

- Evženie Uglyckich, <http://staff.utia.cas.cz/uglickich>
 - skripta, přednášky, materiály ke cvičení
 - doporučená literatura:
 - I. Nagy, E. Suzdaleva. Algorithms and Programs of Dynamic Mixture Estimation. Unified Approach to Different Types of Components, Springer, 2017.
 - D. T. Larose. Discovering Knowledge in Data. An Introduction to Data Mining. Willey, 2005.
 - J. Han, M. Kamber, J. Pei. Data Mining: Concepts and Techniques, 3rd Edition. Morgan Kaufmann, 2011.
 - M. J. Zaki, W. Meira Jr. Data Mining and Analysis: Fundamental Concepts and Algorithms. Cambridge University Press, 2014.
 - konzultační hodiny - osobně/MS Teams
 - moodle
- **Zápočet:** body za práci v hodinách
- **Zkouška:**
 - ústní forma, 5 otázek
 - pouze v **zimním zkouškovém období**, otázky jsou na webu
 - předtermín, doktorandi – téma v oblasti analýzy dat





O čem je předmět Matematické metody analýzy dat?

- Analýza multimodálních dat – spojitych a diskrétních
- Shluková analýza a klasifikace
- Metody na základě modelu, s učitelem a bez učitele

Multimodální data – spojité




- systém – část reality, kterou modelujeme
- multimodální systém – přepíná mezi jednotlivými režimy
Příklad: styl jízdy, dopravní špičky, atd
- naměřená data – multimodální
- tvoří **shluky** (klastry)

- vzdálenost mezi shluky – rozptyl




Multimodální data – diskrétní data, smíšená data

- diskrétní data



- smíšená data



Úlohy shlukování vs. klasifikace

- **Shlukování** (bez učitele)

- nalezení shluků dat s podobnými vlastnostmi (třídění dat do skupin)

- **Algoritmy** na základě:



- modelu (model směsi distribucí)
- centroidů (k-means, k-medoids)
- fuzzy logiky (c-means)
- hustoty (DBSCAN)
- hierarchie shluků

- **Klasifikace** (s učitelem)

- třídění dat do předem známých skupin

- **Algoritmy:**

- model (směsi, log. regrese, naivní Bayes)
- k-nejbližších sousedů
- rozhodovací stromy, náhodné lesy
- podpůrné vektorové stroje
- neuronové sítě



Základní modely – statický normální model pro spojité data

$$y_t = \theta + e_t$$

y_t – modelovaná náhodná veličina (**vektor**)

θ – vektor regresních koeficientů (**neznámé parametry**)

e_t – bílý šum s normálním rozdělením

Příklad:

$$\begin{bmatrix} y_{1;t} \\ y_{2;t} \end{bmatrix} = \begin{bmatrix} \theta_1 \\ \theta_2 \end{bmatrix} + \begin{bmatrix} e_{1;t} \\ e_{2;t} \end{bmatrix}$$

- **Statický** model – vhodný pro shlukování a klasifikaci

Mnohorozměrný lineární normální model ve tvaru hp – obecně

$$f(y_t | \underbrace{\theta}_{\Theta}, R) = (2\pi)^{-\frac{n}{2}} \det(R)^{-\frac{1}{2}} \exp\left\{-\frac{1}{2}(y_t - \theta)' R^{-\frac{1}{2}} (y_t - \theta)\right\}$$


- Střední hodnota, kovarianční matice, Gaussova křivka

Základní modely – kategorický model pro diskrétní data

$y_t \in \{1, 2, 3, \dots, N\}$ – modelovaná veličina

Příklad:

stupeň dopravy (volný provoz až dopravní kolaps)



y_t	1	2	3	4	5	
Θ_i	$\Theta_1 = 0.05$	$\Theta_2 = 0.05$	$\Theta_3 = 0.1$	$\Theta_4 = 0.6$	$\Theta_5 = 0.2$	$\Rightarrow 1$

- Model ve tvaru pravděpodobnostní funkce $f(y_t|\Theta)$
- $\Theta \equiv \{\Theta_i\}_{i=1}^N$ (neznámé parametry)
- Statický model, neurčitost v modelu

Základní modely – Poissonův model pro sčítací data

- $y_t \in \{0, \dots\}$ – modelovaná veličina
- počty náhodných nezávislých událostí za jednotku času

Příklad: počet vozidel, cyklistů, cestujících (za min, h, ...)

- pozor na počet možných realizací

Model ve tvaru hp – Poissonovo rozdělení

$$f(y_t | \underbrace{\lambda}_{\Theta}) = \exp\{-\lambda\} \frac{\lambda^{y_t}}{y_t!}, \quad \lambda - \text{neznámé parametry}$$

- předpoklad λ = střední hodnota = rozptyl

