

Lösung - Übungsblatt 1

(String Matching)

Fabian Panse

panse@informatik.uni-hamburg.de

Universität Hamburg



Universität Hamburg

DER FORSCHUNG | DER LEHRE | DER BILDUNG



Aufgabe 1: Overlap Measure und Jaccard Koeffizient

Gegeben: $x = \text{'Henri Waternoose'}$ und $y = \text{'Henry Waternose'}$

Tokenbildung durch 3-grams

$X = \{ \text{'##H'}, \text{'#He'}, \text{'Hen'}, \text{'enr'}, \text{'nri'}, \text{'ri_'}, \text{'i_W'}, \text{'_Wa'}, \text{'Wat'}, \text{'ate'}, \text{'ter'}, \text{'ern'}, \text{'rno'}, \text{'noo'}, \text{'oos'}, \text{'ose'}, \text{'se#'}, \text{'e##'} \}$

$Y = \{ \text{'##H'}, \text{'#He'}, \text{'Hen'}, \text{'enr'}, \text{'nry'}, \text{'ry_'}, \text{'y_W'}, \text{'_Wa'}, \text{'Wat'}, \text{'ate'}, \text{'ter'}, \text{'ern'}, \text{'rno'}, \text{'nos'}, \text{'ose'}, \text{'se#'}, \text{'e##'} \}$

$X = \{ \text{'##H'}, \text{'#He'}, \text{'Hen'}, \text{'enr'}, \text{'nri'}, \text{'ri_'}, \text{'i_W'}, \text{'_Wa'}, \text{'Wat'}, \text{'ate'}, \text{'ter'}, \text{'ern'}, \text{'rno'}, \text{'noo'}, \text{'oos'}, \text{'ose'}, \text{'se#'}, \text{'e##'} \}$

$Y = \{ \text{'##H'}, \text{'#He'}, \text{'Hen'}, \text{'enr'}, \text{'nry'}, \text{'ry_'}, \text{'y_W'}, \text{'_Wa'}, \text{'Wat'}, \text{'ate'}, \text{'ter'}, \text{'ern'}, \text{'rno'}, \text{'nos'}, \text{'ose'}, \text{'se#'}, \text{'e##'} \}$

$$\Rightarrow O(X, Y) = 13$$

$$\Rightarrow Jacc(X, Y) = 13/22 = 0.591$$

Aufgabe 2: Levenshtein Distanz/Ähnlichkeit

Gegeben: $x = \text{'Sean'}$ und $y = \text{'Shawn'}$

	ϵ	s	h	a	w	n
ϵ	<u>0</u>	1	2	3	4	5
s	1	<u>0</u>	1	2	3	4
e	2	1	<u>1</u>	2	3	4
a	3	2	2	<u>1</u>	<u>2</u>	3
n	4	3	3	2	2	<u>2</u>

$$\Rightarrow \text{LevDst}(x, y) = 2$$

$$\Rightarrow \text{LevSim}(x, y) = 1 - \frac{2}{\max(4,5)} = 0.6$$

Aufgabe 3: Affine Gap Distance

Gegeben: $x = \text{'Martin Thomas Doe'}$ und $y = \text{'Martin T Do'}$

- Kosten für Öffnen einer Lücke: $w_g = 1$
- Kosten für Weiterführen einer Lücke: $w_s = 0.2$
- Die erste Lücke l_1 umfasst den substring 'homas'
- Gesamtkosten der Lücke: $w(l_1) = 1 + 4 \times 0.2 = 1.8$
- Die zweite Lücke l_2 umfasst den substring 'e'
- Gesamtkosten der Lücke: $w(l_2) = 1$

⇒ Gesamtkosten: 2.8

Aufgabe 4: Soundex Code

Gegeben: $x = \text{'depardieu'}$, $y = \text{'debando'}$ und $z = \text{'tepadeu'}$

	'depardieu'	'debando'	'tepadeu'
Step 1	'dprd'	'dbnd'	'tpd'
Step 2	'd163'	'd153'	't13'
Step 3	'd163'	'd153'	't13'
Step 4	'd163'	'd153'	't130'

- Mit Ausnahme des ersten Buchstaben werden alle Vorkommnisse der Buchstaben 'a', 'e', 'i', 'o', 'u', 'y', 'h', und 'w' entfernt
- Mit Ausnahme des ersten Buchstaben werden alle verbliebende Buchstaben durch Ziffern ersetzt ($b,p \rightarrow 1$, $r \rightarrow 6$, $d \rightarrow 3$, $n \rightarrow 5$)
- Alle aufeinanderfolgenden Auftreten der gleichen Ziffer werden durch ein einzelnes Auftreten ersetzt
- Der Code wird auf die Länge vier beschränkt (Auffüllen mit '0')

Aufgabe 5: Extended Jaccard

Gegeben: $x = \text{'Tom John Kim'}$ und $y = \text{'Tim Jon'}$
threshold $\theta = 0.5$


Levenshtein Ähnlichkeiten der Token

	'Tom'	'John'	'Kim'
'Tim'	2/3	0	2/3
'Jon'	1/3	3/4	0

- $shared(X, Y) = \{(\text{'Tom'}, \text{'Tim'}), (\text{'John'}, \text{'Jon'}), (\text{'Kim'}, \text{'Tim'})\}$
- $unique(X) = \emptyset$
 $unique(Y) = \emptyset$
- $ExtJacc(X, Y) = \frac{3}{3+0+0} = \frac{3}{3} = 1$

