

# Vytěžování dat, cvičení 7: Textmining a Redukce dimenzionality

Miroslav Čepek, Michael Anděl



Evropský sociální fond  
Praha & EU: Investujeme do vaší budoucnosti

*Fakulta elektrotechnická, ČVUT*

- ▶ 6.12.: Předzpracování textů + extrakce příznaků s následnou klasifikací
- ▶ 13.12.: SOM – interpretace zpracovaného textu
- ▶ 3.1.: Deadline

1. Získání dokumentů a nahrání do Rapidmineru (či jiného SW)
2. Tokenizace (rozklad textu na jednotlivá slova)
3. Odfiltrování častých a nezajímavých slov
4. Převod slov na kořeny slov (**stemming**)
  - ▶ Převod na jednotná čísla
  - ▶ Převod různých časování/způsoby/vidy na infinitivy
  - ▶ Převod mezi různými variantami slov (příslovce, přídavná jména ← podstatná jména).
5. Vytvoření "word vectoru". (Převod slov na čísla).
6. Tvorba modelu.

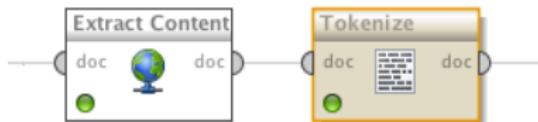
- ▶ Standardní instalace Rapidmineru neobsahuje rozšíření pro Textmining.
- ▶ Musíte nainstalovat rozšíření, ale naštěstí je to velmi jednoduché :).
- ▶ Z menu *Help* vyberte *Update RapidMiner*. Zde zaklikněte *Text Processing* a *Web Mining*.
- ▶ A klikněte na *Install*.

- ▶ Existuje několik uzelů, pro nahrávání dat do RapidMineru.
- ▶ Pro naše účely, kdy máme dokumenty různých typů v různých složkách, nejlépe vyhovuje uzel *Text Processing > Process Documents from Files*.
- ▶ Jedná se o super-uzel, který bude obsahovat pod-uzly transformující dokumenty na číselné vektory.

- ▶ První krok je extrakce textů z HTML (resp. odstranění HTML tagů).
- ▶ Pro to budete potřebovat uzel *Extract Content > HTML Processing > Extract Content*.



- ▶ Rozklad na jednotlivá slova.
- ▶ Slova se rozdělují typicky podle "ne" písmenek. Takto získaná slova se označují jako **termy**.



- ▶ V Rapidmineru existuje uzel "Tokenize", který najdete *Text Processing > Tokenization > Tokenize*.
- ▶ Možnosti rozkladu na slova jsou: non-letters, specify-characters, regular expression, linguistic tokens, linguistic token.

- ▶ Zkuste spustit proud nyní.
- ▶ Výsledkem bude word objekt, který si můžete prohlédnout.
- ▶ Uvidíte počty slov podle typů dokumentů. A také celkový počet slov.
- ▶ Každé slovo nakonec bude reprezentovat vstupní proměnnou.

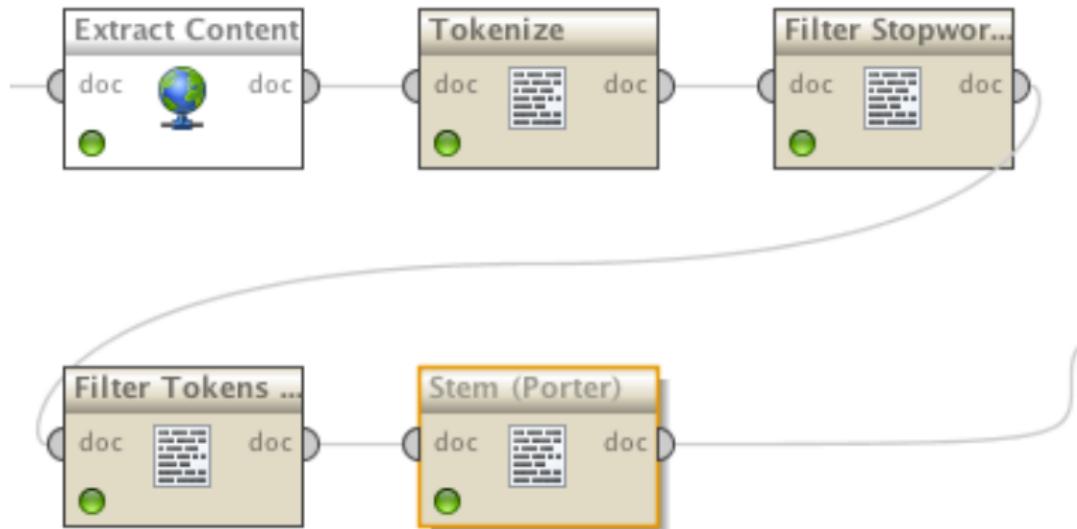
# Filtrování častých a nezajímavých slov

