

# 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 Larry W. Cusick, *How to write proofs*

## 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

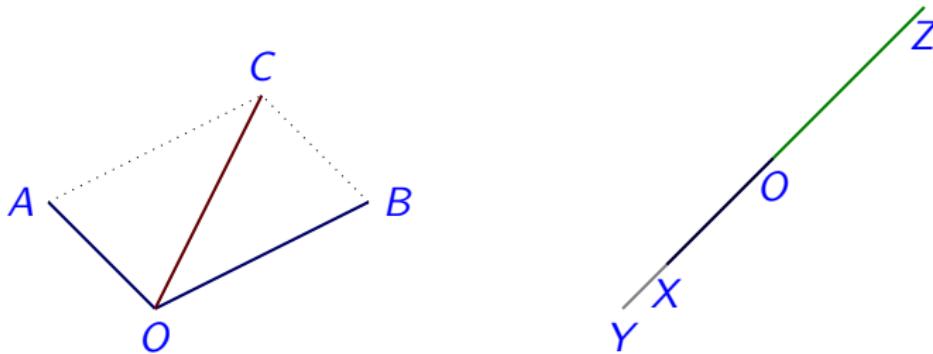
- ① Vektory v rovině (fyzikální, případně geometrická intuice).
- ② Reálné polynomy (značení:  $\mathbb{R}[x]$ ).
- ③  $n$ -tice reálných čísel (značení:  $\mathbb{R}^n$ ,  $n \geq 0$ ).<sup>a</sup>
- ④ Komplexní čísla (značení:  $\mathbb{C}$ ).
- ⑤ Řada dalších příkladů...

---

<sup>a</sup>Důležité: 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<sup>a</sup>  $(a_1, \dots, a_n)$ , 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 také  $\sum_{i=1}^n a_i \cdot \vec{x}_i$  nebo  $\sum_{i \in \{1, \dots, n\}} a_i \cdot \vec{x}_i$

---

<sup>a</sup>Těmto 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.<sup>a</sup>

Od příště budeme pracovat s lineárními prostory nad obecným tělesem.

---

<sup>a</sup>Do 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

- ❶ Standardní sčítání a násobení racionálních čísel: obě operace na množině  $\mathbb{Q}$  **splňují stejné vlastnosti** jako standardní sčítání a násobení na množině  $\mathbb{R}$ .
- ❷ Standardní sčítání a násobení komplexních čísel: obě operace na množině  $\mathbb{C}$  **splňují stejné vlastnosti** jako standardní sčítání a násobení na množině  $\mathbb{R}$ .
- ❸ 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!**<sup>a</sup>

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

---

<sup>a</sup>Toto dokážeme v přednášce 11B.

## 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<sup>a</sup>  $(a_1, \dots, a_n)$ , 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 také  $\sum_{i=1}^n a_i \cdot \vec{x}_i$  nebo  $\sum_{i \in \{1, \dots, n\}} a_i \cdot \vec{x}_i$

---

<sup>a</sup>Těmto 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.

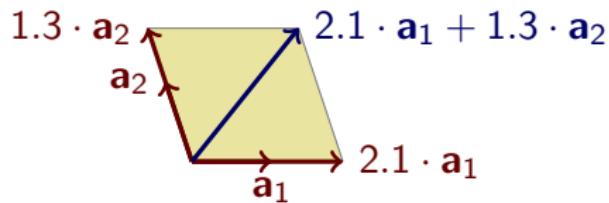
Všechny možné lineární kombinace vektoru  $\mathbf{a}_1$  vytvářejí v  $\mathbb{R}^2$  přímku procházející počátkem (se směrem  $\mathbf{a}_1$ ).

## 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

$$2x + 6y = 2$$

$$3x + 1y = 6$$

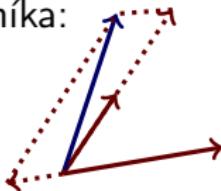
To znamená: koeficienty lineární kombinace jsou řešením jisté soustavy lineárních rovnic nad  $\mathbb{Z}_7$ .

## 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 zápisy:

- 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:<sup>a</sup> 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.

---

<sup>a</sup>Důležité: 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  $\vec{x}_1, \dots, \vec{x}_n \in M$ .

<sup>a</sup>Pozor: 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.<sup>a</sup>

<sup>a</sup>Toto 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 skalárního 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.<sup>a</sup>
- 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).

<sup>a</sup>Tomuto 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<sup>a</sup>

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

---

<sup>a</sup>V 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.<sup>a</sup>



<sup>a</sup>Budeme 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.<sup>a</sup>

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

---

<sup>a</sup>Za 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**.<sup>a</sup>

---

<sup>a</sup>**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  $a_1 \cdot \vec{x}_1 + \dots + a_n \cdot \vec{x}_n = \vec{o}$ , 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  $a_1 \cdot \vec{x}_1 + \dots + a_n \cdot \vec{x}_n = \vec{o}$ , 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:

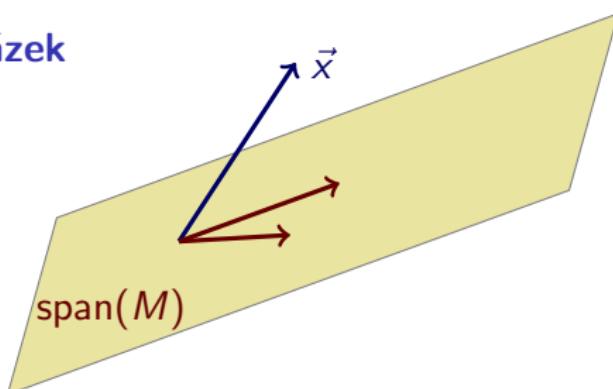
- ① Množina  $M$  je lineárně nezávislá.
- ② Pro každý vektor  $\vec{x} \notin \text{span}(M)$  je množina  $M \cup \{\vec{x}\}$  lineárně nezávislá.

### Důkaz.

Přednáška.



### Ilustrační obrázek



## Věta (charakterisace lineárně závislých množin)

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

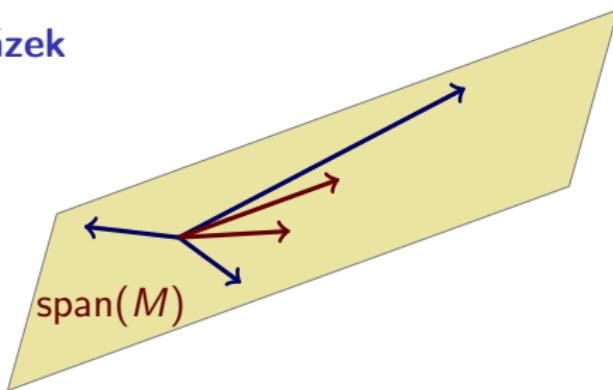
- ① Množina  $M$  je lineárně závislá.
- ② Existuje  $\vec{v} \in M$  tak, že  $\text{span}(M \setminus \{\vec{v}\}) = \text{span}(M)$ .

### 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 $\mathbb{F}^n$ , $n \geq 1$ )

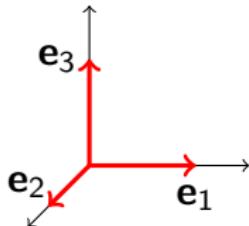
Ať  $\mathbb{F}$  je jakékoli těleso. Označme jako  $K_n = (\mathbf{e}_1, \dots, \mathbf{e}_n)$  následující **seznam** vektorů v  $\mathbb{F}^n$ ,  $n \geq 1$ :

$\mathbf{e}_i$  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,<sup>a</sup> kde  $n$  je přirozené číslo.

---

<sup>a</sup>A 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  $\{\vec{o}\}$  (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<sup>a</sup> lineárních podprostorů prostoru  $\mathbb{R}^n$  (dokonce na lineární podprostory prostoru  $\mathbb{F}^n$ ).

---

<sup>a</sup>To 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  
 $\dim(W_1) = \dim(W_2) = \dim(W_1 \vee W_2)$ .<sup>a</sup>

---

<sup>a</sup>Důkaz: 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:<sup>a</sup>

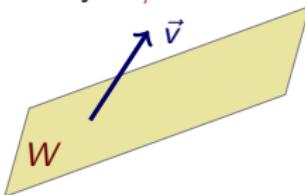
- ①  $\vec{v} \in W$
- ②  $\dim(W) = \dim(W \vee \text{span}(\vec{v}))$

---

<sup>a</sup>Důkaz: domácí cvičení. Postupujte následovně:

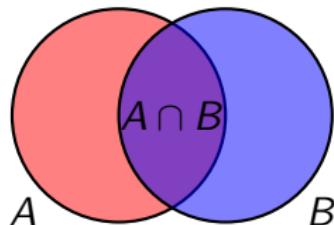
- ① Dokažte:  $\vec{v} \in W$  iff  $\text{span}(\vec{v}) \subseteq W$  iff  $W = W \vee \text{span}(\vec{v})$ .
- ② Použijte větu z předchozí stránky:  $W = W \vee \text{span}(\vec{v})$  iff  $\dim(W) = \dim(W \vee \text{span}(\vec{v})) = \dim(\underbrace{W \vee (W \vee \text{span}(\vec{v}))}_{=W \vee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

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.<sup>a</sup>

---

<sup>a</sup>Znovu 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.<sup>a</sup>

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

---

<sup>a</sup>Ve **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  $\mathbb{Q}$ .<sup>a</sup>

---

<sup>a</sup>Nepovinné: 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:<sup>a</sup>

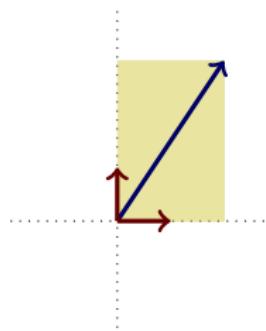
$$\mathbf{coord}_B(\vec{x}) = \begin{pmatrix} a_1 \\ \vdots \\ a_n \end{pmatrix}.$$

---

<sup>a</sup>Tj, souřadnice vektoru  $\vec{x}$  chápeme jako další vektor: vektor souřadnic v  $\mathbb{F}^n$ .

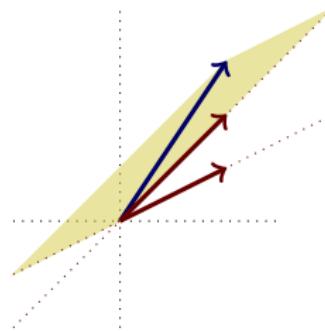
## Příklad (souřadnice stejného vektoru k různým bázím)

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  $\mathbb{R}^2$ .)



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

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



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

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

## 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:<sup>a</sup>

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

---

<sup>a</sup>Tyto 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<sup>a</sup> 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  $x \mapsto g(f(x))$ .

---

<sup>a</sup>Důležité 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:

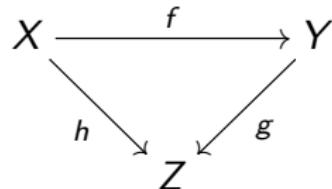
Zobrazení  $f : A \rightarrow B$  je podmnožina  $A \times B$  taková, že pro všechna  $a \in A$  existuje právě jedno  $b \in B$  tak, že  $(a, b) \in f$ .

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  $f : A \rightarrow \emptyset$ .

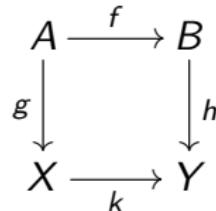
## Několik připomenutí (pokrač.)

### ④ Komutativní trojúhelník:



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

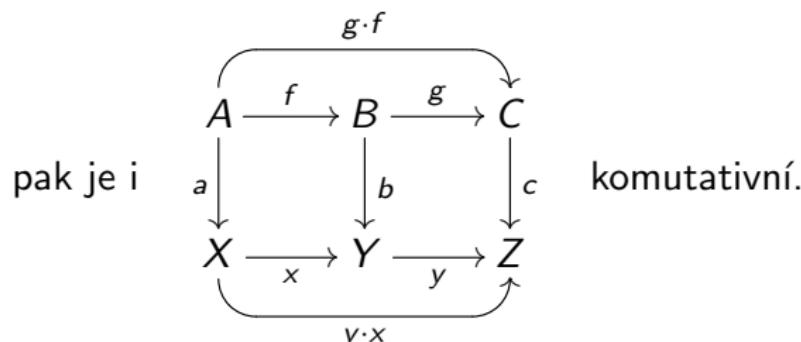
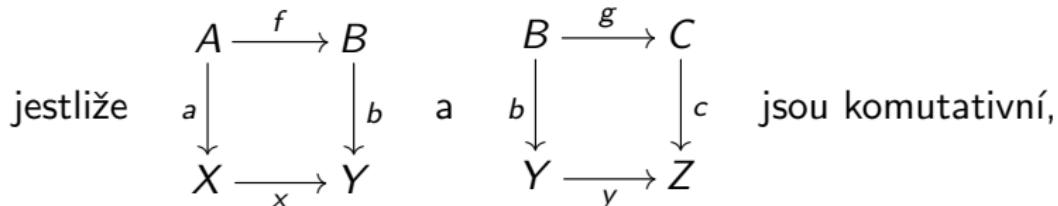
### ⑤ Komutativní čtverec:



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:<sup>a</sup>

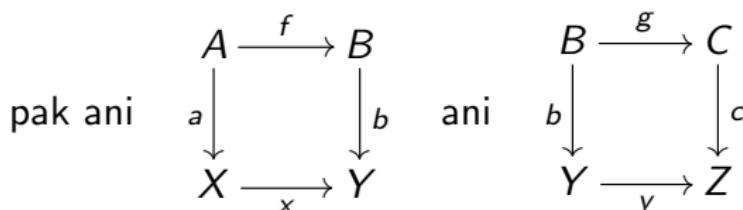
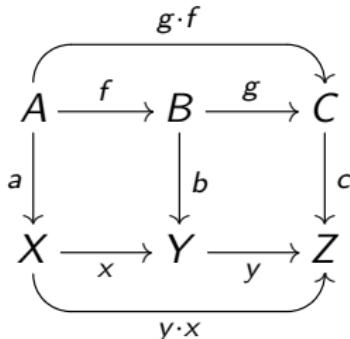


<sup>a</sup>Důležité: projděte si podrobně Příklady 2.2.1–2.2.3 skript.

## Několik připomenutí (pokrač.)

⑦ „Trhání“ komutativních diagramů:<sup>a</sup>

Jestliže je komutativní,



komutativní být nemusí.

<sup>a</sup>Důležité: 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<sup>a</sup>  $g : Y \rightarrow X$  tak, že  $g \cdot f = \text{id}_X$  a  $f \cdot g = \text{id}_Y$ .

---

<sup>a</sup>Tomuto 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 **coord <sub>$B$</sub>**  :  $L \rightarrow \mathbb{F}^n$  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<sup>a</sup> 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  $f : L_1 \rightarrow L_2$ .

---

<sup>a</sup>Připomenutí (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 **matici** (o  $r$  řádcích a  $s$  sloupcích).

## Definice (matice)

Matici  $\mathbf{A}$  nad  $\mathbb{F}$  o  $r$  řádcích a  $s$  sloupcích je tabulka<sup>a</sup>

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

<sup>a</sup>Budeme 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

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

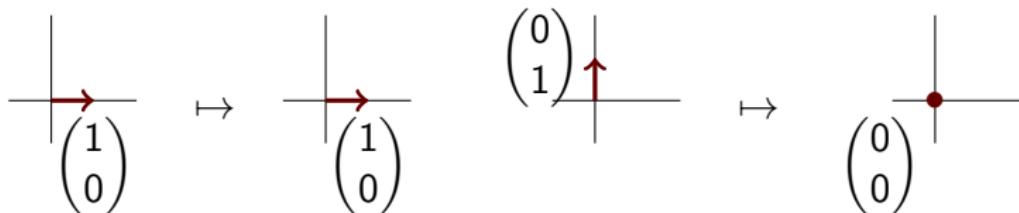
z prostoru  $\mathbb{F}^s$  do prostoru  $\mathbb{F}^r$ , a budeme psát  $\mathbf{A} : \mathbb{F}^s \longrightarrow \mathbb{F}^r$ .



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

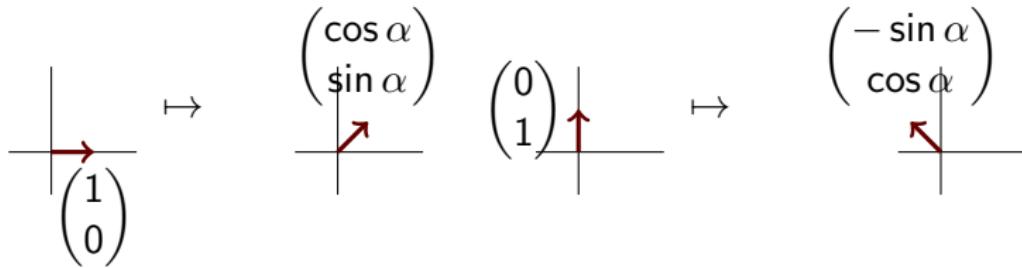


Analogicky: projekce na osu  $y$  je ztotožněna s maticí  $\mathbf{P}_y = \begin{pmatrix} 0 & 0 \\ 0 & 1 \end{pmatrix}$ .

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

- ② Rotace (o úhel  $\alpha$ ) 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<sup>a</sup> (také: shear) je ztotožněno s maticí

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

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

---

<sup>a</sup>Speciální 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  $\alpha$ , **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  $\alpha$ ):  $\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$ . 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  $\alpha$ .

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<sup>a</sup> 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  $\mathbb{F}^r$ .

---

<sup>a</sup>Říkáme 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<sup>a</sup>  $\mathbf{B}$  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  $\text{Lin}(\mathbb{F}^s, \mathbb{F}^r)$ .

<sup>a</sup>Tomuto 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<sup>a</sup>

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

je  $\mathbf{B} \cdot \mathbf{A}$  matice, <sup>b</sup> ježíž  $j$ -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  $\mathbf{A}$ .

---

<sup>a</sup>Diagram 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.**

<sup>b</sup>Položkový 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  $\alpha$ ):  $\begin{pmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{pmatrix}$ .

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  $\alpha$ , **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  $\alpha$ “.

## Příklad (reflexe podle osy, která svírá úhel $\alpha$ s osou x)

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

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

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

## Poznámka

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

---

<sup>a</sup>Důležité: 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<sup>a</sup>  $\mathbf{E}_n : \mathbb{F}^n \rightarrow \mathbb{F}^n$  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:

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

---

<sup>a</sup> 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.<sup>a</sup>

---

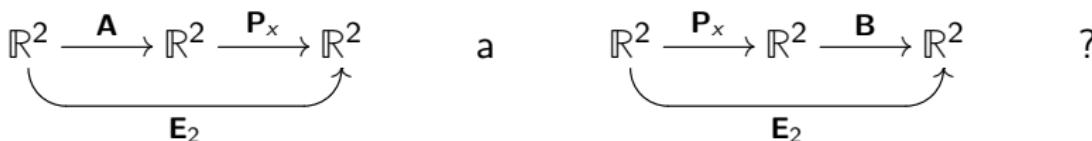
<sup>a</sup> Řešení lze napsat i ve tvaru  $\begin{pmatrix} 3 \\ 0 \end{pmatrix} + \text{span}(\begin{pmatrix} 0 \\ 1 \end{pmatrix})$ . Jak uvidíme, tento druhý způsob zápisu řešení bude mít mnohé výhody.

## 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  $\mathbf{A} : \mathbb{F}^s \rightarrow \mathbb{F}^r$ ,  $\mathbf{e}_j \mapsto \mathbf{a}_j$ .

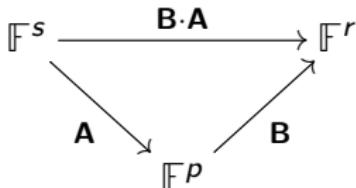
Operace s maticemi odpovídají operacím s lineárními zobrazeními.

## 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<sup>a</sup>  $\mathbf{A} : \mathbf{e}_j \mapsto j$ -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.

---

<sup>a</sup>V 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.<sup>a</sup>

---

<sup>a</sup>Ekvivalentně: 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.

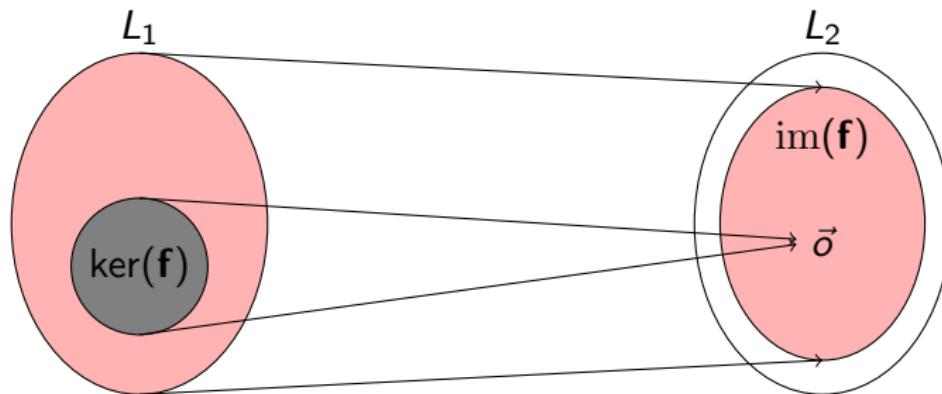
Přednáška.

## 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  $L_2$ .<sup>a</sup>

---

<sup>a</sup>Obecněji:  $\{f(\vec{w}) \mid \vec{w} \in W\}$  je podprostor  $L_2$ , pro jakýkoli podprostor  $W$  prostoru  $L_1$ .

## Důkaz.

Přednáška.



## Definice (defekt a hodnost lineárního zobrazení)

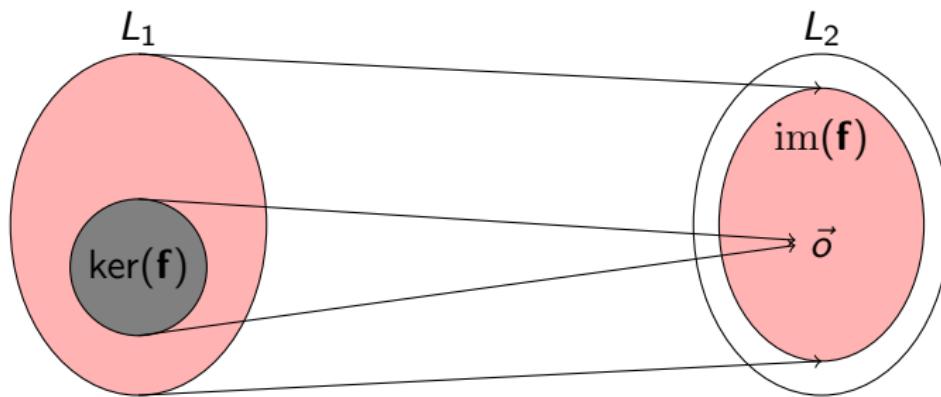
Ať  $f : L_1 \rightarrow L_2$  je lineární zobrazení, ať prostor  $L_1$  má konečnou dimensi. Číslu  $\text{def}(f) = \dim(\ker(f))$  říkáme **defekt** lineárního zobrazení  $f$  a číslu  $\text{rank}(f) = \dim(\text{im}(f))$  říkáme **hodnost** (také: **rank**) lineárního zobrazení  $f$ .

## 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 $\alpha$ 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.<sup>a</sup>

---

<sup>a</sup>Inversním zobrazením rotace o úhel  $\alpha$  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.

