

Aplicação do mwetoolkit na pesquisa de Combinatórias Léxicas Especializadas da linguagem legislativa do meio ambiente

Paulo G. P. Duarte, Anna M. B. Maciel, Cleci R. Bevilacqua

Fourth CAMELEON Project Workshop

13/12/2013

Instituto de Informática, UFRGS



Contextualização

- **TERMISUL**

- Projeto *Combinatórias Léxicas Especializadas (CLEs) da linguagem legal, normativa e científica* (ProjeCOM Legis).

- **Objetivo**

- Coletar as expressões multivocabulares prototípicas da legislação ambiental brasileira e seus equivalentes na legislação do meio ambiente dos países do Mercosul, e nas leis ambientais da Alemanha, Estados Unidos, França, Itália.
- Criar uma base de dados *on-line* com as expressões coletadas.

Objetivo desta comunicação

- Descrever as etapas da aplicação do extrator de expressões multivocabulares (EMs): `mwetoolkit` em um corpus de uma área especializada composto por textos legislativos em português brasileiro

Materiais

- **Corpus especializado**

- **LegisAmb_br**

- 280 diplomas legais de 1934 a 2010 da Base Legis do Projeto TERMISUL, UFRGS, baixados como < brLegis.zip>.
 - Extensão total: 513.731 tokens e 20.811 types.
 - http://www.ufrgs.br/termisul/bases_textuais/legis/legislacao_ambiental.php

- **Corpus de língua geral**

- **PLNBRFULL**


- 100 milhões de palavras da Folha de São Paulo.
 - www.nilc.icmc.usp.br/plnbr

- Lista de padrões de CLEs recorrentes no *corpus* especializado.

mwetoolkit

- Ferramenta desenvolvida por Carlos Ramisch para atuar como extrator de expressões recorrentes formadas por duas ou mais palavras em textos de qualquer língua ou de qualquer linguagem especializada.
- <http://mwetoolkit.sourceforge.net/PHITE.php>

Aplicação



Pré-processamento

Etiquetagem

Tabela 1: Etiquetas do TreeTagger

Adjetivo	ADJ
Advérbio	ADV
Conjunção coordenativa	CONJ
Conjunção Subordinativa	CONJSUB
Determinante	DET
Número Cardinal / Ordinal	CARD
Nome Comum / Próprio	NOM
Particípio passado	PP
Pronome	P
Preposição	PREP
Preposição mais Determinante	PREP+DET
Verbo	V
Verbo mais Preposição	V+P
Separadores dentro da oração	VIRG
Separadores de orações	SENT

- **Corpus**

- *<LegisAmb_br.txt>*

- **Ferramenta**

- TreeTagger
(SCHMID, 1994;
GAMALLO, 2012)

Problemas e soluções

- **Problemas**

- Causados em função da língua (PB), do domínio (Direito Ambiental) e gênero (texto legislativo).

- **Soluções**

- Normalização (*lowercase*);
- Conversão dos caracteres acentuados do código latin1 para o código UTF8;
- Eliminação da marcação catalográfica e macroestrutural dos textos;
- Eliminação dos símbolos \$, %, °, §.

Corpus pré-processado

```
<!DOCTYPE corpus SYSTEM "dtd/mwetoolkit-corpus.dtd">
<corpus >
<s s_id="0">
  <w surface="LEI" pos="NOM" lemma="lei"/>
  <w surface="N" pos="NOM" lemma="n"/>
  <w surface="612" pos="CARD" lemma="@card@"/>
  <w surface="," pos="VIRG" lemma=","/>
  <w surface="DE" pos="NOM" lemma="DE"/>
  <w surface="13" pos="CARD" lemma="@card@"/>
  <w surface="DE" pos="NOM" lemma="DE"/>
  <w surface="JANEIRO" pos="NOM" lemma="janeiro"/>
  <w surface="DE" pos="NOM" lemma="DE"/>
  <w surface="1949" pos="CARD" lemma="@card@"/>
  <w surface="Cria" pos="NOM" lemma="cria"/>
  <w surface="um" pos="DET" lemma="um"/>
  <w surface="Hôrto" pos="NOM" lemma="Hôrto"/>
  <w surface="Florestal" pos="NOM" lemma="Florestal"/>
  <w surface="no" pos="PRP+DET" lemma="em"/>
  <w surface="Município" pos="NOM" lemma="município"/>
  <w surface="de" pos="PRP" lemma="de"/>
  <w surface="Silvânia" pos="NOM" lemma="Silvânia"/>
  <w surface="," pos="VIRG" lemma=","/>
  <w surface="no" pos="PRP+DET" lemma="em"/>
  <w surface="Estado" pos="NOM" lemma="estado"/>
  <w surface="de" pos="PRP" lemma="de"/>
  <w surface="Goiás" pos="NOM" lemma="Goiás"/>
  <w surface="." pos="SENT" lemma="."/>
</s>
```

Lista dos padrões

- Padrões mais recorrentes e menos complexos no corpus especializado.

