{pmatrix} 18 & 21 \\ 21 & 29 \end{pmatrix}$.

^aInversi matice $\mathbf{T}_{B \mapsto K_n}$ nalezneme nejrychleji pomocí adjungované matice.

Příklad (pokrač.)

② Hledaný skalární součin je

$$\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = \frac{18}{81} \cdot x_1 y_1 + \frac{21}{81} \cdot x_1 y_2 + \frac{21}{81} \cdot x_2 y_1 + \frac{29}{81} \cdot x_2 y_2.$$

③ $\left\langle \begin{pmatrix} 2 \\ -3 \end{pmatrix} \mid \begin{pmatrix} 5 \\ -3 \end{pmatrix} \right\rangle =$

$$\frac{18}{81} \cdot 2 \cdot 5 + \frac{21}{81} \cdot 2 \cdot (-3) + \frac{21}{81} \cdot (-3) \cdot 5 + \frac{29}{81} \cdot (-3) \cdot (-3) = 0.$$

④ $\left\langle \begin{pmatrix} 2 \\ -3 \end{pmatrix} \mid \begin{pmatrix} 2 \\ -3 \end{pmatrix} \right\rangle =$

$$\frac{18}{81} \cdot 2 \cdot 2 + \frac{21}{81} \cdot 2 \cdot (-3) + \frac{21}{81} \cdot (-3) \cdot 2 + \frac{29}{81} \cdot (-3) \cdot (-3) = 1.$$

⑤ $\left\langle \begin{pmatrix} 5 \\ -3 \end{pmatrix} \mid \begin{pmatrix} 5 \\ -3 \end{pmatrix} \right\rangle =$


$$\frac{18}{81} \cdot 5 \cdot 5 + \frac{21}{81} \cdot 5 \cdot (-3) + \frac{21}{81} \cdot (-3) \cdot 5 + \frac{29}{81} \cdot (-3) \cdot (-3) = 1.$$

K čemu jsou takové výpočty dobré?

Skalární součin

$$\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = \frac{18}{81} \cdot x_1 y_1 + \frac{21}{81} \cdot x_1 y_2 + \frac{21}{81} \cdot x_2 y_1 + \frac{29}{81} \cdot x_2 y_2$$

z předchozího příkladu „vidí“



jako jednotkovou pravoúhlou síť.

Co zatím v \mathbb{R}^n umíme

Pro zadanou bázi $(\mathbf{b}_1, \dots, \mathbf{b}_n)$ prostoru \mathbb{R}^n umíme sestrojit skalární součin $\langle - | - \rangle$ v \mathbb{R}^n tak, že $(\mathbf{b}_1, \dots, \mathbf{b}_n)$ je ortonormální báze vzhledem k $\langle - | - \rangle$.

Příště se v \mathbb{R}^n naučíme

Pro zadanou bázi $(\mathbf{b}_1, \dots, \mathbf{b}_n)$ prostoru \mathbb{R}^n a zadaný skalární součin $\langle - | - \rangle$ v \mathbb{R}^n nalezneme novou bázi $(\mathbf{c}_1, \dots, \mathbf{c}_n)$, která je ortonormální vzhledem k $\langle - | - \rangle$.

Hledaná báze bude navíc splňovat rovnost

$$\text{span}(\mathbf{b}_1, \dots, \mathbf{b}_k) = \text{span}(\mathbf{c}_1, \dots, \mathbf{c}_k) \text{ pro všechna } k = 1, \dots, n.$$

K tomu bude zapotřebí zavedení nových pojmu: ortogonální projekce a ortogonální rejekce.

Ortogonalisace a ortogonální projekce

Odpřednesenou látku naleznete v kapitole 12.4
skript *Abstraktní a konkrétní lineární algebra*.

Minulé přednášky

- ① Definice skalárního součinu v lineárních prostorech nad \mathbb{R} .
- ② Úplný popis skalárních součinů v prostoru \mathbb{R}^n .

Dnešní přednáška

- ① V této přednášce (a ve všech přednáškách týkajících se skalárního součinu) se zaměříme na lineární prostory nad \mathbb{R} .
- ② Ortogonalní báze a ortonormální báze.
- ③ Ortogonalní projekce. Ortogonalisace a ortonormalisace.

Důležitá aplikace — viz příští přednášku

- ① Metoda nejmenších čtverců.

Připomenutí vlastností ortogonality (minulé přednášky)

Platí-li $\langle \vec{x} | \vec{y} \rangle = 0$, říkáme, že vektory \vec{x} a \vec{y} jsou **ortogonální** (také: **navzájem kolmé**).

① **Pozor:** nulový vektor \vec{o} je kolmý na každý vektor \vec{x} .

Obráceně: jestliže \vec{x} je kolmý na každý vektor, pak $\vec{x} = \vec{o}$.

② Abychom ukázali, že rovnost $\langle \vec{x} | \vec{v} \rangle = 0$ platí pro každý vektor \vec{v} ze $\text{span}(M)$, **stačí ukázat**, že všechny vektory \vec{m} z M platí rovnost $\langle \vec{x} | \vec{m} \rangle = 0$.

Speciální případ výše uvedeného je:^a

Ať $(\vec{b}_1, \dots, \vec{b}_k)$ je báze lineárního podprostoru W lineárního prostoru L . Jestliže platí $\langle \vec{x} | \vec{b}_i \rangle = 0$ pro všechna $i = 1, \dots, k$, potom platí $\langle \vec{x} | \vec{w} \rangle = 0$ pro všechny vektory \vec{w} z W .

^aTento speciální případ několikrát (bez dalších komentářů) v dnešní přednášce použijeme.

Tvrzení (lineární nezávislost ortogonální množiny vektorů)

Ať M je jakákoli množina **nenulových** vektorů s vlastností $\langle \vec{x} | \vec{y} \rangle = 0$ pro jakékoli různé vektory \vec{x}, \vec{y} z M .^a Pak M je lineárně nezávislá množina.

^aTakové množině říkáme **ortogonální množina**.

Důkaz.

Ať $\{\vec{x}_1, \dots, \vec{x}_n\}$ je jakákoli konečná podmnožina M . Ať

$\sum_{i=1}^n a_i \cdot \vec{x}_i = \vec{o}$. Pro libovolné pevné $i_0 \in \{1, \dots, n\}$ platí:

$$0 = \langle \vec{x}_{i_0} | \vec{o} \rangle = \langle \vec{x}_{i_0} | \sum_{i=1}^n a_i \cdot \vec{x}_i \rangle = \sum_{i=1}^n a_i \cdot \langle \vec{x}_{i_0} | \vec{x}_i \rangle = a_{i_0} \cdot \langle \vec{x}_{i_0} | \vec{x}_{i_0} \rangle.$$

Protože $\vec{x}_{i_0} \neq \vec{o}$, platí $\langle \vec{x}_{i_0} | \vec{x}_{i_0} \rangle \neq 0$. Proto $a_{i_0} = 0$.



Několik sloganů

- ① Jestliže $\dim(L) = n$, potom každá ortogonální množina v L má nejvýše n prvků.

Slogan: v prostoru dimenze n může existovat maximálně n navzájem na sebe kolmých nenulových vektorů.

- ② Ortogonální množině v L , která tvoří bázi L , říkáme **ortogonální báze**.

Slogan:^a ortogonální báze je pravoúhlý souřadnicový systém.

- ③ Každou bázi $(\vec{b}_1, \dots, \vec{b}_n)$ lze **normalisovat**: v bázi $(\frac{\vec{b}_1}{\|\vec{b}_1\|}, \dots, \frac{\vec{b}_n}{\|\vec{b}_n\|})$ mají všechny vektory normu 1.

Slogan: normální báze má jednotkové úseky na jednotlivých souřadnicových osách.

^a**Pozor:** jde jen o slogan. Víme, že například leckterý skalární součin v rovině může jako ortogonální vidět vektory, které „ve skutečnosti“ nesvírají pravý úhel.

Definice (ortonormální báze, čili normální a ortogonální báze)

Bázi $(\vec{b}_1, \dots, \vec{b}_n)$ prostoru se skalárním součinem, která splňuje rovnost $\langle \vec{b}_i | \vec{b}_j \rangle = \delta_{ij}$,^a říkáme **ortonormální**.

^aKroneckerův symbol δ splňuje: $\delta_{ii} = 1$, $\delta_{ij} = 0$ pro $i \neq j$.

Poznámky

- ① Kanonická báze $(\mathbf{e}_1, \dots, \mathbf{e}_n)$ prostoru \mathbb{R}^n je ortonormální vzhledem ke standardnímu skalárnímu součinu.
- ② Pro jakoukoli bázi $(\mathbf{b}_1, \dots, \mathbf{b}_n)$ prostoru \mathbb{R}^n existuje jednoznačně určený skalární součin, ve kterém je tato báze ortonormální (viz minulou přednášku).

Stejnou větu lze dokázat pro obecné prostory nad \mathbb{R} konečné dimenze. To dokazovat **nebudeme**.

- ③ Ortonormální báze jsou důležité: umožňují „zpříjemnit“ řadu výpočtů. Viz dále.

Tvrzení (výpočet souřadnic v ortonormální bázi)

Ať $B = (\vec{b}_1, \dots, \vec{b}_n)$ je ortonormální báze prostoru se skalárním

součinem. Pak $\vec{x} = \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \vec{b}_i$, čili $\mathbf{coord}_B(\vec{x}) = \begin{pmatrix} \langle \vec{b}_1 | \vec{x} \rangle \\ \vdots \\ \langle \vec{b}_n | \vec{x} \rangle \end{pmatrix}$.

Důkaz.

Definujeme: $\vec{y} = \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \vec{b}_i$. Musíme ukázat: $\vec{y} = \vec{x}$.

Pro libovolné pevné $i_0 \in \{1, \dots, n\}$ platí:

$$\langle \vec{b}_{i_0} | \vec{y} \rangle = \langle \vec{b}_{i_0} | \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \vec{b}_i \rangle = \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \langle \vec{b}_{i_0} | \vec{b}_i \rangle = \langle \vec{b}_{i_0} | \vec{x} \rangle.$$

Takže $\langle \vec{b}_{i_0} | \vec{x} - \vec{y} \rangle = 0$, pro libovolné pevné $i_0 \in \{1, \dots, n\}$.

Kdyby $\vec{x} - \vec{y} \neq \vec{0}$, byla by $(n+1)$ -prvková množina nenulových vektorů $\{\vec{x} - \vec{y}, \vec{b}_1, \dots, \vec{b}_n\}$ lineárně nezávislá.

To není možné: proto je $\vec{y} = \vec{x}$.



Důsledek (skalární součin v ortonormální bázi)

Ať $B = (\vec{b}_1, \dots, \vec{b}_n)$ je ortonormální báze prostoru se skalárním součinem. Pak platí:^a $\langle \vec{x} | \vec{y} \rangle = \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \langle \vec{b}_i | \vec{y} \rangle$.

^aPodle předchozího to znamená: $\langle \vec{x} | \vec{y} \rangle = \mathbf{x}^T \cdot \mathbf{y}$, kde $\text{coord}_B(\vec{x}) = \mathbf{x}$ a $\text{coord}_B(\vec{y}) = \mathbf{y}$. **Slogan:** skalární součin v ortonormální bázi se počítá jako standardní skalární součin souřadnic.

Důkaz.

$$\begin{aligned} \langle \vec{x} | \vec{y} \rangle &= \left\langle \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \vec{b}_i \mid \sum_{j=1}^n \langle \vec{b}_j | \vec{y} \rangle \cdot \vec{b}_j \right\rangle = \\ &\sum_{i=1}^n \sum_{j=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \langle \vec{b}_j | \vec{y} \rangle \cdot \langle \vec{b}_i | \vec{b}_j \rangle = \sum_{i=1}^n \sum_{j=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \langle \vec{b}_j | \vec{y} \rangle \cdot \delta_{ij} = \\ &\sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \langle \vec{b}_i | \vec{y} \rangle. \end{aligned}$$



Poznámka pro ty, kteří chtějí vidět souvislosti (nepovinné)

Předchozí dvě tvrzení (výpočet souřadnic v ortonormální bázi a výpočet skalárního součinu v ortonormální bázi) jsou pouhou instancí toho, že pro ortonormální bázi $B = (\vec{b}_1, \dots, \vec{b}_n)$ prostoru L tvoří seznam

$$B^* = (\langle \vec{b}_1 | - \rangle, \dots, \langle \vec{b}_n | - \rangle)$$

bázi duálního prostoru L^* , která je **duální bází** k bázi B .

Více se lze dozvědět v kapitole 3.5 **skript**.

Zde se objevují výhody Diracovy (také: bra-ket) notace pro skalární součin. Ve fyzice se vektor \vec{x} často píše jako $|\vec{x}\rangle$ (čteme: **ket** \vec{x}). Příslušný kovektor se píše jako $\langle \vec{x}|$ (čteme: **bra** \vec{x}). Skalární součin $\langle \vec{x} | \vec{y} \rangle$ je pak aplikací kovektoru $\langle \vec{x}|$ na vektor $|\vec{y}\rangle$. Tudiž $\langle \vec{x} | \vec{y} \rangle$ je **bra-ket^a** \vec{x} a \vec{y} .

^aSamozřejmě: bra-ket je jazyková hříčka, správně by mělo být **bracket**.

Další důsledek (úhly vektoru se souřadnicovými osami)

Ať $B = (\vec{b}_1, \dots, \vec{b}_n)$ je ortonormální báze prostoru se skalárním součinem. Ať vektor \vec{x} je **nenulový**. Potom pro úhel φ_{i_0} , který vektor \vec{x} svírá se souřadnicovou osou \vec{b}_{i_0} , platí rovnost^a

$$\cos \varphi_{i_0} = \frac{\langle \vec{b}_{i_0} | \vec{x} \rangle}{\|\vec{x}\|}. \text{ Navíc platí } \sum_{i=1}^n \cos^2 \varphi_i = 1.$$


^a**Všimněme si:** tvrdíme, že $\langle \vec{b}_{i_0} | \vec{x} \rangle$, tj. i_0 -tá souřadnice vektoru \vec{x} vzhledem k bázi B , se počítá jako součin $\|\vec{x}\| \cdot \cos \varphi_{i_0}$. To je zobecnění známého faktu z elementární geometrie roviny (viz další stranu).

Důkaz.

Protože $\langle \vec{b}_{i_0} | \vec{x} \rangle = \underbrace{\|\vec{b}_{i_0}\|}_{=1} \cdot \|\vec{x}\| \cdot \cos \varphi_{i_0}$, platí $\cos \varphi_{i_0} = \frac{\langle \vec{b}_{i_0} | \vec{x} \rangle}{\|\vec{x}\|}$.

Dále: $\sum_{i=1}^n \cos^2 \varphi_i = \sum_{i=1}^n \frac{\langle \vec{b}_i | \vec{x} \rangle^2}{\|\vec{x}\|^2} = \frac{\sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle^2}{\|\vec{x}\|^2} = \frac{\langle \vec{x} | \vec{x} \rangle}{\|\vec{x}\|^2} = 1.$ ■

Předchozí tvrzení v rovině s ortonormální bází $(\mathbf{e}_1, \mathbf{e}_2)$



$$\cos \varphi_1 = \frac{\text{orientovaná délka přilehlé odvěsny}}{\text{délka přepony}} = \frac{\langle \mathbf{e}_1 | \mathbf{x} \rangle}{\|\mathbf{x}\|}$$

$$\cos \varphi_2 = \frac{\text{orientovaná délka přilehlé odvěsny}}{\text{délka přepony}} = \frac{\langle \mathbf{e}_2 | \mathbf{x} \rangle}{\|\mathbf{x}\|}$$

$$\varphi_1 + \varphi_2 = \frac{\pi}{2}, \text{ čili } \cos \varphi_2 = \cos \left(\frac{\pi}{2} - \varphi_1 \right) = \sin \varphi_1$$

$$\text{Tudíž } \cos^2 \varphi_1 + \cos^2 \varphi_2 = \cos^2 \varphi_1 + \sin^2 \varphi_1 = 1.$$

Ortogonální projekce na přímku a ortogonální rejekce přímkou

Ať $\vec{s} \neq \vec{0}$ je vektor v prostoru L se skalárním součinem $\langle - | - \rangle$.

Potom pro každý vektor \vec{x} platí:


① Vektor $\frac{\langle \vec{s} | \vec{x} \rangle}{\langle \vec{s} | \vec{s} \rangle} \cdot \vec{s}$ zjevně leží na přímce $\text{span}(\vec{s})$.

② Vektor $\vec{x} - \frac{\langle \vec{s} | \vec{x} \rangle}{\langle \vec{s} | \vec{s} \rangle} \cdot \vec{s}$ je kolmý na přímku \vec{s} , protože platí

$$\langle \vec{s} | \vec{x} - \frac{\langle \vec{s} | \vec{x} \rangle}{\langle \vec{s} | \vec{s} \rangle} \cdot \vec{s} \rangle = \langle \vec{s} | \vec{x} \rangle - \underbrace{\langle \vec{s} | \vec{x} \rangle \cdot \frac{\langle \vec{s} | \vec{s} \rangle}{\langle \vec{s} | \vec{s} \rangle}}_{=1} = 0$$

Dostáváme tedy **ortogonální rozklad^a** vektoru \vec{x} :

$$\underbrace{\vec{x} - \frac{\langle \vec{s} | \vec{x} \rangle}{\langle \vec{s} | \vec{s} \rangle} \cdot \vec{s}}_{\text{ortogonální rejekce přímkou } \text{span}(\vec{s})}$$




ortogonální projekce na přímku $\text{span}(\vec{s})$

^aSlovník: projekce=promítnutí, rejekce=odmítnutí.

Zobecnění: projekce na podprostor a rejekce podprostorem

Ať W je podprostor lineárního prostoru L se skalárním součinem, ať \vec{x} je libovolný vektor v L .


Vektoru $\text{proj}_W(\vec{x})$, který leží ve W a pro který je $\vec{x} - \text{proj}_W(\vec{x})$ kolmý na všechny vektory z W , říkáme **ortogonální projekce vektoru \vec{x} na podprostor W** .



Vektoru $\vec{x} - \text{proj}_W(\vec{x})$ budeme říkat **ortogonální rejekce vektoru \vec{x} podprostorem W** a budeme jej značit $\text{rej}_W(\vec{x})$.