## 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:

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

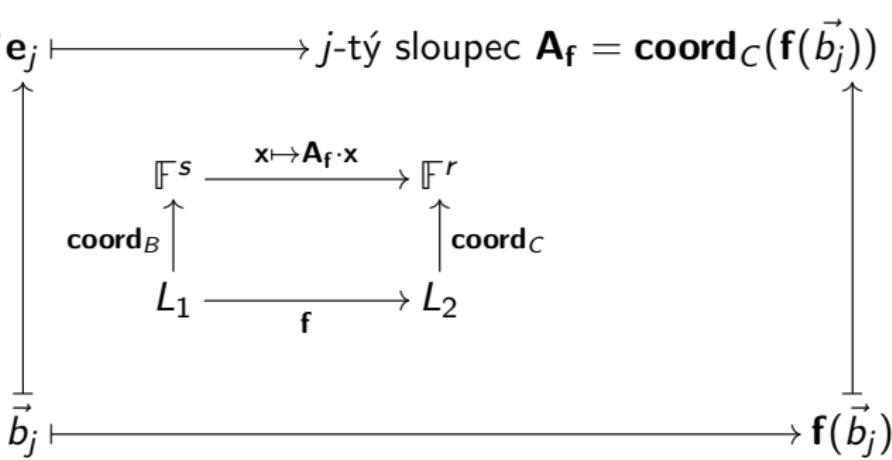
$$\vec{x} \longmapsto \mathbf{f}(\vec{x})$$

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.

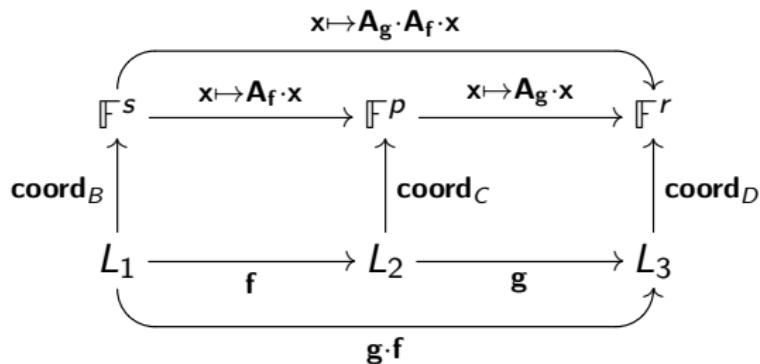
### Důkaz.



## 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.

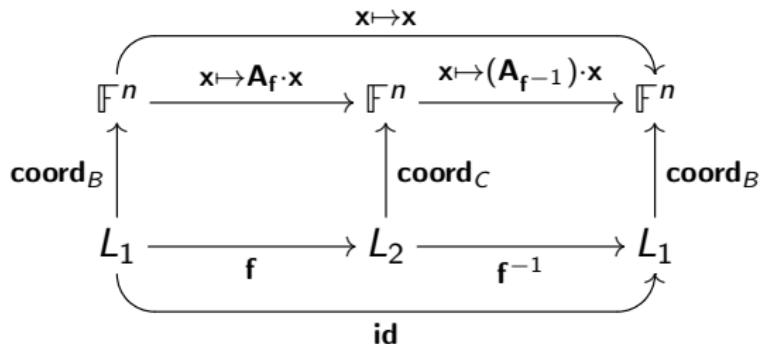


## Věta (matice isomorfismu)

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  $B$ ).<sup>a</sup>

<sup>a</sup>Tj. 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  $\leq 3$  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.

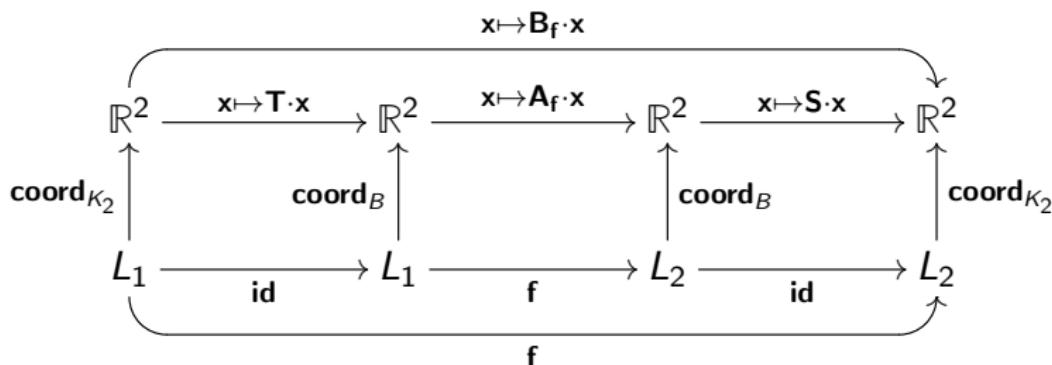
Vzhledem k nekanonické bázi  $B = (\begin{pmatrix} 1 \\ -1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \end{pmatrix})$  má tedy  $f$  matici

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

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.<sup>a</sup>

---

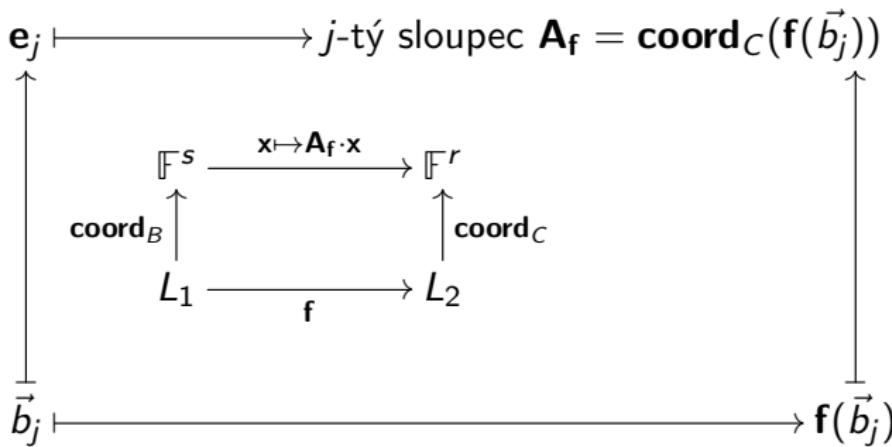
<sup>a</sup>Řadu příkladů tedy v této přednášce nedopočítáme až do konce.

## Příští přednáška

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

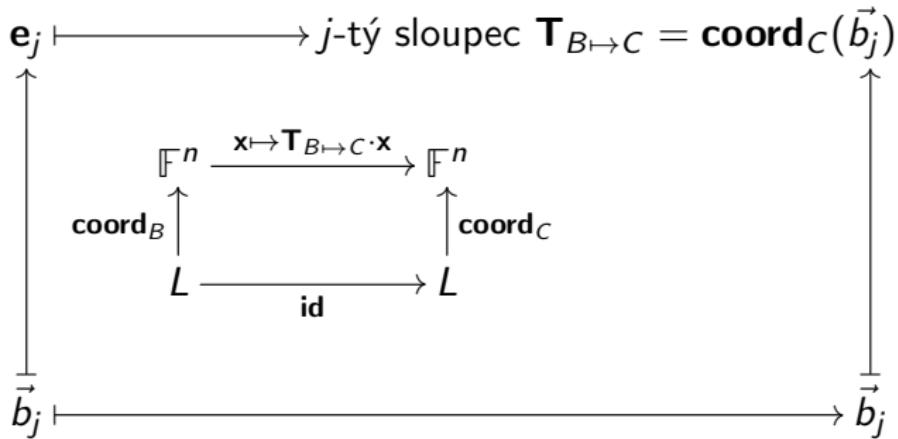
## Připomenutí (výpočet matice lineárního zobrazení)

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<sup>a</sup>  $\mathbf{T}_{B \mapsto C}$ , která splňuje



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

---

<sup>a</sup>Všimněte 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 plyně 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<sup>a</sup> matici  $\mathbf{T}_{B \mapsto C}$ .

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

---

<sup>a</sup>Uvidíme 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<sup>a</sup> maticovou rovnici  $\mathbf{T}_{C \mapsto K_n} \cdot \mathbf{X} = \mathbf{T}_{B \mapsto K_n}$ .

<sup>a</sup>Uvidíme 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)

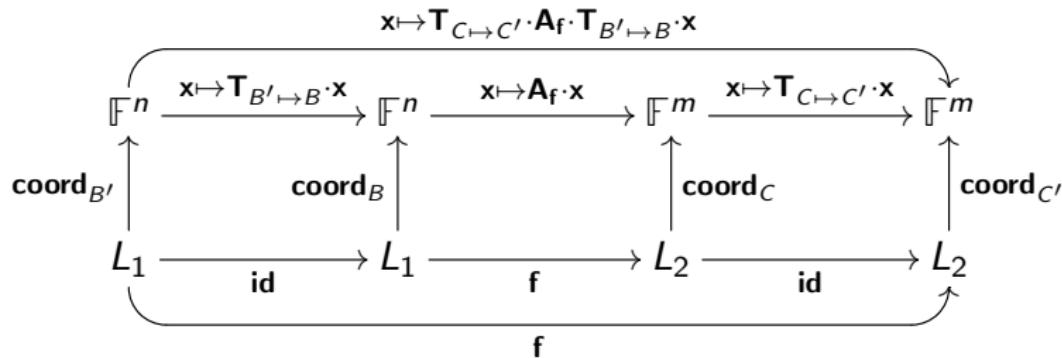
Ať  $\mathbf{f} : L_1 \rightarrow L_2$  je lineární zobrazení,  $\dim(L_1) = n$ ,  $\dim(L_2) = m$ .

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<sup>a</sup>

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

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  $f$ ).

<sup>a</sup>Minulá 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 **matice 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 matice 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  $\mathbb{R}$ .

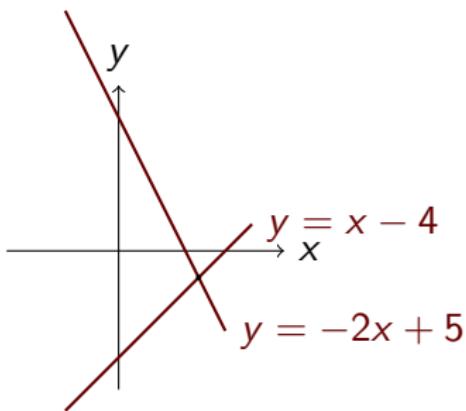
## Připomenutí (dva pohledy na řešení soustav)

Pro soustavu

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

nad  $\mathbb{R}$  je řešení

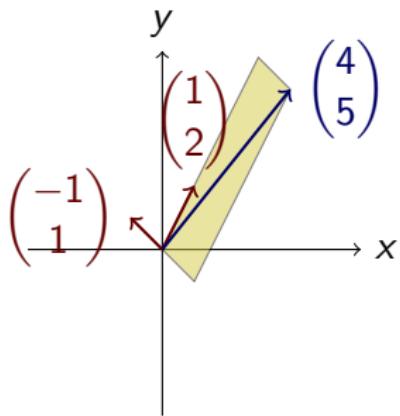
- ① Průsečík dvou přímek:  $x - y = 4$  a  $2x + y = 5$ :



## Připomenutí (dva pohledy na řešení soustav, pokrač.)

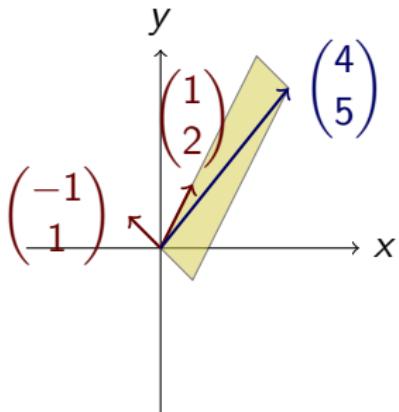
- ② Pravá strana je lineární kombinací sloupců matice soustavy

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

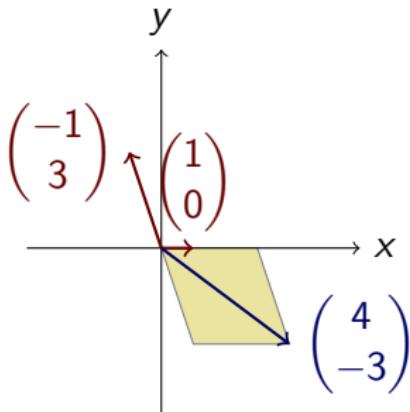


Řešení jsou koeficienty této lineární kombinace.

## 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:<sup>a</sup>

- 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.

<sup>a</sup>Pozorování:  $\mathbf{M}$  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)

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

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

---

<sup>a</sup>Slogan: Ekvivalentní soustavy **stejných** rozměrů mají stejná řešení.

## Tvrzení (základní vlastnosti ekvivalence soustav)

Platí:

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

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

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

## 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<sup>a</sup> 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  $(\mathbf{A} \mid \mathbf{b}) \sim (\mathbf{A}' \mid \mathbf{b}')$ .

---

<sup>a</sup>Důležité: 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<sup>a</sup>** 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  $\mathbf{M}$ .

---

<sup>a</sup>Matice  $\mathbf{M}^T$  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:<sup>a</sup>

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  $\ker(\mathbf{A})$ .

---

<sup>a</sup>Budeme 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 ( $\mathbf{A} | \mathbf{0}$ )

- ① GEM:  $(\mathbf{A} | \mathbf{0}) \sim (\mathbf{A}' | \mathbf{0})$ .
- 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  $(\mathbf{A}' | \mathbf{0})$  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  $\mathbf{A} = (2 \ 3 \ -4)$  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  $\rho$  v prostoru  $\mathbb{R}^3$ . Tato rovina  $\rho$  je v obecné poloze (rovina  $\rho$  neprochází počátkem, protože  $2 \neq 0$ ).

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

### Poznámka

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

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

$$\left( \begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 1 & 1 & 1 & -1 & 5 \\ 2 & 8 & 5 & 3 & 7 \\ 3 & 9 & 6 & 2 & 12 \end{array} \right) \sim \left( \begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & -2 & -1 & -1 & 2 \\ 0 & 2 & 1 & 3 & 1 \\ 0 & 0 & 0 & 2 & 3 \end{array} \right) \begin{matrix} R_1 \\ R_2 - R_1 \\ R_3 - 2R_1 \\ R_4 - 3R_1 \end{matrix}$$

$$\sim \left( \begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 2 & 3 \\ 0 & 0 & 0 & 2 & 3 \end{array} \right) \begin{matrix} R_1 \\ -1/2R_2 \\ R_3 + R_2 \\ R_4 \end{matrix}$$

$$\sim \left( \begin{array}{cccc|c} 1 & 3 & 2 & 0 & 3 \\ 0 & 1 & \frac{1}{2} & \frac{1}{2} & -1 \\ 0 & 0 & 0 & 1 & \frac{3}{2} \\ 0 & 0 & 0 & 0 & 0 \end{array} \right) \begin{matrix} R_1 \\ R_2 \\ 1/2R_3 \\ R_4 - R_3 \end{matrix}$$

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<sup>a</sup>

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

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  $\mathbf{R}_\alpha$ .

Jak nalézt všechna řešení? Předvedeme universální metodu.

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

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

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

<sup>a</sup>Geometrický význam: hledáme všechny transformace  $\mathbf{X}$  roviny, které jsou záměnné s rotací o úhel  $\alpha$ .



## 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  $\pi$  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  $\mathbf{R}_\alpha$  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<sup>a</sup>  
$$\mathbf{A} \cdot \mathbf{X} = \mathbf{B}.$$

---

<sup>a</sup>Protože 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.<sup>a</sup>
- 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:  $\mathbf{X} = (\mathbf{x}_1 \ \mathbf{x}_2 \ \dots \ \mathbf{x}_p)$ .

---

<sup>a</sup>Jak 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

$$\mathbf{X} = \begin{pmatrix} 3 - 7a & -7b \\ a & b \\ -1 + 5a & 1 + 5b \end{pmatrix} = \begin{pmatrix} 3 & 0 \\ 0 & 0 \\ -1 & 1 \end{pmatrix} + a \cdot \begin{pmatrix} -7 & 0 \\ 1 & 0 \\ 5 & 0 \end{pmatrix} + b \cdot \begin{pmatrix} 0 & -7 \\ 0 & 1 \\ 0 & 5 \end{pmatrix}$$

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  $\mathbf{A} \cdot \mathbf{x} = \mathbf{0}$ , 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

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

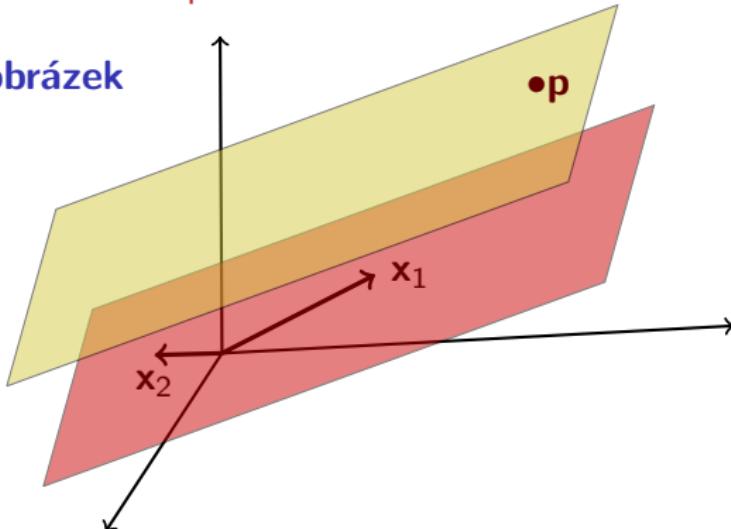
kde vektory  $\mathbf{x}_1, \dots, \mathbf{x}_d$  jsou lineárně nezávislé.

## 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  $\mathbb{F}^s$ .<sup>a</sup> Seznamu  $(\mathbf{x}_1, \dots, \mathbf{x}_d)$  říkáme **směr** (také: **zaměření**) tohoto podprostoru.

<sup>a</sup>Také:  **$d$ -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<sup>a</sup>  $\mathbf{X}^T \cdot \mathbf{a} = \mathbf{o}$  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  $\mathbf{A} \cdot \mathbf{p} = \mathbf{b}$ .



<sup>a</sup>Pozor: 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:<sup>a</sup> 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:  $\mathbf{A} = \begin{pmatrix} -2 & -1 & 5 & 4 & 0 \\ 2 & -1 & -3 & 0 & 4 \end{pmatrix}$ .

<sup>a</sup>Fundamentální 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,<sup>a</sup> 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**).

---

<sup>a</sup>Viz 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

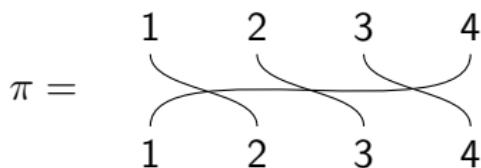
- ① Hlubší poznatky o determinantech.
- ② Aplikace determinantu na řešení čtvercových soustav lineárních rovnic.

## 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: <sup>a</sup>  $\pi = \begin{bmatrix} 1 & 2 & 3 & 4 \\ 2 & 3 & 4 & 1 \end{bmatrix}$
- ③ Strunovým diagramem: <sup>b</sup>



Strunový diagram čteme odhora dolů.

<sup>a</sup>Upozornění: tato tabulka není matice ve smyslu našeho předmětu.

<sup>b</sup>Řešené 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  $\pi$  a potom  $\sigma$  (směrem shora dolů):

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

## 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  $\text{id}_n$ ), každá permutace má inversi vzhledem ke skládání  $\cdot$  (značení a terminologie:  $\pi^{-1}$  je **inversní permutace** k permutaci  $\pi$ ).

## Důkaz.

Plyne okamžitě z vlastností bijekcí.



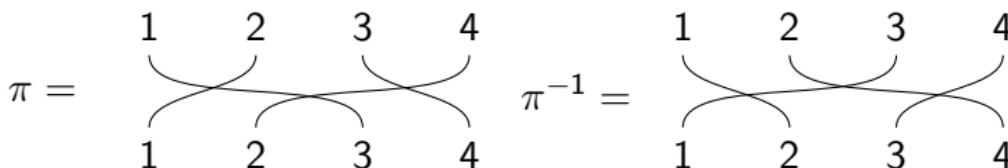
## Definice (znaménko permutace)

Ať  $\pi$  je permutace množiny  $\{1, \dots, n\}$ . Znaménko permutace  $\pi$  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  $\text{id}_n$  v  $S_n$  platí  $\text{sign}(\text{id}_n) = 1$ .
- ② Pro libovolné permutace  $\sigma$  a  $\pi$  v  $S_n$  platí  
 $\text{sign}(\sigma \cdot \pi) = (\text{sign } \sigma) \cdot (\text{sign } \pi)$ .
- ③ Ať  $\pi$  je permutace v  $S_n$ . Pak platí  $\text{sign } \pi = \text{sign}(\pi^{-1})$ .
- ④ Ať  $\pi$  je permutace v  $S_n$ . Označte jako  $\sigma$  permutaci v  $S_n$  vzniklou z  $\pi$  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  $\pi$  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.<sup>a</sup>

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

---

<sup>a</sup>Připomenutí: Položka  $a_{\pi(j),j}$  matice  $\mathbf{A}$  je položka v  $j$ -tém sloupci na  $\pi(j)$ -tému řádku.



## Příklad (Sarrusovo pravidlo pro matice $3 \times 3$ )

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

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

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

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

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

$$\pi_3 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline | & \diagup & | \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

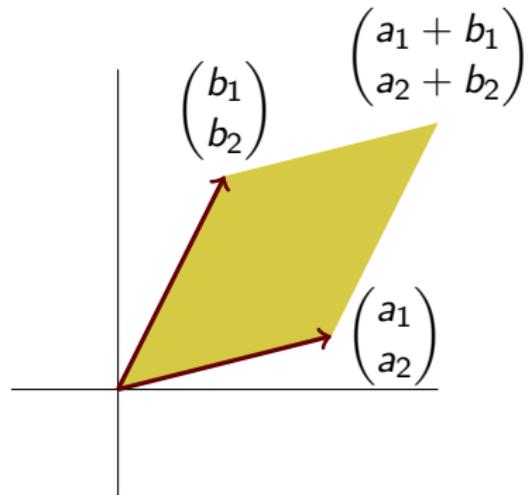
$$\pi_5 = \begin{array}{|c|c|c|} \hline 1 & 2 & 3 \\ \hline \diagup & \diagup & \diagup \\ \hline 1 & 2 & 3 \\ \hline \end{array}$$

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 $2 \times 2$ 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



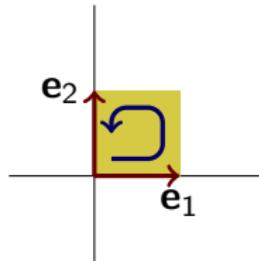
$$\text{kde } \mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} \text{ a } \mathbf{b} = \begin{pmatrix} b_1 \\ b_2 \end{pmatrix}.$$



## Geometrie determinantu (pokrač.)

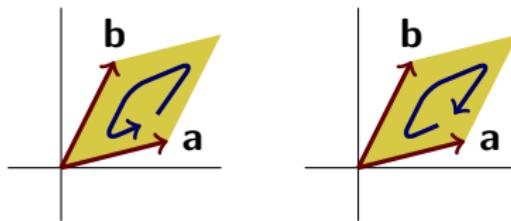
Vlastnosti velikosti  $P(\mathbf{a}, \mathbf{b})$  orientované plochy jsou:

- 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.



$$P(\mathbf{a}, \mathbf{b}) = -P(\mathbf{b}, \mathbf{a})$$

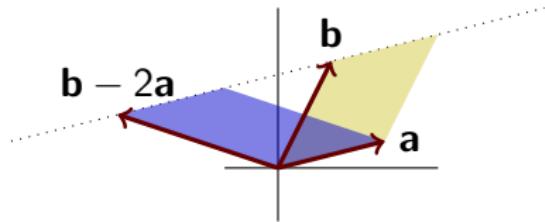
## Geometrie determinantu (pokrač.)

