

Metody pro zpracování nestrukturovaného textu: porovnávání ceníků

P. Hampl, H. Hamplová, J. Ivánek, R. Jiroušek, T. Kroupa,
R. Lněnička, M. Studený, J. Vomlel

ÚTIA AV ČR a Empo, s.r.o

12. října 2005

Předpokládáme následující scénář:

- 1 firma prodávající výpočetní techniku kupuje jednotlivé díly od různých dodavatelů
- 2 dodavatelé poskytují svoje ceníky
- 3 je výhodné porovnat cenu stejných komponent u různých dodavatelů (a např. si vybrat nejlevnějšího dodavatele)

Typický ceník

- obsahuje desetitisíce komponent
- je pouze **částečně strukturovaný**
- ceníky různých dodavatelů jsou vzájemně **nekompatibilní**

Předpokládáme následující scénář:

- 1 firma prodávající výpočetní techniku kupuje jednotlivé díly od různých dodavatelů
- 2 dodavatelé poskytují svoje ceníky
- 3 je výhodné porovnat cenu stejných komponent u různých dodavatelů (a např. si vybrat nejlevnějšího dodavatele)

Typický ceník

- obsahuje desetitisíce komponent
- je pouze **částečně strukturovaný**
- ceníky různých dodavatelů jsou vzájemně **nekompatibilní**

Detailní specifikace ceníku

Ceník je tabulka, ve které

- řádky jsou počítačové **komponenty**
- sloupce jsou **atributy** komponent

Atributy

- jednoznačný identifikátor komponenty - **part number** (pouze někdy)
- **výrobce** komponenty (často pouze zkratka)
- **kategorie** a případně podkategorie, do které komponenta patří
- **popis** komponenty
- **cena** komponenty

Ceník je tabulka, ve které

- řádky jsou počítačové **komponenty**
- sloupce jsou **atributy** komponent

Atributy

- jednoznačný identifikátor komponenty - **part number** (pouze někdy)
- **výrobce** komponenty (často pouze zkratka)
- **kategorie** a případně podkategorie, do které komponenta patří
- **popis** komponenty
- **cena** komponenty

Příklad dvou ceníků

L_1	
<i>Popis</i>	<i>Cena</i>
Cisco 828 G.SHDSL Router 1E, 1G.SHDSL	13 640
HP LaserJet 3030 Print/Scan/Copy/Fax, Paralel,USB	12 529
HP PL DL360R04 X3.0/1M 1G SA6i iLO	59 453
...	...

L_2	
<i>Popis</i>	<i>Cena</i>
Cisco 828 (G.SHDSL)	13 740
LaserJet 3030, tiskárna, kopírka, skener, fax	12 199
...	...

Pro zadaný popis D komponenty nalézt v cenících L_1, \dots, L_k popisy komponent D_1, \dots, D_k , které se nejvíce podobají popisu D .

Příklad výstupu

<i>Popis D</i>	<i>cena v L_1</i>	<i>cena v L_2</i>
Cisco 828 G.SHDSL router	13 640	13 740
HP LaserJet 3030 All-in-One	12 529	12 199
HP PL DL360R04 X3.0/1M 1G SA6i iLO	59 453	-
...

Pro zadaný popis D komponenty nalézt v cenících L_1, \dots, L_k popisy komponent D_1, \dots, D_k , které se nejvíce podobají popisu D .

Příklad výstupu

<i>Popis D</i>	<i>cena v L₁</i>	<i>cena v L₂</i>
Cisco 828 G.SHDSL router	13 640	13 740
HP LaserJet 3030 All-in-One	12 529	12 199
HP PL DL360R04 X3.0/1M 1G SA6i iLO	59 453	-
...

Porovnávání řetězců

- Komponenty jsou k sobě přiřazeny na základě **podobnosti** jejich popisu.
- Popis je řetězec znaků.

Dva základní přístupy pro porovnávání dvou řetězců

1 techniky založené na **znakovém** přístupu

- podobnost je počítána na znakové úrovni
- příkladem metody je **String Edit Distance** - kdy cílem je minimalizace celkové ceny při změnách jednoho popisu na druhý pomocí operací jako např. vkládání znaků, vymazání znaku, či změna znaku.

2 techniky založené na **vektorovém** přístupu

- řetězec je rozdělen na jednotlivá slova - **tokens**
- podobnost se počítá na základě výskytu tokens v obou porovnávaných řetězcích

Porovnávání řetězců

- Komponenty jsou k sobě přiřazeny na základě **podobnosti** jejich popisu.
- Popis je řetězec znaků.

Dva základní přístupy pro porovnávání dvou řetězců

- 1 techniky založené na **znakovém** přístupu
 - podobnost je počítána na znakové úrovni
 - příkladem metody je **String Edit Distance** - kdy cílem je minimalizace celkové ceny při změnách jednoho popisu na druhý pomocí operací jako např. vkládání znaků, vymazání znaku, či změna znaku.
- 2 techniky založené na **vektorovém** přístupu
 - řetězec je rozdělen na jednotlivá slova - **tokens**
 - podobnost se počítá na základě výskytu tokens v obou porovnávaných řetězcích

- Komponenty jsou k sobě přiřazeny na základě **podobnosti** jejich popisu.
- Popis je řetězec znaků.