Ortogonální rejekce je „nejkratší“ ze všech rejekcí

Pro jakýkoli vektor \vec{x} , který neleží ve W , a pro jakýkoli vektor \vec{w} , který ve W leží, vzniká pravoúhlý trojúhelník s odvěsnami $\text{proj}_W(\vec{x}) - \vec{w}$ a $\vec{x} - \text{proj}_W(\vec{x})$, a s přeponou $\vec{x} - \vec{w}$.



Díky Pythagorově větě tedy pro všechny vektory \vec{w} z W platí^a

$$\|\vec{x} - \text{proj}_W(\vec{x})\|^2 \leq \|\vec{x} - \text{proj}_W(\vec{x})\|^2 + \underbrace{\|\text{proj}_W(\vec{x}) - \vec{w}\|^2}_{\geq 0} = \|\vec{x} - \vec{w}\|^2$$

^aNa této nerovnosti je založena metoda nejmenších čtverců, viz téma 11A.

Věta (ortogonální projekce na podprostor s ortogonální bází)

Ať $M = \{\vec{u}_1, \dots, \vec{u}_k\}$ je konečná neprázdná **ortogonální** množina vektorů. Označme $W = \text{span}(M)$. Pro libovolný vektor \vec{x} je

$$\text{proj}_W(\vec{x}) = \sum_{i=1}^k \text{proj}_{\text{span}(\vec{u}_i)}(\vec{x}) = \sum_{i=1}^k \frac{\langle \vec{u}_i | \vec{x} \rangle}{\langle \vec{u}_i | \vec{u}_i \rangle} \cdot \vec{u}_i$$

ortogonální projekce vektoru \vec{x} na podprostor W .

Důkaz.

Evidentně: $\text{proj}_W(\vec{x})$ leží ve W .

Pro každé $i_0 = 1, \dots, k$ platí $\langle \vec{u}_{i_0} | \vec{x} - \text{proj}_W(\vec{x}) \rangle = 0$, protože:

$$\begin{aligned} \langle \vec{u}_{i_0} | \vec{x} - \text{proj}_W(\vec{x}) \rangle &= \langle \vec{u}_{i_0} | \vec{x} \rangle - \langle \vec{u}_{i_0} | \text{proj}_W(\vec{x}) \rangle = \\ &= \langle \vec{u}_{i_0} | \vec{x} \rangle - \langle \vec{u}_{i_0} | \sum_{i=1}^k \frac{\langle \vec{u}_i | \vec{x} \rangle}{\langle \vec{u}_i | \vec{u}_i \rangle} \cdot \vec{u}_i \rangle = \\ &= \langle \vec{u}_{i_0} | \vec{x} \rangle - \sum_{i=0}^k \frac{\langle \vec{u}_i | \vec{x} \rangle}{\langle \vec{u}_i | \vec{u}_i \rangle} \cdot \langle \vec{u}_{i_0} | \vec{u}_i \rangle = \langle \vec{u}_{i_0} | \vec{x} \rangle - \langle \vec{u}_{i_0} | \vec{x} \rangle = 0. \quad \blacksquare \end{aligned}$$

Ortogonalisační proces (Gram-Schmidt)

Každou bázi $B = (\vec{b}_1, \dots, \vec{b}_n)$ prostoru se skalárním součinem lze převést na bázi $C = (\vec{c}_1, \dots, \vec{c}_n)$ s následujícími vlastnostmi:

- ① C je **ortogonální**, tj $\langle \vec{c}_i | \vec{c}_j \rangle = 0$ pro $i \neq j$.
- ② Pro každé $k \in \{1, \dots, n\}$ platí
 $\text{span}\{\vec{b}_1, \dots, \vec{b}_k\} = \text{span}\{\vec{c}_1, \dots, \vec{c}_k\}$.

Důkaz.

Definujeme^a

$$\vec{c}_1 := \vec{b}_1, \quad \vec{c}_{k+1} := \underbrace{\text{rej}_{\text{span}\{\vec{c}_1, \dots, \vec{c}_k\}}(\vec{b}_{k+1})}_{\text{rejekce vektoru } \vec{b}_{k+1} \text{ podprostorem } \text{span}\{\vec{c}_1, \dots, \vec{c}_k\}}$$

Díky definici je splněno $\text{span}\{\vec{b}_1, \dots, \vec{b}_k\} = \text{span}\{\vec{c}_1, \dots, \vec{c}_k\}$, pro každé $k \in \{1, \dots, n\}$.

První podmínka je splněna z definice ortogonální rejekce. ■

^a**Slogan:** Gram-Schmidt je posloupnost postupných ortogonálních rejekcí.

Poznámka (ortonormalisační proces)

Pokud je $C = (\vec{c}_1, \dots, \vec{c}_n)$ ortogonální báze^a prostoru L , je seznam $(\frac{\vec{c}_1}{\|\vec{c}_1\|}, \dots, \frac{\vec{c}_n}{\|\vec{c}_n\|})$ **ortonormální** báze prostoru L (tj je ortogonální a norma každého prvku je 1):

$$\left\langle \frac{\vec{c}_i}{\|\vec{c}_i\|} \mid \frac{\vec{c}_j}{\|\vec{c}_j\|} \right\rangle = \frac{1}{\|\vec{c}_i\| \cdot \|\vec{c}_j\|} \cdot \langle \vec{c}_i \mid \vec{c}_j \rangle = \delta_{ij}$$

Každou konečnou bázi B v prostoru se skalárním součinem tedy lze ortonormalisovat:

- ① Nejprve provedeme Gram-Schmidtův ortogonalisační proces na bázi B . Dostaneme ortogonální bázi C .
- ② Ortogonální bázi C znormalisujeme výše uvedeným postupem.

^aEvidentně pro každé i platí $\|\vec{c}_i\| \neq 0$, protože C je báze.

Příklad (ortogonalisace vektorů — Gram-Schmidt)

Vektory $\mathbf{b}_1 = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$, $\mathbf{b}_2 = \begin{pmatrix} 0 \\ 1 \\ 1 \\ 1 \end{pmatrix}$ a $\mathbf{b}_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 1 \end{pmatrix}$ jsou lineárně

nezávislé v \mathbb{R}^4 . Příslušnou bázi $(\mathbf{b}_1, \mathbf{b}_2, \mathbf{b}_3)$ podprostoru W dimenze 3 označíme B .

Báze B není ortogonální vzhledem ke standardnímu skalárnímu součinu v \mathbb{R}^4 . Bázi B nyní ortogonalisujeme. Výsledné vektory v nové (ortogonální) bázi označíme $\mathbf{c}_1, \mathbf{c}_2, \mathbf{c}_3$. Budeme postupovat Gram-Schmidtovou metodou.

① První vektor: $\mathbf{c}_1 = \mathbf{b}_1 = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$.

Příklad (pokrač.)

② Druhý vektor: spočteme

$$\mathbf{b}_2 - \text{proj}_{\text{span}\{\mathbf{c}_1\}}(\mathbf{b}_2) = \begin{pmatrix} 0 \\ 1 \\ 1 \\ 1 \end{pmatrix} - \frac{3}{4} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} = \begin{pmatrix} -\frac{3}{4} \\ \frac{1}{4} \\ \frac{1}{4} \\ \frac{1}{4} \end{pmatrix}.$$

Užitečný trik: protože skalární násobek nemění ortogonalitu,

$$\text{položíme } \mathbf{c}_2 = 4 \cdot \begin{pmatrix} -\frac{3}{4} \\ \frac{1}{4} \\ \frac{1}{4} \\ \frac{1}{4} \end{pmatrix} = \begin{pmatrix} -3 \\ 1 \\ 1 \\ 1 \end{pmatrix}.$$

Tím se zbavíme pozdějších nepříjemných výpočtů se zlomky.

Příklad (pokrač.)

③ Třetí vektor: spočteme

$$\mathbf{b}_3 - \text{proj}_{\text{span}\{\mathbf{c}_1, \mathbf{c}_2\}}(\mathbf{b}_3) = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 1 \end{pmatrix} - \frac{2}{4} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} - \frac{2}{12} \cdot \begin{pmatrix} -3 \\ 1 \\ 1 \\ 1 \end{pmatrix} =$$

$$\begin{pmatrix} 0 \\ -\frac{2}{3} \\ \frac{1}{3} \\ \frac{1}{3} \end{pmatrix}$$

$$\text{Opět se zbavíme zlomků: } \mathbf{c}_3 = 3 \cdot \begin{pmatrix} 0 \\ -\frac{2}{3} \\ \frac{1}{3} \\ \frac{1}{3} \end{pmatrix} = \begin{pmatrix} 0 \\ -2 \\ 1 \\ 1 \end{pmatrix}.$$

Výpočet je u konce: seznam $(\mathbf{c}_1, \mathbf{c}_2, \mathbf{c}_3)$ je hledaná ortogonální báze.

Příklad (normalisace ortogonální báze)

Normalisace ortogonální báze $\mathbf{c}_1 = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$, $\mathbf{c}_2 = \begin{pmatrix} -3 \\ 1 \\ 1 \\ 1 \end{pmatrix}$,

$\mathbf{c}_3 = \begin{pmatrix} 0 \\ -2 \\ 1 \\ 1 \end{pmatrix}$ podprostoru W v prostoru \mathbb{R}^4 se standardním skalárním součinem je tvořena vektory

$$\frac{\mathbf{c}_1}{\|\mathbf{c}_1\|} = \frac{1}{2} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}, \quad \frac{\mathbf{c}_2}{\|\mathbf{c}_2\|} = \frac{1}{\sqrt{12}} \cdot \begin{pmatrix} -3 \\ 1 \\ 1 \\ 1 \end{pmatrix}, \quad \frac{\mathbf{c}_3}{\|\mathbf{c}_3\|} = \frac{1}{\sqrt{6}} \cdot \begin{pmatrix} 0 \\ -2 \\ 1 \\ 1 \end{pmatrix}$$

Matice ortogonální projekce a metoda nejmenších čtverců

Odpřednesenou látku naleznete v kapitole 12.4 a Dodatku C skript *Abstraktní a konkrétní lineární algebra*.

Minulá přednáška

- ① Ortogonalizační proces (Gram-Schmidt).
- ② Ortogonální projekce a ortogonální rejekce.
- ③ Ortogonální projekce na podprostor s ortogonální bází.

Dnešní přednáška

V této přednášce se zaměříme **pouze** na lineární prostory \mathbb{R}^n nad \mathbb{R} .


- ① Výpočet matice ortogonální projekce na podprostor (s libovolnou bází) v \mathbb{R}^n .
- ② Charakterisace matic ortogonálních projekcí v \mathbb{R}^n .
- ③ Aplikace projekcí na řešení soustav lineárních rovnic (metoda nejmenších čtverců).^a

^aBudeme se věnovat pouze nejjednodušší formě metody nejmenších čtverců v \mathbb{R}^n se standardním skalárním součinem. Vše je podrobně popsáno v tomto výtahu z přednášky.

Připomenutí: projekce na podprostor a rejekce podprostorem

Ať W je podprostor lineárního prostoru L se skalárním součinem, ať \vec{x} je libovolný vektor v L .

Vektoru $\text{proj}_W(\vec{x})$, který leží ve W a pro který je $\vec{x} - \text{proj}_W(\vec{x})$ kolmý na všechny vektory z W , říkáme **ortogonální projekce vektoru \vec{x} na podprostor W** .




Vektoru $\vec{x} - \text{proj}_W(\vec{x})$ říkáme **ortogonální rejekce vektoru \vec{x} podprostorem W** a značíme jej $\text{rej}_W(\vec{x})$.^a

^aSlovník: **projekce**=promítnutí, **rejekce**=odmítnutí.

Ortogonalní rejekce je „nejkratší“ ze všech rejekcí

Pro jakýkoli vektor \vec{x} , který neleží ve W , a pro jakýkoli vektor \vec{w} , který ve W leží, vzniká pravoúhlý trojúhelník s odvěsnami $\text{proj}_W(\vec{x}) - \vec{w}$ a $\vec{x} - \text{proj}_W(\vec{x})$, a s přeponou $\vec{x} - \vec{w}$.



Díky Pythagorově větě tedy pro všechny vektory \vec{w} z W platí^a

$$\|\vec{x} - \text{proj}_W(\vec{x})\|^2 \leq \|\vec{x} - \text{proj}_W(\vec{x})\|^2 + \underbrace{\|\text{proj}_W(\vec{x}) - \vec{w}\|^2}_{\geq 0} = \|\vec{x} - \vec{w}\|^2$$

^aNa této nerovnosti je založena metoda nejmenších čtverců, viz cvičení a druhá část této přednášky.



Projekce na podprostor, u kterého neznáme ortogonální bází

- ① V obecném případě je vždy možno nejprve obecnou bází ortogonalisovat (Gram-Schmidt) a poté použít vzorec pro projekci na podprostor s ortogonální bází.
- ② V případě \mathbb{R}^n lze využít znalosti metrického tensoru, viz níže.

Tvrzení

Ať W je podprostor prostoru \mathbb{R}^n se skalárním součinem zadaným metrickým tensorem \mathbf{G} . Ať vektory $\mathbf{a}_1, \dots, \mathbf{a}_k$ tvoří jakoukoli bází podprostoru W . Označme jako $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_k)$ příslušnou matici. Potom^a

$$\text{proj}_W(\mathbf{x}) = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{G} \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{G} \cdot \mathbf{x}$$

^aTento divoký vzorec má krotkou podobu pro standardní skalární součin: platí $\text{proj}_W(\mathbf{x}) = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{x}$, protože $\mathbf{G} = \mathbf{E}_n$.

Důkaz.

Přednáška.

Příklad (výpočet matice ortogonální projekce)

V prostoru \mathbb{R}^3 se **standardním^a** skalárním součinem nalezněte matici projekce na rovinu $W = \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}\right)$. Víme: pro $\mathbf{A} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \\ 1 & 0 \end{pmatrix}$, je $\mathbf{P}_W = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T$ matice ortogonální projekce na W .

$$\mathbf{P}_W = \begin{pmatrix} 1 & 1 \\ 1 & 1 \\ 1 & 0 \end{pmatrix} \cdot \begin{pmatrix} 3 & 2 \\ 2 & 2 \end{pmatrix}^{-1} \cdot \begin{pmatrix} 1 & 1 & 1 \\ 1 & 1 & 0 \end{pmatrix} = \frac{1}{2} \cdot \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 2 \end{pmatrix}.$$

Například projekci vektoru $\begin{pmatrix} -20 \\ 4 \\ 6 \end{pmatrix}$ na W spočítáme součinem

$$\frac{1}{2} \cdot \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 2 \end{pmatrix} \cdot \begin{pmatrix} -20 \\ 4 \\ 6 \end{pmatrix} = \begin{pmatrix} -8 \\ -8 \\ 6 \end{pmatrix} = 6 \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} + (-14) \cdot \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}.$$

^a Metrický tensor tedy je $\mathbf{G} = \mathbf{E}_3$.

Příklad (výpočet matice ortogonální projekce)

V prostoru \mathbb{R}^2 se skalárním součinem s metrickým tensorem^a

$\mathbf{G} = \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}$ spočtěte matici projekce na přímku $W = \text{span}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right)$.

Víme: pro $\mathbf{A} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$, je $\mathbf{P}_W = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{G} \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{G}$ matice ortogonální projekce.

Tudíž je

$$\mathbf{P}_W = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \cdot ((1 \quad 1) \cdot \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix})^{-1} (1 \quad 1) \cdot \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix} = \frac{1}{5} \cdot \begin{pmatrix} 2 & 3 \\ 2 & 3 \end{pmatrix}.$$

Například projekci vektoru $\begin{pmatrix} 4 \\ 6 \end{pmatrix}$ na W spočítáme součinem

$$\frac{1}{5} \cdot \begin{pmatrix} 2 & 3 \\ 2 & 3 \end{pmatrix} \cdot \begin{pmatrix} 4 \\ 6 \end{pmatrix} = \frac{1}{5} \cdot \begin{pmatrix} 26 \\ 26 \end{pmatrix} = \frac{26}{5} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix}.$$

^a Jde o nestandardní skalární součin: to znamená, že jde o ortogonální projekci vzhledem ke skalárnímu součinu $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{y}$.

Věta (charakterisace matic ortogonálních projekcí)

Ať \mathbb{R}^n je vybaven skalárním součinem $\langle - | - \rangle$ s metrickým tensorem \mathbf{G} . Pro matici $\mathbf{P} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ je ekvivalentní:

- ① \mathbf{P} je matice ortogonální projekce na podprostor $\text{im}(P)$ dimenze k .
- ② $\text{rank}(\mathbf{P}) = k$ a platí $\mathbf{P}^2 = \mathbf{P}$ a $\langle \mathbf{P} \cdot \mathbf{x} | \mathbf{y} \rangle = \langle \mathbf{x} | \mathbf{P} \cdot \mathbf{y} \rangle$.

Důkaz.

Přednáška.



Poznámka

Pro standardní skalární součin v \mathbb{R}^n (tj. pro $\mathbf{G} = \mathbf{E}_n$) lze druhou podmínu přeformulovat takto:

- ② $\text{rank}(\mathbf{P}) = k$ a platí $\mathbf{P}^2 = \mathbf{P}$ a $\mathbf{P}^T = \mathbf{P}$.

Úvaha o bodech na přímce

Ať $\{x_1, x_2, \dots, x_n\}$ je alespoň dvouprvková množina reálných čísel.

Body

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}, \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}, \dots, \begin{pmatrix} x_n \\ y_n \end{pmatrix}$$

v \mathbb{R}^2 leží na přímce tvaru $y = ax + b$ právě tehdy, když soustava rovnic

$$\left(\begin{array}{cc|c} x_1 & 1 & y_1 \\ x_2 & 1 & y_2 \\ \vdots & \vdots & \vdots \\ x_n & 1 & y_n \end{array} \right)$$

nad \mathbb{R} má řešení $\begin{pmatrix} a \\ b \end{pmatrix}$.

Důležité pozorování: protože $\{x_1, x_2, \dots, x_n\}$ je alespoň dvouprvková množina reálných čísel, má matice výše uvedené soustavy hodnost 2.

Úvaha o bodech na přímce (pokrač.)

Ať $\{x_1, x_2, \dots, x_n\}$ je alespoň dvouprvková množina reálných čísel.
Co dělat, když body

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}, \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}, \dots, \begin{pmatrix} x_n \\ y_n \end{pmatrix}$$

v \mathbb{R}^2 na přímce tvaru $y = ax + b$ neleží?