- 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  $\pi$  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**<sup>a</sup> 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

---

<sup>a</sup>Na 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.<sup>a</sup>
- ② Hlubší poznatky o determinantu.
- ③ Aplikace determinantu na řešení čtvercových soustav lineárních rovnic (Cramerova věta). Ukážeme geometrický význam Cramerovy věty.

---

<sup>a</sup>Víme:  $\det(\mathbf{A}^T) = \det(\mathbf{A})$ . 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:<sup>a</sup>

$$\det(\mathbf{A}) = \sum_{i=1}^n a_{ij} \cdot \underbrace{\det(\mathbf{a}_1, \dots, \mathbf{a}_{j-1}, \mathbf{e}_i, \mathbf{a}_{j+1}, \dots, \mathbf{a}_n)}_{\text{Značení: } A_{ij}}.$$

Například (zvolili jsme  $j = 2$ , tj. rozvíjíme podle druhého sloupce):

$$\left| \begin{array}{ccc} -2 & 4 & 5 \\ 3 & 6 & 7 \\ 7 & -2 & 5 \end{array} \right| = 4 \cdot \underbrace{\left| \begin{array}{ccc} -2 & 1 & 5 \\ 3 & 0 & 7 \\ 7 & 0 & 5 \end{array} \right|}_{A_{12}} + 6 \cdot \underbrace{\left| \begin{array}{ccc} -2 & 0 & 5 \\ 3 & 1 & 7 \\ 7 & 0 & 5 \end{array} \right|}_{A_{22}} - 2 \cdot \underbrace{\left| \begin{array}{ccc} -2 & 0 & 5 \\ 3 & 0 & 7 \\ 7 & 1 & 5 \end{array} \right|}_{A_{32}}$$

<sup>a</sup>Této 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<sup>a</sup>  $A_{ij} = (-1)^{i+j} \cdot \det(\mathbf{A}_{ij})$ .

---

<sup>a</sup>Pozor: 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)

$$\begin{vmatrix} 1 & 2 & 0 & 1 \\ 2 & 7 & 6 & 3 \\ 5 & 2 & 0 & 3 \\ 3 & 2 & 5 & 1 \end{vmatrix} = 0 \cdot (-1)^{1+3} \cdot \underbrace{\begin{vmatrix} 2 & 7 & 3 \\ 5 & 2 & 3 \\ 3 & 2 & 1 \end{vmatrix}}_{A_{13}}$$

$$+ 6 \cdot (-1)^{2+3} \cdot \underbrace{\begin{vmatrix} 1 & 2 & 1 \\ 5 & 2 & 3 \\ 3 & 2 & 1 \end{vmatrix}}_{A_{23}}$$

$$+ 0 \cdot (-1)^{3+3} \cdot \underbrace{\begin{vmatrix} 1 & 2 & 1 \\ 2 & 7 & 3 \\ 3 & 2 & 1 \end{vmatrix}}_{A_{33}}$$

$$+ 5 \cdot (-1)^{4+3} \cdot \underbrace{\begin{vmatrix} 1 & 2 & 1 \\ 2 & 7 & 3 \\ 5 & 2 & 3 \end{vmatrix}}_{A_{43}}$$



## 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  $\text{adj}(\mathbf{A}) = \begin{pmatrix} 3 & -7 \\ -5 & 2 \end{pmatrix}$ .



## Cramerova věta (o vztahu matice a adjungované matice)

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  $2 \times 2$ .

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.<sup>a</sup>

---

<sup>a</sup>Pozor: 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 o řešení regulárních soustav (také: Cramerovo pravidlo pro řešení regulárních soustav)

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  $\begin{pmatrix} 2 & 4 \\ -3 & 5 \end{pmatrix} \mid \begin{matrix} 1 \\ 6 \end{matrix}$  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:

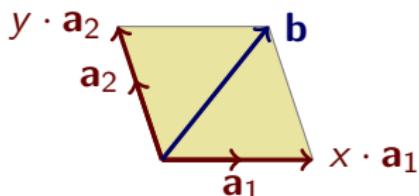
$$\frac{\begin{vmatrix} 2 & 1 \\ -3 & 6 \end{vmatrix}}{\begin{vmatrix} 2 & 4 \\ -3 & 5 \end{vmatrix}} = \frac{15}{22}.$$

Jediné řešení:  $\begin{pmatrix} \frac{-19}{22} \\ \frac{15}{22} \end{pmatrix}$ .

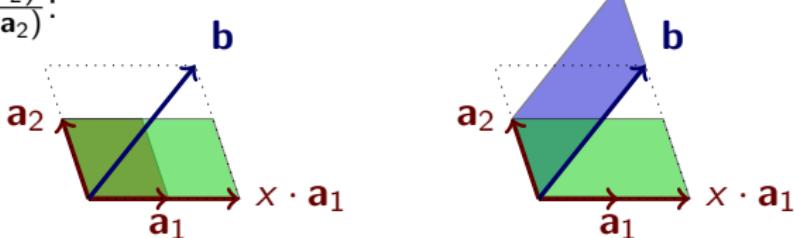
## Geometrie Cramerovy věty pro soustavy $2 \times 2$ nad $\mathbb{R}$

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  $y = \frac{\det(\mathbf{a}_1, \mathbf{b})}{\det(\mathbf{a}_1, \mathbf{a}_2)}$ .

<sup>a</sup>Analogicky 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.<sup>a</sup>

---

<sup>a</sup>Tyto 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<sup>a</sup>  $\mathbf{A} \cdot \mathbf{q} = \mathbf{q}$ .

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  $\mathbf{q} = \begin{pmatrix} 1 \\ 1 \end{pmatrix}$ .

---

<sup>a</sup> 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  $\lambda$  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  $\lambda$  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<sup>a</sup>  $\text{span}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right)$ .

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<sup>b</sup>  $\text{span}\left(\begin{pmatrix} -7 \\ 8 \end{pmatrix}\right)$ .

To znamená:  $\mathbf{A} \cdot \mathbf{x} = -0.5 \cdot \mathbf{x}$  pro všechna  $\mathbf{x}$  ze  $\text{span}\left(\begin{pmatrix} -7 \\ 8 \end{pmatrix}\right)$ .

<sup>a</sup>To jsme již věděli.

<sup>b</sup>To 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 matici  $\mathbf{A}$  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

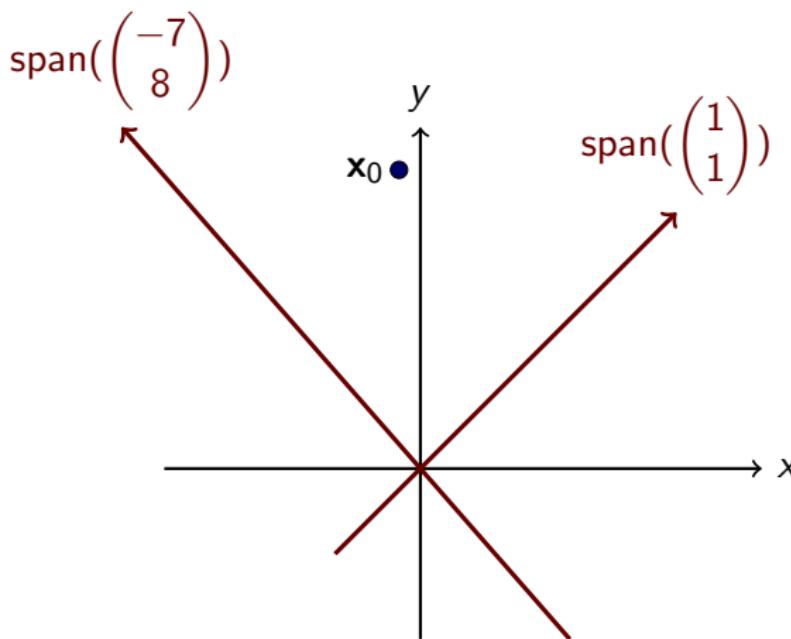
$\mathbf{x}_0$  libovolný vektor z  $\mathbb{R}^2$ ,  $\mathbf{A} \cdot \mathbf{x}_k = \mathbf{x}_{k+1}$ ,  $k \geq 0$ ,

pak se **posloupnost** vektorů  $\mathbf{x}_0, \mathbf{x}_1, \mathbf{x}_2, \dots$  chová následovně:

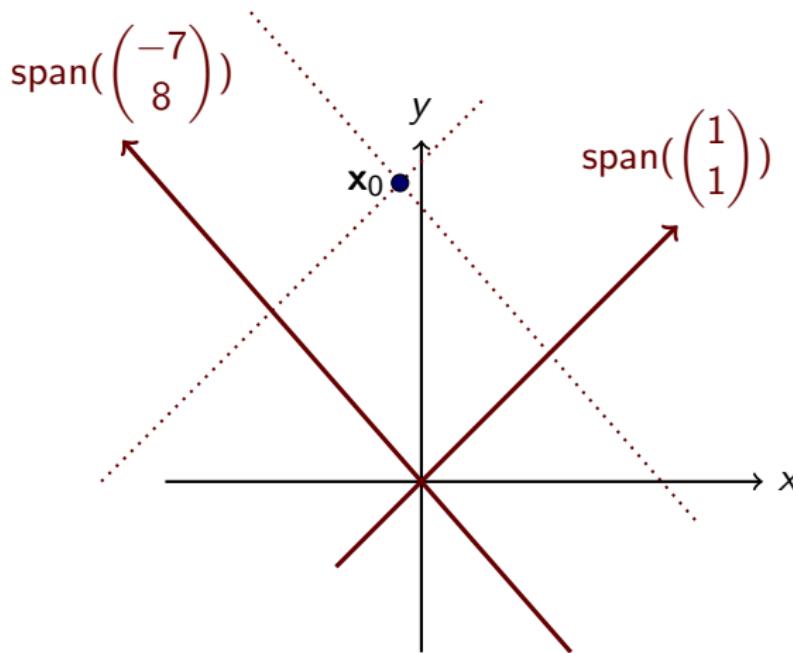
- ① Je-li  $\mathbf{x}_0$  na přímce  $\text{span}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right)$ , jde o posloupnost  $\mathbf{x}_0, \mathbf{x}_0, \mathbf{x}_0, \dots$
- ② Je-li  $\mathbf{x}_0$  na přímce  $\text{span}\left(\begin{pmatrix} -7 \\ 8 \end{pmatrix}\right)$ , jde o posloupnost  $\mathbf{x}_0, -0.5 \cdot \mathbf{x}_0, (-0.5)^2 \cdot \mathbf{x}_0, (-0.5)^3 \cdot \mathbf{x}_0, \dots$
- 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.

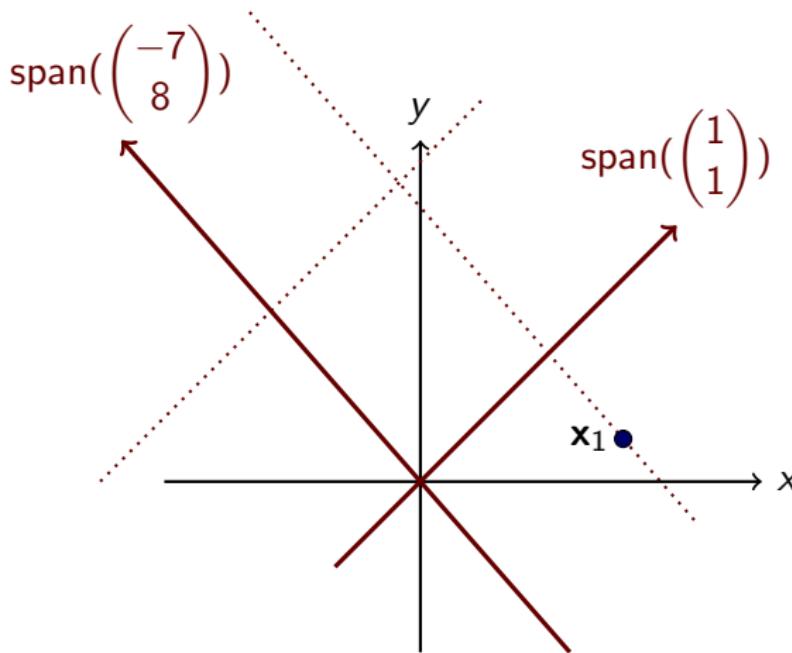
## Příklad (equilibrium stochastických procesů, pokrač.)



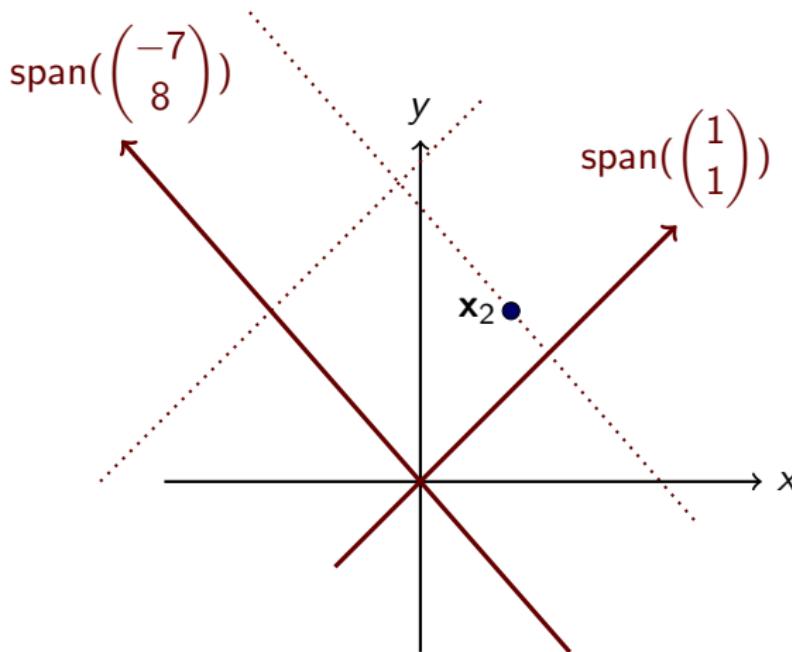
## Příklad (equilibrium stochastických procesů, pokrač.)



## 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  $\lambda$  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**  $\lambda$ .

## Pozorování

Ať  $f : L \rightarrow L$  je lineární zobrazení.

- ① Pro libovolné  $\lambda$  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  $\lambda$  tvoří podprostor  $L$ .<sup>a</sup>
- ②  $\lambda$  je vlastní hodnota  $f$  právě tehdy, když  $\text{eigen}(\lambda, f)$  je netriviální prostor.

---

<sup>a</sup>Říkáme mu **vlastní podprostor** příslušný  $\lambda$ , 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  $\text{char}_{\mathbf{A}}(x) = \text{char}_{\mathbf{B}}(x)$ .<sup>a</sup>  
Důvod:

$$\begin{aligned}\det(\mathbf{B} - x\mathbf{E}_n) &= \det(\mathbf{T}^{-1}\mathbf{AT} - x\mathbf{E}_n) = \det(\mathbf{T}^{-1}\mathbf{AT} - \mathbf{T}^{-1}x\mathbf{T}) = \\ \det(\mathbf{T}^{-1}(\mathbf{A} - x\mathbf{E}_n)\mathbf{T}) &= \det(\mathbf{T}^{-1}) \det(\mathbf{A} - x\mathbf{E}_n) \det(\mathbf{T}) = \\ \det(\mathbf{A} - x\mathbf{E}_n).\end{aligned}$$

---

<sup>a</sup>**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  $\lambda$  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  $\lambda$  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

$$\text{eigen}(3, \mathbf{B}) = \text{span}\left(\begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}\right) \text{ a } \text{eigen}(2, \mathbf{B}) = \text{span}\left(\begin{pmatrix} 0 \\ 3 \\ 4 \end{pmatrix}\right).$$

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  $\mathbf{A} \approx \mathbf{D}$ ,<sup>a</sup> 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

$$(\lambda_1 \cdot \mathbf{e}_1, \lambda_2 \cdot \mathbf{e}_2, \lambda_3 \cdot \mathbf{e}_3, \dots, \lambda_n \cdot \mathbf{e}_n)$$

---

<sup>a</sup>Přesněji:  $\mathbf{A} = \mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1}$ , kde  $\mathbf{T}$  je regulární matic.

## Myšlenka nalezení matic $\mathbf{T}$ a $\mathbf{D}$ v rovnici $\mathbf{A} = \mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1}$

Ať  $\mathbf{D} = D(\lambda_1; \dots; \lambda_n)$ .

- ① Rovnost  $\mathbf{A} = \mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1}$  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  $\mathbf{A} = \mathbf{T} \cdot D(\lambda_1, \dots, \lambda_n) \cdot \mathbf{T}^{-1}$  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  $\lambda_j$  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  $a_1 \cdot \mathbf{t}_{j_1} + a_2 \cdot \mathbf{t}_{j_2} = \mathbf{o}$  plyne

$$\begin{aligned}\mathbf{o} &= (\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot \mathbf{o} \\ &= (\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot (a_1 \cdot \mathbf{t}_{j_1} + a_2 \cdot \mathbf{t}_{j_2}) \\ &= a_1 \cdot \underbrace{(\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot \mathbf{t}_{j_1}}_{\neq \mathbf{o}} + a_2 \cdot \underbrace{(\mathbf{A} - \lambda_{j_2} \cdot \mathbf{E}) \cdot \mathbf{t}_{j_2}}_{=\mathbf{o}}\end{aligned}$$

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  $\lambda$  jako kořene  $\text{char}_{\mathbf{A}}(x)$  je rovna  $\dim(\text{eigen}(\lambda, \mathbf{A}))$ .<sup>a</sup>

---

<sup>a</sup>Násobnosti  $\lambda$  jako kořene  $\text{char}_{\mathbf{A}}(x)$  se někdy říká **algebraická násobnost**  $\lambda$ , číslu  $\dim(\text{eigen}(\lambda, \mathbf{A}))$  se někdy říká **geometrická násobnost**  $\lambda$ .

### 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  $\mathbf{A} = \mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1}$ , 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.<sup>a</sup>

---

<sup>a</sup>Tyto 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).<sup>a</sup>

<sup>a</sup>Této vlastnosti tělesa  $\mathbb{C}$  se říká algebraická uzavřenosť.

- ① Komplexní číslo  $\lambda$  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  $\lambda$  má jako kořen  $p(x)$  **násobnost nula** právě tehdy, když  $\lambda$  není kořenem polynomu  $p(x)$ .

## Důsledek (téma 8B, 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  $\lambda$  platí: násobnost  $\lambda$  jako kořene polynomu  $\text{char}_{\mathbf{A}}(x)$  je rovna  $\dim(\text{eigen}(\lambda, \mathbf{A}))$ .

## Příklad

Pauliho matice<sup>a</sup> 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.

---

<sup>a</sup>Jde 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  $\sigma_x$  (také:  $\sigma_1$ )     $\sigma_y$  (také:  $\sigma_2$ )     $\sigma_z$  (také:  $\sigma_3$ )

**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  $\delta_{jk}$  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  $\epsilon_{jkl}$  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 matice (**nepovinné**)

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.<sup>a</sup>

Potom lze dokázat, že  $\mathbf{A}$  je „téměř diagonalisovatelná“. Přesněji: platí  $\mathbf{A} \approx \mathbf{J}$ , kde

$$\mathbf{J} = \begin{pmatrix} \mathbf{J}_1 & 0 & 0 & 0 & \dots & 0 \\ 0 & \mathbf{J}_2 & 0 & 0 & \dots & 0 \\ 0 & 0 & \mathbf{J}_3 & 0 & \dots & 0 \\ \vdots & & & & & \\ 0 & 0 & 0 & 0 & \dots & \mathbf{J}_n \end{pmatrix}$$

---

<sup>a</sup>To platí například pro libovolnou matici nad  $\mathbb{C}$ .

## Jordanův tvar čtvercové matice (**nepovinné, 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  $\lambda_i$ ; matice  $\mathbf{A}$ . Rozměr matice  $\mathbf{J}_i$  je roven násobnosti vlastní hodnoty  $\lambda_i$  jako kořene  $\text{char}_{\mathbf{A}}(x)$ .

## Příklad

Ať  $\mathbf{A} = \begin{pmatrix} a & -b \\ b & a \end{pmatrix}$  je regulární matice nad  $\mathbb{R}$ . Potom platí:

- 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  $\alpha$

úhel<sup>a</sup> 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  $\alpha$ , následovaná změnou měřítka.

<sup>a</sup>Úhlu  $\alpha$  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  $\lambda$ . 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:

$$\mathbf{A} = \mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1} \text{ pro nějakou regulární matici } \mathbf{T}.$$

Tudíž:  $\mathbf{A}^2 = \mathbf{A} \cdot \mathbf{A} = (\mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1}) \cdot (\mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1}) = \mathbf{T} \cdot \mathbf{D}^2 \cdot \mathbf{T}^{-1}$ .

Obecně:  $\mathbf{A}^k = \mathbf{T} \cdot \mathbf{D}^k \cdot \mathbf{T}^{-1}$ , 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  $F(n)$ .<sup>a</sup>

- 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  $\mathbb{R}$ :  $\lambda_1 = \frac{1+\sqrt{5}}{2}$ ,  $\lambda_2 = \frac{1-\sqrt{5}}{2}$

$$\mathbf{D} = \begin{pmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{pmatrix} = \mathbf{T}^{-1} \cdot \mathbf{F} \cdot \mathbf{T}, \quad \mathbf{T} = \begin{pmatrix} 1 & 1 \\ \lambda_1 & \lambda_2 \end{pmatrix}, \quad \mathbf{F}^n = \mathbf{T} \cdot \mathbf{D}^n \cdot \mathbf{T}^{-1}$$

---

<sup>a</sup>Požadavkům  $F(0) = x_0$  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  $\mathbf{X} = \mathbf{T} \cdot \mathbf{D} \cdot \mathbf{T}^{-1}$  definujeme

$$e^{\mathbf{X}} = \sum_{i=0}^{\infty} \frac{\mathbf{X}^n}{n!} = \sum_{i=0}^{\infty} \frac{\mathbf{T} \cdot \mathbf{D}^n \cdot \mathbf{T}^{-1}}{n!} = \mathbf{T} \cdot \underbrace{\left( \sum_{i=0}^{\infty} \frac{\mathbf{D}^n}{n!} \right)}_{= e^{\mathbf{D}}} \cdot \mathbf{T}^{-1}$$

Konvergenci této řady musíme chápat ve smyslu normy.<sup>a</sup>

Lze ukázat, že matice  $e^{\mathbf{D}}$  je diagonální, a že platí  $e^{\mathbf{D}} = (\delta_{ij} \cdot e^{d_{ij}})$ .

<sup>a</sup>To 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.

## 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  $\mathbb{R}$ .<sup>a</sup>
- ② Skalární součin zavedeme axiomaticky. Odvodíme geometrický význam skalárního součinu.<sup>b</sup>

Axiomatické zavedení skalárního součinu nám umožní převést známé významy z  $\mathbb{R}^n$  (kolmost, délka vektoru, atd) do obecných lineárních prostorů se skalárním součinem.

---

<sup>a</sup>Velmi málo řekneme i o lineárních prostorech nad  $\mathbb{C}$ . Důvod: fyzika a kvantové počítání.

<sup>b</sup>Slogan: 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**,<sup>a</sup> 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  $\vec{x} = \vec{o}$ .

<sup>a</sup>Naše 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.

