

Cvičení 9

Příklad 1: Připomeňte si pojmy vektorový prostor, metrický prostor, metrika, vzdálenost a podobnost.

- Jaké znáte metriky pro určení vzdálenosti mezi dvěma reálnými vektory stejné dimenze?
- Jaké znáte metriky pro určení vzdálenosti mezi dvěma binárními vektory stejné dimenze?
- Jaké znáte metriky pro určení vzdálenosti mezi dvěma slovy nad vybranou abecedou?
- Jak můžete převést vzdálenost na podobnost?

Příklad 2: Rozhodněte, které z níže uvedených zobrazení jsou metrikou, ultrametrikou, pseudometrikou, podobností a nepodobností.

- $d_1 : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$, $d_1(x, y) = |\log(y/x)|$,
- $d_2 : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$, $d_2(x, y) = \|x\|_2 + \|y\|_2$ pro $x \neq y$ a $d_2(x, y) = 0$ pro $x = y$,
- $d_3 : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$, $d_3(x, y) = \|x\|_3 \cdot \|y\|_3$ pro $x \neq y$ a $d_3(x, y) = 0$ pro $x = y$,
- $d_4 : 2^A \times 2^A \rightarrow \mathbb{R}$, kde A je libovolná neprázdná množina a $d_4(x, y) = 1$ pro $x \neq y$ a $d_4(x, y) = 0$ pro $x = y$,
- $d_5 : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$, $d_5(x, y) = e^{|y-x|} - 1$,
- $d_6 : \mathbb{R}^{n \times n} \times \mathbb{R}^{n \times n} \rightarrow \mathbb{R}$, $d_6(X, Y) = \text{rank}(Y - X)$, kde $\text{rank}(X) =$ hodnost matice X ,
- $d_7 : \mathbb{R}^{n \times n} \times \mathbb{R}^{n \times n} \rightarrow \mathbb{R}$, $d_7(X, Y) = \det(Y + X)$,
- $d_8 : \mathbb{R} \times \mathbb{R} \rightarrow \mathbb{R}$, $d_8(x, y) = |x^2 - y^2|$,
- $d_9 : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$, $d_9(x, y) = e^{-\|y-x\|_2}$,
- $d_{10} : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$, $d_{10}(x, y) = \frac{\sum_{i=1}^n (x_i \cdot y_i)}{(\sum_{i=1}^n x_i^2)^{1/2} \cdot (\sum_{i=1}^n y_i^2)^{1/2}} = \frac{x \cdot y}{\|x\|_2 \cdot \|y\|_2}$,
- $d_{11} : \mathbb{R}^n \times \mathbb{R}^n \rightarrow \mathbb{R}$, $d_{11}(x, y) = 1 - \frac{x \cdot y}{\|x\|_2 \cdot \|y\|_2}$.

Příklad 3: Navrhněte způsoby kategorizace a navrhněte způsoby normalizace níže uvedených dat.

- Vstupní vektorový model má na řádku osobu a ve sloupcích jsou informace: pohlaví - m/ž, rok narození, dosažené vzdělání, místo trvalého pobytu, rok získání řidičského průkazu, počet zaplacených pokut, počet nezaplacených pokut.

jméno	m/ž	narození	vzdělání	pobyt	získání ř.p.	zaplacené	nezaplacené
P1	ž	1942	sš	Ostrava	1993	0	1
P2	m	1968	vš	Ostrov nad Ohří	1994	4	0
P3	ž	1957	vš	Ostrovačice	1987	0	0
P4	m	1986	sš	Ostravice	2010	1	0

- Je dán následující vektorový model. Řádky tvoří dokumenty, sloupce tvoří frekvence nalezených termů.

	t1	t2	t3	t4	t5	t6	t7
d1	1	0	0	1	3	0	1
d2	1	0	0	2	2	0	0
d3	0	2	1	1	1	1	0
d4	1	0	3	1	0	1	0

Příklad 4: Výjmenujte a použijte metody pro výpočet vzdálenosti či podobnosti nad nenormovanými a normovanými daty v příkladu 3.

- a) $d(P1, P4) =$, $d(P1, P3) =$, $s(P1, P4) =$, $s(P1, P3) =$
 b) $d(d1, d2) =$, $d(d1, d3) =$, $s(d1, d2) =$, $s(d1, d3) =$

Příklad 5: Pokud je možné, tak použijte dále uvedené metody pro výpočet vzdálenosti a podobnosti mezi dvojicí slov, mezi dvojicí množin nebo mezi dvojicí binárních vektorů. Hammingova vzdálenost, editační vzdálenost (Levenshtein), longest common subsequence, kosinova podobnost, Jaccardova podobnost a Diceova podobnost.

- a) lesnictví - lesněnky
 b) lesněnky - žvýkačky
 c) logika - geolog
 d) 011110 - 111111
 e) kosmický let - komický ret
 f) ACCGATTA - ACAGATAA
 g) 10101 - 01010

Příklad 6: Určete, které prvky patří do uzavřené koule $K_L(\text{les}, 1)$ a které do $K_{LCS}(\text{les}, 1)$ nad množinou $A = \{\text{lem}, \text{len}, \text{les}, \text{lesy}, \text{lep}, \text{lis}, \text{los}, \text{lup}, \text{ples}, \text{nes}, \text{nos}, \text{ves}, \text{vos}, \text{vez}\}$.

Příklad 7: Na množině $A = \{a, b, c, d, e, f\}$ jsou dány následující relace:

- a) ekvivalence ρ_1 , která indukuje rozklad $A/\rho_1 = \{\{a, b, c, d\}, \{e, f\}\}$,
 b) ekvivalence ρ_2 , která indukuje rozklad $A/\rho_2 = \{A\}$,
 c) tolerance ρ_3 , která indukuje pokrytí $A/\rho_3 = \{\{b, d, e, f\}, \{a, b, c, d\}\}$,
 d) $\rho_4 = \{(a, b), (b, c), (c, d), (d, e), (e, f), (f, a)\}$.

Nakreslete grafy, které reprezentují relace ρ_i a určete, zda délka nejkratší cesty v daném grafu je metrikou. Pokud ano, tak určete typ daného metrického prostoru a vypočtete průměr tohoto prostoru ($\text{diam}_i(A) =$).