Lze nalézt přímku tvaru $y = ax + b$, která je (pro zadané body)
nejlepší možnou volbou?^a

Důležité pozorování: soustava rovnic

$$\left(\begin{array}{cc|c} x_1 & 1 & y_1 \\ x_2 & 1 & y_2 \\ \vdots & \vdots & \vdots \\ x_n & 1 & y_n \end{array} \right)$$

řešení mít nemůže, hodnost matice soustavy je ale stále 2.

^aZatím nevíme, co myslíme slovem nejlepší. Pravděpodobně chceme minimalisovat chybu, které se dopustíme.



Příklad

Tři body $\begin{pmatrix} 3 \\ 6 \end{pmatrix}, \begin{pmatrix} 4 \\ 9 \end{pmatrix}, \begin{pmatrix} 5 \\ 10 \end{pmatrix}$ v \mathbb{R}^2 na přímce neleží.^a

Označme soustavu $\left(\begin{array}{cc|c} 3 & 1 & 6 \\ 4 & 1 & 9 \\ 5 & 1 & 10 \end{array} \right)$ jako $(\mathbf{A} | \mathbf{b})$.

Víme:

- ① $(\mathbf{A} | \mathbf{b})$ nemá řešení, tj. vektor \mathbf{b} neleží v prostoru $W = \text{im}(\mathbf{A})$.
- ② Sloupce matice \mathbf{A} tvoří bázi prostoru W .
- ③ Soustava $(\mathbf{A}^T \cdot \mathbf{A} | \mathbf{A}^T \cdot \mathbf{b})$ má právě jedno řešení, protože $\mathbf{A}^T \cdot \mathbf{A}$ je pozitivně definitní (tudíž regulární).

Označme toto řešení $\hat{\mathbf{x}}$. Platí tedy $\hat{\mathbf{x}} = (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{b}$.

- ④ Matice \mathbf{P}_W ortogonální projekce na W je tvaru $\mathbf{P}_W = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T$. Tudíž $\mathbf{A} \cdot \hat{\mathbf{x}} = \mathbf{P}_W \cdot \mathbf{b}$.
- ⑤ Takže: $\|\text{rej}_W(\mathbf{b})\|^2 = \|\mathbf{b} - \mathbf{A} \cdot \hat{\mathbf{x}}\|^2 \leq \|\mathbf{b} - \mathbf{A} \cdot \mathbf{x}\|^2$ pro vš \mathbf{x} . To je ono: **minimalisovali jsme čtverec chyby $\|\mathbf{b} - \mathbf{A} \cdot \mathbf{x}\|$** .


^aBody na první pohled „téměř“ leží na přímce $y = 2x$.



Příklad (pokrač.)

Vyřešíme tedy soustavu $(\mathbf{A} \mid \mathbf{b}) = \left(\begin{array}{cc|c} 3 & 1 & 6 \\ 4 & 1 & 9 \\ 5 & 1 & 10 \end{array} \right)$ metodou nejmenších čtverců.^a

- ① Soustava $(\mathbf{A}^T \cdot \mathbf{A} \mid \mathbf{A}^T \cdot \mathbf{b})$ má tvar $\left(\begin{array}{cc|c} 50 & 12 & 104 \\ 12 & 3 & 25 \end{array} \right)$ a má jediné řešení $\begin{pmatrix} 2 \\ 1/3 \end{pmatrix}$.
- ② Hledaná přímka má tvar $y = 2x + \frac{1}{3}$.



^a Řešením získáme „nejlepší možnou“ přímku, kterou lze proložit zadanými body. Říká se jí **regresní přímka**.



Příklad (pokrač.)

Vektor $\begin{pmatrix} 2 \\ 1/3 \end{pmatrix}$ není řešením soustavy $\left(\begin{array}{cc|c} 3 & 1 & 6 \\ 4 & 1 & 9 \\ 5 & 1 & 10 \end{array} \right)$.

$$\text{Platí } \begin{pmatrix} 3 & 1 \\ 4 & 1 \\ 5 & 1 \end{pmatrix} \cdot \begin{pmatrix} 2 \\ 1/3 \end{pmatrix} = \begin{pmatrix} 19/3 \\ 25/3 \\ 31/3 \end{pmatrix}.$$

Čtverec chyby, které jsme se dopustili, je

$$\left\| \begin{pmatrix} 6 \\ 9 \\ 10 \end{pmatrix} - \begin{pmatrix} 19/3 \\ 25/3 \\ 31/3 \end{pmatrix} \right\|^2 = \left\| \begin{pmatrix} -1/3 \\ 2/3 \\ -1/3 \end{pmatrix} \right\|^2 = 2/3$$

a jde o nejmenší čtverec chyby.

Řešení soustavy rovnic metodou nejmenších čtverců

Ať $(\mathbf{A} | \mathbf{b})$ je soustava nad \mathbb{R} , kde matice \mathbf{A} má lineárně nezávislé sloupce. Řešení soustavy $(\mathbf{A} | \mathbf{b})$ metodou nejmenších čtverců probíhá následovně:


- ① Protože \mathbf{A} má lineárně nezávislé sloupce, je matice $\mathbf{A}^T \cdot \mathbf{A}$ pozitivně definitní, tedy regulární.
- ② Soustava $(\mathbf{A}^T \cdot \mathbf{A} | \mathbf{A}^T \cdot \mathbf{b})$ má tedy jediné řešení, označme toto řešení $\hat{\mathbf{x}} = (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{b}$.

Tomuto jedinému řešení $\hat{\mathbf{x}}$ se říká **řešení soustavy $(\mathbf{A} | \mathbf{b})$ metodou nejmenších čtverců**.

Má to následující důvod:

- ① Platí rovnost $\mathbf{A} \cdot \hat{\mathbf{x}} = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{b}$. To znamená, že $\mathbf{A} \cdot \hat{\mathbf{x}}$ je **ortogonální projekce** vektoru \mathbf{b} na $\text{im}(\mathbf{A})$.
- ② Protože **ortogonální rejekce** $\mathbf{b} - \mathbf{A} \cdot \hat{\mathbf{x}}$ vektoru \mathbf{b} podprostorem $\text{im}(\mathbf{A})$ je „nejkratší“ rejekcí vektoru \mathbf{b} podprostorem $\text{im}(\mathbf{A})$, platí $\|\mathbf{b} - \mathbf{A} \cdot \hat{\mathbf{x}}\|^2 \leq \|\mathbf{b} - \mathbf{A} \cdot \mathbf{x}\|^2$, pro každé \mathbf{x} .

Ilustrace řešení soustavy $(A | b)$ metodou nejmenších čtverců




Pokud má matice soustavy $(\mathbf{A} | \mathbf{b})$ lineárně nezávislé sloupce, potom platí:

- ① Soustava $(\mathbf{A} | \mathbf{b})$ má právě jedno řešení $\hat{\mathbf{x}}$ metodou nejmenších čtverců.
- ② Pro každé \mathbf{x} platí nerovnost $\|\mathbf{b} - \mathbf{A} \cdot \hat{\mathbf{x}}\|^2 \leq \|\mathbf{b} - \mathbf{A} \cdot \mathbf{x}\|^2$.

Další pohled na řešení soustavy $(\mathbf{A} \mid \mathbf{b})$ metodou nejmenších čtverců

Pro matici $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_k)$ s lineárně nezávislými sloupci tvoří seznam $(\mathbf{a}_1, \dots, \mathbf{a}_k)$ uspořádanou bázi podprostoru $W = \text{im}(\mathbf{A})$.

Řešení $\hat{\mathbf{x}}$ soustavy $(\mathbf{A} \mid \mathbf{b})$ metodou nejmenších čtverců je **vektor souřadnic** vektoru $\mathbf{P}_W \cdot \mathbf{b}$ vzhledem k uspořádané bázi $(\mathbf{a}_1, \dots, \mathbf{a}_k)$.



Příklad (řešení soustavy rovnic metodou nejmenších čtverců)

Soustava $(\mathbf{A} \mid \mathbf{b}) = \left(\begin{array}{cc|c} 1 & 1 & 2 \\ 1 & 1 & 3 \\ 1 & 0 & 2 \end{array} \right)$ nemá řešení (Frobeniova věta).

V našem případě: $\mathbf{A} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \\ 1 & 0 \end{pmatrix}$, $\mathbf{b} = \begin{pmatrix} 2 \\ 3 \\ 2 \end{pmatrix}$, $\mathbf{A}^T \cdot \mathbf{A} = \begin{pmatrix} 3 & 2 \\ 2 & 2 \end{pmatrix}$,
 $\mathbf{A}^T \cdot \mathbf{b} = \begin{pmatrix} 7 \\ 5 \end{pmatrix}$.

Soustava $\left(\begin{array}{cc|c} 3 & 2 & 7 \\ 2 & 2 & 5 \end{array} \right)$ má jediné řešení $\hat{\mathbf{x}} = \begin{pmatrix} 2 \\ 0.5 \end{pmatrix}$.

Protože $\mathbf{A} \cdot \hat{\mathbf{x}} = \begin{pmatrix} 2.5 \\ 2.5 \\ 2 \end{pmatrix}$, vektor $\hat{\mathbf{x}}$ není řešením soustavy $(\mathbf{A} \mid \mathbf{b})$.

Ovšem jakýkoli jiný vektor \mathbf{x} by „dopadl ještě hůře“. Pro všechny vektory \mathbf{x} z \mathbb{R}^2 totiž platí nerovnost

$$0.5 = \|\mathbf{b} - \mathbf{A} \cdot \hat{\mathbf{x}}\|^2 \leq \|\mathbf{b} - \mathbf{A} \cdot \mathbf{x}\|^2$$



Příklad (proložení paraboly)

Ať $\{x_1, x_2, \dots, x_n\}$ je alespoň tříprvková množina reálných čísel.

Body

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}, \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}, \dots, \begin{pmatrix} x_n \\ y_n \end{pmatrix}$$

v \mathbb{R}^2 leží na parabole tvaru $y = ax^2 + bx + c$ právě tehdy, když soustava rovnic

$$\left(\begin{array}{ccc|c} x_1^2 & x_1 & 1 & y_1 \\ x_2^2 & x_2 & 1 & y_2 \\ \vdots & \vdots & \vdots & \vdots \\ x_n^2 & x_n & 1 & y_n \end{array} \right)$$

má řešení $\begin{pmatrix} a \\ b \\ c \end{pmatrix}$.

Příklad (proložení paraboly, pokrač.)

Důležité pozorování: protože $\{x_1, x_2, \dots, x_n\}$ je alespoň tříprvková množina reálných čísel, má matice soustavy

$$\left(\begin{array}{ccc|c} x_1^2 & x_1 & 1 & y_1 \\ x_2^2 & x_2 & 1 & y_2 \\ \vdots & \vdots & \vdots & \vdots \\ x_n^2 & x_n & 1 & y_n \end{array} \right)$$

hodnost 3.

Opravdu: at' x_i, x_j, x_k jsou tři navzájem různé hodnoty z množiny $\{x_1, x_2, \dots, x_n\}$.

Potom

$$\begin{vmatrix} x_i^2 & x_i & 1 \\ x_j^2 & x_j & 1 \\ x_k^2 & x_k & 1 \end{vmatrix} = (x_i - x_k) \cdot (x_i - x_k) \cdot (x_j - x_k) \neq 0$$

Příklad (proložení paraboly, pokrač.)

Ať $\{x_1, x_2, \dots, x_n\}$ je alespoň tříprvková množina reálných čísel.

Body

$$\begin{pmatrix} x_1 \\ y_1 \end{pmatrix}, \begin{pmatrix} x_2 \\ y_2 \end{pmatrix}, \dots, \begin{pmatrix} x_n \\ y_n \end{pmatrix}$$

v \mathbb{R}^2 lze proložit parabolu $y = ax^2 + bx + c$, kde $\begin{pmatrix} a \\ b \\ c \end{pmatrix}$ je řešením soustavy rovnic

$$\left(\begin{array}{ccc|c} x_1^2 & x_1 & 1 & y_1 \\ x_2^2 & x_2 & 1 & y_2 \\ \vdots & \vdots & \vdots & \vdots \\ x_n^2 & x_n & 1 & y_n \end{array} \right)$$

metodou nejmenších čtverců.

Závěrečná poznámka

Řešení soustav metodou nejmenších čtverců má řadu aplikací. Je základem **regresních metod** v matematické statistice, viz například knihu

- Douglas C. Montgomery a George C. Runger, *Applied statistics and probability for engineers*, 3.ed, John Wiley & Sons, New York, 2003.

Historická poznámka

Autorem metody nejmenších čtverců je německý matematik Karl Friedrich Gauss (1777–1855). V roce 1801 Gauss tuto metodu použil pro predikci dráhy planetky **Ceres**, která 40 dní po objevení zmizela evropským astronomům za Sluncem. Gauss předpověděl polohu, kde se planetka za 10 měsíců opět objeví.

SVD rozklad a pseudoinverse

Odpřednesenou látku naleznete v kapitole 14 skript
Abstraktní a konkrétní lineární algebra.

Cíle této přednášky

- 1 Každá **symetrická** matice $\mathbf{A} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ má **pouze reálné vlastní hodnoty a je diagonalisovatelná.**^a

Navíc: vlastní vektory symetrické matice tvoří „hezkou bázi“ prostoru \mathbb{R}^n .

- 2 Jako důsledek předchozího ukážeme, že **každou** matici $\mathbf{M} : \mathbb{R}^s \rightarrow \mathbb{R}^r$ lze napsat jako^b

$$\mathbf{M} = \underbrace{\mathbf{U} \mathbf{S} \mathbf{V}^T}_{\text{SVD rozklad } \mathbf{M}}$$

kde \mathbf{S} je „diagonální“ a $\mathbf{U}^{-1} = \mathbf{U}^T$ a $\mathbf{V}^{-1} = \mathbf{V}^T$.

- 3 Ukážeme aplikace SVD rozkladu.

^aTento výsledek **nebudeme dokazovat**, vyžaduje hlubší znalosti z reálné analýzy.

^bVýpočty z této přednášky jsou časově velmi náročné. U ústní zkoušky může být vyžadováno základní pochopení teorie (str 7 a 8 tohoto tématu), nikoli výpočty.



Věta o hlavních osách (pro standardní skalární součin)


Pro každou **symetrickou** reálnou matici $\mathbf{A} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ existuje **ortonormální** báze \mathbb{R}^n složená z vlastních vektorů matice \mathbf{A} . Navíc matice \mathbf{A} má pouze **reálné** vlastní hodnoty.

Důkaz.

Bez důkazu (je těžký). Viz Důsledek 14.1.5 **skript**.



Vysvětlení



\mathbf{A} zobrazuje jednotkovou kouli na (případně degenerovaný) elipsoid.

Důsledek — SVD rozklad matice pro stand. skalární součin

Libovolnou matici $\mathbf{M} : \mathbb{R}^s \rightarrow \mathbb{R}^r$ lze zapsat ve tvaru \mathbf{USV}^T , kde

- ① $\mathbf{V} : \mathbb{R}^s \rightarrow \mathbb{R}^s$ a $\mathbf{U} : \mathbb{R}^r \rightarrow \mathbb{R}^r$ jsou **ortogonální**, tj. $\mathbf{V}^T = \mathbf{V}^{-1}$ a $\mathbf{U}^T = \mathbf{U}^{-1}$.
- ② $\mathbf{S} : \mathbb{R}^s \rightarrow \mathbb{R}^r$ má na hlavní diagonále kladná čísla $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_h$ (tzv. **singulární hodnoty** matice \mathbf{M}), kde $h = \text{rank}(\mathbf{M})$. Všude jinde má matice \mathbf{S} nuly.

Myšlenka důkazu.

- ① Matice $\mathbf{A} = \mathbf{M}^T \mathbf{M} : \mathbb{R}^s \rightarrow \mathbb{R}^s$ je symetrická. Její vlastní hodnoty jsou **nezáporné**. Seřaďte je: $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_s \geq 0$. Označte příslušnou **ortonormální** bázi jako $(\mathbf{v}_1, \dots, \mathbf{v}_s)$.
- ② Definujte $\sigma_1 = \sqrt{\lambda_1}, \dots, \sigma_s = \sqrt{\lambda_s}$. Vyberte **nenulová** σ_i : $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_h > 0$ a definujte $\mathbf{u}_i = \mathbf{M}\mathbf{v}_i/\sigma_i$ pro $i = 1, \dots, h$ a doplňte na **ortonormální** bázi $(\mathbf{u}_1, \dots, \mathbf{u}_r)$.

Příklad (SVD rozklad)

Nalezneme SVD rozklad pro $\mathbf{M} = \begin{pmatrix} 14 & 4 & 11 \\ -2 & 8 & 7 \end{pmatrix}$.

$$\textcircled{1} \quad \mathbf{M}^T \mathbf{M} = \begin{pmatrix} 14 & -2 \\ 4 & 8 \\ 11 & 7 \end{pmatrix} \cdot \begin{pmatrix} 14 & 4 & 11 \\ -2 & 8 & 7 \end{pmatrix} = \begin{pmatrix} 200 & 40 & 140 \\ 40 & 80 & 100 \\ 140 & 100 & 170 \end{pmatrix}$$

\textcircled{2} Vlastní hodnoty $\mathbf{M}^T \mathbf{M}$ jsou $\lambda_1 = 360$, $\lambda_2 = 90$, $\lambda_3 = 0$.

Příslušná **ortonormální báze** vlastních vektorů je

$$\left(\begin{pmatrix} 2/3 \\ 1/3 \\ 2/3 \end{pmatrix}, \begin{pmatrix} -2/3 \\ 2/3 \\ 1/3 \end{pmatrix}, \begin{pmatrix} 1/3 \\ -2/3 \\ 2/3 \end{pmatrix} \right). \text{ Tudíž } \mathbf{V} = \begin{pmatrix} 2/3 & -2/3 & -1/3 \\ 1/3 & 2/3 & -2/3 \\ 2/3 & 1/3 & 2/3 \end{pmatrix}.$$

\textcircled{3} Singulární hodnoty \mathbf{M} jsou $\sigma_1 = \sqrt{\lambda_1} = 6\sqrt{10}$,

$$\sigma_2 = \sqrt{\lambda_2} = 3\sqrt{10}.$$

Příklad (SVD rozklad, pokrač.)