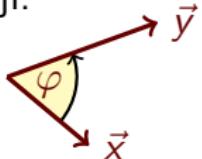
## Poznámka (skalární součin pro prostory nad $\mathbb{C}$ )

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  $\varphi$  je úhel, který svírají:<sup>a</sup>



Tento skalární součin splňuje všechny tři požadované vlastnosti: je komutativní, lineární ve druhé souřadnici a pozitivně definitní.

<sup>a</sup>Důležitá 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  $\varphi$  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<sup>a</sup>  $\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} | \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = x_1 y_1 + x_2 y_1 + x_1 y_2 + 2x_2 y_2$  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  $\langle \mathbf{x} | \mathbf{y} \rangle = \langle \mathbf{y} | \mathbf{x} \rangle$ .

<sup>a</sup>K 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  $\varphi$   $= \cos \varphi$  pro jediné  $\varphi \in [0; \pi]$

říkáme úhel mezi vektory  $\vec{x}$  a  $\vec{y}$ .

## Definice (norma vektoru)

Normu vektoru  $\vec{x}$  definujeme<sup>a</sup> jako  $\|\vec{x}\| = \sqrt{\langle \vec{x} | \vec{x} \rangle}$ .

<sup>a</sup>Nerovnost 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  $\langle \vec{x} | \vec{v} \rangle = 0$ .

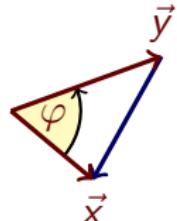
**Slogan:** ortogonalitu stačí ověřovat pouze pro množinu generátorů podprostoru.

Ortogonalitou se budeme podrobněji zabývat v příštích přednáškách.



## Příklady (geometrie prostoru se skalárním součinem)

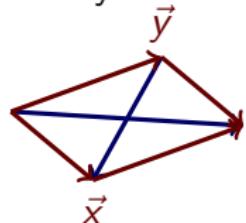
- ① **Kosinová věta:** Nenulové vektory  $\vec{x}$  a  $\vec{y}$  určují trojúhelník



$$\text{Platí: } \|\vec{x} - \vec{y}\|^2 = \|\vec{x}\|^2 + \|\vec{y}\|^2 - \underbrace{2 \cdot \langle \vec{x} | \vec{y} \rangle}_{2 \cdot \|\vec{x}\| \cdot \|\vec{y}\| \cdot \cos \varphi}.$$

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:<sup>a</sup> skalární součin  $\rightsquigarrow$  norma  $\rightsquigarrow$  metrika.

<sup>a</sup>Obrácené 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  $\langle \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix} | \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix} \rangle = -1$ , 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.<sup>a</sup>

---

<sup>a</sup>V 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  $\varphi$  v hyperbolické geometrii.

## Příklad (rotace a standardní skalární součin)

Připomenutí: rotace o úhel  $\alpha$  je  $\mathbf{R}_\alpha : \mathbb{R}^2 \rightarrow \mathbb{R}^2$ , kde<sup>a</sup>

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

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.**

---

<sup>a</sup>Povšimněme 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):<sup>a</sup>  $\delta_{ij} = \langle \mathbf{e}_i | \mathbf{e}_j \rangle = \langle \mathbf{A} \cdot \mathbf{e}_i | \mathbf{A} \cdot \mathbf{e}_j \rangle = \mathbf{e}_i^T \cdot \mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{e}_j$ , takže  $\mathbf{A}^T \cdot \mathbf{A} = \mathbf{E}_n$ .

Ze (2) plyne (1):

$$\langle \mathbf{A} \cdot \mathbf{x} | \mathbf{A} \cdot \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{A}^T \cdot \mathbf{A} \cdot \mathbf{y} = \mathbf{x}^T \cdot \mathbf{A}^{-1} \cdot \mathbf{A} \cdot \mathbf{y} = \mathbf{x}^T \cdot \mathbf{y} = \langle \mathbf{x} | \mathbf{y} \rangle. \quad \blacksquare$$

<sup>a</sup>Připomenutí: pro Kroneckerův symbol  $\delta$  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 zachovává standardní skalární součin (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**:

$$\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle = (x_1 \quad x_2) \cdot \underbrace{\begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}}_{\mathbf{G}} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} = x_1y_1 + x_2y_1 + x_1y_2 + 2x_2y_2$$

## 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:

$$\begin{aligned}\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle &= x_1 y_1 + x_2 y_2 \\ &= (x_1 \quad x_2) \cdot \underbrace{\begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}}_{\mathbf{E}_2} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}\end{aligned}$$

2 „Nezvyklý“ skalární součin:

$$\begin{aligned}\left\langle \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} y_1 \\ y_2 \end{pmatrix} \right\rangle &= x_1 y_1 + x_2 y_1 + x_1 y_2 + 2 x_2 y_2 \\ &= (x_1 \quad x_2) \cdot \underbrace{\begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}}_{\mathbf{G}} \cdot \begin{pmatrix} y_1 \\ y_2 \end{pmatrix}\end{aligned}$$

V obou případech je součin zadán jistou maticí typu  $2 \times 2$ . 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“<sup>a</sup> matice  $\mathbf{G}$ .

Opravdu: Matice  $\mathbf{G} = (g)$  typu  $1 \times 1$  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.

<sup>a</sup>Jde 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:

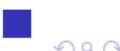
- ①  **$\mathbf{G}$  je pozitivně definitní.**
- ② Matice  $\mathbf{G}$  je symetrická a determinanty všech matic  $\mathbf{G}_k = (g_{ij})_{i=1,\dots,k,j=1,\dots,k}$ , kde  $1 \leq k \leq n$ , jsou kladné.<sup>a</sup>
- ③ Matice  $\mathbf{G}$  je symetrická a nerovnost  $\mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{x} \geq 0$  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  $\mathbf{G} = \mathbf{R}^T \cdot \mathbf{R}$ .

---

<sup>a</sup>Tento 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  
 $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{E}_n \cdot \mathbf{y} = \mathbf{x}^T \cdot \mathbf{y}$  v  $\mathbb{R}^n$ .

- 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  
 $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{y}$  v  $\mathbb{R}^2$ .

## 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<sup>a</sup> 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  $\langle \mathbf{x} | \mathbf{y} \rangle = \mathbf{x}^T \cdot \mathbf{G} \cdot \mathbf{y}$ .

---

<sup>a</sup>Matici  $\mathbf{G}$  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<sup>a</sup> matici  $\mathbf{G} = \begin{pmatrix} a & b \\ b & d \end{pmatrix}$  a příslušný skalární součin  $\langle - | - \rangle$  je množina<sup>b</sup>

$$\left\{ \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \| \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \| = 1 \right\}$$

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.

<sup>a</sup>Připomenutí: platí  $a > 0$  a  $ad - b^2 > 0$ .

<sup>b</sup>Připomenutí:  $\| - \|$  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:<sup>a</sup>  $\langle \mathbf{e}_i | \mathbf{e}_j \rangle = \mathbf{e}_i^T \cdot \mathbf{e}_j = \delta_{ij} = \begin{cases} 0, & \text{pro } i \neq j \\ 1, & \text{pro } i = j \end{cases}$

---

<sup>a</sup>Takovým 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  
 $\mathbf{G}_1 - \mathbf{G}_2 = \mathbf{0}_{n,n}$ .

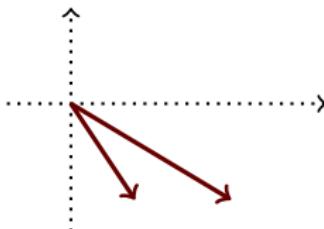
Tudíž  $\mathbf{G}_1 = \mathbf{G}_2$ .



## 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<sup>a</sup>  $\mathbf{T}_{K_n \mapsto B} = (\mathbf{T}_{B \mapsto K_n})^{-1} = \frac{1}{9} \cdot \begin{pmatrix} -3 & -5 \\ 3 & 2 \end{pmatrix}$  a  $\mathbf{G} = (\mathbf{T}_{K_n \mapsto B})^T \cdot \mathbf{T}_{K_n \mapsto B} = \frac{1}{81} \cdot \begin{pmatrix} 18 & 21 \\ 21 & 29 \end{pmatrix}$ .

---

<sup>a</sup>Matici  $\mathbf{T}_{K_n \mapsto B}$  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  $\left\langle \begin{pmatrix} 5 \\ -3 \end{pmatrix} \mid \begin{pmatrix} 5 \\ -3 \end{pmatrix} \right\rangle =$

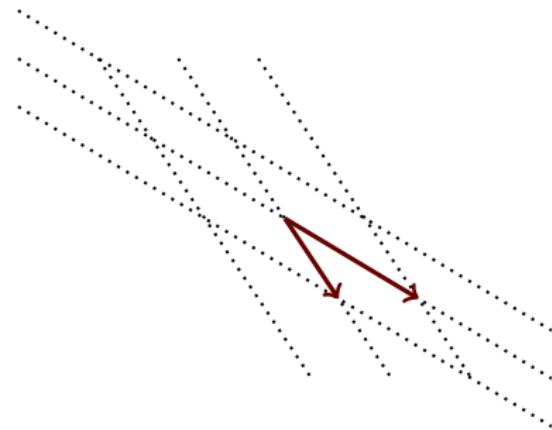
$$\frac{18}{81} \cdot 5 \cdot 5 + \frac{21}{81} \cdot 5 \cdot (-3) + \frac{21}{81} \cdot (-3) \cdot 5 + \frac{29}{81} \cdot (-3) \cdot (-3) = 1.$$

## 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.

## Příští přednáška

- ① Hlubší poznatky o ortogonálních projkcích.
- ② Metoda nejmenších čtverců.<sup>a</sup>

---

<sup>a</sup>Budeme se věnovat pouze nejjednodušší formě metody nejmenších čtverců v  $\mathbb{R}^n$  se standardním skalárním součinem. Vše je podrobně popsáno ve výtahu z příští přednášky. Viz také Dodatek C skript.



## 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:<sup>a</sup>

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  $W$ .

---

<sup>a</sup>Tento 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  $M$ .<sup>a</sup> Pak  $M$  je lineárně nezávislá množina.

---

<sup>a</sup>Takové 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:**<sup>a</sup> 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.

---

<sup>a</sup>**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  $\langle \vec{b}_i | \vec{b}_j \rangle = \delta_{ij}$ ,<sup>a</sup> říkáme **ortonormální**.

---

<sup>a</sup>Kroneckerův symbol  $\delta$  splňuje:  $\delta_{ii} = 1$ ,  $\delta_{ij} = 0$  pro  $i \neq j$ .

### Poznámky

- ❶ Kanonická báze  $(\mathbf{e}_1, \dots, \mathbf{e}_n)$  prostoru  $\mathbb{R}^n$  je ortonormální vzhledem ke standardnímu skalárnímu součinu.
- ❷ 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**.

- ❸ 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<sup>a</sup>  $\vec{x} = \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \vec{b}_i$ , čili  $\text{coord}_B(\vec{x}) = \begin{pmatrix} \langle \vec{b}_1 | \vec{x} \rangle \\ \vdots \\ \langle \vec{b}_n | \vec{x} \rangle \end{pmatrix}$ .

---

<sup>a</sup>Tato rovnost je konečně-dimensionální variantou rozvoje ve Fourierovu řadu.

### 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:<sup>a</sup>  $\langle \vec{x} | \vec{y} \rangle = \sum_{i=1}^n \langle \vec{b}_i | \vec{x} \rangle \cdot \langle \vec{b}_i | \vec{y} \rangle$ .

<sup>a</sup> Podle předchozího to znamená:  $\langle \vec{x} | \vec{y} \rangle = \mathbf{x}^T \cdot \mathbf{y}$ , kde  $\mathbf{coord}_B(\vec{x}) = \mathbf{x}$  a  $\mathbf{coord}_B(\vec{y}) = \mathbf{y}$ . **Slogan:** skalární součin v ortonormální bázi se počítá jako standardní skalární součin souřadnic. Jde o konečně-dimensionální variantu **Parsevalovy rovnosti** z teorie Fourierových řad.

### 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<sup>a</sup>**  $\vec{x}$  a  $\vec{y}$ .

---

<sup>a</sup>Samozřejmě: 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  $\varphi_{i_0}$ , který vektor  $\vec{x}$  svírá se souřadnicovou osou  $\vec{b}_{i_0}$ , platí rovnost<sup>a</sup>

$$\cos \varphi_{i_0} = \frac{\langle \vec{b}_{i_0} | \vec{x} \rangle}{\|\vec{x}\|}. \text{ Navíc platí } \sum_{i=1}^n \cos^2 \varphi_i = 1.$$

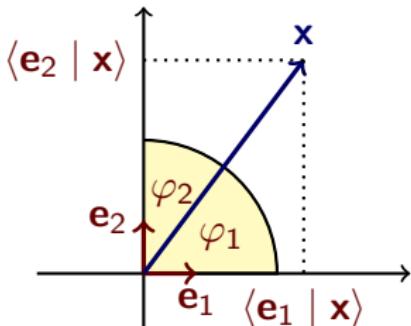
<sup>a</sup>**Všimněme si:** tvrdíme, že  $\langle \vec{b}_{i_0} | \vec{x} \rangle$ , tj.  $i_0$ -tá souřadnice vektoru  $\vec{x}$  vzhledem k bázi  $B$ , se počítá jako součin  $\|\vec{x}\| \cdot \cos \varphi_{i_0}$ . To je zobecnění známého faktu z elementární geometrie roviny (viz další stranu).

### 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 $(\mathbf{e}_1, \mathbf{e}_2)$



$$\cos \varphi_1 = \frac{\text{orientovaná délka přilehlé odvěsny}}{\text{délka přepony}} = \frac{\langle \mathbf{e}_1 | \mathbf{x} \rangle}{\|\mathbf{x}\|}$$

$$\cos \varphi_2 = \frac{\text{orientovaná délka přilehlé odvěsny}}{\text{délka přepony}} = \frac{\langle \mathbf{e}_2 | \mathbf{x} \rangle}{\|\mathbf{x}\|}$$

$$\varphi_1 + \varphi_2 = \frac{\pi}{2}, \text{ čili } \cos \varphi_2 = \cos \left( \frac{\pi}{2} - \varphi_1 \right) = \sin \varphi_1$$

$$\text{Tudíž } \cos^2 \varphi_1 + \cos^2 \varphi_2 = \cos^2 \varphi_1 + \sin^2 \varphi_1 = 1.$$

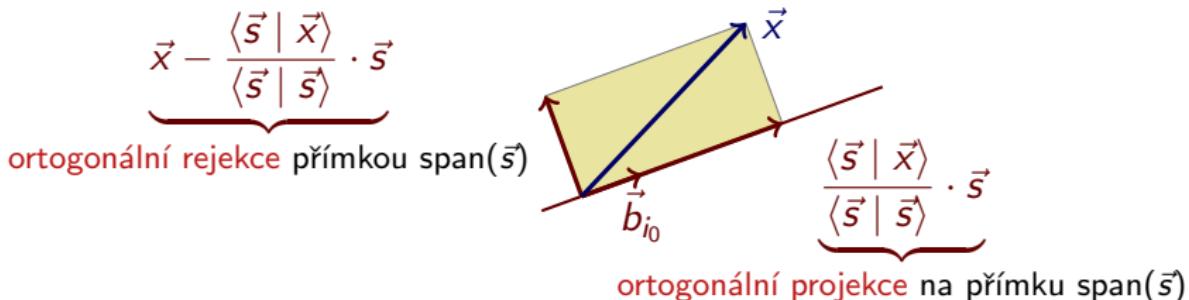
## Projekce na přímku a rejekce přímkomu

Ať  $\vec{s}$  je nenulový vektor v prostoru se skalárním součinem. Potom pro každý vektor  $\vec{x}$  platí:

- ① Vektor  $\frac{\langle \vec{s} | \vec{x} \rangle}{\langle \vec{s} | \vec{s} \rangle} \cdot \vec{s}$  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  $\text{span}(\vec{s})$ .

$$\langle \vec{s} | \vec{x} - \frac{\langle \vec{s} | \vec{x} \rangle}{\langle \vec{s} | \vec{s} \rangle} \cdot \vec{s} \rangle = \langle \vec{s} | \vec{x} \rangle - \frac{\langle \vec{s} | \vec{x} \rangle}{\langle \vec{s} | \vec{s} \rangle} \cdot \langle \vec{s} | \vec{s} \rangle = 0$$

Dostáváme tedy **ortogonální rozklad<sup>a</sup>** vektoru  $\vec{x}$ :



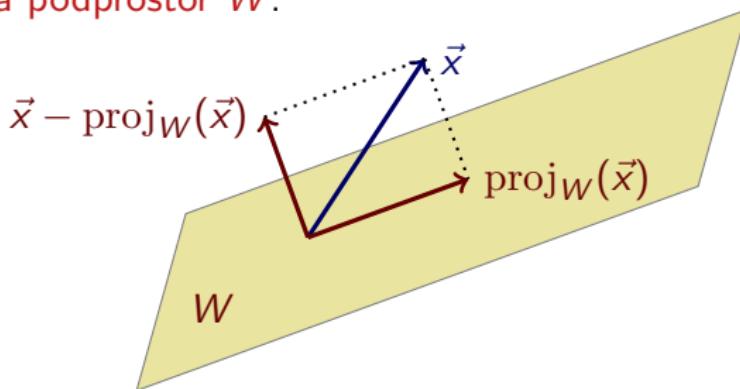
<sup>a</sup>Slovník: **projekce**=promítnutí, **rejekce**=odmítnutí.



## Zobecnění: projekce na podprostor a rejekce podprostorem

Ať  $W$  je podprostor lineárního prostoru  $L$  se skalárním součinem, ať  $\vec{x}$  je libovolný vektor v  $L$ .

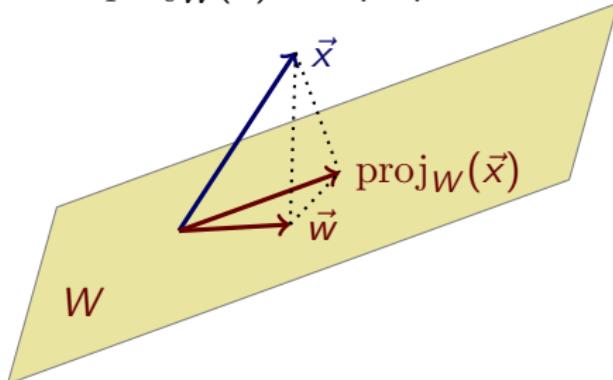
Vektoru  $\text{proj}_W(\vec{x})$ , který leží ve  $W$  a pro který je  $\vec{x} - \text{proj}_W(\vec{x})$  kolmý na všechny vektory z  $W$ , říkáme **ortogonální projekce vektoru  $\vec{x}$  na podprostor  $W$** .



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<sup>a</sup>

$$\|\vec{x} - \text{proj}_W(\vec{x})\|^2 \leq \|\vec{x} - \text{proj}_W(\vec{x})\|^2 + \underbrace{\|\text{proj}_W(\vec{x}) - \vec{w}\|^2}_{\geq 0} = \|\vec{x} - \vec{w}\|^2$$

---

<sup>a</sup>Na této nerovnosti je založena metoda nejmenších čtverců, viz cvičení a příští přednáška, nebo Dodatek C skript.



## 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  $\vec{x}$  platí

$$\text{proj}_W(\vec{x}) = \sum_{i=1}^k \frac{\langle \vec{u}_i | \vec{x} \rangle}{\langle \vec{u}_i | \vec{u}_i \rangle} \cdot \vec{u}_i \quad (\text{tj. } \text{proj}_W(\vec{x}) = \sum_{i=1}^k \text{proj}_{\text{span}(\vec{u}_i)}(\vec{x}))$$

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:

$$\langle \vec{u}_{i_0} | \vec{x} - \text{proj}_W(\vec{x}) \rangle = \langle \vec{u}_{i_0} | \vec{x} \rangle - \langle \vec{u}_{i_0} | \text{proj}_W(\vec{x}) \rangle =$$

$$\langle \vec{u}_{i_0} | \vec{x} \rangle - \langle \vec{u}_{i_0} | \sum_{i=1}^k \frac{\langle \vec{u}_i | \vec{x} \rangle}{\langle \vec{u}_i | \vec{u}_i \rangle} \cdot \vec{u}_i \rangle =$$

$$\langle \vec{u}_{i_0} | \vec{x} \rangle - \sum_{i=0}^k \frac{\langle \vec{u}_i | \vec{x} \rangle}{\langle \vec{u}_i | \vec{u}_i \rangle} \cdot \langle \vec{u}_{i_0} | \vec{u}_i \rangle = \langle \vec{u}_{i_0} | \vec{x} \rangle - \langle \vec{u}_{i_0} | \vec{x} \rangle = 0.$$



## 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<sup>a</sup>

$$\vec{c}_1 := \vec{b}_1, \quad \vec{c}_{k+1} := \underbrace{\vec{b}_{k+1} - \text{proj}_{\text{span}\{\vec{c}_1, \dots, \vec{c}_k\}}(\vec{b}_{k+1})}_{\text{rejekce vektoru } \vec{b}_{k+1} \text{ podprostorem } \text{span}\{\vec{c}_1, \dots, \vec{c}_k\}}$$

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. ■

<sup>a</sup>**Slogan:** Gram-Schmidt je posloupnost postupných ortogonálních rejekcí.



## Poznámka (ortonormalisační proces)

Pokud je  $C = (\vec{c}_1, \dots, \vec{c}_n)$  ortogonální báze<sup>a</sup> 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.

---

<sup>a</sup>Evidentně 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

$$\frac{\mathbf{c}_1}{\|\mathbf{c}_1\|} = \frac{1}{2} \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}, \quad \frac{\mathbf{c}_2}{\|\mathbf{c}_2\|} = \frac{1}{\sqrt{12}} \cdot \begin{pmatrix} -3 \\ 1 \\ 1 \\ 1 \end{pmatrix}, \quad \frac{\mathbf{c}_3}{\|\mathbf{c}_3\|} = \frac{1}{\sqrt{6}} \cdot \begin{pmatrix} 0 \\ -2 \\ 1 \\ 1 \end{pmatrix}$$

## Projekce na podprostor, u kterého neznáme ortogonální bází

- ① V obecném případě je vždy možno nejprve obecnou bázi 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 další přednášku.

# Ortogonalní 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).<sup>a</sup>

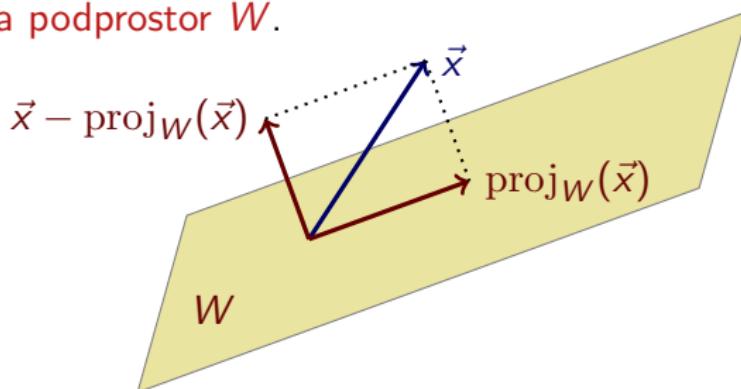
---

<sup>a</sup>Budeme 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  $W$** .