- ▶ Protože vstupních proměnných bude i tak moc, je vhodné některé z nich eliminovat.
- ▶ První způsob je filtrování obvyklých a nezajímavých slov.
- ▶ V Rapidmineru se to děje uzlem *Text Processing > Filtering > Filter Stopwords (English)*.
- ▶ Tím z dokumentu odstraníte termy (slova), která se v angličtině vyskytuje příliš často.
- ▶ Například spojky, běžná slovesa, předložky, apod...
- ▶ Uzel v Rapidmineru obsahuje seznam předdefinovaných slov.

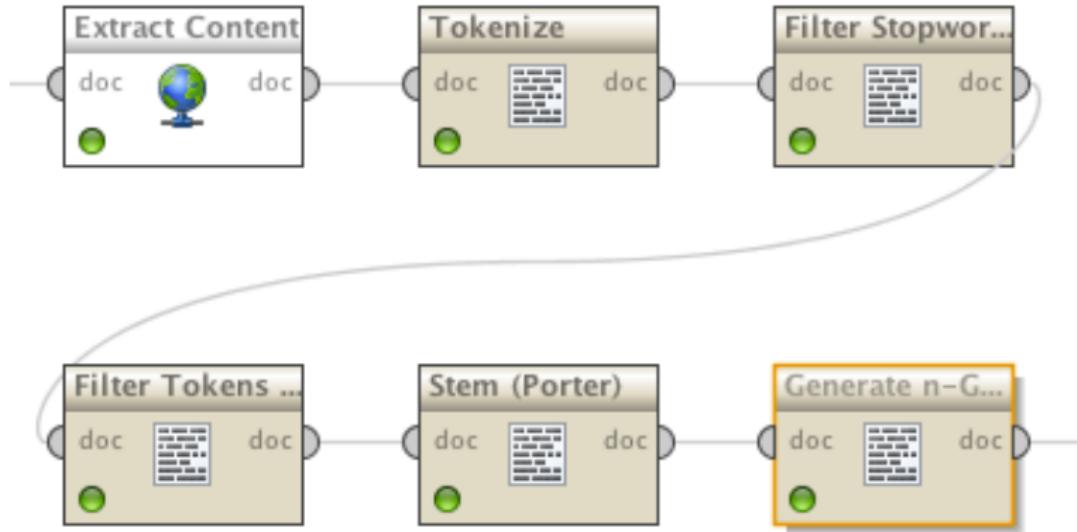


- ▶ Existuje několik způsobů, jak najít kořen slova.
- ▶ Například hrubou silou – tj tabulka mapující každé slovo a každý jeho tvar na odpovídající kořen.
- ▶ Jeden z dalších používaných algoritmů (pro Angličtinu) je tzv. Porterův algoritmus.
  - ▶ Iterativně odebírá známé koncovky anglických slov.
  - ▶ Má seznam přípon a ty se pokouší postupně odebrat (pokud to lze).
  - ▶ Například HOPEFULNESS → HOPEFUL → HOPE.
- ▶ <http://tartarus.org/martin/PorterStemmer/def.txt>

# Převod slov na kořeny slov – Stemming (2)



- ▶ Někdy se v dokumentech vyskytují zajímavé kombinace (po sobě jdoucích) slov.
- ▶ N-Gram je term, který obsahuje posloupnost term maximální délky N.
- ▶ Uzel *Text Processing > Transformation > Generate n-Grams (Terms)* vygeneruje všechny kombinace termů.



- ▶ Jednak umožňuje zahodit málo (nebo moc) často se vyskytující termy (slova a n-gramy).
- ▶ Jednotlivé možnosti vybíráte combo-boxem Prune method.
- ▶ Další důležitá věc je zaškrtnout Create word vector.
- ▶ A vybrat vhodnou metodu pro Vector creation.

The screenshot shows the configuration interface for the 'Process Documents from Files' node. It includes several checkboxes and dropdown menus:

- create word vector**: Checked.
- vector creation**: Set to "TF-IDF".
- add meta information**: Checked.
- keep text**: Unchecked.
- prune method**: Set to "absolute".
- prune below absolute**: Set to "5".
- prune above absolute**: Set to "999".