④ $\mathbf{u}_1 = \mathbf{M}\mathbf{v}_1/\sigma_1$ a $\mathbf{u}_2 = \mathbf{M}\mathbf{v}_2/\sigma_2$:

$$\frac{1}{6\sqrt{10}} \cdot \begin{pmatrix} 14 & 4 & 11 \\ -2 & 8 & 7 \end{pmatrix} \cdot \begin{pmatrix} 2/3 \\ 1/3 \\ 2/3 \end{pmatrix} = \begin{pmatrix} 3/\sqrt{10} \\ 1/\sqrt{10} \end{pmatrix}$$

$$\frac{1}{3\sqrt{10}} \cdot \begin{pmatrix} 14 & 4 & 11 \\ -2 & 8 & 7 \end{pmatrix} \cdot \begin{pmatrix} -2/3 \\ 2/3 \\ 1/3 \end{pmatrix} = \begin{pmatrix} -1/\sqrt{10} \\ 3/\sqrt{10} \end{pmatrix}$$

⑤ Plný SVD rozklad \mathbf{M} je:

$$\begin{pmatrix} 14 & 4 & 11 \\ -2 & 8 & 7 \end{pmatrix} = \begin{pmatrix} 3/\sqrt{10} & -1/\sqrt{10} \\ 1/\sqrt{10} & 3/\sqrt{10} \end{pmatrix} \cdot \begin{pmatrix} 6\sqrt{10} & 0 & 0 \\ 0 & 3\sqrt{10} & 0 \end{pmatrix} \cdot \begin{pmatrix} 2/3 & -2/3 & 1/3 \\ 1/3 & 2/3 & -2/3 \\ 2/3 & 1/3 & 2/3 \end{pmatrix}^T$$

Geometrie SVD rozkladu $\mathbf{M} = \mathbf{U}\mathbf{S}\mathbf{V}^T$

Matice $\mathbf{V} = (\mathbf{v}_1, \dots, \mathbf{v}_s)$ a $\mathbf{U} = (\mathbf{u}_1, \dots, \mathbf{u}_r)$ jsou tvořeny vektory nových ortonormálních bází V a U prostorů \mathbb{R}^s a \mathbb{R}^r , ve kterých se $\mathbf{M} : \mathbb{R}^s \rightarrow \mathbb{R}^r$ jeví jako změna měřítka $\mathbf{S} : \mathbb{R}^s \rightarrow \mathbb{R}^r$.

$$\mathbb{R}^s \xrightarrow{\mathbf{T}_{K_s \mapsto V}} \mathbb{R}^s \xrightarrow{\mathbf{S}} \mathbb{R}^r \xrightarrow{\mathbf{T}_{U \mapsto K_r}} \mathbb{R}^r$$

Protože $\mathbf{T}_{K_s \mapsto V} = (\mathbf{T}_{V \mapsto K_s})^{-1} = \mathbf{V}^{-1} = \mathbf{V}^T$ a $\mathbf{T}_{U \mapsto K_r} = \mathbf{U}$, znázorňuje vrchní obrázek opravdu


$$\mathbb{R}^s \xrightarrow{\mathbf{V}^T} \mathbb{R}^s \xrightarrow{\mathbf{S}} \mathbb{R}^r \xrightarrow{\mathbf{U}} \mathbb{R}^r$$

A to je přesně SVD rozklad matice \mathbf{M} .


Geometrie SVD rozkladu $\mathbf{M} = \mathbf{U}\mathbf{S}\mathbf{V}^T$ (pokrač.)

Obraz jednotkové koule v \mathbb{R}^s při zobrazení $\mathbf{x} \mapsto \mathbf{Mx}$:

- 1 Rotace (případně nevlastní) $\mathbf{V}^T : \mathbb{R}^s \rightarrow \mathbb{R}^s$:



- 2 Změna měřítka (případně i s degenerací) $\mathbf{S} : \mathbb{R}^s \rightarrow \mathbb{R}^r$:



- 3 Rotace (případně nevlastní) $\mathbf{U} : \mathbb{R}^r \rightarrow \mathbb{R}^r$:



Redukce SVD rozkladu a approximace SVD rozkladem

Plný SVD rozklad \mathbf{USV}^T matice \mathbf{M} hodnosti h lze psát jako

$$\mathbf{M} = \sum_{j=1}^h \sigma_j \cdot \mathbf{u}_j \cdot \mathbf{v}_j^T$$

kde \mathbf{u}_j jsou sloupce \mathbf{U} a \mathbf{v}_j jsou sloupce \mathbf{V} .

Částečné součty

$$\mathbf{M}_k = \sum_{j=1}^k \sigma_j \cdot \mathbf{u}_j \cdot \mathbf{v}_j^T$$

pro $k \leq h$ mají hodnost k a platí

$$\|\mathbf{M} - \mathbf{M}_k\|_F = \min \{\|\mathbf{M} - \mathbf{X}\|_F \mid \mathbf{X} : \mathbb{R}^s \rightarrow \mathbb{R}^r, \text{ rank}(\mathbf{X}) \leq k\}$$

kde

$$\|\mathbf{X}\|_F = \sqrt{\sum_{j=1}^s \mathbf{x}_j^T \cdot \mathbf{x}_j} = \sqrt{\sum_{j=1}^s \sum_{i=1}^r x_{ij}^2}$$

je **Frobeniova norma** matice $\mathbf{X} = (\mathbf{x}_1, \dots, \mathbf{x}_s) = (x_{ij})$.

Příklad

Pro $\mathbf{M} = \begin{pmatrix} 14 & 4 & 11 \\ -2 & 8 & 7 \end{pmatrix}$ lze psát její SVD rozklad

$$\mathbf{M} = \begin{pmatrix} 3/\sqrt{10} & -1/\sqrt{10} \\ 1/\sqrt{10} & 3/\sqrt{10} \end{pmatrix} \cdot \begin{pmatrix} 6\sqrt{10} & 0 & 0 \\ 0 & 3\sqrt{10} & 0 \end{pmatrix} \cdot \begin{pmatrix} 2/3 & -2/3 & 1/3 \\ 1/3 & 2/3 & -2/3 \\ 2/3 & 1/3 & 2/3 \end{pmatrix}^T$$

jako

$$\mathbf{M} = 6\sqrt{10} \cdot \begin{pmatrix} 3/\sqrt{10} \\ 1/\sqrt{10} \end{pmatrix} \cdot (2/3 \quad 1/3 \quad 2/3) + 3\sqrt{10} \cdot \begin{pmatrix} -1/\sqrt{10} \\ 3/\sqrt{10} \end{pmatrix} \cdot (-2/3 \quad 2/3 \quad 1/3)$$

a

$$\mathbf{M}_1 = 6\sqrt{10} \cdot \begin{pmatrix} 3/\sqrt{10} \\ 1/\sqrt{10} \end{pmatrix} \cdot (2/3 \quad 1/3 \quad 2/3) = \begin{pmatrix} 18/15 & 9/15 & 18/15 \\ 6/15 & 3/15 & 6/15 \end{pmatrix}$$

Platí

$$\frac{\|\mathbf{M} - \mathbf{M}_1\|_F}{\|\mathbf{M}\|_F} = \frac{3\sqrt{10}}{\sqrt{450}} \approx 0.477$$

Chyba při nahrazení částečným součtem SVD rozkladu

Platí rovnost:

$$\|\mathbf{M} - \mathbf{M}_k\|_F = \sqrt{\sigma_{k+1}^2 + \dots + \sigma_h^2}$$

Speciálně:

$$\|\mathbf{M}\|_F = \sqrt{\sigma_1^2 + \dots + \sigma_h^2}$$


Podílu

$$\frac{\|\mathbf{M} - \mathbf{M}_k\|_F}{\|\mathbf{M}\|_F} = \sqrt{\frac{\sigma_{k+1}^2 + \dots + \sigma_h^2}{\sigma_1^2 + \dots + \sigma_h^2}}$$

říkáme **relativní změna matice \mathbf{M}** (při nahrazení \mathbf{M} k -tým částečným součtem jejího SVD rozkladu).

SVD rozklad matic lze použít ke komprezii dat

Obrázek



lze zadat maticí

$$\mathbf{M} = \begin{pmatrix} 0 & 0 & 0.5 & 0.5 & 0.5 & 0.5 & 0 & 0 \\ 0 & 0.5 & 0 & 0 & 0 & 0 & 0.5 & 0 \\ 0.5 & 0 & 0 & 0 & 0 & 0 & 0 & 0.5 \\ 0.5 & 0 & 1 & 0 & 0 & 1 & 0 & 0.5 \\ 0.5 & 0 & 0 & 0 & 0 & 0 & 0 & 0.5 \\ 0.5 & 0 & 0 & 0 & 0 & 0 & 0 & 0.5 \\ 0.5 & 0 & 1 & 0 & 0 & 1 & 0 & 0.5 \\ 0.5 & 0 & 0 & 1 & 1 & 0 & 0 & 0.5 \\ 0 & 0.5 & 0 & 0 & 0 & 0 & 0.5 & 0 \\ 0 & 0 & 0.5 & 0.5 & 0.5 & 0.5 & 0 & 0 \end{pmatrix}$$

kde 0 = bílá, 0.5 = šedá, 1 = černá.

SVD rozklad matice lze použít ke komprezii dat (pokrač.)





SVD rozklad matice \mathbf{M} má tvar \mathbf{USV}^T , kde matice \mathbf{S} je:

$$\mathbf{S} = \begin{pmatrix} 2.57 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1.61 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1.13 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1.00 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \end{pmatrix}$$

Ke komprezii stačí použít první čtyři **singulární hodnoty** (prvky na hlavní diagonále \mathbf{S}) matice \mathbf{M} , protože pátá až osmá singulární hodnota je rovna nule.

SVD rozklad matice lze použít ke komprezii dat (pokrač.)

Obrázky pro první čtyři aproximace matice \mathbf{M} vypadají takto:



Relativní změny matice \mathbf{M} jsou následující:

$$\frac{\|\mathbf{M} - \mathbf{M}_1\|_F}{\|\mathbf{M}\|_F} \approx \sqrt{\frac{1.61^2 + 1.13^2 + 1.00^2}{2.57^2 + 1.61^2 + 1.13^2 + 1.00^2}} \approx 0.65$$


$$\frac{\|\mathbf{M} - \mathbf{M}_2\|_F}{\|\mathbf{M}\|_F} \approx \sqrt{\frac{1.13^2 + 1.00^2}{2.57^2 + 1.61^2 + 1.13^2 + 1.00^2}} \approx 0.45$$

$$\frac{\|\mathbf{M} - \mathbf{M}_3\|_F}{\|\mathbf{M}\|_F} \approx \sqrt{\frac{1.00^2}{2.57^2 + 1.61^2 + 1.13^2 + 1.00^2}} \approx 0.30$$

$$\frac{\|\mathbf{M} - \mathbf{M}_4\|_F}{\|\mathbf{M}\|_F} \approx \sqrt{\frac{0}{2.57^2 + 1.61^2 + 1.13^2 + 1.00^2}} = 0.00$$

Co dělat, když matice $A : \mathbb{R}^s \rightarrow \mathbb{R}^r$ nemá inversi?

$$\mathbb{R}^s \xleftarrow{A^+} \mathbb{R}^r$$



Tvrzení

Ať $\mathbf{A} : \mathbb{R}^s \rightarrow \mathbb{R}^r$ je matici. Potom existuje nanejvýš jedna matici $\mathbf{A}^+ : \mathbb{R}^r \rightarrow \mathbb{R}^s$, která splňuje následující čtyři podmínky^a

$$\mathbf{AA}^+\mathbf{A} = \mathbf{A}, \quad \mathbf{A}^+\mathbf{AA}^+ = \mathbf{A}^+, \quad (\mathbf{A}^+\mathbf{A})^T = \mathbf{A}^+\mathbf{A}, \quad (\mathbf{AA}^+)^T = \mathbf{AA}^+$$

^aMatici \mathbf{A}^+ , která tyto čtyři podmínky splňuje, říkáme **pseudoinverse** matice \mathbf{A} .

Důkaz.

Bez důkazu (není těžký, ale není zajímavý). Pro zájemce, viz Tvrzení 14.4.1 **skript**. ■

Příklady pseudoinversí

- ① At' $\mathbf{A} : \mathbb{R}^n \rightarrow \mathbb{R}^n$ je regulární matici. Potom $\mathbf{A}^+ = \mathbf{A}^{-1}$.

Platí totiž rovnosti:

- ① $\mathbf{A}\mathbf{A}^{-1}\mathbf{A} = \mathbf{A}$
- ② $\mathbf{A}^{-1}\mathbf{A}\mathbf{A}^{-1} = \mathbf{A}^{-1}$
- ③ $(\mathbf{A}^{-1}\mathbf{A})^T = \mathbf{E}_n = \mathbf{A}^{-1}\mathbf{A}$
- ④ $(\mathbf{A}\mathbf{A}^{-1})^T = \mathbf{E}_n = \mathbf{A}\mathbf{A}^{-1}$

- ② At' $\mathbf{O}_{s,r} : \mathbb{R}^s \rightarrow \mathbb{R}^r$. Potom $(\mathbf{O}_{s,r})^+ = \mathbf{O}_{r,s}$.

Platí totiž rovnosti:

- ① $\mathbf{O}_{s,r}\mathbf{O}_{r,s}\mathbf{O}_{s,r} = \mathbf{O}_{s,r}$
- ② $\mathbf{O}_{r,s}\mathbf{O}_{s,r}\mathbf{O}_{r,s} = \mathbf{O}_{r,s}$
- ③ $(\mathbf{O}_{r,s}\mathbf{O}_{s,r})^T = \mathbf{O}_{s,s} = \mathbf{O}_{r,s}\mathbf{O}_{s,r}$
- ④ $(\mathbf{O}_{s,r}\mathbf{O}_{r,s})^T = \mathbf{O}_{r,r} = \mathbf{O}_{s,r}\mathbf{O}_{r,s}$

Příklady pseudoinversí (pokrač.)

③ Até $\mathbf{A} : \mathbb{R}^k \rightarrow \mathbb{R}^n$ má hodnost k . Potom $\mathbf{A}^+ = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$.

Platí totiž rovnosti:

$$\textcircled{1} \quad \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A} = \mathbf{A}$$

$$\textcircled{2} \quad (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A} (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$$

$$\textcircled{3} \quad ((\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A})^T = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{A}$$

$$\textcircled{4} \quad (\mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T)^T = \mathbf{A}(\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T$$

Pozorování: v tomto případě platí

$$\mathbf{A}\mathbf{A}^+ \mathbf{b} = \text{proj}_{\text{im}(\mathbf{A})}(\mathbf{b})$$

To nás nepřekvapuje: tak jsme pseudoinversi vymysleli!

Věta (nalezení pseudoinverse pomocí SVD rozkladu)

At' $\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T$ je plný SVD rozklad matice $\mathbf{A} : \mathbb{R}^s \rightarrow \mathbb{R}^r$. Potom platí:

- 1 Matice

$$\mathbf{S}^+ = \left(\frac{1}{\sigma_1} \mathbf{e}_1, \dots, \frac{1}{\sigma_h} \mathbf{e}_h, \underbrace{\mathbf{0}, \dots, \mathbf{0}}_{(r-h)\text{-krát}} \right)$$

je pseudoinverse matice \mathbf{S} .

- 2 Matice

$$\mathbf{A}^+ = \mathbf{V}\mathbf{S}^+\mathbf{U}^T$$

je pseudoinverse matice \mathbf{A} .

Důkaz.

Bez důkazu. Viz Důsledek 14.4.5 skript.



Příklad (výpočet pseudoinverse pomocí SVD rozkladu)

Nalezneme \mathbf{M}^+ pro matici

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

Plný SVD rozklad matice \mathbf{M} je roven

$$\begin{pmatrix} 3/\sqrt{10} & -1/\sqrt{10} \\ 1/\sqrt{10} & 3/\sqrt{10} \end{pmatrix} \cdot \begin{pmatrix} 6\sqrt{10} & 0 & 0 \\ 0 & 3\sqrt{10} & 0 \end{pmatrix} \cdot \begin{pmatrix} 2/3 & -2/3 & 1/3 \\ 1/3 & 2/3 & -2/3 \\ 2/3 & 1/3 & 2/3 \end{pmatrix}^T$$

a proto

$$\begin{aligned} \mathbf{M}^+ &= \begin{pmatrix} 2/3 & -2/3 & 1/3 \\ 1/3 & 2/3 & -2/3 \\ 2/3 & 1/3 & 2/3 \end{pmatrix} \cdot \begin{pmatrix} 1/(6\sqrt{10}) & 0 \\ 0 & 1/(3\sqrt{10}) \\ 0 & 0 \end{pmatrix} \cdot \begin{pmatrix} 3/\sqrt{10} & -1/\sqrt{10} \\ 1/\sqrt{10} & 3/\sqrt{10} \end{pmatrix}^T \\ &= \frac{1}{180} \cdot \begin{pmatrix} 10 & -10 \\ 7 & 13 \\ 4 & 8 \end{pmatrix} \end{aligned}$$

Další aplikace SVD rozkladu — nepovinné

- ① Pseudoinverse matic souvisí s metodou nejmenších čtverců, viz Dodatek C *skript*.

Metoda nejmenších čtverců slouží k „proložení optimální křivky“ naměřenými daty s nejmenší kvadratickou chybou.

- ② Latentní sémantické indexování databází (také: LSI), viz Dodatek G *skript*.

Pro databáze lze vytvořit vektorový model a SVD rozklad lze použít k vyhledání skrytých sémantických konceptů v databázi.

- ③ Analýza hlavní komponenty (také: PCA), viz Dodatek G *skript*.

Při analýze multidimensionálních dat lze objevit „hlavní komponenty dat“, tj. lze nalézt podstatné naměřené veličiny.

- ④ A mnoho dalších aplikací...

Vzájemná poloha affinních podprostorů

Odpřednesenou látku naleznete v kapitolách 7.1, 7.2 a 7.3 skript *Abstraktní a konkrétní lineární algebra*.

Co již víme? (přednášky z teorie soustav lineárních rovnic)

- Pro $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$ a \mathbf{b} z \mathbb{F}^r je obecné řešení soustavy $\mathbf{Ax} = \mathbf{b}$ tvaru $\mathbf{p} + \ker(\mathbf{A})$.

Množina $\mathbf{p} + \ker(\mathbf{A})$ je *d-dimensionální affinní podprostor* (kde $d = \text{def}(\mathbf{A})$) v prostoru \mathbb{F}^s . Tato plocha *prochází* bodem \mathbf{p} .

