Relations extracted from a Portuguese dictionary: results and first evaluation

Hugo Gonçalo Oliveira*, Diana Santos, Paulo Gomes
hroliv@dei.uc.pt, diana.santos@sintef.no, pgomes@dei.uc.pt

* Hugo Gonçalo Oliveira is supported by FCT, grant SFRH/BD/44955/2008.

University of Coimbra
Faculty of Sciences and Technology
Department of Informatics Engineering

Knowledge and Intelligent Systems Laboratory
Cognitive and Media Systems Group
Centre of Informatics and Systems of the University of Coimbra

SINTEF
Natural Language Technologies Group

Introduction

- Natural language processing needs access to semantic knowledge
- Lexical ontologies
  - Conceptual models of a language, structured on words and meanings
  - Lexico-semantic relations
    - Synonymy: *car* syn *auto*
    - Hyponymy (is-a): *taxi* is-a *car*
    - Meronymy (part-of): *wheel* part-of *car*
    - Cause, purpose, location...

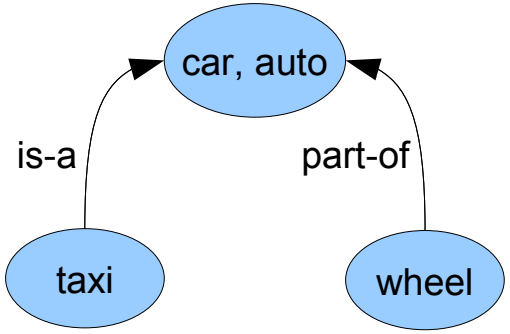

Construction of an ontology

- Handcraft:
  - More reliable
  - Difficult to maintain and update
- Semi-automatic:
  - From dictionaries
    - Semantic authorities, restricted vocabulary
    - General knowledge
  - From corpora
    - Much available, rich on specific domains
    - Unrestricted text, harder to process

Lexical ontologies
For English

- Handcrafted:
  - Princeton WordNet
  - Cyc
  - Berkeley FrameNet
- Semi-automatic construction:
  - MindNet

Lexical ontologies

For Portuguese

- Handcrafted:
  - Tep (http://www.nilc.icmc.usp.br/tep2/)
  - WordNet.BR (http://www.nilc.icmc.usp.br/~arianidf/WordNet-BR.html)
  - WordNet.PT (http://cvc.instituto-camoes.pt/wordnet/)
  - MultiWordNet.PT (http://mwnpt.di.fc.ul.pt/)
- Semi-automatic construction:
  - PAPEL (http://www.linguateca.pt/PAPEL)