Dva základní přístupy pro porovnávání dvou řetězců

- 1 techniky založené na **znakovém** přístupu
 - podobnost je počítána na znakové úrovni
 - příkladem metody je **String Edit Distance** - kdy cílem je minimalizace celkové ceny při změnách jednoho popisu na druhý pomocí operací jako např. vkládání znaků, vymazání znaku, či změna znaku.
- 2 techniky založené na **vektorovém** přístupu
 - řetězec je rozdělen na jednotlivá slova - **tokens**
 - podobnost se počítá na základě výskytu tokens v obou porovnávaných řetězcích

Součet délek podřetězců prvního řetězce obsažených v druhém řetězci a dlouhých minimálně dva znaky.

Definition

$$\text{Similarity}(R_1, R_2) = \sum_{k=1}^{\text{Length}(R_1)-1} \sum_{\substack{R \in \mathcal{R}_1^k \cap \mathcal{R}_2 : \\ \text{Length}(R) \geq 2}} \text{Length}(R)$$

- \mathcal{R}_i^k je množina všech podřetězců řetězce R_i začínajících na k -té pozici
- \mathcal{R}_i je množina všech podřetězců řetězce R_i

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 1$

$$\text{Similarity}(R_1, R_2) = 0$$

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

$k = 1$

$R = \text{"WI"}$

$Length(R) = 2$

$Similarity(R_1, R_2) = 2$

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

$k = 1$

$R = \text{"WIN"}$

$Length(R) = 3$

$$Similarity(R_1, R_2) = 2 + 3$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 2$

$$\textit{Similarity}(R_1, R_2) = 2 + 3$$

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

$k = 2$

$R = \text{"IN"}$

$Length(R) = 2$

$$Similarity(R_1, R_2) = 2 + 3 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 3$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 4$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 5$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 6$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 7$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S	_	T	E	R	M
---	---	---	---	---	---	---	---	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 8$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2$$

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S	-	T	E	R	M
---	---	---	---	---	---	---	---	---	---	---	---

R_2

W	I	N	-	T	R	M	N	L
---	---	---	---	---	---	---	---	---

$k = 8$

$R = "T"$

$Length(R) = 2$

$$Similarity(R_1, R_2) = 2 + 3 + 2 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 9$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2 + 2$$

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

$k = 10$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2 + 2$$

Příklad výpočtu podobnosti

 R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

 R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

 $k = 11$

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2 + 2$$

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

$k = 11$

$R = \text{"RM"}$

$Length(R) = 2$

$$Similarity(R_1, R_2) = 2 + 3 + 2 + 2 + 2$$

Příklad výpočtu podobnosti

R_1

W	I	N	D	O	W	S		T	E	R	M
---	---	---	---	---	---	---	--	---	---	---	---

R_2

W	I	N		T	R	M	N	L
---	---	---	--	---	---	---	---	---

$$\text{Similarity}(R_1, R_2) = 2 + 3 + 2 + 2 + 2 = 11$$

- 5 ceníků - jeden z nich byl **referenční**
- testovací data: 277 komponent z referenčního ceníku

Hodnocení

- přesnost = počet správně nalezených komponent / celkový počet komponent v testovacích datech
- TLE = počet správně nalezených komponent / počet komponent s vyšší než prahovou hodnotou podobnosti
- PNM = počet správně nalezených komponent se *stejným part number* / celkový počet komponent v testovacích datech

<i>ceník</i>	<i>počet položek</i>	<i>přesnost</i>	<i>TLE</i>	<i>PNM</i>
2	9 670	19,49%	81,25%	9,75%
3	7 941	19,49%	86,84%	13,72%
4	24 076	55,96%	92,05%	33,94%
5	22 182	40,43%	94,74%	23,83%

Problémy přístupu:

- při pouhé permutaci slov v popisu se výsledná podobnost výrazně sníží
- není možné uvažovat zkratky, synonyma, termíny v jiném jazyce protože nepracujeme se slovy, ale se znaky

Definition

$$\textit{Similarity}(R_1, R_2) = \sum_{i=1}^d w(x_i, R_1) \cdot w(x_i, R_2)$$

- d je počet slov (tokens)
- $w(x_i, R_j)$ je normalizovaná váha slova (token) v řetězci R_j . Pokud se slovo v řetězci nevyskytuje je rovna nule.

<i>ceník</i>	<i>přesnost</i>	<i>přesnost po vyřazení neexist. položek</i>
2	20,95%	37,35%
3	16,89%	34,27%
4	40,54%	46,51%
5	36,49%	52,94%

Problémy:

- jak rozdělit řetězec na slova (jaké znaky použít jako separátory)?
- je třeba vytvořit slovník synonym, zkratek, případně i významů slov.

Co bychom chtěli v budoucnu udělat:

- vytvořit **slovník** synonym, zkratek - nejlépe i s významy slov
 - např. výrobce, název komponenty, parametr komponenty
- využít částečnou strukturu popisu komponenty rozdělenou do **atributů**
 - v některých cenících jsou atributy: výrobce, skupina komponent
- použít jednoduchá produkční pravidla (bezkontextové či regulární gramatiky) pro definici některých **významových skupin**
 - např. 1,2 GHz