- Jakoukoli podmnožinu prostoru \mathbb{F}^s tvaru $\mathbf{p} + W$, kde W je *lineární podprostor* prostoru \mathbb{F}^s a \mathbf{p} je bod \mathbb{F}^s , lze považovat za množinu řešení nějaké vhodné soustavy rovnic $\mathbf{Ax} = \mathbf{b}$.

Dnešní přednáška

- Zaměříme^a se na *affinní podprostory* prostoru \mathbb{R}^n nad \mathbb{R} .
- Budeme studovat *vzájemnou polohu* affiních podprostorů prostoru \mathbb{R}^n .
- Porovnáme dva popisy affiních podprostorů: *parametrický zápis* a *rovnicový zápis*.


^aCelá dnešní přednáška projde v prostorech typu \mathbb{F}^n nad \mathbb{F} , kde \mathbb{F} je těleso.

Definice

Množině $\mathbf{p} + W = \{\mathbf{p} + \mathbf{x} \mid \mathbf{x} \in W\}$, kde W je lineární podprostor prostoru \mathbb{R}^n a \mathbf{p} je bod z \mathbb{R}^n , říkáme **affinní podprostor** prostoru \mathbb{R}^n .

Dimenze^a affiního prostoru $\mathbf{p} + W$ je číslo $\dim(W)$. Lineárnímu prostoru W říkáme **směr** affiního podprostoru $\mathbf{p} + W$.

^aAffinním podprostorům v \mathbb{R}^n dimenze 0 budeme říkat **body**, affinním podprostorům v \mathbb{R}^n dimenze 1 budeme říkat **přímky**, affinním podprostorům v \mathbb{R}^n dimenze 2 budeme říkat **roviny**.



Příklady affiních podprostorů prostoru \mathbb{R}^4

Množiny

$$\begin{pmatrix} 1 \\ -2 \\ 6 \\ 7 \end{pmatrix}, \quad \begin{pmatrix} 10 \\ 9 \\ 3 \\ -1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 4 \\ 5 \\ 0 \end{pmatrix}\right), \quad \begin{pmatrix} 1 \\ 7 \\ -3 \\ 9 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 2 \\ 3 \\ -2 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 2 \\ -2 \\ 0 \end{pmatrix}\right)$$

$$\begin{pmatrix} 1 \\ 6 \\ 0 \\ 1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}\right)$$

jsou affiní podprostory prostoru \mathbb{R}^4 . Jejich dimenze jsou postupně 0, 1, 2 a 3. A jejich směry jsou:

$$\left\{\begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}\right\}, \quad \text{span}\left(\begin{pmatrix} 1 \\ 4 \\ 5 \\ 0 \end{pmatrix}\right), \quad \text{span}\left(\begin{pmatrix} 2 \\ 3 \\ -2 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 2 \\ -2 \\ 0 \end{pmatrix}\right), \quad \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}\right)$$

Příklad (vzájemná poloha přímek v \mathbb{R}^3 , intuitivní výpočet)

- ① Přímky $\begin{pmatrix} 0 \\ -1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right)$ a $\begin{pmatrix} 0 \\ 1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right)$ jsou rovnoběžné.

Obě přímky mají **stejný směr**, je jím vektor $\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}$.

- ② Přímky $\begin{pmatrix} 0 \\ -1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right)$ a $\begin{pmatrix} 0 \\ -1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}\right)$ jsou různoběžné.

To zjistíme následujícím způsobem: přímky **nejsou** rovnoběžné:

rovnost $\text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right) = \text{span}\left(\begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}\right)$ **neplatí**. Navíc mají obě

přímky **společný bod**, je jím vektor $\begin{pmatrix} 0 \\ -1 \\ 2 \end{pmatrix}$.

Příklad (vzájemná poloha přímek v \mathbb{R}^3 , pokrač.)

- ③ Přímky $\begin{pmatrix} 3 \\ 3 \\ 1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right)$ a $\begin{pmatrix} 3 \\ 3 \\ 0 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}\right)$ jsou mimoběžné.

To zjistíme následujícím způsobem: přímky nejsou rovnoběžné:

rovnost $\text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right) = \text{span}\left(\begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}\right)$ neplatí. Navíc obě přímky nemají společný bod: neexistují reálná čísla s, t tak, že

$$\begin{pmatrix} 3 \\ 3 \\ 1 \end{pmatrix} + s \cdot \begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix} = \begin{pmatrix} 3 \\ 3 \\ 0 \end{pmatrix} + t \cdot \begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}$$

O tom se lze snadno přesvědčit řešením příslušné soustavy rovnic.

Jak postupovat v \mathbb{R}^n ?

Potřebujeme dobré definice a dobrá kritéria vzájemné polohy!

Definice (vzájemná poloha affiních podprostorů)


Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affinní podprostory prostoru \mathbb{R}^n . Řekneme, že

- ① π a π' jsou **rovnoběžné**, pokud platí $W \subseteq W'$ nebo $W' \subseteq W$.
- ② π a π' jsou **různoběžné**, pokud nejsou rovnoběžné a mají alespoň jeden společný bod.
- ③ π a π' jsou **mimoběžné**, pokud nejsou rovnoběžné a nemají žádný společný bod.

Dimensi lineárního podprostoru $W \cap W'$ budeme říkat **stupeň rovnoběžnosti** affiních podprostorů π a π' .

Poznámka

Pro dva affinní podprostory π a π' prostoru \mathbb{R}^n platí:



Tvrzení (charakterisace rovnoběžných disjunktních affiních podprostorů)

Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affinní podprostupy prostoru \mathbb{R}^n . Ať $W' \subseteq W$. Potom jsou následující podmínky ekvivalentní:

- ① Afinní podprostupy π a π' jsou **disjunktní**.
- ② Pro jakýkoli vektor \mathbf{x} v π a jakýkoli vektor \mathbf{x}' v π' vektor $\mathbf{x} - \mathbf{x}'$ neleží ve W .
- ③ Vektor $\mathbf{p} - \mathbf{p}'$ neleží ve W .
- ④ Existuje vektor \mathbf{x} v π a existuje vektor \mathbf{x}' v π' tak, že vektor $\mathbf{x} - \mathbf{x}'$ neleží ve W .

Důkaz.

Přednáška.



Tvrzení (charakterisace různoběžných affiních podprostorů)

Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affinní podprostory prostoru \mathbb{R}^n , které nejsou rovnoběžné. Potom jsou následující podmínky ekvivalentní:

- ① Afinní podprostory π a π' jsou různoběžné.
- ② Pro jakýkoli vektor \mathbf{x} v π a jakýkoli vektor \mathbf{x}' v π' vektor $\mathbf{x} - \mathbf{x}'$ leží ve $W \vee W'$.
- ③ Vektor $\mathbf{p} - \mathbf{p}'$ leží ve $W \vee W'$.
- ④ Existuje vektor \mathbf{x} v π a existuje vektor \mathbf{x}' v π' tak, že vektor $\mathbf{x} - \mathbf{x}'$ leží ve $W \vee W'$.

Důkaz.

Přednáška.



Tvrzení (charakterisace mimoběžných affiních podprostorů)

Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affinní podprostupy prostoru \mathbb{R}^n , které nejsou rovnoběžné. Potom jsou následující podmínky ekvivalentní:

- ① Afinní podprostupy π a π' jsou mimoběžné.
- ② Vektor $\mathbf{p} - \mathbf{p}'$ neleží ve $W \vee W'$.

Důkaz.

Přednáška.



Příklad (dva různé zápisy jedné přímky)


Dva zápisy téže přímky v \mathbb{R}^2

$$\underbrace{\begin{pmatrix} 1 \\ 2 \end{pmatrix} + \begin{pmatrix} 3 \\ 1 \end{pmatrix} \cdot t, \quad t \in \mathbb{R}}_{\text{parametrický zápis}}$$

$$\underbrace{-x + 3y = 5}_{\text{rovnicový zápis}}$$

Oba typy zápisu jsme již potkali při úvahách o řešitelnosti soustav lineárních rovnic a zapisovali je jako

$$\begin{pmatrix} 1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 3 \\ 1 \end{pmatrix}\right) \quad (-1 \ 3 \mid 5)$$



Získáváme informace o směrovém vektoru a normálovém vektoru.

Tvrzení (Existence parametrického a rovnicového zápisu)

Ať $\pi = \mathbf{p} + W$ je d -dimensionální affinní podprostor prostoru \mathbb{R}^n . Potom existují dvě matice $\mathbf{S} : \mathbb{R}^d \rightarrow \mathbb{R}^n$ a $\mathbf{N}^T : \mathbb{R}^n \rightarrow \mathbb{R}^{n-d}$ tak, že platí:

- ① Platí $\text{im}(\mathbf{S}) = W = \ker(\mathbf{N}^T)$, $\text{rank}(\mathbf{N})^T = n - d$ a $\text{rank}(\mathbf{S}) = d$.
- ② Vektor \mathbf{x} leží v π právě tehdy, když platí rovnost $\mathbf{x} = \mathbf{p} + \mathbf{S} \cdot \mathbf{t}$ pro nějaké \mathbf{t} . Tomuto zápisu říkáme **parametrický zápis** affiního podprostoru π .
- ③ Vektor \mathbf{x} leží v π právě tehdy, když platí rovnost $\mathbf{N}^T \cdot (\mathbf{x} - \mathbf{p}) = \mathbf{0}$. Tomuto zápisu říkáme **rovnicový zápis** affiního podprostoru π .


Důkaz.

Přednáška.



Poznámky

1



$$\text{im}(\mathbf{S}) = W = \ker(\mathbf{N}^T)$$

Pozor: musí platit rovnosti $\text{rank}(\mathbf{S}) = d$ a $\text{rank}(\mathbf{N}^T) = n - d$.

2 Proč je rovnicový zápis ve tvaru $\mathbf{N}^T \cdot (\mathbf{x} - \mathbf{p}) = \mathbf{o}$?

- 1 Bod \mathbf{p} vyhovuje rovnici $\mathbf{N}^T \cdot (\mathbf{x} - \mathbf{p}) = \mathbf{o}$. Ihned vidíme, že affinní podprostor prochází bodem \mathbf{p} .
- 2 Pokud označíme jako $\mathbf{N} = (\mathbf{n}_1, \dots, \mathbf{n}_{n-d})$, pak rovnost $\mathbf{N}^T \cdot (\mathbf{x} - \mathbf{p}) = \mathbf{o}$ je ekvivalentní rovnostem $\langle \mathbf{n}_1 | \mathbf{x} - \mathbf{p} \rangle = 0, \langle \mathbf{n}_2 | \mathbf{x} - \mathbf{p} \rangle = 0, \dots, \langle \mathbf{n}_{n-d} | \mathbf{x} - \mathbf{p} \rangle = 0$

To znamená, že sloupce matice \mathbf{N} si lze přestavit jako **seznam lineárně nezávislých „normál“** příslušného affiního podprostoru.



Tvrzení (charakterisace rovnoběžných disjunktních affiních podprostorů)

Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affiní podprostupy prostoru \mathbb{R}^n , zadány parametricky jako $\mathbf{x} = \mathbf{p} + \mathbf{S} \cdot \mathbf{t}$ a $\mathbf{x}' = \mathbf{p}' + \mathbf{S}' \cdot \mathbf{t}'$.

① Následující podmínky jsou ekvivalentní:

- ① Platí $W' \subseteq W$.
- ② Platí $\text{span}(\mathbf{s}'_1, \dots, \mathbf{s}'_{d'}) \subseteq \text{span}(\mathbf{s}_1, \dots, \mathbf{s}_d)$, kde $\mathbf{S}' = (\mathbf{s}'_1, \dots, \mathbf{s}'_{d'})$ a $\mathbf{S} = (\mathbf{s}_1, \dots, \mathbf{s}_d)$.
- ③ Simultánní soustava $(\mathbf{S} | \mathbf{S}')$ má řešení.

② Ať $W' \subseteq W$. Následující podmínky ekvivalentní:

- ① Afinní podprostupy π a π' jsou **disjunktní**.
- ② Pro jakýkoli vektor $\mathbf{x} \in \pi$ a jakýkoli vektor $\mathbf{x}' \in \pi'$ soustava $(\mathbf{S} | \mathbf{x} - \mathbf{x}')$ nemá řešení.
- ③ **Soustava $(\mathbf{S} | \mathbf{p} - \mathbf{p}')$ nemá řešení**.
- ④ Existuje vektor $\mathbf{x} \in \pi$ a existuje vektor $\mathbf{x}' \in \pi'$ tak, že soustava $(\mathbf{S} | \mathbf{x} - \mathbf{x}')$ nemá řešení.

Důkaz.

Přednáška.



Tvrzení (charakterisace různoběžných affiních podprostorů)

Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affinní podprostory prostoru \mathbb{R}^n , které nejsou rovnoběžné. Ať π a π' zadány parametricky jako $\mathbf{x} = \mathbf{p} + \mathbf{S} \cdot \mathbf{t}$ a $\mathbf{x}' = \mathbf{p}' + \mathbf{S}' \cdot \mathbf{t}'$. Potom jsou následující podmínky ekvivalentní:

- ① Afinní podprostоры π a π' jsou různoběžné.
- ② Pro jakýkoli vektor \mathbf{x} v π a jakýkoli vektor \mathbf{x}' v π' soustava $(\mathbf{S}', \mathbf{S} | \mathbf{x} - \mathbf{x}')$ má řešení.
- ③ Soustava $(\mathbf{S}', \mathbf{S} | \mathbf{p} - \mathbf{p}')$ má řešení.
- ④ Existuje vektor \mathbf{x} v π a existuje vektor \mathbf{x}' v π' tak, že soustava $(\mathbf{S}', \mathbf{S} | \mathbf{x} - \mathbf{x}')$ má řešení.

Důkaz.

Přednáška.



Tvrzení (charakterisace mimoběžných affiních podprostorů)

Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affinní podprostupy prostoru \mathbb{R}^n , které nejsou rovnoběžné. Ať π a π' zadány parametricky jako $\mathbf{x} = \mathbf{p} + \mathbf{S} \cdot \mathbf{t}$ a $\mathbf{x}' = \mathbf{p}' + \mathbf{S}' \cdot \mathbf{t}'$. Potom jsou následující podmínky ekvivalentní:

- ① Afinní podprostupy π a π' jsou mimoběžné.
- ② Soustava $(\mathbf{S}', \mathbf{S} | \mathbf{p} - \mathbf{p}')$ nemá řešení.


Důkaz.

Přednáška.



Důležitá poznámka

Při rozhodování o vzájemné poloze affiních podprostorů π a π' je velmi rozumné postupovat podle obrázku



Povšiměte si, že tak tomu bude ve všech následujících příkladech.

Příklad 1 (vzájemná poloha dvou rovin v \mathbb{R}^5)

V \mathbb{R}^5 rozhodněte o vzájemné poloze affiních podprostorů

$$\pi = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}\right) \quad \pi' = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1 \\ 0 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 0 \end{pmatrix}\right)$$

- ① Rovnoběžnost: ani jedna ze simultánních soustav

$$\left(\begin{array}{cc|cc} 1 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{array} \right)$$

$$\left(\begin{array}{cc|cc} 0 & 0 & 1 & 0 \\ 1 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{array} \right)$$

nemá řešení. Takže π a π' nejsou rovnoběžné.

Příklad 1 (vzájemná poloha dvou rovin v \mathbb{R}^5 , pokrač.)

- ① Různoběžnost: stačí zjistit, zda soustava^a

$$\left(\begin{array}{cccc|c} 1 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & -1 \\ 0 & 0 & 0 & 0 & 1 \end{array} \right)$$

má řešení. Protože řešení neexistuje, jsou π a π' mimoběžné.

Závěr: roviny π a π' jsou mimoběžné.

^aPravá strana je $\mathbf{p} - \mathbf{p}'$.

Příklad 2 (vzájemná poloha přímek v \mathbb{R}^3)

Rozhodněte o vzájemné poloze přímek $\pi = \begin{pmatrix} 0 \\ -1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right)$ a

$$\pi' = \begin{pmatrix} 0 \\ 1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right).$$

- ① Rovnoběžnost: obě simultánní soustavy

$$\left(\begin{array}{c|c} 0 & 0 \\ 2 & 2 \\ 1 & 1 \end{array} \right)$$

$$\left(\begin{array}{c|c} 0 & 0 \\ 2 & 2 \\ 1 & 1 \end{array} \right)$$

mají zjevně řešení; π a π' jsou **rovnoběžné**.

- ② Jsou π a π' disjunktní? Stačí zjistit, zda soustava rovnic

$$\left(\begin{array}{c|c} 0 & 0 \\ 2 & -2 \\ 1 & 0 \end{array} \right)$$

má řešení. Pravá strana je $\mathbf{p} - \mathbf{p}'$.



Příklad 2 (vzájemná poloha přímek v \mathbb{R}^3 , pokrač.)

Soustava

$$\left(\begin{array}{c|c} 0 & 0 \\ 2 & -2 \\ 1 & 0 \end{array} \right)$$

evidentně řešení nemá; přímky π a π' jsou **disjunktní**.

Závěr: přímky π a π' jsou **rovnoběžné a disjunktní**.

Příklad 3 (vzájemná poloha přímek v \mathbb{R}^3)

Rozhodněte o vzájemné poloze přímek $\pi = \begin{pmatrix} 0 \\ -1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right)$ a

$\pi' = \begin{pmatrix} 0 \\ -1 \\ 2 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}\right)$.

Příklad 3 (vzájemná poloha přímek v \mathbb{R}^3 , pokrač.)

- ① Rovnoběžnost: žádná ze simultánních soustav

$$\left(\begin{array}{c|c} 0 & 3 \\ 2 & 2 \\ 1 & 1 \end{array} \right)$$

$$\left(\begin{array}{c|c} 3 & 0 \\ 2 & 2 \\ 1 & 1 \end{array} \right)$$

řešení nemá; přímky π a π' nejsou rovnoběžné.

- ② Různoběžnost: protože soustava^a

$$\left(\begin{array}{cc|c} 0 & 3 & 0 \\ 2 & 2 & 0 \\ 1 & 1 & 0 \end{array} \right)$$

má řešení, jsou přímky π a π' různoběžné.

Závěr: přímky π a π' jsou různoběžné.

^aPravá strana je $\mathbf{p} - \mathbf{p}'$.