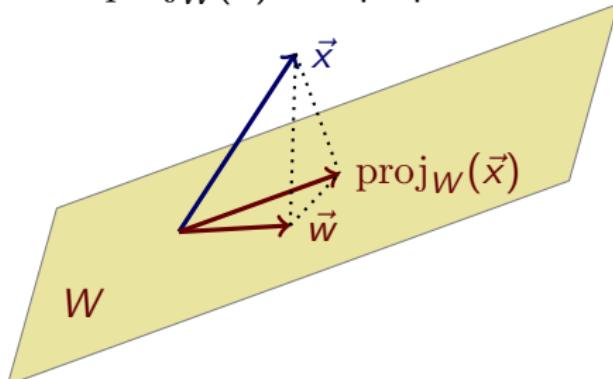


Vektoru  $\vec{x} - \text{proj}_W(\vec{x})$  říkáme **ortogonální rejekce vektoru  $\vec{x}$  podprostorem  $W$**  a značíme jej  $\text{rej}_W(\vec{x})$ .<sup>a</sup>

<sup>a</sup>Slovník: **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<sup>a</sup>

$$\|\vec{x} - \text{proj}_W(\vec{x})\|^2 \leq \|\vec{x} - \text{proj}_W(\vec{x})\|^2 + \underbrace{\|\text{proj}_W(\vec{x}) - \vec{w}\|^2}_{\geq 0} = \|\vec{x} - \vec{w}\|^2$$

---

<sup>a</sup>Na 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<sup>a</sup>

$$\text{proj}_W(\mathbf{x}) = \mathbf{A} \cdot (\mathbf{A}^T \cdot \mathbf{G} \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{G} \cdot \mathbf{x}$$

---

<sup>a</sup>Tento 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<sup>a</sup>** 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

$$\frac{1}{2} \cdot \begin{pmatrix} 1 & 1 & 0 \\ 1 & 1 & 0 \\ 0 & 0 & 2 \end{pmatrix} \cdot \begin{pmatrix} -20 \\ 4 \\ 6 \end{pmatrix} = \begin{pmatrix} -8 \\ -8 \\ 6 \end{pmatrix} = 6 \cdot \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} + (-14) \cdot \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}.$$

<sup>a</sup> 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<sup>a</sup>

$\mathbf{G} = \begin{pmatrix} 1 & 1 \\ 1 & 2 \end{pmatrix}$  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

$$\frac{1}{5} \cdot \begin{pmatrix} 2 & 3 \\ 2 & 3 \end{pmatrix} \cdot \begin{pmatrix} 4 \\ 6 \end{pmatrix} = \frac{1}{5} \cdot \begin{pmatrix} 26 \\ 26 \end{pmatrix} = \frac{26}{5} \cdot \begin{pmatrix} 1 \\ 1 \end{pmatrix}.$$

<sup>a</sup> 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?<sup>a</sup>

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.

<sup>a</sup>Zatím 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.<sup>a</sup>

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  $\|\mathbf{b} - \mathbf{A} \cdot \mathbf{x}\|$ .**

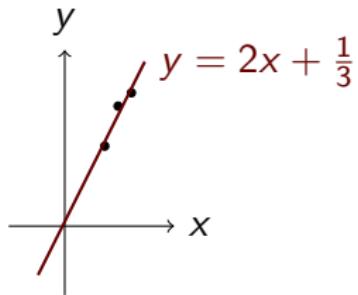
<sup>a</sup>Body na první pohled „téměř“ leží na přímce  $y = 2x$ .



**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.<sup>a</sup>

- 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  $y = 2x + \frac{1}{3}$ .



<sup>a</sup>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

$$\left\| \begin{pmatrix} 6 \\ 9 \\ 10 \end{pmatrix} - \begin{pmatrix} 19/3 \\ 25/3 \\ 31/3 \end{pmatrix} \right\|^2 = \left\| \begin{pmatrix} -1/3 \\ 2/3 \\ -1/3 \end{pmatrix} \right\|^2 = 6/9$$

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:

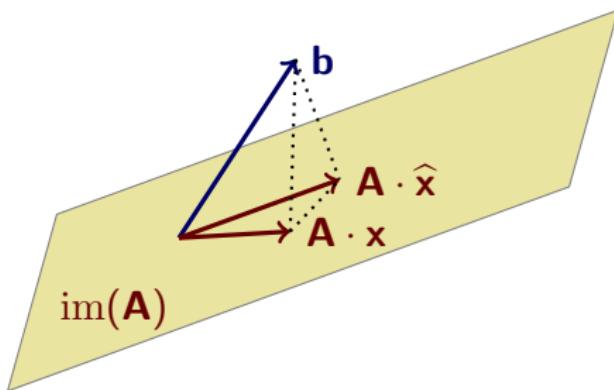
- ① Protože  $\mathbf{A}$  má lineárně nezávislé sloupce, je matice  $\mathbf{A}^T \cdot \mathbf{A}$  pozitivně definitní, tedy regulární.
- ② Soustava  $(\mathbf{A}^T \cdot \mathbf{A} | \mathbf{A}^T \cdot \mathbf{b})$  má tedy jediné řešení, označme toto řešení  $\hat{\mathbf{x}} = (\mathbf{A}^T \cdot \mathbf{A})^{-1} \cdot \mathbf{A}^T \cdot \mathbf{b}$ .

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 $(\mathbf{A} \mid \mathbf{b})$ metodou nejmenších čtverců



Pokud má matice soustavy  $(\mathbf{A} \mid \mathbf{b})$  lineárně nezávislé sloupce, potom platí:

- ① Soustava  $(\mathbf{A} \mid \mathbf{b})$  má právě jedno řešení  $\hat{\mathbf{x}}$  metodou nejmenších čtverců.
- ② Pro každé  $\mathbf{x}$  platí nerovnost  $\|\mathbf{b} - \mathbf{A} \cdot \hat{\mathbf{x}}\|^2 \leq \|\mathbf{b} - \mathbf{A} \cdot \mathbf{x}\|^2$ .

## 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

$$\left( \begin{array}{c} x_1 \\ y_1 \end{array} \right), \left( \begin{array}{c} x_2 \\ y_2 \end{array} \right), \dots, \left( \begin{array}{c} x_n \\ y_n \end{array} \right)$$

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.

## Uvedení do lineárních kódů

Odpřednesenou látku naleznete v dodatku I  
skript *Abstraktní a konkrétní lineární algebra*.

## Dnešní přednáška

- ① Základní geometrické myšlenky teorie lineárních kódů.
- ② Generující a kontrolní matice lineárního podprostoru.

## Dobré zdroje dalších informací

- ① Richard Wesley Hamming (1915–1998): Bellovy laboratoře, ~1946, technika pro opravu chyb na děrných štítcích
- ② J. Adámek, *Foundations of coding*, John Wiley & Sons, New York, 1991
- ③ D. J. C. MacKay, *Information theory, inference and learning algorithms*, Cambridge Univ. Press, 2003
- ④ W. C. Huffman a V. Pless, *Fundamentals of error-correcting codes*, Cambridge Univ. Press, 2003

## Příští přednáška

- ① Základy ortogonální geometrie v prostorech tvaru  $\mathbb{F}^n$  nad  $\mathbb{F}$ , kde  $\mathbb{F}$  je obecné těleso.

## Kódování versus šifrování

- ① **Kódování:** dvě strany (Alice a Bob) si vyměňují zprávy. Při přenosu zpráv může dojít k poškození vyslané zprávy.

Předpokládejme, že Alice píše Bobovi. Chceme umožnit Bobovi opravit poškozenou zprávu **bez nutnosti zpětného dotazu** Alice.

Můžeme použít metody lineární algebry: **lineární kódy**.

- ② **Šifrování:** dvě strany (Alice a Bob) si vyměňují zprávy. Při přenosu zpráv **nemůže** dojít k poškození vyslané zprávy, ale **může** dojít k odposlechu třetí stranou (ta se jmenuje Eve<sup>a</sup>).

Předpokládejme, že Alice píše Bobovi. Chceme takovou komunikaci, kterou Eve **nedokáže efektivně přečíst**.

K účinnému šifrování je třeba použít sofistikovaných metod. Viz např. J. Velebil, *Diskrétní matematika*, Praha, 2007.

---

<sup>a</sup>Z anglického *eavesdropper* — ten, kdo tajně naslouchá.

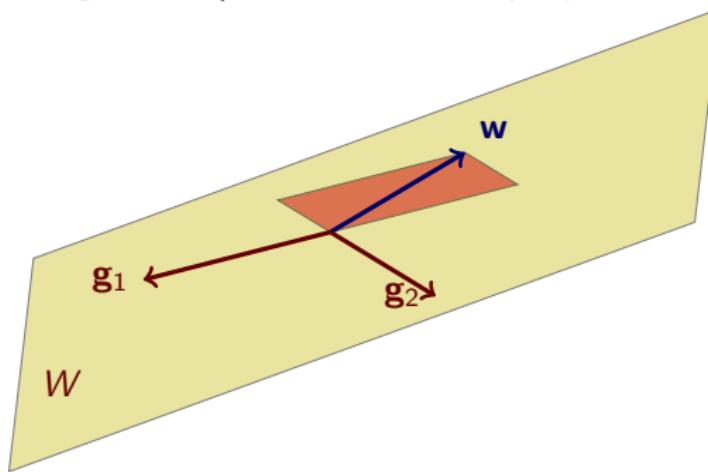


## Rovina v $\mathbb{R}^3$ jako lineární kód

Rovina  $x + y - z = 0$  je lineární podprostor  $W$  dimenze 2 v  $\mathbb{R}^3$ .

① Volbou uspořádané báze  $W$  lze generovat prvky  $W$ .

- ①  $W$  má usp. bázi (např.)  $(\mathbf{g}_1, \mathbf{g}_2)$ , kde  $\mathbf{g}_1 = \begin{pmatrix} 1 \\ 2 \\ 3 \end{pmatrix}$ ,  $\mathbf{g}_2 = \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix}$ .
- ② Tudíž  $\mathbf{w} \in W$  iff existují jednoznačně určená  $a_1, a_2 \in \mathbb{R}$  tak, že  $a_1 \cdot \mathbf{g}_1 + a_2 \cdot \mathbf{g}_2 = \mathbf{w}$ . (Protože báze určuje systém souřadnic.)



## Rovina v $\mathbb{R}^3$ jako lineární kód (pokrač.)

Rovina  $x + y - z = 0$  je lineární podprostor  $W$  dimenze 2 v  $\mathbb{R}^3$ .

③ Vektor  $\begin{pmatrix} a_1 \\ a_2 \end{pmatrix}$  budeme považovat za vektor informačních bitů.

Neboli: volbou  $a_1, a_2$  lze vygenerovat  $\mathbf{w} \in W$  takto:

$$\underbrace{\begin{pmatrix} 1 & 0 \\ 2 & 1 \\ 3 & 1 \end{pmatrix}}_{\text{generující matice } \mathbf{G}} \cdot \begin{pmatrix} a_1 \\ a_2 \end{pmatrix} = \begin{pmatrix} a_1 \\ 2a_1 + a_2 \\ 3a_1 + a_2 \end{pmatrix} = \mathbf{w}$$

Vektor  $\mathbf{w}$  Alice odešle Bobovi.

Vektor  $\mathbf{w}$  obsahuje redundantní informaci.<sup>a</sup> Tato redundantní informace chrání původní informační bity před poškozením.

---

<sup>a</sup>Podíl délky informace a celkové délky kódového slova (tzv. information rate kódu) je tedy v našem případě  $\frac{2}{3}$ .

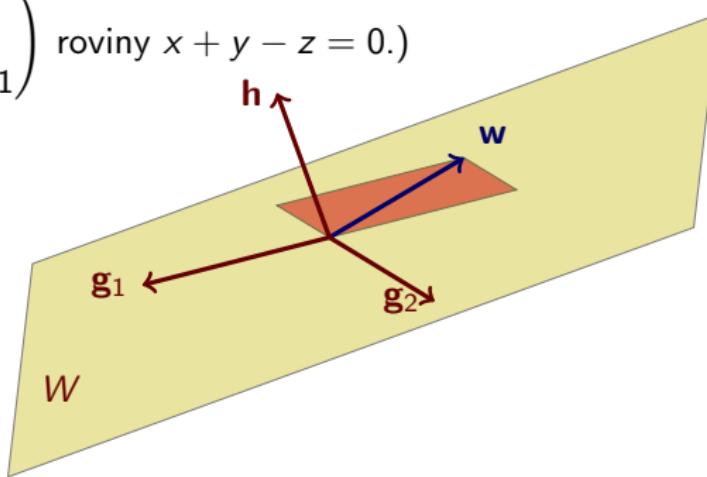
## Rovina v $\mathbb{R}^3$ jako lineární kód (pokrač.)

Rovina  $x + y - z = 0$  je lineární podprostor  $W$  dimenze 2 v  $\mathbb{R}^3$ .

- ② Volbou ortogonálního doplňku  $W$  lze testovat, zda vektory leží ve  $W$ .<sup>a</sup>

- ①  $W$  má ortogonální doplněk. Tudíž  $\mathbf{w} \in W$  iff  $\mathbf{h}^T \cdot \mathbf{w} = \mathbf{0}$ .  
(Protože ortogonální doplněk je dán normálovým vektorem

$$\mathbf{h} = \begin{pmatrix} 1 \\ 1 \\ -1 \end{pmatrix} \text{ roviny } x + y - z = 0.$$



<sup>a</sup>Co je ortogonální doplněk vysvětlíme přesně v příští přednášce. Zatím se odvoláváme na intuici v  $\mathbb{R}^3$ .



## Rovina v $\mathbb{R}^3$ jako lineární kód (pokrač.)

② Neboli: syndrom s vektoru  $\mathbf{v} = \begin{pmatrix} v_1 \\ v_2 \\ v_3 \end{pmatrix}$ , kde

$$s = \underbrace{\begin{pmatrix} 1 & 1 & -1 \end{pmatrix}}_{\text{kontrolní matice}} \cdot \begin{pmatrix} v_1 \\ v_2 \\ v_3 \end{pmatrix}$$

určuje míru příslušnosti vektoru  $\mathbf{v}$  do  $W$ .

Povšimněme si: syndrom s vektoru  $\mathbf{v}$  je hodnota standardního skalárního součinu  $\langle \mathbf{h} | \mathbf{v} \rangle = \mathbf{h}^T \cdot \mathbf{v}$  v  $\mathbb{R}^3$ .

Syndrom vektoru  $\mathbf{v}$  je tedy nulový právě tehdy, když jsou vektory  $\mathbf{v}$  a  $\mathbf{h}$  ortogonální.<sup>a</sup>

<sup>a</sup>V příští přednášce zobecníme pojem ortogonality vzhledem ke standardnímu skalárnímu součinu z prostorů  $\mathbb{R}^n$  na prostory tvaru  $\mathbb{F}^n$ , kde  $\mathbb{F}$  je obecné těleso.

## Rovina v $\mathbb{R}^3$ jako lineární kód (pokrač.)

Rovina  $x + y - z = 0$  je lineární podprostor  $W$  dimenze 2 v  $\mathbb{R}^3$ .

Generující a kontrolní matice:  $\mathbf{G} = \begin{pmatrix} 1 & 0 \\ 2 & 1 \\ 3 & 1 \end{pmatrix}$ ,  $\mathbf{h}^T = (1 \ 1 \ -1)$ .

Alice z informace  $\begin{pmatrix} 3 \\ 2 \end{pmatrix}$  vygeneruje kódové slovo  $\mathbf{G} \cdot \begin{pmatrix} 3 \\ 2 \end{pmatrix} = \begin{pmatrix} 3 \\ 8 \\ 11 \end{pmatrix}$  z prostoru  $W$ . Toto slovo odešle Bobovi.

Bob přijme slovo  $\begin{pmatrix} 3 \\ 7 \\ 11 \end{pmatrix}$ . Došlo k poškození? Bob spočte syndrom přijatého slova:

$$\mathbf{h}^T \cdot \begin{pmatrix} 3 \\ 7 \\ 11 \end{pmatrix} = -1$$

Syndrom je nenulový, k chybě došlo. Na jaké posici k chybě došlo?  
Jak ji opravit?

## Nearest neighbour decoding

Pokud jsme nepřijali kódové slovo, chceme najít kódové slovo, které je (v nějakém smyslu) **nejblíže<sup>a</sup>** přijatému slovu. Přijaté slovo pak nahradíme tímto nejbližším kódovým slovem.

<sup>a</sup>Zatím jde jen o slogan; v příští přednášce zavedeme **Hammingovu vzdálenost** (kódových) slov.

## Problémy při opravě v lineárních kódech nad $\mathbb{R}$

- ① Základní problém při nearest neighbour decoding nad  $\mathbb{R}$ : reálných čísel je příliš mnoho.
- ② Potřebujeme „konečné číselné obory“, které se chovají stejně jako  $\mathbb{R}$ . Neboli: potřebujeme obecná **konečná tělesa**.<sup>a</sup>

**Důvod:** chceme použít lineární algebru.

<sup>a</sup>Potřebujeme **dostatečnou zásobu** konečných těles  $\mathbb{F}$ . Existence nekonečně mnoha konečných těles souvisí s existencí nekonečného počtu **prvočísel** — viz příští přednášku.

## Příklad: kód 10-ISBN

Deset cifer: použity jsou symboly z množiny  $\{0, 1, 2, 3, 4, 5, 6, 7, 8, 9, X\}$ . Chápeme je jako zbytky po dělení číslem 11.

Příklad:

0–141–01878–X

kde jednotlivé skupiny znamenají:

- ① 0 jazyk knihy (angličtina)
- ② 141 nakladatelství (Penguin Mathematics)
- ③ 01878 číslo knihy, přidělené nakladatelstvím
- ④ X kontrolní bit

Obecně: kódové slovo kódu 10-ISBN je  $x_1x_2x_3x_4x_5x_6x_7x_8x_9x_{10}$ , kde  $\sum_{i=1}^{10} ix_i = 0$  jako zbytek po dělení číslem 11.

## Kód 10-ISBN (pokrač.)

Kdy je řetězec  $x_1x_2x_3x_4x_5x_6x_7x_8x_9x_{10}$  kódem ISBN?  
Právě tehdy, když jeho syndrom

$$\underbrace{(1, 2, 3, 4, 5, 6, 7, 8, 9, X)}_{\text{kontrolní matice } \mathbf{H}^T \text{ kódu 10-ISBN}} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \\ x_{10} \end{pmatrix}$$

je nula (počítáno jako zbytek po dělení číslem 11).<sup>a</sup>

<sup>a</sup>Povšimněme si: ISBN chápeme jako vektor v  $(\mathbb{Z}_{11})^{10}$ . Příeme je tedy do sloupců.



## Kód 10-ISBN (pokrač.)

Jak vytvořit kód ISBN?

Info o knize<sup>a</sup> = 9 bitů. Jak spočítat kontrolní bit?

$$\underbrace{\begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}}_{\text{generující matice } \mathbf{G} \text{ kódu 10-ISBN}} \cdot \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \\ x_{10} \end{pmatrix} = \begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \\ x_5 \\ x_6 \\ x_7 \\ x_8 \\ x_9 \\ x_{10} \end{pmatrix}$$

počítáno jako zbytek po dělení číslem 11.

<sup>a</sup>Povšimněme si: informační byty chápeme jako vektor  $v \in (\mathbb{Z}_{11})^9$ . Píšeme je tedy do sloupců.



## Kód 10-ISBN (pokrač.)

- ① Kódy 10-ISBN = vektory v lineárním podprostoru  $W$  lineárního prostoru  $(\mathbb{Z}_{11})^{10}$ .  
Uspořádaná báze  $B$  prostoru  $W$  = sloupce matice  $\mathbf{G}$ .  
Dimenze  $W = 9$ .
- ② Info o knize = vektor souřadnic  $\mathbf{a}$  vektoru  $\mathbf{w}$  ve  $W$  vzhledem k uspořádané bázi  $B$ . Platí vztah  $\mathbf{w} = \mathbf{G} \cdot \mathbf{a}$ .
- ③ Test při příjmu slova  $\mathbf{v} =$  výpočet syndromu  $\mathbf{H}^T \cdot \mathbf{v}$  slova  $\mathbf{v}$ .  
Sloupce  $\mathbf{H}$  = báze ortogonálního doplňku k  $W$ .

Kód 10-ISBN = lineární 11-kód délky 10 a dimenze 9.

Kód 10-ISBN je schopen detekovat jednu chybu a prohození dvou pozic,<sup>a</sup> viz Příklad 3.3.2 textu *Diskrétní matematika*.

---

<sup>a</sup>To jsou běžné písářské chyby. 10-ISBN je starý kód, začíná být nahrazován kódem 13-ISBN.

## Lineární podprostory prostoru $\mathbb{F}^n$ nad $\mathbb{F}$ (znovu a mírně jinak)

Ať  $W$  je lineární podprostor prostoru  $\mathbb{F}^n$  nad  $\mathbb{F}$ . Víme, že platí  $0 \leq \dim(W) \leq n$ . Předpokládejme, že  $\dim(W) = k > 0$ .

- Zvolme uspořádanou bázi  $(\mathbf{g}_1, \dots, \mathbf{g}_k)$  prostoru  $W$ . Označme jako  $\mathbf{G} : \mathbb{F}^k \rightarrow \mathbb{F}^n$  matici se sloupcovým zápisem  $(\mathbf{g}_1, \dots, \mathbf{g}_k)$ .

Podle věty o dimensi jádra a obrazu platí  $\text{rank}(\mathbf{G}) = k$  a  $\text{def}(\mathbf{G}) = 0$ . Navíc platí  $\text{im}(\mathbf{G}) = W$ .

Z toho okamžitě plyne:

- Pro jakoukoli volbu vektoru  $\mathbf{a}$  z  $\mathbb{F}^k$  je  $\mathbf{G} \cdot \mathbf{a}$  vektor ve  $W$ .
- Vektor  $\mathbf{w}$  z  $\mathbb{F}^n$  leží ve  $W$  právě tehdy, když soustava rovnic  $(\mathbf{G} \mid \mathbf{w})$  má právě jedno řešení (označme je  $\mathbf{a}$ ).

Toto jediné řešení  $\mathbf{a}$  z  $\mathbb{F}^k$  je vektor souřadnic vektoru  $\mathbf{w}$  vzhledem k uspořádané bázi  $(\mathbf{g}_1, \dots, \mathbf{g}_k)$ .

Matici  $\mathbf{G}$  říkáme **generující matici**<sup>a</sup> lineárního podprostoru  $W$ .

---

<sup>a</sup>Generující matice podprostoru  $W$  není jednoznačně určena: volbou **jiné** báze podprostoru  $W$  získáme **jinou** generující matici.



## Lineární podprostory prostoru $\mathbb{F}^n$ nad $\mathbb{F}$ (pokrač.)

Ať  $W$  je lineární podprostor prostoru  $\mathbb{F}^n$  nad  $\mathbb{F}$  s uspořádanou bází  $(\mathbf{g}_1, \dots, \mathbf{g}_k)$ ,  $k > 0$ .

- ② Protože  $W = \text{span}(\mathbf{g}_1, \dots, \mathbf{g}_k)$ , existuje soustava rovnic tvaru  $(\mathbf{H}^T | \mathbf{o})$  tak, že řešení  $(\mathbf{H}^T | \mathbf{o})$  je přesně  $W$ .<sup>a</sup>

Podle Frobeniovy věty platí  $\text{rank}(\mathbf{H}^T) = n - k$  a  $\text{def}(\mathbf{H}^T) = k$ .

Víme, že rozměry  $\mathbf{H}^T$  můžeme volit tak, aby platilo  $\mathbf{H}^T : \mathbb{F}^n \rightarrow \mathbb{F}^{n-k}$ .

Matici  $\mathbf{H}^T$  říkáme **kontrolní matici**<sup>b</sup> lineárního podprostoru  $W$ .

Důvod: vektor  $\mathbf{w}$  leží ve  $W$  právě tehdy, když  $\mathbf{H}^T \cdot \mathbf{w} = \mathbf{o}$ . Maticí  $\mathbf{H}^T$  tedy **kontrolujeme** přítomnost vektoru v podprostoru  $W$ .