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE dict SYSTEM "dtd/mwetoolkit-patterns.dtd">
<patterns>
  <pat> <w pos="NOM"> <w pos="PRP+DET"> <w pos="NOM"></pat>
  <pat> <w pos="NOM"> <w pos="PRP"> <w pos="NOM"></pat>
  <pat> <w pos="NOM"> <w pos="PRP"> <w pos="NOM"> <w pos="ADJ"> </pat>
</patterns>
```

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE dict SYSTEM "dtd/mwetoolkit-patterns.dtd">
<patterns>
  <pat> <w pos="V"> <w pos="NOM"> </pat>
  <pat> <w pos="V"> <w pos="DET"> <w pos="NOM"> </pat>
  <pat> <w pos="V"> <w pos="PRP+DET"> <w pos="NOM"> </pat>
  <pat> <w pos="V"> <w pos="NOM"> <w pos="ADJ"> </pat>
  <pat> <w pos="V"> <w pos="DET"> <w pos="NOM"> <w pos="PRP+DET"> <w pos="NOM"> </pat>
</patterns>
```

Indexação

- Criação de um índice baseado em uma estrutura de dados que permite o rápido acesso a n-gramas de qualquer extensão (*suffix arrays*) ao longo de todo o corpus `<taggedLegisAmb_br.xml>` e no PLNBRFULL.

Extração de candidatos a CLEs

patterns.xml → corpus.xml → candidates-from-index.xml

Candidatos extraídos

```
<?xml version="1.0" encoding="UTF-8"?>
<!DOCTYPE candidates SYSTEM "dtd/mwtoolkit-candidates.dtd">
<candidates >
  <meta>
  </meta>
  <cand candid="0">
    <ngram>
      <w surface="cometer" pos="V" />
      <w surface="a" pos="DET" />
      <w surface="funcionários" pos="NOM" />
    </ngram>
    <occurs>
    <ngram>
      <w surface="cometer" lemma="cometer" pos="V" />
      <w surface="a" lemma="a" pos="DET" />
      <w surface="funcionários" lemma="funcionário" pos="NOM" />
      <freq name="corpus" value="1" />
    </ngram>
    </occurs>
  </cand>
</candidates>
```

Contagem

```
1 <?xml version="1.0" encoding="UTF-8"?>
2 <!DOCTYPE candidates SYSTEM "dtd/mwetoolkit-candidates.dtd">
3 <candidates >
4 <meta>
5   <corpusize name="legisamb" value="674696" />
6 </meta>
7 <cand candid="0">
8   <ngram>
9     <w lemma="chefe" pos="NOM" >
10      <freq name="legisamb" value="79" />
11    </w>
12     <w lemma="de" pos="PRP+DET" >
13      <freq name="legisamb" value="74322" />
14    </w>
15     <w lemma="casa" pos="NOM" >
16      <freq name="legisamb" value="24" />
17    </w>
18     <freq name="legisamb" value="7" />
19   </ngram>
20   <occurs>
21     <ngram>
22       <w surface="Chefe" lemma="chefe" pos="NOM" />
23       <w surface="da" lemma="de" pos="PRP+DET" />
24       <w surface="Casa" lemma="casa" pos="NOM" />
25       <freq name="legisamb" value="7" />
26     </ngram>
27   </occurs>
28 </cand>
29
```

Medidas associativas

- Medidas associativas:
 - mle: *Maximum Likelihood Estimator*
 - t: *Student's t test score*

Medidas associativas

```
1 <?xml version="1.0" encoding="UTF-8" ?>
2 <!DOCTYPE candidates SYSTEM "dtd/mwetoolkit-candidates.dtd">
3 <candidates >
4 <meta>
5   <corpussize name="corpus" value="674696" />
6   <metafeat name="mle_corpus" type="real" />
7   <metafeat name="t_corpus" type="real" />
8 </meta>
9 <cand candid="0">
10  <ngram>
11    <w surface="atender" pos="V" >
12      <freq name="corpus" value="151" />
13    </w>
14    <w surface="à" pos="PRP+DET" >
15      <freq name="corpus" value="3039" />
16    </w>
17    <w surface="notificação" pos="NOM" >
18      <freq name="corpus" value="111" />
19    </w>
20    <freq name="corpus" value="1" />
21  </ngram>
22  <occurs>
23    <ngram>
24      <w surface="atender" lemma="atender" pos="V" />
25      <w surface="à" lemma="a" pos="PRP+DET" />
26      <w surface="notificação" lemma="notificação" pos="NOM" />
27      <freq name="corpus" value="1" />
28    </ngram>
29  </occurs>
30  <features>
31    <feat name="mle_corpus" value="1.48214899747e-06" />
32    <feat name="t_corpus" value="0.999888104385" />
33  </features>
34 </cand>
35
```