Příklad 4 (vzájemná poloha přímek v \mathbb{R}^3)

Rozhodněte o vzájemné poloze přímek $\pi = \begin{pmatrix} 3 \\ 3 \\ 1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 2 \\ 1 \end{pmatrix}\right)$ a $\pi' = \begin{pmatrix} 3 \\ 3 \\ 0 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 3 \\ 2 \\ 1 \end{pmatrix}\right)$.

- ① Rovnoběžnost: žádná ze simultánních soustav

$$\left(\begin{array}{c|c} 0 & 3 \\ 2 & 2 \\ 1 & 1 \end{array} \right) \quad \left(\begin{array}{c|c} 3 & 0 \\ 2 & 2 \\ 1 & 1 \end{array} \right)$$

řešení nemá; přímky π a π' nejsou rovnoběžné.

Příklad 4 (vzájemná poloha přímek v \mathbb{R}^3 , pokrač.)

② Různoběžnost: soustava^a

$$\left(\begin{array}{cc|c} 0 & 3 & 0 \\ 2 & 2 & 0 \\ 1 & 1 & 1 \end{array} \right)$$

nemá řešení, přímky π a π' jsou mimoběžné.

Závěr: přímky π a π' jsou mimoběžné.

^aPravá strana je $\mathbf{p} - \mathbf{p}'$.

Příklad 5 (vzájemná poloha dvou rovin v \mathbb{R}^4)

V \mathbb{R}^4 rozhodněte o vzájemné poloze affiních podprostorů

$$\pi = \begin{pmatrix} 1 \\ -2 \\ 3 \\ 1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 0 \\ 3 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ 2 \\ 3 \\ 1 \end{pmatrix}\right) \quad \pi' = \begin{pmatrix} 2 \\ -1 \\ 3 \\ 1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 0 \\ 0 \\ 3 \\ 1 \end{pmatrix}, \begin{pmatrix} 0 \\ 2 \\ 3 \\ 1 \end{pmatrix}\right)$$

- ① Rovnoběžnost: řešíme simultánní soustavy

$$\left(\begin{array}{cc|cc} 1 & 1 & 0 & 0 \\ 0 & 2 & 0 & 2 \\ 3 & 3 & 3 & 3 \\ 1 & 1 & 1 & 1 \end{array} \right)$$

$$\left(\begin{array}{cc|cc} 0 & 0 & 1 & 1 \\ 0 & 2 & 0 & 2 \\ 3 & 3 & 3 & 3 \\ 1 & 1 & 1 & 1 \end{array} \right)$$

Roviny budou rovnoběžné, pokud alespoň jedna simultánní soustava má řešení.

Příklad 5 (vzájemná poloha dvou rovin v \mathbb{R}^4 , pokrač.)

① Pomocí Gaussovy eliminace dostáváme

$$\left(\begin{array}{cc|cc} 1 & 1 & 0 & 0 \\ 0 & 2 & 0 & 2 \\ 3 & 3 & 3 & 3 \\ 1 & 1 & 1 & 1 \end{array} \right) \sim \left(\begin{array}{cc|cc} 1 & 1 & 0 & 0 \\ 0 & 2 & 0 & 2 \\ 0 & 0 & 3 & 3 \\ 0 & 0 & 1 & 1 \end{array} \right) \begin{matrix} R_1 \\ R_2 \\ R_3 - 3R_1 \\ R_4 - R_1 \end{matrix}$$

Simultánní soustava

$$\left(\begin{array}{cc|cc} 1 & 1 & 0 & 0 \\ 0 & 2 & 0 & 2 \\ 3 & 3 & 3 & 3 \\ 1 & 1 & 1 & 1 \end{array} \right)$$

tedy řešení nemá.

Příklad 5 (vzájemná poloha dvou rovin v \mathbb{R}^4 , pokrač.)

① Pomocí Gaussovy eliminace dostáváme

$$\left(\begin{array}{cc|cc} 0 & 0 & 1 & 1 \\ 0 & 2 & 0 & 2 \\ 3 & 3 & 3 & 3 \\ 1 & 1 & 1 & 1 \end{array} \right) \sim \left(\begin{array}{cc|cc} 1 & 1 & 1 & 1 \\ 0 & 2 & 0 & 2 \\ 0 & 0 & 1 & 1 \\ 3 & 3 & 3 & 3 \end{array} \right) \begin{matrix} R_4 \\ R_2 \\ R_1 \\ R_3 \end{matrix} \sim \left(\begin{array}{cc|cc} 1 & 1 & 1 & 1 \\ 0 & 2 & 0 & 2 \\ 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 \end{array} \right) \begin{matrix} R_1 \\ R_2 \\ R_3 \\ R_4 - 3R_1 \end{matrix}$$

Ani simultánní soustava

$$\left(\begin{array}{cc|cc} 0 & 0 & 1 & 1 \\ 0 & 2 & 0 & 2 \\ 3 & 3 & 3 & 3 \\ 1 & 1 & 1 & 1 \end{array} \right)$$

tedy řešení nemá.

Ukázali jsme, že π a π' nejsou rovnoběžné.

Příklad 5 (vzájemná poloha dvou rovin v \mathbb{R}^4 , pokrač.)

② Různoběžnost: stačí zjistit, zda soustava^a

$$\left(\begin{array}{cccc|c} 1 & 1 & 0 & 0 & -1 \\ 0 & 2 & 0 & 2 & -1 \\ 3 & 3 & 3 & 3 & 0 \\ 1 & 1 & 1 & 1 & 0 \end{array} \right)$$

má řešení.

$$\left(\begin{array}{cccc|c} 1 & 1 & 0 & 0 & -1 \\ 0 & 2 & 0 & 2 & -1 \\ 3 & 3 & 3 & 3 & 0 \\ 1 & 1 & 1 & 1 & 0 \end{array} \right) \sim \left(\begin{array}{cccc|c} 1 & 1 & 0 & 0 & -1 \\ 0 & 2 & 0 & 2 & -1 \\ 0 & 0 & 3 & 3 & 3 \\ 0 & 0 & 1 & 1 & 1 \end{array} \right) \begin{matrix} R_1 \\ R_2 \\ R_3 - 3R_1 \\ R_4 - R_1 \end{matrix} \left(\begin{array}{cccc|c} 1 & 1 & 0 & 0 & -1 \\ 0 & 2 & 0 & 2 & -1 \\ 0 & 0 & 3 & 3 & 3 \\ 0 & 0 & 0 & 0 & 0 \end{array} \right) \begin{matrix} R_1 \\ R_2 \\ R_3 \\ 3R_4 - R_3 \end{matrix}$$

Řešení existuje, π a π' jsou různoběžné.

Závěr: roviny π a π' jsou různoběžné.

^aPravá strana je $\mathbf{p} - \mathbf{p}'$.

Závěrečná poznámka

Tvrzení o rovnoběžnosti, různoběžnosti, mimoběžnosti, existenci parametrického zápisu a rovnicového zápisu lze **stejným způsobem** dokázat v prostoru \mathbb{F}^n , kde \mathbb{F} je **jakékoli těleso**.^a

^aTo znamená: rozumíme například pojmu rovnoběžnosti, různoběžnosti, mimoběžnosti affiních podprostorů prostoru \mathbb{C}^6 nad \mathbb{C} .

Co příště a přespříště?

- ➊ Zavedeme **vektorový součin** v \mathbb{R}^n , kde $n \geq 2$.
- ➋ Naučíme se počítat **vzájemné vzdálenosti** affiních podprostorů prostoru \mathbb{R}^n .

Tyto výsledky budou podstatně využívat existenci **standardního skalárního součinu** v \mathbb{R}^n .

Vektorový součin

Odpřednesenou látku naleznete v dodacích B.1 a B.2 skript *Abstraktní a konkrétní lineární algebra*.

Dnešní přednáška

Budeme pracovat v \mathbb{R}^n nad \mathbb{R} se **standardním** skalárním součinem.

- ① Naučíme se spočítat **objem k -rovnoběžnostěnu** pro $k \leq n$.^a
- ② V \mathbb{R}^n , pro $n \geq 2$, zavedeme **vektorový součin** libovolného seznamu vektorů $(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})$. Dokážeme některé vlastnosti vektorového součinu. Tím si připravíme půdu pro příští přednášku.

^aPřipomeňme, že umíme spočítat (dokonce orientovaný) objem n -rovnoběžnostěnu v \mathbb{R}^n .

Příští přednáška

Budeme pracovat v \mathbb{R}^n nad \mathbb{R} se **standardním** skalárním součinem, a tím pádem se **standardním** pojmem vzdálenosti.

Výsledky dnešní (a minulé) přednášky využijeme ke stanovení **vzdálenosti dvou affinních podprostorů** prostoru \mathbb{R}^n .

Problém

V \mathbb{R}^n je zadán seznam vektorů $(\mathbf{a}_1, \dots, \mathbf{a}_k)$, kde $k \leq n$. Jak nalézt neorientovaný objem

$$V_k(\mathbf{a}_1, \dots, \mathbf{a}_k)$$

rovnoběžnostěnu, určeného seznamem $(\mathbf{a}_1, \dots, \mathbf{a}_k)$?

Řešení

Označme $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_k)$.

- ① Jestliže $k = n$, potom

$$V_n(\mathbf{a}_1, \dots, \mathbf{a}_n) = \text{absolutní hodnota } \det(\mathbf{A})$$

- ② Jestliže $k < n$, potom $\det(\mathbf{A})$ není definován, protože matice \mathbf{A} není čtvercová!

Matice $\mathbf{A}^T \mathbf{A}$ ale čtvercová je (má rozměry $k \times k$). Uvidíme, že platí

$$V_n(\mathbf{a}_1, \dots, \mathbf{a}_k) = \sqrt{\det(\mathbf{A}^T \mathbf{A})}$$

Definice (Gramova matice a Gramův determinant)

Ať matice $\mathbf{A} : \mathbb{R}^k \rightarrow \mathbb{R}^n$ má sloupcový zápis $(\mathbf{a}_1, \dots, \mathbf{a}_k)$, kde $k \leq n$.

- ① Matici $\mathbf{A}^T \mathbf{A} : \mathbb{R}^k \rightarrow \mathbb{R}^k$ budeme říkat **Gramova matice** seznamu vektorů $(\mathbf{a}_1, \dots, \mathbf{a}_k)$.
- ② Determinantu $\det(\mathbf{A}^T \mathbf{A})$ budeme říkat **Gramův determinant** seznamu $(\mathbf{a}_1, \dots, \mathbf{a}_k)$ a značit jej $\text{Gram}(\mathbf{a}_1, \dots, \mathbf{a}_k)$.

Pozorování

V j -tém sloupci a i -tému řádku matice $\mathbf{A}^T \mathbf{A}$ je hodnota **standardního** skalárního součinu $\langle \mathbf{a}_i | \mathbf{a}_j \rangle = \mathbf{a}_i^T \cdot \mathbf{a}_j$.

Tento jednoduchý fakt umožní dát Gramově determinantu $\text{Gram}(\mathbf{a}_1, \dots, \mathbf{a}_k)$ jasný **geometrický význam**.

Tvrzení (význam Gramova determinantu)

Ať $(\mathbf{a}_1, \dots, \mathbf{a}_k)$ je seznam vektorů v \mathbb{R}^n , $1 \leq k \leq n$. Potom platí:

- ① $\text{Gram}(\mathbf{a}_1, \dots, \mathbf{a}_k) \geq 0$.
- ② $\text{Gram}(\mathbf{a}_1, \dots, \mathbf{a}_k) > 0$ právě tehdy, když vektory $\mathbf{a}_1, \dots, \mathbf{a}_k$ jsou lineárně nezávislé.
- ③ Hodnota $\sqrt{\text{Gram}(\mathbf{a}_1, \dots, \mathbf{a}_k)}$ udává **k -dimensionální objem rovnoběžnostěnu v \mathbb{R}^n** , určeného seznamem $(\mathbf{a}_1, \dots, \mathbf{a}_k)$.

^a**Slogan:** Gramova matice $\mathbf{A}^T \mathbf{A}$ je „druhá mocnina“ matice $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_k)$. Proto je $\det(\mathbf{A}^T \mathbf{A})$ „druhá mocnina“ „determinantu“ \mathbf{A} . Absolutní hodnota „determinantu“ \mathbf{A} je tudíž $\sqrt{\det(\mathbf{A}^T \mathbf{A})} = \sqrt{\text{Gram}(\mathbf{a}_1, \dots, \mathbf{a}_k)}$. **Jde ale pouze o slogan, který slouží k zapamatování; matice \mathbf{A} obecně není čtvercová, proto o determinantu matice \mathbf{A} obecně nemůžeme mluvit!**

Důkaz.

Bez důkazu. Důkaz není těžký, ale je zdlouhavý, viz Tvrzení B.1.3 skript.

Příklad


Určete 2-dimensionální objem rovnoběžnostěnu v \mathbb{R}^3 , určeného

$$\text{vektory } \mathbf{a}_1 = \begin{pmatrix} 1 \\ 2 \\ 0 \end{pmatrix} \text{ a } \mathbf{a}_2 = \begin{pmatrix} 3 \\ 2 \\ 0 \end{pmatrix}.$$

Gramova matice a Gramův determinant seznamu $(\mathbf{a}_1, \mathbf{a}_2)$ jsou

$$\begin{pmatrix} \langle \mathbf{a}_1 | \mathbf{a}_1 \rangle & \langle \mathbf{a}_1 | \mathbf{a}_2 \rangle \\ \langle \mathbf{a}_2 | \mathbf{a}_1 \rangle & \langle \mathbf{a}_2 | \mathbf{a}_2 \rangle \end{pmatrix} = \begin{pmatrix} 5 & 7 \\ 7 & 13 \end{pmatrix} \quad \text{Gram}(\mathbf{a}_1, \mathbf{a}_2) = \det \begin{pmatrix} 5 & 7 \\ 7 & 13 \end{pmatrix} = 16$$

Hledaný 2-dimensionální objem je $\sqrt{\text{Gram}(\mathbf{a}_1, \mathbf{a}_2)} = 4$.



Příklad

Určete 3-dimensionální objem rovnoběžnostěnu v \mathbb{R}^4 , určeného

$$\text{vektory } \mathbf{a}_1 = \begin{pmatrix} 1 \\ 2 \\ 1 \\ 3 \end{pmatrix}, \mathbf{a}_2 = \begin{pmatrix} 1 \\ -1 \\ 1 \\ 0 \end{pmatrix} \text{ a } \mathbf{a}_3 = \begin{pmatrix} 1 \\ 1 \\ 1 \\ 0 \end{pmatrix}.$$

Gramova matice a Gramův determinant seznamu $(\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3)$ jsou

$$\begin{pmatrix} \langle \mathbf{a}_1 | \mathbf{a}_1 \rangle & \langle \mathbf{a}_1 | \mathbf{a}_2 \rangle & \langle \mathbf{a}_1 | \mathbf{a}_3 \rangle \\ \langle \mathbf{a}_2 | \mathbf{a}_1 \rangle & \langle \mathbf{a}_2 | \mathbf{a}_2 \rangle & \langle \mathbf{a}_2 | \mathbf{a}_3 \rangle \\ \langle \mathbf{a}_3 | \mathbf{a}_1 \rangle & \langle \mathbf{a}_3 | \mathbf{a}_2 \rangle & \langle \mathbf{a}_3 | \mathbf{a}_3 \rangle \end{pmatrix} = \begin{pmatrix} 15 & 0 & 4 \\ 0 & 3 & 1 \\ 4 & 1 & 3 \end{pmatrix}$$

$$\text{Gram}(\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3) = \det \begin{pmatrix} 15 & 0 & 4 \\ 0 & 3 & 1 \\ 4 & 1 & 3 \end{pmatrix} = 72$$

Hledaný 3-dimensionální objem je

$$\sqrt{\text{Gram}(\mathbf{a}_1, \mathbf{a}_2, \mathbf{a}_3)} = \sqrt{72} \approx 8.485$$

Připomenutí známých faktů a definice vektorového součinu

- 1 Pro každé lineární zobrazení $f : \mathbb{R}^n \rightarrow \mathbb{R}$ existuje jediný vektor a v \mathbb{R}^n tak, že

$$f(x) = a^T \cdot x = \langle a | x \rangle$$

Jednoduché: f „je“ matic s 1 řádkem a n sloupců, označme ji a^T , pro a z \mathbb{R}^n .

- 2 Pro libovolný seznam (x_1, \dots, x_{n-1}) vektorů z \mathbb{R}^n , $n \geq 2$, je zobrazení

$\det(x_1, \dots, x_{n-1}, -) : \mathbb{R}^n \rightarrow \mathbb{R}$, $x \mapsto \det(x_1, \dots, x_{n-1}, x)$
lineární.

- 3 To znamená, že pro zadaný seznam (x_1, \dots, x_{n-1}) existuje jednoznačně určený vektor a z \mathbb{R}^n tak, že platí

$$\det(x_1, \dots, x_{n-1}, x) = a^T \cdot x = \langle a | x \rangle$$

pro všechna x z \mathbb{R}^n .

Místo a budeme psát $\times(x_1, \dots, x_{n-1})$ a budeme mu říkat vektorový součin seznamu (x_1, \dots, x_{n-1}) .



Přepis definice vektorového součinu seznamu $(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})$

$\mathbf{v} \in \mathbb{R}^n$, $n \geq 2$

$$\langle \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mid \mathbf{x} \rangle = \det(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}, \mathbf{x}) \text{ pro všechna } \mathbf{x} \in \mathbb{R}^n.$$

Základní vlastnost vektorového součinu seznamu

$(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mathbf{v} \in \mathbb{R}^n$, $n \geq 2$

Pro jakékoli $j = 1, \dots, n-1$ platí

$$\langle \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mid \mathbf{x}_j \rangle = 0$$

tj. vektor $\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})$ je **kolmý** na všechny vektory \mathbf{x}_j ,
 $j = 1, \dots, n-1$.

To je snadné:

$$\langle \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mid \mathbf{x}_j \rangle = \underbrace{\det(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}, \mathbf{x}_j)}_{\text{determinant se dvěma shodnými sloupci}} = 0$$

Tvrzení (výpočet vektorového součinu v \mathbb{R}^n , $n \geq 2$)

Platí rovnost $\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) = \sum_{i=1}^n \det(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}, \mathbf{e}_i) \cdot \mathbf{e}_i$.

Důkaz.