- ▶ Nyní máme slova (termy) a jejich počty v jednotlivých dokumentech.
- ▶ Před předložením shlukovací (či jakékoliv jiné) metodě je potřeba tyto počty nějak přetrasformovat.
- ▶ V Rapidmineru jsou na výběr následující možnosti:
  - ▶ Term Frequency – normalizovaný počet výskytů termu  
$$\left( \frac{\text{počet výskytu termu}}{\text{celkový počet termů}} \right)$$
  - ▶ Term Occurrences
  - ▶ Binary Term Occurrences
  - ▶ **TF-IDF**

- ▶ Míra ukazující, jak moc je term specifický pro daný dokument.
- ▶ Zahrnuje v sobě dvě části Term Frequency a Inverse Document Frequency.
- ▶ Term Frequency je definován takto:

$$tf(t) = \frac{\text{počet výskytu termu}}{\text{celkový počet termů}}$$

- ▶ Inverse Document Frequency ukazuje, jak často se vyskytuje term v ostatních dokumentech.

$$idf(t) = \log \frac{\|D\|}{\|\{d : t \in d\}\|}$$

- ▶  $\|D\|$  – Celkový počet dokumentů.
- ▶  $\|\{d : t \in d\}\|$  – Počet dokumentů, ve kterých se term  $t$  vyskytuje.

- ▶ Term Frequency - Inverse Document Frequency nakonec získáme, když tyto dvě míry vynásobíme.

$$td - idf(t, d) = tf(t, d) * idf(t)$$

- ▶ V RapidMineru bohužel nejsou žádné vhodné shlukovací metody. Čili použijeme Matlab a SOM toolbox.
- ▶ K exportu z RapidMineru lze použít uzel *Export > Data > Write CSV*
- ▶ Abychom se nemuseli trápit v Matlabu s načítáním ošklivých hodnot, můžeme využít uzlu *Export > Data > Write CSV* k odstranění sloupců, které obhashují nečíselná a pomocná data.
- ▶ V méém případě jde o sloupce: Description, Keywords, Language, Robots, Title, label, metadata\_date, metadata\_file, metadata\_path.
- ▶ Pro import použijeme v MATLABu funkci `importdata`.

- ▶ 6.12.: Předzpracování textů + extrakce příznaků s následnou klasifikací:
  1. Předzpracujte texty z přiložených 20-ti fór do *word-vector* reprezentace podle návodu výše.
  2. Implementujte v RM kNN process a pokuste se klasifikovat data (*word vectory*) zpět do jednotlivých fór.
  3. Opakujte bod 2, tentokrát ale neklasifikujte v prostoru word vectorů, nýbrž v prostoru jejich *hlavních komponent*. Tj. vytvořte nejdřív rozklad word vectorů do hlavních komponent (blok PCA a teprve v této neové reprezentaci klasifikujte). POkuste se interpretovat nějakou zajímavou komponentu.
  4. Vyčíslete odhad klasifikační přesnosti přístupů 2 a 3. Výsledky srovnajte a zdůvodněte.
- ▶ 13.12.: SOM – interpretace zpracovaného textu
- ▶ 3.1.: Deadline - report

- ▶ Pokud se chcete podívat, jak se textmining provádí v Rapidmineru, doporučuji následující sérii videí:
  - ▶ [http://www.youtube.com/watch?v=hpvda\\_Rfg3s](http://www.youtube.com/watch?v=hpvda_Rfg3s)
  - ▶ <http://www.youtube.com/watch?v=EjD2M4r4mBM>
  - ▶ <http://www.youtube.com/watch?v=vhMzUi-FMy0>
  - ▶ <http://www.youtube.com/watch?v=ToxzfYECx0U>
  - ▶ <http://www.youtube.com/watch?v=BRvjWLwSScQ>
  - ▶ <http://www.youtube.com/watch?v=9I0BcMuhPe8>
- ▶ Video přednáška o Textminingu  
[http://videolectures.net/ess07\\_grobelnik\\_twdm/](http://videolectures.net/ess07_grobelnik_twdm/)

- ▶ [http://eprints.pascal-network.org/archive/00000017/01/Tutorial\\_Marko.pdf](http://eprints.pascal-network.org/archive/00000017/01/Tutorial_Marko.pdf)
- ▶ <http://www.cs.sunysb.edu/~cse634/presentations/TextMining.pdf>