Contraste: corpus de domínio e corpus de referência

```
1 <?xml version="1.0" encoding="UTF-8"?>
2 <!DOCTYPE candidates SYSTEM "dtd/mwetoolkit-candidates.dtd">
3 <candidates >
4 <meta>
5   <corpus size name="corpus" value="674696" />
6   <corpus size name="folha.corpus" value="2064512" />
7   <metafeat name="csmwe_corpus" type="real" />
8   <metafeat name="simplifiediff_corpus" type="real" />
9   <metafeat name="simplecsmwe_corpus" type="real" />
10  <metafeat name="mle_corpus" type="real" />
11  <metafeat name="t_corpus" type="real" />
12  <metafeat name="pmi_corpus" type="real" />
13  <metafeat name="dice_corpus" type="real" />
14  <metafeat name="ll_corpus" type="real" />
15  <metafeat name="mle_folha.corpus" type="real" />
16  <metafeat name="t_folha.corpus" type="real" />
17  <metafeat name="pmi_folha.corpus" type="real" />
18  <metafeat name="dice_folha.corpus" type="real" />
19  <metafeat name="ll_folha.corpus" type="real" />
20 </meta>
21 <cand candid="0">
22   <ngram>
23     <w lemma="chefe" pos="NOM" >
24       <freq name="corpus" value="79" />
25       <freq name="folha.corpus" value="164" />
26     </w>
27     <w lemma="de" pos="PRP+DET" >
28       <freq name="corpus" value="74322" />
29       <freq name="folha.corpus" value="139437" />
30     </w>
31     <w lemma="casa" pos="NOM" >
32       <freq name="corpus" value="24" />
33       <freq name="folha.corpus" value="875" />
34     </w>
35     <freq name="corpus" value="7" />
36     <freq name="folha.corpus" value="0" />
37   </ngram>
38   <occurs>
39     <ngram>
40       <w surface="Chefe" lemma="chefe" pos="NOM" />
41       <w surface="da" lemma="de" pos="PRP+DET" />
42       <w surface="Casa" lemma="casa" pos="NOM" />
43       <freq name="corpus" value="7" />
44     </ngram>
45   </occurs>
46
```

Etapas seguintes

- Filtragem dos candidatos para que tenhamos uma quantidade menor de dados para serem analisados. Isso é feito através do próprio mwetoolkit, ou utilizando alguma ferramenta externa, como R ou MS Excel
- Análise dos candidatos filtrados.

Referências

- ANTHONY, L. *AntConc (3.2.1 w)*. Tokyo: Waseda University, 2008. Disponível em <http://www.antlab.sci.waseda.ac.jp/software.html>. Acesso em: 28 de abr 2012.
- BEVILACQUA, C.R; MACIEL, A. M. B.; REUILLARD, P. C. R.; SCHEEREN, C. M. Combinatórias Léxicas Especializadas: etapas prévias para identificação e tratamento. XII Simposio Iberoamericano de Terminología RITerm 2010. Actas. Vol. 2. Buenos Aires: Colegio de Traductores de la Ciudad de Buenos Aires, 2012, p. 272-283.
- BEVILACQUA, C. R.; MACIEL, A. M. B.; REUILLARD, P. C. R.; SCHEEREN, C. M.; KILIAN, Cristiane Krause. Combinatórias Léxicas da Linguagem Legislativa: uma abordagem orientada pelo *corpus*. In: MURAKAWA, Clotilde de Almeida Azevedo; SILVA, Odair Luiz (Org.) *Terminologia: uma ciência interdisciplinar*. Araraquara, FCL-UNESP Laboratório Editorial/Cultura Acadêmica Editora, 2013 p. 277-244.
- GAMALLO, Pablo. *PoS Tree-Tagger for Portuguese and Galician*. 2005 Disponível em: < <http://gramatica.usc.es/~gamallo/tagger.htm> > Acesso em: 02/02/2012.
- KRIEGER, MACIEL, FINATTO, ROCHA, BEVILACQUA. Dicionário de Direito Ambiental: terminologia das leis do meio ambiente Rio de Janeiro: Lexikon, 2008.
- RAMISCH, Carlos. *A generic and open framework for multiword expressions treatment: from acquisition to applications*. 2012. Disponível em: http://www.inf.ufrgs.br/~ceramisch/download_files/thesis/ Acesso em 30/08/2012.
- RAMISCH, Carlos; VILLAVICENCIO, Aline; BOITET, Christian, 2010 *Framework for Multiword Expression Identification*. Disponível em http://www.lrec-conf.org/proceedings/lrec2010/pdf/803_Paper.pdf Acesso em: 12/03/2012.
- SCHMID, Helmut. Probabilistic Part of Speech Tagging using decision trees, 1994) Disponível em: <ftp://ftp.ims.uni-stuttgart.de/pub/corpora/tree-tagger1.pdf> Acesso em: 03/11/2011.