Aufgabe 5: Generalized Jaccard


Gegeben: $x = \text{'Tom John Kim'}$ und $y = \text{'Tim Jon'}$
threshold $\theta = 0.5$



$$\text{GenJacc}(X, Y) = \frac{0.66+0.75}{3+2-2} = \frac{1.41}{3} = 0.47$$

Aufgabe 5: Generalized Jaccard


Gegeben: $x = \text{'Tom John Kim'}$ und $y = \text{'Tim Jon'}$
threshold $\theta = 0.5$



$$\text{GenJacc}(X, Y) = \frac{0.66 + 0.75}{3 + 2 - 2} = \frac{1.41}{3} = 0.47$$


Aufgabe 5: Generalized Jaccard

Gegeben: $x = \text{'Tom John Kim'}$ und $y = \text{'Tim Jon'}$
threshold $\theta = 0.5$



$$\text{GenJacc}(X, Y) = \frac{0.66+0.75}{3+2-2} = \frac{1.41}{3} = 0.47$$

Aufgabe 5: Monge-Elkan



$$MongeElkan(Y, X) = \frac{1}{3} \times (0.66 + 0.75 + 0.66) = 0.69$$

Aufgabe 6: TF/IDF

term frequency:

<u>tf</u>	x_1	x_2	x_3	x_4	x_5	x_6
'Insurance'	1	1	0	1	0	0
'Company'	1	0	1	0	1	0
'A&B'	0	1	0	0	1	0
'BC'	0	0	1	0	0	0
'AX'	0	0	1	1	0	0
'XY'	0	0	0	0	0	2
'Enterprises'	0	0	0	0	0	1

Aufgabe 6: TF/IDF

inverse document frequency:

<u>idf</u>	
'Insurance'	$6/3 = 2$
'Company'	$6/3 = 2$
'A&B'	$6/2 = 3$
'BC'	$6/1 = 6$
'AX'	$6/2 = 3$
'XY'	$6/1 = 6$
'Enterprises'	$6/1 = 6$

Aufgabe 6: TF/IDF

Kosinus Ähnlichkeit zwischen x_2 und x_4 :

$$v_2 = \langle 2, 0, 3, 0, 0, 0, 0 \rangle$$

$$v_4 = \langle 2, 0, 0, 0, 3, 0, 0 \rangle$$

$$\begin{aligned} \Rightarrow \text{CosSim}(x_2, x_4) &= (4 + 0 + 0 + 0 + 0 + 0 + 0) / (\sqrt{4 + 9} \times \sqrt{4 + 9}) \\ &= 4 / (\sqrt{13} \times \sqrt{13}) = 4/13 \end{aligned}$$

Aufgabe 7: Skalierbarkeit

- a) Aufbauen eines invertierten Indexes über die Token der einzelnen Stringwerte von B

Menge B
$Y_1 = \{\text{alpha, beta, delta, iota}\}$
$Y_2 = \{\text{gamma, delta}\}$
$Y_3 = \{\text{alpha, beta, zeta}\}$
$Y_4 = \{\text{alpha, gamma, iota, zeta}\}$
$Y_5 = \{\text{alpha, iota}\}$

Token in B	ID Listen
alpha	1,3,4,5
beta	1,3
gamma	2,4
delta	1,2
iota	1,4,5
zeta	3,4

- Kandidaten aufgrund Token 'alpha': $\{1,3,4,5\}$
- Kandidaten aufgrund Token 'delta': $\{1,2\}$
- Kandidaten aufgrund Token 'zeta': $\{3,4\}$
- Gesamte Menge an Kandidaten: $\{1,2,3,4,5\}$ (also alle)

Aufgabe 7: Skalierbarkeit

b) Verwendung des Size Filterings

Menge B

$$Y_1 = \{\text{alpha, beta, delta, iota}\}$$

$$Y_2 = \{\text{gamma, delta}\}$$

$$Y_3 = \{\text{alpha, beta, zeta}\}$$

$$Y_4 = \{\text{alpha, gamma, iota, zeta}\}$$

$$Y_5 = \{\text{alpha, iota}\}$$

- Gegeben: $\theta = 0.8$ und $X = \{\text{alpha, delta, zeta}\}$
- Damit y_i ein Match von x sein kann, muss also gelten:

$$2.4 = 3 \times 0.8 \leq |Y_i| \leq 3/0.8 = 3.75$$

⇒ Das einzige $y_i \in B$ für welches dies gilt ist y_3

- Gesamte Menge an Kandidaten: $\{3\}$

Aufgabe 7: Skalierbarkeit

c) Verwendung des Prefix Filterings

Menge B

$Y_1 = \{\text{alpha, beta, delta, iota}\}$

$Y_2 = \{\text{gamma, delta}\}$

$Y_3 = \{\text{alpha, beta, zeta}\}$

$Y_4 = \{\text{alpha, gamma, iota, zeta}\}$

$Y_5 = \{\text{alpha, iota}\}$

Y_i	k	X_{k-1}
1	4	\emptyset
2	3	{alpha}
3	3	{alpha}
4	4	\emptyset
5	3	{alpha}

- Gegeben: $\theta = 0.8$, $|X| = 3$, Jaccard Koeffizient
- Damit y_i ein Match von x sein kann, muss also gelten:

$$|X \cap Y_i| \geq k = \lceil \frac{\theta}{1+\theta} \times (|X| + |Y_i|) \rceil = \lceil 0.444 \times (3 + |Y_i|) \rceil$$

- Y_i muss die ersten $|X| - (k - 1)$ Token von X beinhalten
- ⇒ 1 und 4 scheiden aus, da sie 4 gemeinsame Token bräuchten
- ⇒ 2, 3 und 5 sind Kandidaten wenn sie 'alpha' beinhalten
- Gesamte Menge an Kandidaten: {3,5}