<sup>a</sup>Slogan:  $\mathbf{H}$  je normální podprostoru  $W$ . To je důvod, proč píšeme v soustavě  $(\mathbf{H}^T | \mathbf{o})$  matici soustavy jako **transponovanou**.

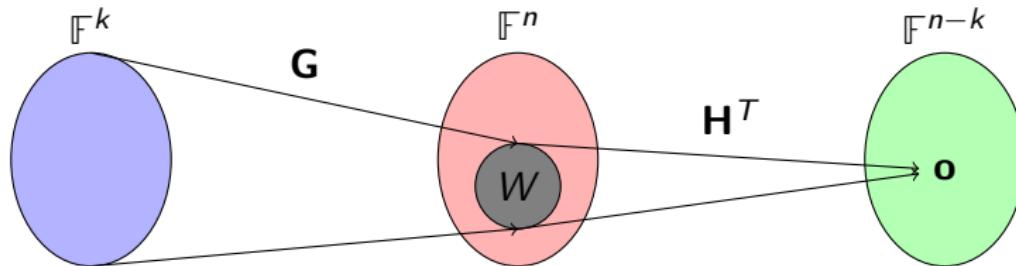
<sup>b</sup>Kontrolní matici podprostoru  $W$  není jednoznačně určena: volbou **jiné** soustavy rovnic získáme **jinou** kontrolní matici.



## Základní vztah matic $\mathbf{G}$ a $\mathbf{H}^T$ pro lineární podprostor $W$

Platí

$$\begin{aligned}\{\mathbf{w} \in \mathbb{F}^n \mid \mathbf{G} \cdot \mathbf{a} = \mathbf{w} \text{ pro něj. } \mathbf{a} \in \mathbb{F}^k\} &= \text{im}(\mathbf{G}) \\ &= W \\ &= \ker(\mathbf{H}^T) \\ &= \{\mathbf{w} \in \mathbb{F}^n \mid \mathbf{H}^T \cdot \mathbf{w} = \mathbf{0} \text{ v } \mathbb{F}^{n-k}\}\end{aligned}$$



Jinými slovy:  $\mathbf{H}^T \cdot \mathbf{G} = \mathbf{0}_{k,n-k}$  a  $\text{rank}(\mathbf{G}) = \text{def}(\mathbf{H}^T)$ .

## Co bude následovat v další přednášce?

- ① V prostorech tvaru  $\mathbb{F}^n$  zavedeme vztah **ortogonality**. To nám umožní mluvit přesně o generujících a kontrolních maticích lineárních podprostorů prostoru  $\mathbb{F}^n$ .
- ② V prostorech tvaru  $\mathbb{F}^n$  zavedeme pojem **Hammingovy vzdálenosti** vektorů. To nám později umožní zformulovat přesně metody **detekce** a **opravy** chyb v lineárních kódech.
- ③ Ukážeme, že existuje **nekonečně mnoho konečných těles** tvaru  $\mathbb{Z}_p$ , kde  $p$  je prvočíslo.

## A co v následujících přednáškách?

Nahlédneme do teorie lineárních kódů.

- ① Prostudujeme Hammingův (7, 4)-kód.
- ② Ukážeme, jak Hammingova vzdálenost souvisí s detekcí a opravou chyb.
- ③ Ukážeme, jak vytvořit kontrolní matici z generující matice (a naopak).



## Ortogonalita a Hammingova vzdálenost v $\mathbb{F}^n$

Odpřednesenou látku naleznete v dodatku I  
skript *Abstraktní a konkrétní lineární algebra*.

## Dnešní přednáška

- ① Konečná tělesa tvaru  $\mathbb{Z}_p$ , kde  $p$  je prvočíslo.
- ② Základy ortogonální geometrie v  $\mathbb{F}^n$ , kde  $\mathbb{F}$  je obecné těleso.
- ③ Hammingova vzdálenost v  $\mathbb{F}^n$ .

## Příští přednáška

- ① Základy kódování v prostorech  $(\mathbb{Z}_p)^n$  nad  $\mathbb{Z}_p$ , kde  $p$  je prvočíslo.

## Připomenutí (viz druhou přednášku) — definice tělesa

Množině  $\mathbb{F}$  spolu se dvěma operacemi **sčítání**  $+ : \mathbb{F} \times \mathbb{F} \rightarrow \mathbb{F}$ ,  
**násobení**  $\cdot : \mathbb{F} \times \mathbb{F} \rightarrow \mathbb{F}$ , říkáme **těleso**, pokud jsou splněny  
následující podmínky:

- ① **Axiomy pro sčítání:** sčítání je komutativní, asociativní a má neutrální prvek 0. Každý prvek má opačný prvek vzhledem ke sčítání.
- ② **Axiomy pro násobení:** násobení je komutativní, asociativní a má neutrální prvek 1.
- ③ **Distributivní zákony:**<sup>a</sup> platí  $a \cdot (b + c) = a \cdot b + a \cdot c$  a  $(b + c) \cdot a = b \cdot a + c \cdot a$ .
- ④ **Test invertibility:**  $a \neq 0$  právě tehdy, když existuje  $a^{-1}$ .

---

<sup>a</sup>Díky komutativitě násobení stačí požadovat platnost pouze jednoho z distributivních zákonů.

## Počítání modulo číslo

Zvolme přirozené číslo  $m \geq 2$ . Sčítání a násobení definujeme na **zbytcích** po dělení číslem  $m$ . Množinu zbytků označíme  $\mathbb{Z}_m$ .

Například: pro  $m = 4$  je  $\mathbb{Z}_4 = \{0, 1, 2, 3\}$ . Tabulky sčítání a násobení v  $\mathbb{Z}_4$  jsou:

+	0	1	2	3
0	0	1	2	3
1	1	2	3	0
2	2	3	0	1
3	3	0	1	2

·	0	1	2	3
0	0	0	0	0
1	0	1	2	3
2	0	2	0	2
3	0	3	2	1

Například (jako zbytky):  $2 + 3 = 5 = 1$ ,  $2 \cdot 3 = 6 = 2$  v  $\mathbb{Z}_4$ .

Pozor:  $3^{-1} = 3$  (protože  $3 \cdot 3 = 1$ ), ale  $2^{-1}$  neexistuje.

Tedy  $\mathbb{Z}_4$  není těleso. Důvod: existuje  $a \neq 0$ , pro které neexistuje  $a^{-1}$ . Test invertibility je **jediný** z axiomů tělesa, který je v  $\mathbb{Z}_4$  porušen.



## Věta

$\mathbb{Z}_m$  je těleso právě tehdy, když  $m$  je prvočíslo.<sup>a</sup>

<sup>a</sup>Viz také Tvrzení 1.2.2 skript.

## Důkaz.

- ① Je-li  $m = a \cdot b$  složené číslo ( $a > 1$  a  $b > 1$ ), potom  $a \cdot b = 0$  v  $\mathbb{Z}_m$ , takže ani  $a$  ani  $b$  nemají inversi v  $\mathbb{Z}_m$ .
- ② Je-li  $m$  prvočíslo, ukážeme indukcí, že každé číslo  $a$  z množiny  $\{1, \dots, m-1\}$  má v  $\mathbb{Z}_m$  inversi.

① Je-li  $a = 1$ , pak  $a^{-1} = 1$ .

② At'  $a$  splňuje  $1 < a \leq m-1$ . Předpokládejme, že každé číslo z množiny  $\{1, \dots, a-1\}$  má v  $\mathbb{Z}_m$  inversi.

Vydělme  $m$  číslem  $a$  se zbytkem:  $m = q \cdot a + a'$ , kde  $a' < a$  je zbytek po dělení. Protože  $m$  je prvočíslo, platí  $a' \geq 1$ . Potom platí  $0 = q \cdot a + a'$  v  $\mathbb{Z}_m$ .

Takže v  $\mathbb{Z}_m$  platí  $a' = (-q) \cdot a$ . Protože  $a'$  má podle indukčního předpokladu inversi, platí v  $\mathbb{Z}_m$  rovnost  $1 = \underbrace{(a'^{-1} \cdot (-q)) \cdot a}_{=a^{-1}}$ .

## Příklady těles tvaru $\mathbb{Z}_p$ , $p$ prvočíslo

1 Těleso  $\mathbb{Z}_2$ :

+	0	1
0	0	1
1	1	0

.	0	1
0	0	0
1	0	1

2 Těleso  $\mathbb{Z}_3$ :

+	0	1	2
0	0	1	2
1	1	2	0

.	0	1	2
0	0	0	0
1	0	1	2

## Příklady těles tvaru $\mathbb{Z}_p$ , $p$ prvočíslo (pokrač.)

- ③ Násobení v tělese  $\mathbb{Z}_{11}$  (vzpomeňte si na 10-ISBN):

.	0	1	2	3	4	5	6	7	8	9	10
0	0	0	0	0	0	0	0	0	0	0	0
1	0	1	2	3	4	5	6	7	8	9	10
2	0	2	4	6	8	10	1	3	5	7	9
3	0	3	6	9	1	4	7	10	2	5	8
4	0	4	8	1	5	9	2	6	10	3	7
5	0	5	10	4	9	3	8	2	7	1	6
6	0	6	1	7	2	8	3	9	4	10	5
7	0	7	3	10	6	2	9	5	1	8	4
8	0	8	5	2	10	7	4	1	9	6	3
9	0	9	7	5	3	1	10	8	6	4	2
10	0	10	9	8	7	6	5	4	3	2	1

## Poznámky k existenci prvočísel

- ① Množina  $\mathbb{P}$  všech prvočísel je **nekonečná** množina. Hledání velkých prvočísel je ale velmi obtížné.
- ② The Great Internet Mersenne Prime Search.

Ke dni 9. 2. 2024 je největším známým prvočíslem číslo

$$2^{82\,589\,933} - 1 \quad (\text{GIMPS, 7. 12. 2018})$$

Má 24 862 048 cifer.<sup>a</sup> Viz například stránky:

- ① <http://primes.utm.edu/primes/>
- ② <http://www.mersenne.org/>

- ③ O některých testech prvočíselnosti se lze dočíst například v textu J. Velebil, *Diskrétní matematika*, Praha, 2007.

---

<sup>a</sup>Jak vypadá **binární zápis** tohoto prvočísla? Uvědomme si, že **každé** číslo tvaru  $2^k - 1$  má ve svém binárním zápisu  $k$  jedniček.

## Úplný popis konečných těles

Tělesa tvaru  $\mathbb{Z}_p$ , kde  $p$  je prvočíslo, **netvoří** úplný seznam konečných těles.

Vytvoření úplného seznamu konečných těles vyžaduje rozumět výpočtům v okruhu  $\mathbb{Z}_p[x]$  (okruh polynomů nad  $\mathbb{Z}_p$ ) **modulo polynom**.

Více například v textu

J. Velebil, *Diskrétní matematika*, Praha, 2007.

Obecná konečná tělesa umožňují studium dalších aplikací:

- ① Cyklické kódy.
- ② Šifrování na eliptických křivkách.
- ③ A řadu dalších.

## Připomenutí skalárního součinu v $\mathbb{R}^n$ nad $\mathbb{R}$

Skalární součin  $\langle - | - \rangle$  v  $\mathbb{R}^n$  je funkce tvaru

$$\langle - | - \rangle : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$$

která splňuje tři podmínky:

- ① Pro vš.  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  platí rovnost  $\langle \mathbf{x} | \mathbf{y} \rangle = \langle \mathbf{y} | \mathbf{x} \rangle$ .
- ② Pro vš.  $\mathbf{x} \in \mathbb{R}^n$  platí, že  $\langle \mathbf{x} | - \rangle : \mathbb{R}^n \rightarrow \mathbb{R}$  je lineární zobrazení.
- ③ Pro vš.  $\mathbf{x} \in \mathbb{R}^n$  platí  $\langle \mathbf{x} | \mathbf{x} \rangle \geq 0$ . Rovnost  $\langle \mathbf{x} | \mathbf{x} \rangle = 0$  platí právě tehdy, když  $\mathbf{x} = \mathbf{0}$ .

### Poznámka

Třetí podmínu šlo zformulovat, protože  $\mathbb{R}$  je uspořádané těleso, tj. protože umíme rozpoznat nezáporná reálná čísla. Obecné těleso ale „rozumně“ uspořádat jít nemusí.<sup>a</sup>

---

<sup>a</sup>Např. těleso  $\mathbb{C}$  uspořádat nelze, viz Příklad 1.3.8 *skript*. Viz také následující příklad.



## Příklad (žádné konečné těleso $\mathbb{F}$ není uspořádané těleso)

Ať  $\mathbb{F}$  je konečné těleso. V množině  $\mathbb{F}$  nelze zadat podmnožinu  $\mathbb{F}_+$  (množinu kladných prvků tělesa  $\mathbb{F}$ ), která splňuje následující dvě podmínky:

- ① Platí přesně jedna z podmínek  $a = 0$ ,  $a \in \mathbb{F}_+$ ,  $-a \in \mathbb{F}_+$ .
- ② Jestliže  $a \in \mathbb{F}_+$  a  $b \in \mathbb{F}_+$ , pak  $a + b \in \mathbb{F}_+$  a  $ab \in \mathbb{F}_+$ .

Postupujeme sporem: ať taková množina  $\mathbb{F}_+$  existuje.<sup>a</sup>

Protože  $\mathbb{F}$  je konečná množina, existuje nejmenší kladné přirozené číslo  $n$  tak, že  $\underbrace{1 + \cdots + 1}_{n\text{-krát}} = 0$ .

Z axiomů pro  $\mathbb{F}_+$  plyne, že platí  $a^2 \in \mathbb{F}_+$  pro vš.  $a \neq 0$ .

Protože  $1 = 1^2$ , musí platit  $1 \in \mathbb{F}_+$  a  $\underbrace{1 + \cdots + 1}_{n\text{-krát}} \in \mathbb{F}_+$ . To je spor.

<sup>a</sup>Množina  $\mathbb{F}_+$  s těmito vlastnostmi umožňuje definovat uspořádání:  $a < b$  iff  $b - a \in \mathbb{F}_+$ .

## Tvrzení (vlastnosti zobrazení $\gamma : (\mathbf{x}, \mathbf{y}) \mapsto \mathbf{x}^T \cdot \mathbf{y}$ pro $\mathbf{x}, \mathbf{y} \in \mathbb{F}^n$ )

Ať  $\mathbb{F}$  je jakékoli těleso. Zobrazení  $\gamma : (\mathbf{x}, \mathbf{y}) \mapsto \mathbf{x}^T \cdot \mathbf{y}$  z množiny  $\mathbb{F}^n \times \mathbb{F}^n$  do množiny  $\mathbb{F}$  se chová **velmi podobně** jako standardní skalární součin v  $\mathbb{R}^n$ . To jest, platí následující:

- ① Pro vš.  $\mathbf{x}, \mathbf{y} \in \mathbb{F}^n$  platí  $\gamma(\mathbf{x}, \mathbf{y}) = \gamma(\mathbf{y}, \mathbf{x})$ .
- ② Pro vš.  $\mathbf{x} \in \mathbb{F}^n$  je zobrazení  $\gamma(\mathbf{x}, -) : \mathbb{F}^n \rightarrow \mathbb{F}$  lineární.

Podmínka

- ③ Rovnost  $\gamma(\mathbf{x}, \mathbf{x}) = 0$  platí právě tehdy, když  $\mathbf{x} = \mathbf{o}$ .  
ale obecně **neplatí** (protipříklad lze nalézt například v  $(\mathbb{Z}_2)^2$ ).

### Důkaz.

- ① Protože  $\gamma(\mathbf{x}, \mathbf{y}) = \mathbf{x}^T \cdot \mathbf{y}$  a  $\gamma(\mathbf{y}, \mathbf{x}) = \mathbf{y}^T \cdot \mathbf{x} = (\mathbf{x}^T \cdot \mathbf{y})^T$ , platí<sup>a</sup>  $\gamma(\mathbf{x}, \mathbf{y}) = \gamma(\mathbf{y}, \mathbf{x})$ .

---

<sup>a</sup>Každá matice rozměrů  $1 \times 1$  je totiž symetrická.

## Důkaz (pokrač.).

- ② Pro vš.  $\mathbf{x}$  z  $\mathbb{F}^n$  je zobrazení  $\gamma(\mathbf{x}, -) : \mathbb{F}^n \rightarrow \mathbb{F}$  lineární, protože
$$\begin{aligned}\gamma(\mathbf{x}, a_1 \cdot \mathbf{y}_1 + a_2 \cdot \mathbf{y}_2) &= \mathbf{x}^T \cdot (a_1 \cdot \mathbf{y}_1 + a_2 \cdot \mathbf{y}_2) = \\ a_1 \cdot \mathbf{x}^T \cdot \mathbf{y}_1 + a_2 \cdot \mathbf{x}^T \cdot \mathbf{y}_2 &= a_1 \cdot \gamma(\mathbf{x}, \mathbf{y}_1) + a_2 \cdot \gamma(\mathbf{x}, \mathbf{y}_2).\end{aligned}$$
- ③ Pro  $\mathbf{x} = \begin{pmatrix} 1 \\ 1 \end{pmatrix} \in (\mathbb{Z}_2)^2$  platí  $\gamma(\mathbf{x}, \mathbf{x}) = \mathbf{x}^T \cdot \mathbf{x} = 0$ . ■

## K čemu jsme použili pozitivní definitnost skalárních součinů?

Použili jsme ji pouze k důkazu C-S-B nerovnosti (tím pádem pro definici úhlu mezi vektory a pro definici normy a metriky vytvořené skalárním součinem).

Positivní definitnost jsme nepotřebovali pro definici ortogonality.

**Připomenutí:** vektory  $\mathbf{x}, \mathbf{y} \in \mathbb{R}^n$  jsou ortogonální (vzhledem ke skalárnímu součinu  $\langle - | - \rangle$ ), pokud platí  $\langle \mathbf{x} | \mathbf{y} \rangle = 0$ .

## Definice (ortogonalita v $\mathbb{F}^n$ )

Řekneme, že vektory  $\mathbf{x}, \mathbf{y}$  z  $\mathbb{F}^n$  jsou **ortogonální<sup>a</sup>** (také: **navzájem na sebe kolmé**), pokud platí  $\mathbf{x}^T \cdot \mathbf{y} = 0$ .

---

<sup>a</sup>Přesněji: v  $\mathbb{F}^n$  jde o ortogonalitu vzhledem k  $\gamma(\mathbf{x}, \mathbf{y}) = \mathbf{x}^T \cdot \mathbf{y}$ .

**Slogan:** ortogonalita v  $\mathbb{F}^n$  zobecňuje ortogonalitu vzhledem ke standardnímu skalárnímu součinu v  $\mathbb{R}^n$ .

## Definice (ortogonální doplněk lineárního podprostoru $\mathbb{F}^n$ )

Pro lineární podprostor  $W$  prostoru  $\mathbb{F}^n$  definujeme jeho **ortogonální doplněk** jako množinu

$$W^\perp = \{\mathbf{x} \in \mathbb{F}^n \mid \mathbf{w}^T \cdot \mathbf{x} = 0 \text{ pro všechna } \mathbf{w} \text{ z } W\}$$

### Poznámka

Protože  $\mathbf{w}^T \cdot \mathbf{x} = 0$  iff  $\mathbf{x}^T \cdot \mathbf{w} = 0$ , platí

$$W^\perp = \{\mathbf{x} \in \mathbb{F}^n \mid \mathbf{x}^T \cdot \mathbf{w} = 0 \text{ pro všechna } \mathbf{w} \text{ z } W\}$$

## Věta (vlastnosti ortogonálního doplňku)

Ať  $W$  je lineární podprostor prostoru  $\mathbb{F}^n$ . Potom platí:

- ①  $W^\perp$  je opět lineární podprostor prostoru  $\mathbb{F}^n$ .
- ② Je-li  $\dim(W) = k$ , pak  $\dim(W^\perp) = n - k$ .
- ③ Platí  $(W^\perp)^\perp = W$ .

### Důkaz.

- ① ① Pro všechna  $w$  z  $W$  platí  $w^T \cdot o = 0$ . Tedy  $o$  je ve  $W^\perp$ .
- ② Jestliže  $x_1$  a  $x_2$  jsou ve  $W^\perp$ , pak

$$w^T \cdot (a_1 \cdot x_1 + a_2 \cdot x_2) = a_1 \cdot \underbrace{w^T \cdot x_1}_{=0} + a_2 \cdot \underbrace{w^T \cdot x_2}_{=0} = 0$$

pro všechna  $w$  ve  $W$ . Ukázali jsme, že  $W^\perp$  je uzavřen v  $\mathbb{F}^n$  na tvorbu lineárních kombinací.

Takže  $W^\perp$  je lineární podprostor<sup>a</sup> prostoru  $\mathbb{F}^n$ .

<sup>a</sup>Elegantní důkaz téhož:  $W^\perp = \bigcap_{w \in W} \ker(\gamma(w, -))$ , kde  $\gamma(w, x) = w^T \cdot x$ .



## Důkaz (pokrač.).

- ② Označme jako  $(\mathbf{a}_1, \dots, \mathbf{a}_k)$  uspořádanou bázi  $W$ . Pro matici  $\mathbf{A} = (\mathbf{a}_1, \dots, \mathbf{a}_k)$  platí:  $\mathbf{x}$  je ve  $W^\perp$  iff  $\mathbf{A}^T \cdot \mathbf{x} = \mathbf{0}$  iff  $\mathbf{x}$  je v  $\ker(\mathbf{A}^T)$ . Neboli:  $W^\perp = \ker(\mathbf{A}^T)$ .

Protože  $\text{rank}(\mathbf{A}^T) = \text{rank}(\mathbf{A}) = k$  a protože  $\mathbf{A}^T : \mathbb{F}^n \rightarrow \mathbb{F}^k$ , je  $\text{def}(\mathbf{A}^T) = n - k$  podle věty o dimensi jádra a obrazu.

To znamená, že  $\dim(W^\perp) = n - k$ .

- ③ Zjevně platí  $W \subseteq (W^\perp)^\perp$ , protože každý vektor  $\mathbf{w}$  z  $W$  je ortogonální ke každému vektoru z  $W^\perp$ .

Je-li  $\dim(W) = k$ , je  $\dim((W^\perp)^\perp) = n - (n - k) = k$ .

Proto  $W = (W^\perp)^\perp$ .



## Příklad (rovnost $W = W^\perp$ může platit)

Pro podmnožinu  $W = \left\{ \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \end{pmatrix} \right\}$  lineárního prostoru  $(\mathbb{Z}_2)^2$  platí:<sup>a</sup>

①  $W$  je lineární podprostor prostoru  $(\mathbb{Z}_2)^2$ .

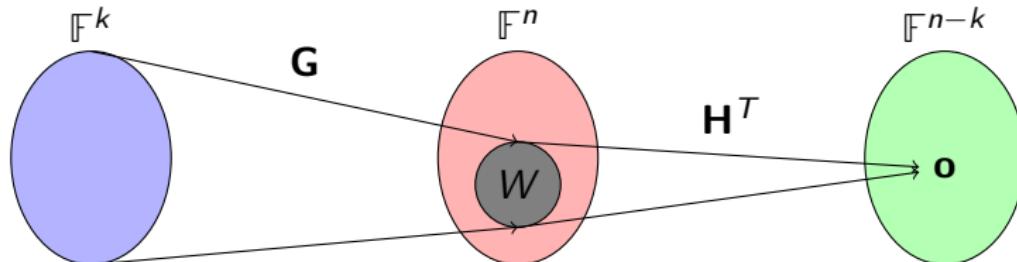
②  $W = \text{span}\left(\begin{pmatrix} 1 \\ 1 \end{pmatrix}\right)$ ,  $\dim(W) = 1$ .