Platí $\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) = \sum_{i=1}^n \underbrace{\langle \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mid \mathbf{e}_i \rangle}_{=i\text{-tá souřadnice vektoru } \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})} \cdot \mathbf{e}_i$,

protože $(\mathbf{e}_1, \dots, \mathbf{e}_n)$ je **ortonormální báze** pro standardní skalární součin v prostoru \mathbb{R}^n . Ale

$$\sum_{i=1}^n \underbrace{\langle \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mid \mathbf{e}_i \rangle}_{=\det(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}, \mathbf{e}_i)} \cdot \mathbf{e}_i = \sum_{i=1}^n \det(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}, \mathbf{e}_i) \cdot \mathbf{e}_i$$

podle definice vektorového součinu. ■

Výpočet vektorového součinu v \mathbb{R}^2

$$\times(\mathbf{x}) = \sum_{i=1}^2 \det(\mathbf{x}, \mathbf{e}_i) \cdot \mathbf{e}_i = \det(\mathbf{x}, \mathbf{e}_1) \cdot \mathbf{e}_1 + \det(\mathbf{x}, \mathbf{e}_2) \cdot \mathbf{e}_2$$

Takže

$$\times\left(\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}\right) = \underbrace{\det\left(\begin{pmatrix} x_1 & 1 \\ x_2 & 0 \end{pmatrix}\right)}_{=-x_2} \cdot \begin{pmatrix} 1 \\ 0 \end{pmatrix} + \underbrace{\det\left(\begin{pmatrix} x_1 & 0 \\ x_2 & 1 \end{pmatrix}\right)}_{=x_1} \cdot \begin{pmatrix} 0 \\ 1 \end{pmatrix} = \begin{pmatrix} -x_2 \\ x_1 \end{pmatrix}$$

a to je **známý** výpočet vektoru, kolmého na vektor $\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$.

Například $\times\left(\begin{pmatrix} 6 \\ 12 \end{pmatrix}\right) = \begin{pmatrix} -12 \\ 6 \end{pmatrix}$.

Výpočet vektorového součinu v \mathbb{R}^3 (je zvykem psát $\mathbf{x}_1 \times \mathbf{x}_2$ místo $\times(\mathbf{x}_1, \mathbf{x}_2)$)

$$\mathbf{x}_1 \times \mathbf{x}_2 = \det(\mathbf{x}_1, \mathbf{x}_2, \mathbf{e}_1) \cdot \mathbf{e}_1 + \det(\mathbf{x}_1, \mathbf{x}_2, \mathbf{e}_2) \cdot \mathbf{e}_2 + \det(\mathbf{x}_1, \mathbf{x}_2, \mathbf{e}_3) \cdot \mathbf{e}_3$$

Takže

$$\begin{aligned}
 & \times \left(\begin{pmatrix} x_{11} \\ x_{21} \\ x_{31} \end{pmatrix}, \begin{pmatrix} x_{12} \\ x_{22} \\ x_{32} \end{pmatrix} \right) = \underbrace{\det \left(\begin{pmatrix} x_{11} & x_{12} & 1 \\ x_{21} & x_{22} & 0 \\ x_{31} & x_{32} & 0 \end{pmatrix} \right)}_{= \det \left(\begin{pmatrix} x_{21} & x_{22} \\ x_{31} & x_{32} \end{pmatrix} \right)} \cdot \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix} + \underbrace{\det \left(\begin{pmatrix} x_{11} & x_{12} & 0 \\ x_{21} & x_{22} & 1 \\ x_{31} & x_{32} & 0 \end{pmatrix} \right)}_{= -\det \left(\begin{pmatrix} x_{11} & x_{12} \\ x_{31} & x_{32} \end{pmatrix} \right)} \cdot \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix} \\
 & + \underbrace{\det \left(\begin{pmatrix} x_{11} & x_{12} & 0 \\ x_{21} & x_{22} & 0 \\ x_{31} & x_{32} & 1 \end{pmatrix} \right)}_{= \det \left(\begin{pmatrix} x_{11} & x_{12} \\ x_{21} & x_{22} \end{pmatrix} \right)} \cdot \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix} = \begin{pmatrix} x_{21}x_{32} - x_{31}x_{22} \\ x_{31}x_{12} - x_{11}x_{32} \\ x_{11}x_{22} - x_{21}x_{12} \end{pmatrix}
 \end{aligned}$$

a to je nezapamatovatelné.



Mnemotechnická pomůcka (nejde o definici vektorového součinu)

$$\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) = \begin{vmatrix} x_{11} & x_{12} & \dots & x_{1,n-1} & \mathbf{e}_1 \\ x_{21} & x_{22} & \dots & x_{2,n-1} & \mathbf{e}_2 \\ \vdots & & & & \vdots \\ x_{n-1,1} & x_{n-1,2} & \dots & x_{n-2,n-1} & \mathbf{e}_{n-1} \\ x_{n1} & x_{n2} & \dots & x_{n,n-1} & \mathbf{e}_n \end{vmatrix}$$

Jde o ryze formální^a zápis, ale užitečný. Například

$$\times\left(\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}\right) = \begin{vmatrix} x_1 & \mathbf{e}_1 \\ x_2 & \mathbf{e}_2 \end{vmatrix} \quad \begin{pmatrix} x_{11} \\ x_{21} \\ x_{31} \end{pmatrix} \times \begin{pmatrix} x_{12} \\ x_{22} \\ x_{32} \end{pmatrix} = \begin{vmatrix} x_{11} & x_{12} & \mathbf{e}_1 \\ x_{21} & x_{22} & \mathbf{e}_2 \\ x_{31} & x_{32} & \mathbf{e}_3 \end{vmatrix}$$

a tak dále. A takové vzorce se již zapamatovat dají.

^aNapravo od rovnítka totiž mezi značkami pro determinant není zapsána matici. Počítejte ale, jako by to determinant byl. Viz následující příklady.

Příklad (výpočet vektorového součinu v \mathbb{R}^3)

$$\begin{pmatrix} 3 \\ -1 \\ 2 \end{pmatrix} \times \begin{pmatrix} 1 \\ 0 \\ 4 \end{pmatrix} = \begin{vmatrix} 3 & 1 & \mathbf{e}_1 \\ -1 & 0 & \mathbf{e}_2 \\ 2 & 4 & \mathbf{e}_3 \end{vmatrix} = 3 \cdot 0 \cdot \mathbf{e}_3 + 1 \cdot \mathbf{e}_2 \cdot 2 + (-1) \cdot 4 \cdot \mathbf{e}_1 \\ - 2 \cdot 0 \cdot \mathbf{e}_1 - (-1) \cdot 1 \cdot \mathbf{e}_3 - 4 \cdot \mathbf{e}_2 \cdot 3 \\ = \begin{pmatrix} -4 \\ -10 \\ 1 \end{pmatrix}$$

Příklad (výpočet vektorového součinu v \mathbb{R}^4)

$$\times \left(\begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix} \right) = \begin{vmatrix} 1 & 0 & 1 & \mathbf{e}_1 \\ 0 & 1 & 1 & \mathbf{e}_2 \\ 0 & 0 & 1 & \mathbf{e}_3 \\ 0 & 0 & 1 & \mathbf{e}_4 \end{vmatrix} = \begin{vmatrix} 1 & 1 & \mathbf{e}_2 \\ 0 & 1 & \mathbf{e}_3 \\ 0 & 1 & \mathbf{e}_4 \end{vmatrix} = \begin{vmatrix} 1 & \mathbf{e}_3 \\ 1 & \mathbf{e}_4 \end{vmatrix} \\ = \mathbf{e}_4 - \mathbf{e}_3 = \begin{pmatrix} 0 \\ 0 \\ -1 \\ 1 \end{pmatrix}$$

Tvrzení (další vlastnosti vektorového součinu v \mathbb{R}^n , $n \geq 2$)

- ① Funkce $(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mapsto \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})$ je lineární v každé položce.
- ② $\times(\mathbf{x}_{\pi(1)}, \dots, \mathbf{x}_{\pi(n-1)}) = \text{sign}(\pi) \cdot \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})$, pro $\pi \in S_{n-1}$.
- ③ $\times(\mathbf{e}_{\pi(1)}, \dots, \mathbf{e}_{\pi(n-1)}) = \text{sign}(\pi) \cdot \mathbf{e}_{\pi(n)}$, pro $\pi \in S_n$.
- ④ $\|\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})\|^2 = \det(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}, \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}))$.
- ⑤ $\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) = \mathbf{0}$ platí právě tehdy, když vektory $\mathbf{x}_1, \dots, \mathbf{x}_{n-1}$ jsou lineárně závislé.
- ⑥ $\|\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})\| = \sqrt{\text{Gram}(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})}$. To jest: norma $\|\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})\|$ je rovna $(n-1)$ -dimensionálnímu objemu rovnoběžnostěnu určeného vektory $\mathbf{x}_1, \dots, \mathbf{x}_{n-1}$.

Poznámky k důkazu na přednášce. Všechny vlastnosti plynou **okamžitě** z vlastností determinantu a z **definice** vektorového součinu.

Metrické výpočty v \mathbb{R}^n

Odpřednesenou látku naleznete v dodacích B.3 a B.4
skript *Abstraktní a konkrétní lineární algebra*.

Minulé přednášky

1 Víme, co je **affinní podprostor** dimenze d v prostoru \mathbb{R}^n .

Připomenutí: jde o množinu $\mathbf{p} + W = \{\mathbf{p} + \mathbf{x} \mid \mathbf{x} \in W\}$, kde W je lineární podprostor dimenze d v \mathbb{R}^n a \mathbf{p} je vektor v \mathbb{R}^n .

- 2 Pro dva affinní podprostupy $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ v \mathbb{R}^n umíme rozhodnout, zda jsou **rovnoběžné**, nebo **různoběžné**, nebo **mimoběžné**.
- 3 Víme, co je **vektorový součin**^a $\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})$ seznamu vektorů $(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})$ v \mathbb{R}^n , kde $n \geq 2$.

Připomenutí: $\langle \times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}) \mid \mathbf{x} \rangle = \det(\mathbf{x}_1, \dots, \mathbf{x}_{n-1}, \mathbf{x})$
platí pro všechna \mathbf{x} z \mathbb{R}^n .

Dále **víme, že platí rovnost**

$$\|\times(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})\| = \sqrt{\text{Gram}(\mathbf{x}_1, \dots, \mathbf{x}_{n-1})}.$$

^aProstor \mathbb{R}^n je vybaven **standardním** skalárním součinem $\langle \mathbf{x} \mid \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{y}$.



Dnešní přednáška

Pro dva affinní podprostory π, π' prostoru \mathbb{R}^n se **standardním** skalárním součinem spočteme jejich **vzájemnou vzdálenost**.

V dalším budeme značit:

- ① $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{y}$ je **standardní** skalární součin v \mathbb{R}^n .
- ② $\|\mathbf{x}\|$ je **norma** v \mathbb{R}^n , vytvořená standardním skalárním součinem, tj. $\|\mathbf{x}\| = \sqrt{\langle \mathbf{x} | \mathbf{x} \rangle} = \sqrt{\mathbf{x}^T \cdot \mathbf{x}}$.

Pro $\mathbf{x} = \begin{pmatrix} x_1 \\ \vdots \\ x_n \end{pmatrix}$ a $\mathbf{y} = \begin{pmatrix} y_1 \\ \vdots \\ y_n \end{pmatrix}$ je

$$\|\mathbf{x} - \mathbf{y}\| = \sqrt{\sum_{i=1}^n (x_i - y_i)^2}$$

To jest: $\|\mathbf{x} - \mathbf{y}\|$ je **standardní eukleidovská vzdálenost** vektorů \mathbf{x} a \mathbf{y} z prostoru \mathbb{R}^n .

Definice

Ať π a π' jsou dva affinní podprostupy prostoru \mathbb{R}^n . Reálnému číslu^a

$$\omega(\pi, \pi') = \inf \left\{ \|x - x'\| \mid x \in \pi, x' \in \pi' \right\}$$

říkáme **vzájemná vzdálenost** π a π' .

^aZ definice vzájemné vzdálenosti ihned plyne, že $\omega(\pi, \pi') = \omega(\pi', \pi)$.

Poznámky k definici

- ① Pro $n = 0$ nebo $n = 1$ není definice příliš zajímavá.
 - ① $\mathbb{R}^0 = \{\mathbf{o}\}$, proto pro jakákoli π a π' platí $\omega(\pi, \pi') = 0$.
 - ② Prostor \mathbb{R}^1 má jako affinní podprostupy buď body nebo celé \mathbb{R}^1 . To znamená $\omega(\mathbf{p}, \mathbf{p}') = \|\mathbf{p} - \mathbf{p}'\|$, nebo $\omega(\mathbf{p}, \mathbb{R}) = \omega(\mathbb{R}, \mathbb{R}) = 0$.
- ② V obecném \mathbb{R}^n víme: $\left\{ \|x - x'\| \mid x \in \pi, x' \in \pi' \right\}$ je **neprázdná** a **zdola omezená** množina reálných čísel. Tudíž její **infimum** existuje a reálné číslo $\omega(\pi, \pi')$ je korektně definováno.

Problém: jak spočítat hodnotu $\omega(\pi, \pi')$ v obecném \mathbb{R}^n ?

Věta (výpočet vzáj. vzdálenosti dvou affinních podprostorů)

Ať $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ jsou dva affinní podprostory prostoru \mathbb{R}^n . Potom platí:^a

$$\omega(\pi, \pi') = \|\text{rej}_{W \vee W'}(\mathbf{p} - \mathbf{p}')\|$$

^aProtože $\omega(\pi, \pi') = \omega(\pi', \pi)$, je také $\omega(\pi, \pi') = \|\text{rej}_{W \vee W'}(\mathbf{p}' - \mathbf{p})\|$.

Hlavní myšlenky důkazu (u zkoušky budou požadovány pouze tyto myšlenky)

- 1 Vzdálenost π a π' by měla být délka kolmé příčky prostorů π a π' .

Tak je tomu v \mathbb{R}^2 při výpočtu vzdálenosti dvou rovnoběžek.

Obecný případ by měl dopadnout analogicky.

- 2 Obecně: kolmá příčka k π , π' by měla mít směr V , kde $V = \{\mathbf{v} \mid \langle \mathbf{w} \mid \mathbf{v} \rangle = 0 \text{ pro všechna } \mathbf{w} \text{ z } W \vee W'\}$ je množina všech vektorů, které jsou kolmé na podprostor $W \vee W'$.

Je to ale v pořádku? Je V lineární podprostor prostoru \mathbb{R}^n ?

Hlavní myšlenky důkazu (pokrač.)

- ③ Vše je v pořádku:

$$\begin{aligned} V &= \{\mathbf{v} \mid \langle \mathbf{w} \mid \mathbf{v} \rangle = 0 \text{ pro všechna } \mathbf{w} \in W \vee W'\} \\ &= \bigcap_{\mathbf{w} \in W \vee W'} \{\mathbf{v} \mid \langle \mathbf{w} \mid \mathbf{v} \rangle = 0\} \\ &= \bigcap_{\mathbf{w} \in W \vee W'} \ker(\langle \mathbf{w} \mid - \rangle) \end{aligned}$$

Proto je V lineární podprostor prostoru \mathbb{R}^n .

- ④ Najdeme^a body \mathbf{x}_0 v π a \mathbf{x}'_0 v π' tak, že platí rovnost^b
 $\mathbf{x}_0 - \mathbf{x}'_0 = \text{rej}_{W \vee W'}(\mathbf{p} - \mathbf{p}')$.

To znamená, že $\mathbf{x}_0 - \mathbf{x}'_0 \in V$, proto $\mathbf{x}_0 + V = \mathbf{x}'_0 + V$ je
 hledaná kolmá příčka π , π' , procházející body \mathbf{x}_0 a \mathbf{x}'_0 .

^aTo je mírně technické (nikoli těžké): viz důkaz Věty B.3.3 skript.

^bPodle definice V platí také $\mathbf{x}_0 - \mathbf{x}'_0 = \text{proj}_V(\mathbf{p} - \mathbf{p}')$. Toho v dalších výpočtech několikrát využijeme.



Hlavní myšlenky důkazu (pokrač.)

- ⑤ Pro jakékoli $x \in \pi$ a jakékoli $x' \in \pi'$ platí

$$x' - x = \underbrace{(x'_0 - x_0)}_{\in V} + \underbrace{(x' - x'_0)}_{\in W \vee W'} + (x_0 - x)$$

Proto podle Pythagorovy věty^a platí

$$\|x' - x\|^2 = \|x'_0 - x_0\|^2 + \|(x' - x'_0) + (x_0 - x)\|^2$$

a tedy $\|x' - x\|^2 \geq \|x'_0 - x_0\|^2$, neboli


$$\|x' - x\| \geq \|x'_0 - x_0\| = \|\text{rej}_{W \vee W'}(\mathbf{p}' - \mathbf{p})\| = \|\text{rej}_{W \vee W'}(\mathbf{p} - \mathbf{p}')\|$$

To znamená, že platí^b $\omega(\pi, \pi') = \|\text{rej}_{W \vee W'}(\mathbf{p} - \mathbf{p}')\|$. ■

^a Z definice V platí $\langle x'_0 - x_0 \mid (x' - x'_0) + (x_0 - x) \rangle = 0$.

^b Podle definice V platí také $\omega(\pi, \pi') = \|\text{proj}_V(\mathbf{p} - \mathbf{p}')\|$.

Obrázek



Poznámky

- ① Vzorec $\omega(\pi, \pi') = \|\text{rej}_{W \vee W'}(\mathbf{p} - \mathbf{p}')\|$ platí v \mathbb{R}^n s libovolným skalárním součinem $\langle - | - \rangle$, který vytváří normu $\| - \|$.

Důkaz hlavní věty totiž nikde nevyužívá, že skalární součin $\langle - | - \rangle$ je standardní.

Jediné, co důkaz vyžaduje, je pojem ortogonální rejekce a platnost Pythagorovy věty.^a

- ② V dalším se omezíme na standardní skalární součin v prostorech \mathbb{R}^2 a \mathbb{R}^3 .

Tam jsou příslušné vzorce pro vzájemnou vzdálenost dvou affiních podprostorů poměrně snadno pochopitelné.

^aPřipomenutí: ortogonální projekce umíme počítat pro libovolný skalární součin v \mathbb{R}^n , vzorce jsou však poněkud barokní. Takže, pro libovolný skalární součin v \mathbb{R}^n , umíme počítat (barokním způsobem) i ortogonální rejekce. Pythagorova věta platí pro libovolný skalární součin v \mathbb{R}^n .