③ 
$$\begin{aligned} W^\perp &= \left\{ \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \mid \begin{pmatrix} 0 \\ 0 \end{pmatrix}^T \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 0 \text{ a současně } \begin{pmatrix} 1 \\ 1 \end{pmatrix}^T \cdot \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 0 \right\} \\ &= W \end{aligned}$$

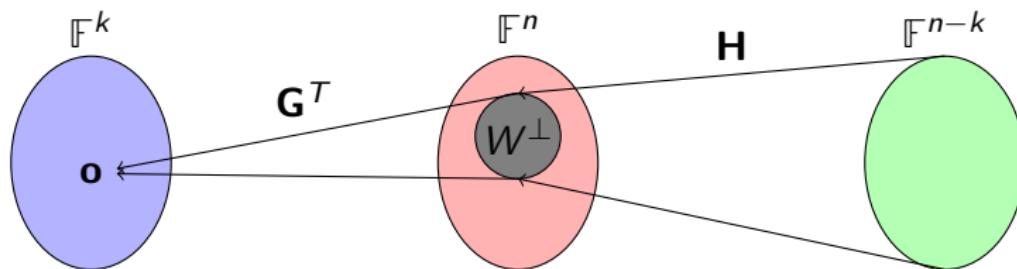
---

<sup>a</sup>Pro zájemce (**nepovinné**): „absurdní“ rovnost  $W = W^\perp$  je způsobena degenerovaností podprostoru  $W$  prostoru  $(\mathbb{Z}_2)^2$ . Všechny vektory podprostoru  $W$  jsou totiž na sebe navzájem kolmé.

## Dualita generujících a kontrolních matic podprostoru



$$\text{im}(\mathbf{G}) = W = \ker(\mathbf{H}^T)$$



$$\text{im}(\mathbf{H}) = W^\perp = \ker(\mathbf{G}^T)$$

## Definice (Hammingova vzdálenost v $\mathbb{F}^n$ )

Pro vektory  $\mathbf{x}, \mathbf{y}$  z  $\mathbb{F}^n$  definujeme

$$d_H(\mathbf{x}, \mathbf{y}) = \text{počet různých položek vektorů } \mathbf{x} \text{ a } \mathbf{y}$$

Přirozenému číslu  $d_H(\mathbf{x}, \mathbf{y})$  říkáme **Hammingova vzdálenost** vektorů  $\mathbf{x}$  a  $\mathbf{y}$ .

### Poznámka

Pro všechny vektory  $\mathbf{x}, \mathbf{y}$  z  $\mathbb{F}^n$  platí  $d_H(\mathbf{x}, \mathbf{y}) \leq n$ .

## Tvrzení (Hammingova vzdálenost je metrika na $\mathbb{F}^n$ )

Pro všechny vektory  $\mathbf{x}, \mathbf{y}, \mathbf{z}$  z  $\mathbb{F}^n$  platí:

- ①  $d_H(\mathbf{x}, \mathbf{y}) \geq 0$ , rovnost nastává právě tehdy, když  $\mathbf{x} = \mathbf{y}$ .
- ②  $d_H(\mathbf{x}, \mathbf{y}) = d_H(\mathbf{y}, \mathbf{x})$ .
- ③  $d_H(\mathbf{x}, \mathbf{y}) \leq d_H(\mathbf{x}, \mathbf{z}) + d_H(\mathbf{z}, \mathbf{y})$ .

### Důkaz.

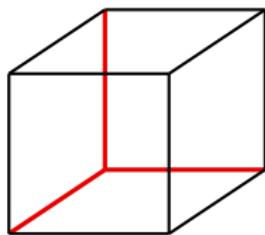
Důkaz plyne okamžitě z definice  $d_H$ .



## Příklad (Hammingova vzdálenost v $(\mathbb{Z}_2)^3$ )

Osm vektorů  $\begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 0 \\ 1 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$

prostoru  $(\mathbb{Z}_2)^3$  si lze představit jako vrcholy krychle (červené hrany jsou souřadnicové osy):



Hammingova vzdálenost dvou vektorů je pak délka nejkratší cesty po hranách krychle z jednoho vrcholu do druhého.

Podobnou představu lze mít o Hammingově vzdálenosti vektorů v prostoru  $(\mathbb{Z}_2)^n$ : vektory v  $(\mathbb{Z}_2)^n$  jsou vrcholy  $n$ -dimenionální krychle.



# Lineární kódy

Odpřednesenou látku naleznete v dodatku I  
skript *Abstraktní a konkrétní lineární algebra*.

## Dnešní přednáška

- ① Analýza Hammingova (7, 4)-kódu.
- ② Lineární kódy nad  $\mathbb{Z}_p$ .
- ③ Oprava a detekce chyb.
- ④ Syndrome decoding a nearest neighbour decoding.

## Další možné doplňující informace

- ① J. Adámek, *Foundations of coding*, John Wiley & Sons, 1991
- ② D. J. C. MacKay, *Information theory, inference and learning algorithms*, Cambridge Univ. Press, 2003
- ③ W. C. Huffman a V. Pless, *Fundamentals of error-correcting codes*, Cambridge Univ. Press, 2003

## Připomenutí (minulé přednášky):

Teorie lineárních prostorů nad obecným tělesem  $\mathbb{F}$  byla vybudována.

Příkladem těles jsou  $\mathbb{Z}_p$ , kde  $p$  je prvočíslo.

To znamená:

- ① Umíme určit bázi a dimensi podprostorů  $W$  lineárního prostoru  $(\mathbb{Z}_p)^n$ .
- ② Umíme pracovat s maticemi nad  $\mathbb{Z}_p$  a řešit soustavy lineárních rovnic nad  $\mathbb{Z}_p$ .

Navíc:

- ③ V prostoru  $(\mathbb{Z}_p)^n$  rozumíme relaci ortogonality a Hammingově vzdálenosti.
- ④ V prostoru  $(\mathbb{Z}_p)^n$  rozumíme generujícím a kontrolním maticím lineárních podprostorů.

## Příklad (Hammingův (7, 4)-kód)

$V(\mathbb{Z}_2)^7$  zvolme lineární podprostor  $W$  dimenze 4 s bází danou vektory

$$\mathbf{g}_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \\ 1 \end{pmatrix}, \mathbf{g}_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \\ 1 \\ 0 \\ 1 \end{pmatrix}, \mathbf{g}_3 = \begin{pmatrix} 0 \\ 0 \\ 1 \\ 0 \\ 1 \\ 1 \\ 0 \end{pmatrix}, \mathbf{g}_4 = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 1 \\ 1 \\ 1 \\ 1 \end{pmatrix}$$

Generující matice  $\mathbf{G}$  podprostoru  $W$  je

$$\mathbf{G} = (\mathbf{g}_1, \mathbf{g}_2, \mathbf{g}_3, \mathbf{g}_4) = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 1 & 1 & 1 \\ 1 & 0 & 1 & 1 \\ 1 & 1 & 0 & 1 \end{pmatrix}$$

## Příklad (Hammingův (7, 4)-kód, pokrač.)

- ①  $\text{rank}(\mathbf{G}) = 4$ , tudíž máme k disposici 4 info bity.
- ② Dimenze ortogonálního doplňku  $7 - 4 = 3$ . Informace bude chráněna třemi bity (redundance).

- ③ Posílání zpráv: informace  $\begin{pmatrix} 1 \\ 1 \\ 0 \\ 1 \end{pmatrix}$  vytváří kódové slovo

$$\mathbf{G} \cdot \begin{pmatrix} 1 \\ 1 \\ 0 \\ 1 \end{pmatrix} = \begin{pmatrix} 1 \\ 1 \\ 0 \\ 1 \\ 0 \\ 0 \\ 1 \end{pmatrix}.$$

Pozorování:  $\mathbf{G}$  je v blokovém tvaru  $\begin{pmatrix} \mathbf{E}_4 \\ \mathbf{B} \end{pmatrix}$ .<sup>a</sup>

---

<sup>a</sup>Takovým kódům se říká **systematické**: jsou v nich jasně odděleny informační a ochranné bity.



## Příklad (Hammingův (7, 4)-kód, pokrač.)

Kontrolní (Hammingova) matice

$$\mathbf{H}^T = \begin{pmatrix} \mathbf{h}_1^T \\ \mathbf{h}_2^T \\ \mathbf{h}_3^T \end{pmatrix} = \begin{pmatrix} 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 \end{pmatrix}$$

Jde o ideální kód, pokud došlo nejvíše k jedné chybě:<sup>a</sup>

- ➊ Odesláno  $\mathbf{w}$ , přijmeme  $\mathbf{v}$  a předpokládáme, že došlo k nejvíše jedné chybě. Tj.  $\mathbf{v} = \mathbf{w} + \mathbf{e}$  ( $\mathbf{e}$  je error pattern). Víme, že  $\mathbf{e}$  obsahuje nejvíše jednu jedničku.
- ➋ Spočteme syndrom  $\mathbf{s}$  slova  $\mathbf{v}$ :  $\mathbf{s} = \mathbf{H}^T \mathbf{v} = \mathbf{H}^T \mathbf{e}$ .
  - ➌ Jestliže  $\mathbf{s} = \mathbf{0}$ , při přenosu nedošlo k chybě, tj.  $\mathbf{e} = \mathbf{0}$ , neboli  $\mathbf{v} = \mathbf{w}$ .
  - ➍ Jestliže  $\mathbf{s}$  je  $i$ -tý sloupec  $\mathbf{H}^T$ , je  $\mathbf{e} = \mathbf{e}_i$ . Došlo k chybě na  $i$ -tém místě. Opravíme ji:  $\mathbf{w} = \mathbf{v} - \mathbf{e}_i$ .
- ➎ Isolujeme info byty.

---

<sup>a</sup> Jde dokonce o příklad tzv perfektního kódu pro opravu jedné chyby, viz příští přednášku.



## Příklad (Hammingův (7, 4)-kód, pokrač.)

Co se stane, pokud error pattern  $\mathbf{e}$  obsahuje dvě jedničky? Tj., co nastane, pokud při přenosu došlo k **právě dvěma chybám**?

Spočteme syndrom  $\mathbf{s}$  slova  $\mathbf{v}$ :  $\mathbf{s} = \mathbf{H}^T \mathbf{v} = \mathbf{H}^T \mathbf{e}$ .

Pokud jsou jedničky v  $\mathbf{e}$  na místech  $i$  a  $j$ , je  $\mathbf{H}^T \mathbf{e}$  součet  $i$ -tého a  $j$ -tého sloupce matice  $\mathbf{H}^T$ .

Připomeňme, že

$$\mathbf{H}^T = \begin{pmatrix} 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 \end{pmatrix}$$

Dvě chyby na první a druhé pozici současně tedy nerozlišíme od jedné chyby na pouze třetí pozici.

## Problém návrhu lineárního kódu

Jak vyvážit následující požadavky? Chceme co největší opravné schopnosti kódu a co nejmenší počet kontrolních bitů.

Tyto požadavky jsou intuitivně protichůdné.

**V plné obecnosti se nyní budeme věnovat dvěma tématům**

- ① Způsoby dekódování lineárních kódů.
- ② Opravné a ochranné schopnosti lineárních kódů.

Obě téma mají jasnou **geometrickou** interpretaci.

## Definice (lineární kód)

Ať  $p$  je prvočíslo. Lineární  $p$ -kód délky  $n$  a dimenze  $k$  je lineární podprostor  $W$  prostoru  $(\mathbb{Z}_p)^n$ ,  $\dim(W) = k$ ,  $0 \leq k \leq n$ .

Terminologie:

- ① Prvkům  $(\mathbb{Z}_p)^n$  říkáme také **slova**, prvkům  $W$  **kódová slova**.<sup>a</sup>
- ② **Generující matice**  $\mathbf{G} : (\mathbb{Z}_p)^k \rightarrow (\mathbb{Z}_p)^n$  kódu  $W$  je (jakákoli) generující matice podprostoru  $W$ .
- ③ Vektoru  $\mathbf{w} = \mathbf{G} \cdot \mathbf{a}$  říkáme **kódové slovo určené vektorem informace**  $\mathbf{a}$  ze  $(\mathbb{Z}_p)^k$ .
- ④ **Kontrolní matice**  $\mathbf{H}^T : (\mathbb{Z}_p)^n \rightarrow (\mathbb{Z}_p)^{n-k}$  je (jakákoli) kontrolní matice podprostoru  $W$ .
- ⑤ Součinu  $\mathbf{s} = \mathbf{H}^T \cdot \mathbf{v}$  říkáme **syndrom slova**  $\mathbf{v}$ .

---

<sup>a</sup>Slova a kódová slova jsou **vektory** v  $(\mathbb{Z}_p)^n$ , píšeme je tedy do **sloupce**. Poznámky ke značení v jiné literatuře uvedeme na příští přednášce.

## Geometrie error patternu a jeho syndromu

Ať  $W$  je lineární  $p$ -kód délky  $n$  a dimenze  $k$  s generující maticí  $\mathbf{G} = (\mathbf{g}_1, \dots, \mathbf{g}_k)$  a kontrolní maticí  $\mathbf{H}^T$ . Zvolme jakékoli slovo  $\mathbf{e}$  ze  $(\mathbb{Z}_p)^n$  (tzv. **error pattern**) a označme  $\mathbf{H}^T \cdot \mathbf{e} = \mathbf{s}$  syndrom slova  $\mathbf{e}$ .

Z lineární algebry okamžitě plyne:<sup>a</sup>

$\mathbf{e} + W$  je  $k$ -dimensionální plocha v  $(\mathbb{Z}_p)^n$ .

Tato plocha prochází bodem  $\mathbf{e}$  a má směr  $(\mathbf{g}_1, \dots, \mathbf{g}_k)$ .

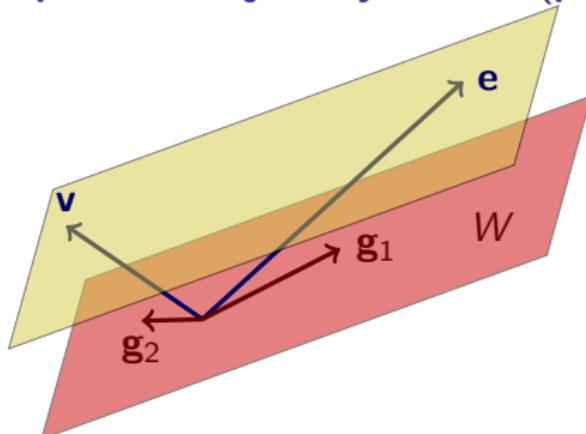
Platí totiž, že  $\mathbf{e} + W$  je přesně množina řešení soustavy  $(\mathbf{H}^T \mid \mathbf{s})$ .

Jiný pohled na totéž:  $\mathbf{e} + W$  je přesně množina všech slov  $\mathbf{v}$  ze  $(\mathbb{Z}_p)^n$  se syndromem  $\mathbf{s} = \mathbf{H}^T \cdot \mathbf{e}$ .

---

<sup>a</sup>Připomeňte si přednášku 6B.

## Geometrie error patternu a jeho syndromu (pokrač.)



$k$ -dimensionální plocha  $\mathbf{e} + W$  v  $(\mathbb{Z}_p)^n$  je přesně množina všech slov  $\mathbf{v}$  ze  $(\mathbb{Z}_p)^n$  se syndromem  $\mathbf{s}$ .

**Dekódovací strategie:** přijmeme-li slovo  $\mathbf{v}$ , stačí nalézt  $\mathbf{e}$  tak, aby  $\mathbf{v}$  bylo v  $\mathbf{e} + W$ . Potom bylo odesláno slovo  $\mathbf{w} = \mathbf{v} - \mathbf{e}$ .

**Problém této strategie:** je pro  $\mathbf{v}$  error pattern  $\mathbf{e}$  určen jednoznačně?  
**Není!** Existuje ale „přirozená“ volba: at'  $\mathbf{e}$  je „co nejblíže“  $\mathbf{o}$ .

V úvahách o dekódování, opravách a detekci chyb budou hrát roli následující pojmy:

### Definice (Hammingova váha slova a min. distance kódu)

- ① **Hammingova váha**  $w_H(\mathbf{v}) = d_H(\mathbf{v}, \mathbf{o})$  slova  $\mathbf{v}$ . Zjevně platí:  
 $w_H(\mathbf{v})$  = počet nenulových položek slova  $\mathbf{v}$ .
- ② **Minimální (Hammingova) distance kódu  $W$**   
 $\text{dist}(W) = \min\{w_H(\mathbf{w}) \mid \mathbf{w} \text{ je nenulové slovo ve } W\}.$

### Poznámka (jiný vzorec pro minimální distanci kódu)

Platí:  $\text{dist}(W) = \min\{d_H(\mathbf{w}, \mathbf{w}') \mid \mathbf{w}, \mathbf{w}' \text{ jsou různá slova z } W\}.$

Opravdu: pro různá slova  $\mathbf{w}, \mathbf{w}'$  z  $W$  je  $\mathbf{w} - \mathbf{w}'$  nenulové slovo z  $W$  a platí  $d_H(\mathbf{w}, \mathbf{w}') = w_H(\mathbf{w} - \mathbf{w}')$ . Obráceně, pro nenulové slovo  $\mathbf{w}$  z  $W$  je  $w_H(\mathbf{w}) = d_H(\mathbf{w}, \mathbf{o})$  Hammingova vzdálenost dvou různých slov ve  $W$ .

## Tvrzení

Ať  $\mathbf{H}^T$  je kontrolní matici kódu  $W$ . Pro kladné přirozené číslo  $d$  jsou následující podmínky ekvivalentní:

- ① Kód  $W$  má minimální distanci  $d$ .
- ② Každých  $d - 1$  sloupců matice  $\mathbf{H}^T$  je lineárně nezávislých a některých  $d$  sloupců matice  $\mathbf{H}^T$  je lineárně závislých.

## Důkaz.

Kód  $W$  obsahuje slovo  $\mathbf{w}$  váhy  $w > 0$  iff  $\mathbf{H}^T \cdot \mathbf{w} = \mathbf{0}$  iff  $w > 0$  sloupců  $\mathbf{H}^T$  je lineárně závislých. ■

## Důsledek (Singletonův odhad)

Ať  $W$  je kód délky  $n$  a dimenze  $k$ . Potom  $\text{dist}(W) \leq n - k + 1$ .

## Důkaz.

Pro kontrolní matici  $\mathbf{H}^T$  kódu  $W$  platí  $\text{rank}(\mathbf{H}^T) = n - k$ . Tudíž  $\text{dist}(W) - 1 \leq n - k$ .



## Příklad (minimální distance Hammingova (7, 4)-kódu)

Hammingův (7, 4)-kód má kontrolní matici

$$\mathbf{H}^T = \begin{pmatrix} 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 \end{pmatrix}$$

Označme jako  $d$  minimální distanci tohoto kódu.

Singletonův odhad dává:  $d - 1 \leq 7 - 4 + 1$ , čili  $d \leq 5$ .

Ve skutečnosti platí  $d = 3$ .

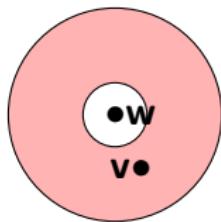
Proč? Například první tři sloupce matice  $\mathbf{H}^T$  jsou lineárně závislé, jakákoli dvojice sloupců matice  $\mathbf{H}^T$  je lineárně nezávislá.

## Definice (detekce a oprava chyb)

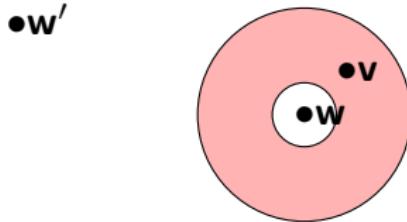
Ať  $W$  je lineární kód. Řekneme, že

- ①  $W$  **detekuje**  $t$  chyb, pokud pro každé  $\mathbf{w}$  ve  $W$  a každé  $\mathbf{v}$  takové, že  $1 \leq d_H(\mathbf{w}, \mathbf{v}) \leq t$ , platí:  $\mathbf{v}$  není ve  $W$ .
- ②  $W$  **opravuje**  $t$  chyb, pokud pro každé  $\mathbf{w}$  ve  $W$  a každé  $\mathbf{v}$  takové, že  $1 \leq d_H(\mathbf{w}, \mathbf{v}) \leq t$ , platí:  $d_H(\mathbf{w}, \mathbf{v}) < d_H(\mathbf{w}', \mathbf{v})$  pro všechna  $\mathbf{w}'$  z  $W$  různá od  $\mathbf{w}$ .

## Geometrie detekce a opravy chyb (slogany)



Detekce: slova **nedaleko** od kódového slova **nejsou** ve  $W$ .



Oprava: slova **nedaleko** od kódového slova **jsou** daleko od jiných slov z  $W$ .

## Tvrzení

Kód  $W$  detekuje  $t$  chyb právě tehdy, když  $\text{dist}(W) > t$ .

### Důkaz.

- ① Até  $\text{dist}(W) \leq t$ . Zvolme kódová slova  $\mathbf{w}, \mathbf{w}'$  tak, že  $d_H(\mathbf{w}, \mathbf{w}') = \text{dist}(W)$ . Potom  $1 \leq d_H(\mathbf{w}, \mathbf{w}') \leq t$ .

To znamená, že nelze detekovat následujících  $t$  chyb: odesláno slovo  $\mathbf{w}$ , přijato slovo  $\mathbf{w}'$ .

- ② Até  $\text{dist}(W) > t$ . Zvolme  $\mathbf{w}$  ve  $W$  a  $\mathbf{v}$  takové, že platí  $1 \leq d_H(\mathbf{w}, \mathbf{v}) \leq t$ .

Potom  $d_H(\mathbf{w}, \mathbf{v}) < \text{dist}(W)$ , takže  $\mathbf{v}$  nemůže být kódové slovo.



## Tvrzení

Kód  $W$  opravuje  $t$  chyb právě tehdy, když  $\text{dist}(W) > 2t$ .

### Důkaz.

- At'  $\text{dist}(W) \leq 2t$ . Zvolme kódová slova  $\mathbf{w}, \mathbf{w}'$  tak, že  $d_H(\mathbf{w}, \mathbf{w}') = \text{dist}(W)$  a označme jako  $i_1, \dots, i_r$  indexy položek, ve kterých se  $\mathbf{w}$  a  $\mathbf{w}'$  liší.

Definujme  $\mathbf{v}$  jako slovo, které má stejné položky jako  $\mathbf{w}$ , kromě položek  $i_2, i_4, \dots$ , na kterých má stejné položky jako  $\mathbf{w}'$ .

Potom  $1 \leq d_H(\mathbf{w}, \mathbf{v}) \leq \frac{r}{2} \leq t$ , ale  $d_H(\mathbf{w}', \mathbf{v}) \leq d_H(\mathbf{w}, \mathbf{v})$ .

- At'  $\text{dist}(W) > 2t$ . At'  $\mathbf{w}$  je ve  $W$  a at' platí  $1 \leq d_H(\mathbf{w}, \mathbf{v}) \leq t$ .

Pro jakékoli  $\mathbf{w}'$  ve  $W$  platí  $d_H(\mathbf{w}, \mathbf{w}') \geq \text{dist}(W) > 2t$ .

To znamená, že  $2t < d_H(\mathbf{w}, \mathbf{w}') \leq d_H(\mathbf{w}, \mathbf{v}) + d_H(\mathbf{v}, \mathbf{w}')$ .

Takže  $d_H(\mathbf{w}', \mathbf{v}) > 2t - d_H(\mathbf{w}, \mathbf{v}) \geq 2t - t = t \geq d_H(\mathbf{w}, \mathbf{v})$ .