Důležité upozornění

Ve zbytku přednášky odvodíme celou řadu vzorců pro vzájemnou vzdálenost affiných podprostorů v \mathbb{R}^2 a v \mathbb{R}^3 se standardními skalárními součiny. Tyto vzorce **nebudou** zkoušeny stylem: *Napište vzorec pro vzdálenost bodu od přímky v \mathbb{R}^3 , atd.*

Bude vyžadováno:

- ① Znát obecný vzorec $\omega(\pi, \pi') = \|\text{rej}_{W \vee W'}(\mathbf{p} - \mathbf{p}')\|$ pro vzájemnou vzdálenost affiných podprostorů $\pi = \mathbf{p} + W$ a $\pi' = \mathbf{p}' + W'$ v prostoru \mathbb{R}^n a znát hlavní myšlenky jeho odvození z předchozích stran.
- ② Z přednášky o ortogonálních projekcích a ortogonálních rejekcích znát vzorec

$$\text{proj}_{\text{span}(\mathbf{v})}(\mathbf{x}) = \frac{\langle \mathbf{v} | \mathbf{x} \rangle}{\langle \mathbf{v} | \mathbf{v} \rangle} \cdot \mathbf{v}$$

pro **nenulový** vektor \mathbf{v} z \mathbb{R}^n . Viz následující stranu.

- ③ Tvůrčí uplatnění výše uvedeného vzorce pro ortogonální projekci k nalezení vzájemných vzdáleností v \mathbb{R}^2 a v \mathbb{R}^3 .




Připomenutí (přednáška o ortogonálních projekcích a ortogonálních rejkcích)

$\forall \mathbb{R}^n$ pro nenulový vektor \mathbf{v} platí

$$\|\text{proj}_{\text{span}(\mathbf{v})}(\mathbf{x})\| = \left\| \frac{\langle \mathbf{v} | \mathbf{x} \rangle}{\langle \mathbf{v} | \mathbf{v} \rangle} \cdot \mathbf{v} \right\| = \left| \frac{\langle \mathbf{v} | \mathbf{x} \rangle}{\langle \mathbf{v} | \mathbf{v} \rangle} \right| \cdot \|\mathbf{v}\| = \frac{|\langle \mathbf{v} | \mathbf{x} \rangle|}{\|\mathbf{v}\|^2} \cdot \|\mathbf{v}\| = \frac{|\langle \mathbf{v} | \mathbf{x} \rangle|}{\|\mathbf{v}\|}$$

a tudíž

$$\|\text{rej}_{\text{span}(\mathbf{v})}(\mathbf{x})\| = \|\mathbf{x} - \text{proj}_{\text{span}(\mathbf{v})}(\mathbf{x})\| = \left\| \mathbf{x} - \frac{\langle \mathbf{v} | \mathbf{x} \rangle}{\langle \mathbf{v} | \mathbf{v} \rangle} \cdot \mathbf{v} \right\|$$



Vzdálenost bodu od přímky v \mathbb{R}^2

① Vzdálenost \mathbf{p}' od $\pi = \mathbf{p} + \text{span}(\mathbf{s})$. V tomto případě je^a

$$\mathbf{1} \quad W \vee W' = \text{span}(\mathbf{s}).$$

$$\mathbf{2} \quad \omega(\mathbf{p}', \pi) = \|\text{rej}_{\text{span}(\mathbf{s})}(\mathbf{p} - \mathbf{p}')\| = \left\| (\mathbf{p} - \mathbf{p}') - \frac{\langle \mathbf{s} | \mathbf{p} - \mathbf{p}' \rangle}{\langle \mathbf{s} | \mathbf{s} \rangle} \cdot \mathbf{s} \right\|$$

Pro $\mathbf{p}' = \begin{pmatrix} 2 \\ 4 \end{pmatrix}$ a $\pi = \underbrace{\begin{pmatrix} 3 \\ 0 \end{pmatrix}}_{=\mathbf{p}} + \text{span}(\underbrace{\begin{pmatrix} 3 \\ 6 \end{pmatrix}}_{=\mathbf{s}})$ je tedy $\omega(\mathbf{p}', \pi)$ rovno

$$\left\| \begin{pmatrix} 1 \\ -4 \end{pmatrix} - \frac{\langle \begin{pmatrix} 3 \\ 6 \end{pmatrix} | \begin{pmatrix} 1 \\ -4 \end{pmatrix} \rangle}{\langle \begin{pmatrix} 3 \\ 6 \end{pmatrix} | \begin{pmatrix} 3 \\ 6 \end{pmatrix} \rangle} \cdot \begin{pmatrix} 3 \\ 6 \end{pmatrix} \right\| = \dots = \frac{6\sqrt{5}}{5}$$

^aTento vzorec není příliš „hezký“. Lepší postup: definujte $\mathbf{n} = \times(\mathbf{s})$ a pracujte s přímkou π ve tvaru $\mathbf{n}^T(\mathbf{x} - \mathbf{p}) = 0$. Viz další příklad.

Vzdálenost bodu od přímky v \mathbb{R}^2 (pokrač.)

② Vzdálenost \mathbf{p}' od π ve tvaru $\mathbf{n}^T(\mathbf{x} - \mathbf{p}) = 0$. V tomto případě je

$$① V = \text{span}(\mathbf{n}).$$

② Neznáme směr \mathbf{s} zadané přímky, ale platí $\omega(\mathbf{p}', \pi) =$

$$\|\text{rej}_{\text{span}(\mathbf{s})}(\mathbf{p}' - \mathbf{p})\| = \|\text{proj}_{\text{span}(\mathbf{n})}(\mathbf{p}' - \mathbf{p})\| = \frac{|\langle \mathbf{n} | \mathbf{p}' - \mathbf{p} \rangle|}{\|\mathbf{n}\|}$$

$$= \frac{|\mathbf{n}^T(\mathbf{p}' - \mathbf{p})|}{\|\mathbf{n}\|} = \frac{|\mathbf{n}^T \mathbf{p}' - \mathbf{n}^T \mathbf{p}|}{\|\mathbf{n}\|}$$

Pro $\mathbf{p}' = \begin{pmatrix} 2 \\ 4 \end{pmatrix}$ a přímku π zadanou rovnicí $\underbrace{-6x + 3y}_{=\mathbf{n}^T \mathbf{x}} = \underbrace{-18}_{=\mathbf{n}^T \mathbf{p}}$

je tedy $\omega(\mathbf{p}', \pi)$ rovno

$$\frac{|-6 \cdot 2 + 3 \cdot 4 + 18|}{\sqrt{45}} = \frac{18}{\sqrt{45}} = \frac{6\sqrt{5}}{5}$$

^aJde o stejnou přímku, jako v minulém příkladu.

Vzdálenost dvou přímek v \mathbb{R}^2

Jsou zadány přímky $\pi = \mathbf{p} + \text{span}(\mathbf{s})$ a $\pi' = \mathbf{p}' + \text{span}(\mathbf{s}')$.

- ① $\text{span}(\mathbf{s}) \vee \text{span}(\mathbf{s}') =$

$$\begin{cases} = \text{span}(\mathbf{s}), & \text{jsou-li } \mathbf{s} \text{ a } \mathbf{s}' \text{ lineárně závislé,} \\ & \text{tj. jsou-li } \pi \text{ a } \pi' \text{ rovnoběžné} \\ = \mathbb{R}^2, & \text{jsou-li } \mathbf{s} \text{ a } \mathbf{s}' \text{ lineárně nezávislé,} \\ & \text{tj. jsou-li } \pi \text{ a } \pi' \text{ různoběžné} \end{cases}$$

- ② Pokud $\text{span}(\mathbf{s}) \vee \text{span}(\mathbf{s}') = \text{span}(\mathbf{s})$, je

$$\omega(\pi, \pi') = \|\text{rej}_{\text{span}(\mathbf{s})}(\mathbf{p} - \mathbf{p}')\| = \omega(\mathbf{p}', \pi)$$

Vzdálenost bodu od přímky již umíme počítat.

- ③ Pokud $\text{span}(\mathbf{s}) \vee \text{span}(\mathbf{s}') = \mathbb{R}^2$, je

$$\omega(\pi, \pi') = \|\text{rej}_{\mathbb{R}^2}(\mathbf{p} - \mathbf{p}')\| = \|\mathbf{o}\| = 0$$

Vzdálenost bodu od přímky v \mathbb{R}^3

Je dán bod \mathbf{p}' a přímka $\pi = \mathbf{p} + \text{span}(\mathbf{s})$. Potom

$$\begin{aligned}\omega(\mathbf{p}', \pi) &= \|\text{rej}_{\text{span}(\mathbf{s})}(\mathbf{p} - \mathbf{p}')\| = \|(\mathbf{p} - \mathbf{p}') - \text{proj}_{\text{span}(\mathbf{s})}(\mathbf{p} - \mathbf{p}')\| \\ &= \left\| (\mathbf{p} - \mathbf{p}') - \frac{\langle \mathbf{s} | \mathbf{p} - \mathbf{p}' \rangle}{\langle \mathbf{s} | \mathbf{s} \rangle} \cdot \mathbf{s} \right\|\end{aligned}$$

což je **formálně stejný** vzorec jako v \mathbb{R}^2 .

Je-li přímka π zadána rovnicově jako $\mathbf{N}^T(\mathbf{x} - \mathbf{p}) = \mathbf{0}$, kde $\text{rank}(\mathbf{N}) = 2$, pak $V = \text{im}(\mathbf{N})$. Proto

$$\omega(\mathbf{p}', \pi) = \|\text{rej}_{\text{span}(\mathbf{s})}(\mathbf{p} - \mathbf{p}')\| = \|\text{proj}_{\text{im}(\mathbf{N})}(\mathbf{p} - \mathbf{p}')\| = \|\mathbf{N}(\mathbf{N}^T \mathbf{N})^{-1} \mathbf{N}^T(\mathbf{p} - \mathbf{p}')\|$$

Leckdy je **lepší postup** je vyřešit soustavu $\mathbf{N}^T \mathbf{x} = \mathbf{N}^T \mathbf{p}$, získat tak π v parametrickém tvaru a použít výše uvedený vzorec.

Vzdálenost bodu od roviny v \mathbb{R}^3

Pro vzdálenost bodu \mathbf{p}' od roviny π ve tvaru $\mathbf{n}^T(\mathbf{x} - \mathbf{p}) = 0$ platí

$$\omega(\mathbf{p}', \pi) = \|\text{proj}_{\text{span}(\mathbf{n})}(\mathbf{p}' - \mathbf{p})\| = \frac{|\mathbf{n}^T(\mathbf{p}' - \mathbf{p})|}{\|\mathbf{n}\|} = \frac{|\mathbf{n}^T \mathbf{p}' - \mathbf{n}^T \mathbf{p}|}{\|\mathbf{n}\|}$$

kde jsme využili toho, že \mathbf{n} je **normála** roviny π .

Získáváme tak **formálně stejný** vzorec jako pro vzdálenost bodu od přímky v \mathbb{R}^2 .

Je-li rovina π zadána jako $\mathbf{p} + \text{span}(\mathbf{s}_1, \mathbf{s}_2)$, **je vhodné** spočítat^a $\mathbf{n} = \mathbf{s}_1 \times \mathbf{s}_2$ a **použít předchozí postup** pro rovinu π ve tvaru $\mathbf{n}^T(\mathbf{x} - \mathbf{p}) = 0$.

^aPřipomenutí mnemotechniky: $\mathbf{n} = \mathbf{s}_1 \times \mathbf{s}_2 = \begin{vmatrix} s_{11} & s_{12} & \mathbf{e}_1 \\ s_{21} & s_{22} & \mathbf{e}_2 \\ s_{31} & s_{32} & \mathbf{e}_3 \end{vmatrix}$.

Vzdálenost přímky od roviny v \mathbb{R}^3

Ať $\pi' = \mathbf{p}' + \text{span}(\mathbf{s}')$ je přímka a $\pi = \mathbf{p} + \text{span}(\mathbf{s}_1, \mathbf{s}_2)$ je rovina.

Platí

$$\text{span}(\mathbf{s}') \vee \text{span}(\mathbf{s}_1, \mathbf{s}_2) = \begin{cases} \mathbb{R}^3, & \text{pokud } \mathbf{s}', \mathbf{s}_1, \mathbf{s}_2 \text{ jsou lineárně nezávislé,} \\ & \text{tj., pokud } \pi' \text{ a } \pi \text{ jsou různoběžné,} \\ \text{span}(\mathbf{s}_1, \mathbf{s}_2), & \text{pokud } \pi' \text{ a } \pi \text{ jsou rovnoběžné.} \end{cases}$$

- ① Je-li $\text{span}(\mathbf{s}') \vee \text{span}(\mathbf{s}_1, \mathbf{s}_2) = \mathbb{R}^3$, je

$$\omega(\pi', \pi) = \|\text{rej}_{\mathbb{R}^3}(\mathbf{p}' - \mathbf{p})\| = \|\mathbf{o}\| = 0$$

- ② Je-li $\text{span}(\mathbf{s}') \vee \text{span}(\mathbf{s}_1, \mathbf{s}_2) = \text{span}(\mathbf{s}_1, \mathbf{s}_2)$, je

$$\omega(\pi', \pi) = \|\text{rej}_{\text{span}(\mathbf{s}_1, \mathbf{s}_2)}(\mathbf{p}' - \mathbf{p})\| = \|\text{proj}_{\text{span}(\mathbf{s}_1 \times \mathbf{s}_2)}(\mathbf{p}' - \mathbf{p})\|$$

$$= \frac{|\langle \mathbf{s}_1 \times \mathbf{s}_2 \mid \mathbf{p}' - \mathbf{p} \rangle|}{\|\mathbf{s}_1 \times \mathbf{s}_2\|} = \frac{|\det(\mathbf{s}_1, \mathbf{s}_2, \mathbf{p}' - \mathbf{p})|}{\sqrt{\text{Gram}(\mathbf{s}_1, \mathbf{s}_2)}}$$

Příklad

Najdeme vzájemnou vzdálenost $\pi' = \begin{pmatrix} 2 \\ -3 \\ -1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 1 \\ 9 \\ 14 \end{pmatrix}\right)$ a
 $\pi = \begin{pmatrix} 2 \\ 3 \\ 0 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 2 \\ 4 \\ 6 \end{pmatrix}, \begin{pmatrix} -3 \\ 1 \\ 2 \end{pmatrix}\right)$. Protože $\begin{vmatrix} 1 & 2 & -3 \\ 9 & 4 & 1 \\ 14 & 6 & 2 \end{vmatrix} = 0$, jsou
 π a π' rovnoběžné.

Platí

$$\omega(\pi, \pi') = \frac{|\det\begin{pmatrix} 2 & -3 & 0 \\ 4 & 1 & -6 \\ 6 & 2 & -1 \end{pmatrix}|}{\sqrt{\text{Gram}\left(\begin{pmatrix} 2 \\ 4 \\ 6 \end{pmatrix}, \begin{pmatrix} -3 \\ 1 \\ 2 \end{pmatrix}\right)}} = \frac{|\det\begin{pmatrix} 2 & -3 & 0 \\ 4 & 1 & -6 \\ 6 & 2 & -1 \end{pmatrix}|}{\sqrt{\det\begin{pmatrix} 56 & 10 \\ 10 & 14 \end{pmatrix}}} = \frac{142}{\sqrt{684}} \approx 5.43$$

Vzdálenost přímky od přímky v \mathbb{R}^3

Ať $\pi' = \mathbf{p}' + \text{span}(\mathbf{s}')$ a $\pi = \mathbf{p} + \text{span}(\mathbf{s})$ jsou přímky.

Platí

$$\text{span}(\mathbf{s}') \vee \text{span}(\mathbf{s}) = \begin{cases} \text{span}(\mathbf{s}), & \text{pokud } \mathbf{s}' \text{ a } \mathbf{s}, \text{ jsou lineárně závislé} \\ & \text{tj., pokud } \pi' \text{ a } \pi \text{ jsou rovnoběžné,} \\ \text{span}(\mathbf{s}', \mathbf{s}), & \text{pokud } \pi' \text{ a } \pi \text{ nejsou rovnoběžné.} \end{cases}$$

- ① Je-li $\text{span}(\mathbf{s}') \vee \text{span}(\mathbf{s}) = \text{span}(\mathbf{s})$, je

$$\omega(\pi', \pi) = \|\text{rej}_{\text{span}(\mathbf{s})}(\mathbf{p}' - \mathbf{p})\| = \omega(\mathbf{p}', \pi)$$

a vzdálenost bodu od přímky už umíme počítat.

- ② Je-li $\text{span}(\mathbf{s}') \vee \text{span}(\mathbf{s}) = \text{span}(\mathbf{s}', \mathbf{s})$, je

$$\omega(\pi', \pi) = \|\text{rej}_{\text{span}(\mathbf{s}', \mathbf{s})}(\mathbf{p}' - \mathbf{p})\| = \|\text{proj}_{\text{span}(\mathbf{s}' \times \mathbf{s})}(\mathbf{p}' - \mathbf{p})\|$$

$$= \frac{|\langle \mathbf{s}' \times \mathbf{s} \mid \mathbf{p}' - \mathbf{p} \rangle|}{\|\mathbf{s}' \times \mathbf{s}\|} = \frac{|\det(\mathbf{s}', \mathbf{s}, \mathbf{p}' - \mathbf{p})|}{\sqrt{\text{Gram}(\mathbf{s}', \mathbf{s})}}$$

Příklad

Najdeme vzájemnou vzdálenost $\pi' = \begin{pmatrix} 2 \\ 3 \\ 1 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix}\right)$ a
 $\pi = \begin{pmatrix} 2 \\ 3 \\ 0 \end{pmatrix} + \text{span}\left(\begin{pmatrix} 3 \\ 1 \\ -1 \end{pmatrix}\right)$. Přímky π a π' zjevně **nejsou rovnoběžné**.

Platí

$$\omega(\pi, \pi') = \frac{|\det\begin{pmatrix} 2 & 3 & 0 \\ 1 & 1 & 0 \\ 1 & -1 & 1 \end{pmatrix}|}{\sqrt{\text{Gram}\left(\begin{pmatrix} 2 \\ 1 \\ 1 \end{pmatrix}, \begin{pmatrix} 3 \\ 1 \\ -1 \end{pmatrix}\right)}} = \frac{|-1|}{\sqrt{\det\begin{pmatrix} 6 & 6 \\ 6 & 11 \end{pmatrix}}} = \frac{1}{\sqrt{30}} \approx 0.183$$