## Syndrome decoding

Ať  $W$  je lineární  $p$ -kód délky  $n$  a dimenze  $k$ . Předpokládejme, že odeslané kódové slovo z  $W$  bylo přijato jako slovo  $\mathbf{v}$  ze  $(\mathbb{Z}_p)^n$ .

**Syndrome decoding** je následující dekódovací procedura:

- ① Spočteme syndrom  $\mathbf{H}^T \cdot \mathbf{v} = \mathbf{s}$  slova  $\mathbf{v}$ .
- ② Nalezneme takové řešení soustavy  $(\mathbf{H}^T \mid \mathbf{s})$  tvaru  $\mathbf{e} + W$ , kde Hammingova váha  $w_H(\mathbf{e})$  je **nejmenší** možná.<sup>a</sup>

Předpokládáme, že bylo odesláno kódové slovo  $\mathbf{w} = \mathbf{v} - \mathbf{e}$ .

---

<sup>a</sup>Pokud je takových  $\mathbf{e}$  více, vybereme některé z nich náhodně.

## Kolik různých syndromů existuje?

Kontrolní matice  $W$  je lineární zobrazení  $\mathbf{H}^T : (\mathbb{Z}_p)^n \rightarrow (\mathbb{Z}_p)^{n-k}$ .

Slovo  $\mathbf{s}$  je syndrom právě když  $\mathbf{s}$  leží v  $\text{im}(\mathbf{H}^T)$ .

Protože  $\text{rank}(\mathbf{H}^T) = n - k$ , existuje celkem  $p^{n-k}$  různých syndromů.



## Příklad (Hammingův (7, 4)-kód a syndrome decoding)

Existuje 8 různých syndromů:  $\mathbf{s}_0 = \begin{pmatrix} 0 \\ 0 \\ 0 \end{pmatrix}$ ,  $\mathbf{s}_1 = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix}$ ,  $\mathbf{s}_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \end{pmatrix}$ ,  
 $\mathbf{s}_3 = \begin{pmatrix} 0 \\ 1 \\ 1 \end{pmatrix}$ ,  $\mathbf{s}_4 = \begin{pmatrix} 1 \\ 0 \\ 0 \end{pmatrix}$ ,  $\mathbf{s}_5 = \begin{pmatrix} 1 \\ 0 \\ 1 \end{pmatrix}$ ,  $\mathbf{s}_6 = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix}$ ,  $\mathbf{s}_7 = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$ .

Vyřešením příslušných soustav nalezneme 8 „nejmenších“ error

paterns:  $\mathbf{e}_0 = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$ ,  $\mathbf{e}_1 = \begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$ ,  $\mathbf{e}_2 = \begin{pmatrix} 0 \\ 1 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \end{pmatrix}$ , ...,  $\mathbf{e}_7 = \begin{pmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ 1 \end{pmatrix}$ .

Vidíme, že syndrome decoding Hammingova (7, 4)-kódu je korektní pro opravu nejvíše jedné chyby.<sup>a</sup>

---

<sup>a</sup>Dekódování již nelze nijak vylepšit, protože minimální distance tohoto kódu je 3.



## Nearest neighbour decoding

Ať  $W$  je linární  $p$ -kód délky  $n$  a dimenze  $k$ . Předpokládejme, že odeslané kódové slovo z  $W$  bylo přijato jako slovo  $\mathbf{v}$  ze  $(\mathbb{Z}_p)^n$ .

**Nearest neighbour decoding** je následující dekódovací procedura:

- ① Pokud je  $\mathbf{v}$  kódové slovo, předpokládáme, že k žádné chybě nedošlo.

Předpokládáme tedy, že bylo odesláno kódové slovo  $\mathbf{v}$ .

- ② Pokud  $\mathbf{v}$  kódové slovo není, nalezneme takové kódové slovo  $\mathbf{w}$ , pro které je Hammingova vzdálenost  $d_H(\mathbf{v}, \mathbf{w})$  **nejmenší**.<sup>a</sup>

Předpokládáme, že bylo odesláno kódové slovo  $\mathbf{w}$ .

---

<sup>a</sup>Pokud je takových kódových  $\mathbf{w}$  slov více, vybereme některé z nich náhodně.

## Tvrzení (syndrome decoding = nearest neighbour decoding)

Ať  $W$  je linární  $p$ -kód délky  $n$  a dimenze  $k$ . Předpokládejme, že odeslané kódové slovo z  $W$  bylo přijato jako slovo  $\mathbf{v}$  ze  $(\mathbb{Z}_p)^n$ . Potom množiny

$$\{\mathbf{w} \in W \mid \text{Hammingova vzdálenost } d_H(\mathbf{v}, \mathbf{w}) \text{ je nejmenší}\}$$

a

$$\{\mathbf{w} \in W \mid \text{Hammingova váha } w_H(\mathbf{v} - \mathbf{w}) \text{ je nejmenší}\}$$

jsou stejné.

To jest: syndrome decoding a nearest neighbour decoding jsou totožné procedury.

### Důkaz.

Podle definice Hammingovy vzdálenosti platí pro libovolné vektory  $\mathbf{x}, \mathbf{y}$  rovnost  $d_H(\mathbf{x}, \mathbf{y}) = d_H(\mathbf{x} - \mathbf{y}, \mathbf{0}) = w_H(\mathbf{x} - \mathbf{y})$ .

# Perfektní lineární kódy

Odpřednesenou látku naleznete v dodatku I  
skript *Abstraktní a konkrétní lineární algebra*.

## Minulé přednášky

- ① Detekce a oprava chyb v lineárních kódech.
- ② Hammingův  $(7, 4)$ -kód.

## Dnešní přednáška

- ① Kódy perfektní pro opravu  $t$  chyb.
- ② Obecné Hammingovy kódy.
- ③ Jako aplikaci teorie kódů vyřešíme Hat Problem (**nepovinné**).

## Další možné doplňující informace

- ① J. Adámek, *Foundations of coding*, John Wiley & Sons, 1991
- ② D. J. C. MacKay, *Information theory, inference and learning algorithms*, Cambridge Univ. Press, 2003

## Definice (perfektní kód pro $t$ chyb)

Řekneme, že lineární kód  $W$  délky  $n$  nad  $\mathbb{Z}_p$  je **perfektní pro  $t$  chyb**, pokud pro každé  $\mathbf{v}$  ze  $(\mathbb{Z}_p)^n$  existuje právě jedno  $\mathbf{w}$  z  $W$  tak, že  $d_H(\mathbf{w}, \mathbf{v}) \leq t$ .

## Poznámky

- 1 Kód  $W$  je perfektní pro  $t$  chyb právě tehdy, když platí

$$(\mathbb{Z}_p)^n = \bigcup_{\mathbf{w} \in W} \text{Ball}_t(\mathbf{w})$$

kde

$$\text{Ball}_t(\mathbf{w}) = \{\mathbf{v} \in (\mathbb{Z}_p)^n \mid d_H(\mathbf{w}, \mathbf{v}) \leq t\}$$

je **koule** v  $(\mathbb{Z}_p)^n$  se středem ve  $\mathbf{w}$  a poloměrem  $t$ . Toto sjednocení je navíc disjunktní.<sup>a</sup>

Je-li  $W$  perfektní pro  $t$  chyb, pak  $\text{dist}(W) = 2t + 1$ . Takže  $W$  opravuje  $t$  chyb.

---

<sup>a</sup>**Slogan:** kód  $W$  je perfektní pro  $t$  chyb právě tehdy, když  $(\mathbb{Z}_p)^n$  lze pokrýt disjunktními koulemi se středy v kódových slovech a poloměrem  $t$ .



## Poznámky (pokrač.)

### ② Počet prvků jedné koule

$$\text{Ball}_t(\mathbf{w}) = \{\mathbf{v} \mid d_H(\mathbf{w}, \mathbf{v}) = 0\} \cup \{\mathbf{v} \mid d_H(\mathbf{w}, \mathbf{v}) = 1\} \cup \dots$$

$$\dots \cup \{\mathbf{v} \mid d_H(\mathbf{w}, \mathbf{v}) = t - 1\} \cup \{\mathbf{v} \mid d_H(\mathbf{w}, \mathbf{v}) = t\}$$

je roven součtu

$$\sum_{i=0}^t \underbrace{\binom{n}{i}}_{\substack{\text{výběr} \\ \text{lišících} \\ \text{se znaků}}} \cdot \overbrace{(p-1)^i}^{\substack{\text{výběr} \\ \text{lišících} \\ \text{se posic}}}, \quad \text{kde } \binom{n}{i} = \frac{n!}{i! \cdot (n-i)!}.$$

## Poznámky (pokrač.)

- ③ Kód  $W$  je perfektní pro  $t$  chyb právě tehdy, když platí rovnost

$$p^n = (\text{počet slov ve } W) \cdot \sum_{i=0}^t \binom{n}{i} \cdot (p-1)^i$$

Víme-li navíc, že  $W$  má dimensi  $k$ , lze tuto rovnost psát jako

$$p^{n-k} = \sum_{i=0}^t \binom{n}{i} \cdot (p-1)^i$$

protože takové  $W$  obsahuje přesně  $p^k$  slov.

- ④ Pro obecný lineární kód  $W$  dimense  $k$  opravující  $t$  chyb platí pouze **nerovnost**

$$p^{n-k} \geq \sum_{i=0}^t \binom{n}{i} \cdot (p-1)^i$$

které se říká **sphere-packing bound**.



## Poznámky

- ① Klasifikace perfektních kódů nad  $\mathbb{Z}_p$  existuje, jde však o **těžký** a hluboký výsledek. Viz například knihu
  - W. C. Huffman a V. Pless, *Fundamentals of error-correcting codes*, Cambridge Univ. Press, 2003
- ② Uvidíme příklad třídy kódů, perfektních pro 1 chybu.  
Jde o třídu takzvaných **Hammingových kódů**.
- ③ Vesmírný program NASA používá perfektní kódy pro přenos fotografií z družic.

Například sondy Voyager 1 a Voyager 2 používaly pro přenos fotografií Jupitera a Saturnu perfektní kód (**Golay (24,12,8) code**).

## Definice (Hammingův kód)

Hammingův kód je kód nad  $\mathbb{Z}_2$  délky  $n = 2^m - 1$  s kontrolní maticí  $\mathbf{H}^T$ , která má  $m$  řádků a sloupce matice  $\mathbf{H}^T$  přesně odpovídají binárním zápisům všech čísel  $1, \dots, 2^m - 1$ , kde  $m \geq 1$  je přirozené číslo.

## Příklady

- 1 Kontrolní matice Hammingova kódu pro  $m = 1$ :

$$\mathbf{H}^T = (1)$$

Délka tohoto kódu je 1, dimenze 0.<sup>a</sup> Inf. rate =  $\frac{0}{1} = 0$ .

- 2 Kontrolní matice Hammingova kódu pro  $m = 2$ :

$$\mathbf{H}^T = \begin{pmatrix} 0 & 1 & 1 \\ 1 & 0 & 1 \end{pmatrix}$$

Délka tohoto kódu je 3, dimenze 1. Inf. rate =  $\frac{1}{3} = 0.33\dots$

---

<sup>a</sup>Jde tedy o triviální kód  $(\mathbb{Z}_2)^0 = \{\mathbf{0}\}$ , který není příliš použitelný.

## Příklady (pokrač.)

- ③ Kontrolní matice Hammingova  $(7, 4)$ -kódu (zde je  $m = 3$ ):

$$\mathbf{H}^T = \begin{pmatrix} 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 \end{pmatrix}$$

Délka tohoto kódu je 7, dimenze 4. Inf. rate =  $\frac{4}{7} = 0.57\dots$

- ④ Kontrolní matice Hammingova kódu pro  $m = 4$ :

$$\mathbf{H}^T = \begin{pmatrix} 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 & 1 & 1 & 1 \\ 0 & 0 & 0 & 1 & 1 & 1 & 1 & 0 & 0 & 0 & 0 & 1 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 & 0 & 0 & 1 & 1 & 0 & 0 & 1 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 0 & 1 & 1 \end{pmatrix}$$

Délka tohoto kódu je 15, dimenze 11. Inf. rate =  $\frac{11}{15} = 0.73\dots$

- ⑤ Pro obecné  $m \geq 1$  je délka příslušného Hammingova kódu  $2^m - 1$ , dimenze je rovna  $2^m - 1 - m$  a inf. rate je roven

$$\frac{2^m - 1 - m}{2^m - 1} = 1 - \frac{m}{2^m - 1}$$



## Tvrzení

Ať  $W$  je Hammingův kód délky  $n = 2^m - 1$ ,  $m \geq 2$ . Potom  $W$  je perfektní pro 1 chybu.

## Důkaz.

Chceme ukázat rovnost

$$p^{n-k} = \sum_{i=0}^t \binom{n}{i} \cdot (p-1)^i$$

kde  $p = 2$ ,  $t = 1$ ,  $n = 2^m - 1$  a  $k = 2^m - 1 - m$ .

Opravdu, platí:

$$\underbrace{\binom{2^m - 1}{0}}_{=1} + \underbrace{\binom{2^m - 1}{1}}_{=2^m - 1} = 1 + 2^m - 1 = 2^m = 2^{n-k}$$

## The Hat Problem (Todd Ebert, 1998)

Skupina vězňů hraje následující hru o svobodu:

- ① Každý vězeň dostane buď černý nebo bílý klobouk (klobouky se rozdávají náhodně s pravděpodobností 1/2).
- ② Každý vidí barvy klobouků ostatních, barvu svého klobouku nevidí nikdo.
- ③ Skupina hraje jako tým. Vyhrají, pokud alespoň jeden uhodne správně barvu svého klobouku a nikdo ze skupiny nehádá špatně.
- ④ Před začátkem hry se vězni na strategii domlouvat mohou, po začátku hry spolu komunikovat nesmí.

**Simple-minded strategie:** hádejme náhodně, pravděpodobnost výhry je pak 1/2.

Existuje strategie lepší?

**Ano:** je-li  $m \geq 2$ , pak pro skupinu  $n = 2^m - 1$  vězňů pomůže příslušný **Hammingův kód**.



## Optimální vyhrávací strategie pro Hat Problem

Označme jako  $W$  Hammingův kód délky  $n = 2^m - 1$ , kde  $m \geq 2$ .

Slova  $\mathbf{v}$  ze  $(\mathbb{Z}_2)^n$  budeme považovat za **distribuci klobouků**:

- ① 0 v  $i$ -té položce slova  $\mathbf{v}$  znamená: vězeň  $i$  má černý klobouk.
- ② 1 v  $i$ -té položce slova  $\mathbf{v}$  znamená: vězeň  $i$  má bílý klobouk.

Pro zadanou distribuci  $\mathbf{v}$  definujme slovo  $\mathbf{v}_i$  jako distribuci, která má shodné položky se slovem  $\mathbf{v}$ , **kromě**  $i$ -té položky, kde je 0.<sup>a</sup>

Platí rovnost  $\mathbf{v} = \mathbf{v}_i + a_i \mathbf{e}_i$ , kde  $a_i \in \mathbb{Z}_2$  je pevné.

**Strategie  $i$ -tého vězně:**

- ① Jesliže  $\mathbf{v}_i + b_i \mathbf{e}_i \notin W$  pro jakékoli  $b_i$  ze  $\mathbb{Z}_2$ , vězeň  $i$  mlčí.
- ② Jesliže  $\mathbf{v}_i + b_i \mathbf{e}_i \in W$  pro nějaké  $b_i$  ze  $\mathbb{Z}_2$ , vězeň  $i$  prohlásí, že má klobouk barvy  $1 + b_i$ .

---

<sup>a</sup>Slovo  $\mathbf{v}_i$  je tedy definováno jako distribuce, kterou  $i$ -tý vězeň skutečně vidí a který **předpokládá**, že má černý klobouk.

## Optimální vyhrávací strategie pro Hat Problem (pokrač.)

Strategie je dobře definovaná: nemůže současně platit

$$\mathbf{v}_i + 0 \cdot \mathbf{e}_i \in W \text{ a } \mathbf{v}_i + 1 \cdot \mathbf{e}_i \in W.$$

Kdyby platilo  $\mathbf{v}_i + 0 \cdot \mathbf{e}_i \in W$  a  $\mathbf{v}_i + 1 \cdot \mathbf{e}_i \in W$ , pak součet  $(\mathbf{v}_i + 0 \cdot \mathbf{e}_i) + (\mathbf{v}_i + 1 \cdot \mathbf{e}_i) = \mathbf{e}_i$  leží ve  $W$ . To není možné, protože syndrom  $\mathbf{e}_i$  je  $i$ -tý sloupec kontrolní matice  $\mathbf{H}^T$  a ten je nenulový.<sup>a</sup>

- 1 Jestliže  $\mathbf{v}$  není ve  $W$ , strategie dává vítězství.

Pokud  $\mathbf{v}$  není ve  $W$ , existuje jediné  $j$  tak, že  $\mathbf{v} + \mathbf{e}_j$  je ve  $W$ . Hammingův kód je totiž perfektní pro 1 chybu. Vězeň  $j$  tedy správně uhodl barvu svého klobouku. Navíc všichni ostatní vězni museli mlčet: pro  $i \neq j$  by v opačném případě muselo platit  $\mathbf{v}_i + b_i \mathbf{e}_i \in W$  pro nějaké  $b_i$ .

---

<sup>a</sup>Připomenutí: kontrolní matice Hammingova kódu má ve sloupcích binární zápisu nenulových čísel  $1, \dots, 2^m - 1$ .

## Optimální vyhrávací strategie pro Hat Problem (pokrač.)

Protože  $\mathbf{v} + \mathbf{e}_j = \mathbf{v}_i + a_i \mathbf{e}_i + \mathbf{e}_j \in W$  a  $\mathbf{v}_i + b_i \mathbf{e}_i \in W$ , platí  
 $(\mathbf{v}_i + a_i \mathbf{e}_i + \mathbf{e}_j) + (\mathbf{v}_i + b_i \mathbf{e}_i) = (a_i + b_i) \mathbf{e}_i + \mathbf{e}_j \in W$ .

Syndrom slova  $(a_i + b_i) \mathbf{e}_i + \mathbf{e}_j$  je ale nenulový, to je spor.

- ② Jestliže  $\mathbf{v}$  je ve  $W$ , každý hádá špatně.

Opravdu: pro každé  $i$  platí  $\mathbf{v} = \mathbf{v}_i + a_i \mathbf{e}_i \in W$  a  $i$ -tý vězeň tedy prohlásí, že má klobouk barvy  $1 + a_i$ , ačkoli má ve skutečnosti klobouk barvy  $a_i$ .

## Optimální vyhrávací strategie pro Hat Problem (pokrač.)

To znamená, že pravděpodobnost výhry při této strategii je přesně

$$1 - \frac{\text{počet slov ve } W}{\text{počet slov v } (\mathbb{Z}_2)^n} = 1 - \frac{2^{2^m-1-m}}{2^{2^m-1}} = 1 - \frac{1}{2^m}$$

- ① Například pro  $m = 2$  (tedy pro skupinu  $n = 2^2 - 1 = 3$  vězňů) je pravděpodobnost výhry  $3/4 = 0.75$ .<sup>a</sup>
- ② Pro  $m = 3$  (tj. pro  $n = 2^3 - 1 = 7$  vězňů) je pravděpodobnost výhry  $7/8 = 0.875$ .
- ③ Pro  $m = 4$  (tj. pro  $n = 2^4 - 1 = 15$  vězňů) je pravděpodobnost výhry  $15/16 = 0.9375$ .
- ④ Pro  $m = 5$  (tj. pro  $n = 2^5 - 1 = 31$  vězňů) je pravděpodobnost výhry  $31/32 = 0.96875$ .
- ⑤ Atd.

To je vždy lepší výsledek než simple-minded strategie (která dává vždy pravděpodobnost  $1/2$ ).

<sup>a</sup> Je užitečným cvičením si optimální strategii pro  $m = 2$  vyzkoušet.

## Důležité upozornění

V teorii lineárních kódů je zvykem psát vektory z  $\mathbb{F}^n$  do **řádku** (na rozdíl od B6B01LAG). Co tím ztrácíme a co tím získáváme?

- ➊ Vycvičení dosavadním průběhem této přednášky, **ztrácíme** okamžitý geometrický přehled o tom, co se při kódování skutečně děje.

**Pro zájemce:** ve skutečnosti geometrický přehled **neztrácíme**; pracujeme jen s kovektory místo s vektory, viz kapitolu 3.5 **skript**.

To znamená, že kódování má jasnou geometrickou interpretaci v **duálním prostoru**.

- ➋ **Získáváme** kompatibilitu s rozsáhlou literaturou o kódování.

Protože nám šlo jen o velmi krátký úvod do lineárních kódů, psali jsme vektory nadále do sloupců. Kdo bude číst jinou literaturu z kódování, bude velmi pravděpodobně muset všechny matice a maticové rovnice z teorie kódů transponovat.

## Která lineární algebra je tedy ta „správná“?

- ① Psaní vektorů z  $\mathbb{F}^n$  do sloupců nám umožnilo chápout součin  $\mathbf{A} \cdot \mathbf{x}$  jako funkční hodnotu lineárního zobrazení  $\mathbf{A}$  v bodě  $\mathbf{x}$ . Chápání součinu  $\mathbf{A} \cdot \mathbf{x}$  jako funkční hodnoty vedlo k přirozené geometrické interpretaci maticových výpočtů.

To je ve shodě s tím, jak značíme funkční hodnoty ve zbytku matematiky: značku  $f(x)$  chápeme jako funkční hodnotu funkce  $f$  v bodě  $x$ .

- ② Při psaní vektorů z  $\mathbb{F}^n$  do řádku bychom museli hodnotu lineárního zobrazení  $\mathbf{A}$  v bodě  $\mathbf{x}$  značit  $\mathbf{x} \cdot \mathbf{A}$ .

Tento způsob uvažování o maticovém součinu je ve shodě s (menšinovým) názorem, že funkční hodnotu funkce  $f$  v bodě  $x$  bychom měli značit  $(x)f$ . Takovému značení funkčních hodnot se říká **reverse Polish notation** (RPN).

## Proč jsme v přednášce zvolili „sloupcovou“ lineární algebru?

- 1 Protože na RPN nejsme zvyklí, zvolili jsme „sloupcovou“ lineární algebru. Je totiž ve shodě s tím, jak uvažujeme ve zbytku matematiky.
- 2 „Řádková“ lineární algebra navíc není ve svém značení úplně důsledná. Dochází tak k absurditám:<sup>a</sup> například soustava rovnic

$$\left( \begin{array}{cc|c} 2 & -1 & 3 \\ 4 & 7 & 11 \end{array} \right)$$

ze „sloupcové“ lineární algebry by se v „řádkové“ lineární algebře měla správně zapisovat

$$\left( \begin{array}{cc} 2 & 4 \\ -1 & 7 \\ \hline 3 & 11 \end{array} \right)$$

ale neděje se tak. „Řádková“ lineární algebra pro soustavy rovnic přebírá zápis „sloupcové“ lineární algebry!

<sup>a</sup>Vzpomeňte si, kolikrát se v textech z „řádkové“ lineární algebry objevuje rčení: „... jednotlivé vektory nyní napišeme do sloupců matic...“



## Závěrečné poznámky

- ① Poslední čtyři přednášky byly **pouze nahlédnutím** do teorie kódů.
- ② Skutečné studium teorie kódů vyžaduje zvládnutí **dalších partií** matematiky:
  - ① Teorie informace.
  - ② Teorie pravděpodobnosti.
  - ③ Teorie grup.
  - ④ A dalších...

Více se lze dozvědět v doporučené (tj. **nepovinné**) literatuře.