PAPEL

- Palavras Associadas Porto Editora Linguateca

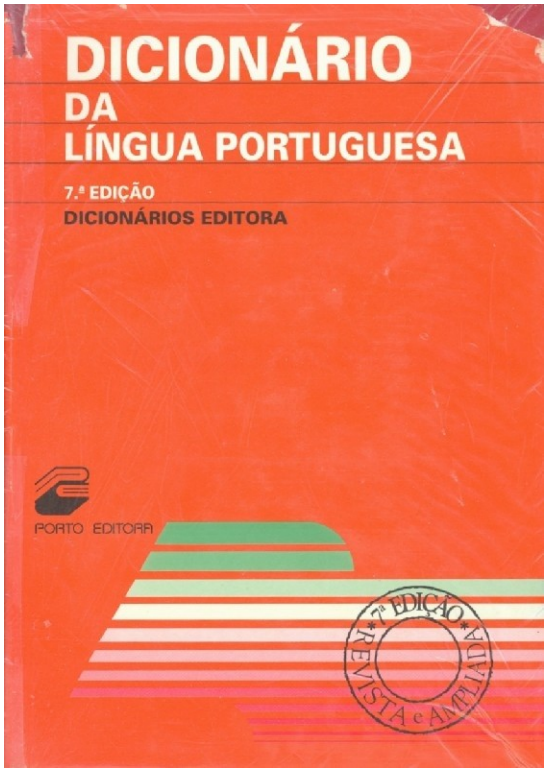

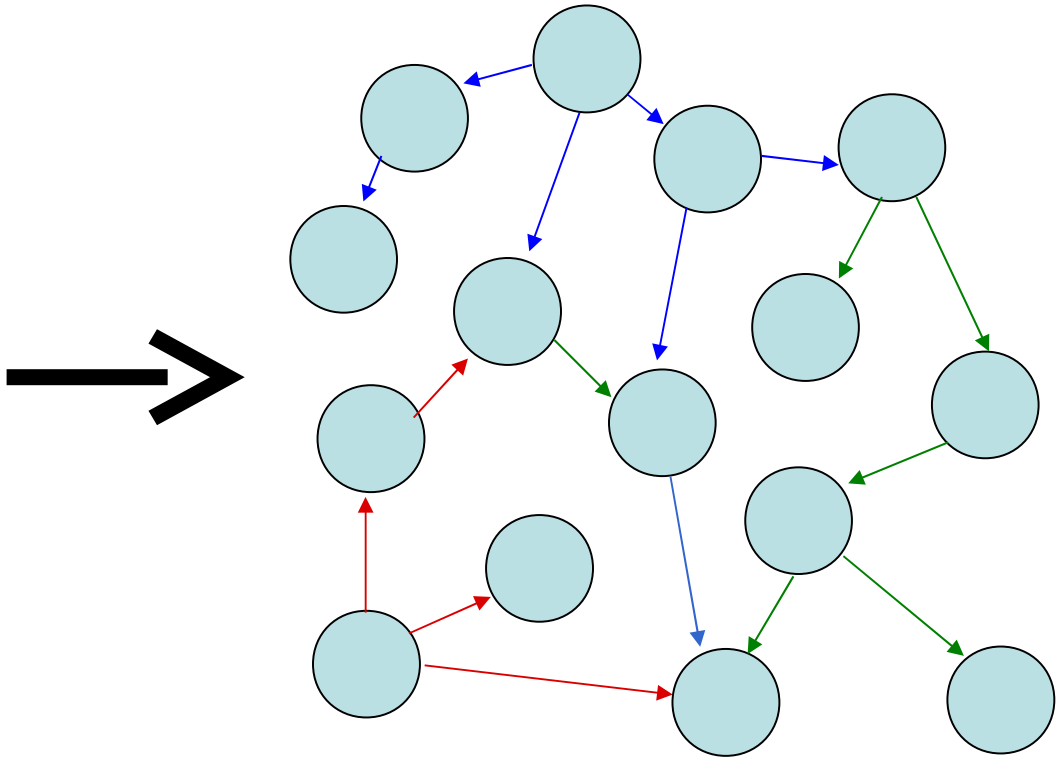

PAPEL

- About 200,000 relational triples between Portuguese terms, in PAPEL 1.1:

Group	Name	Args.	Qnt.	Examples
Synonymy	SINONIMO_N_DE	n,n	37,259	(*auxílio, contributo*)
	SINONIMO_V_DE	v,v	21,534	(*tributar, colectar*)
	SINONIMO_ADJ_DE	adj,adj	19,073	(*flexível, moldável*)
	SINONIMO_ADV_DE	adv,adv	1,169	(*após, seguidamente*)
Hypernymy	HIPERONIMO_DE	n,n	61,477	(*planta, salva*)
Meronymy	PARTE_DE	n,n	9,970	(*cauda, cometa*)
	PARTE_DE_ALGO_COM_PROP	n,adj	3,806	(*tampa, coberto*)
	PROP_DE_ALGO_PARTE_DE	adj,n	900	(*celular, célula*)
Cause	CAUSADOR_DE	n,n	1,010	(*fricção, assadura*)
	CAUSADOR_DE_ALGO_COM_PROP	n,adj	17	(*paixão, passional*)
	PROP_DE_ALGO_CAUSADOR_DE	adj,n	498	(*reactivo, reacção*)
	ACCAO_QUE_CAUSA	v,n	6,399	(*limpar, purgação*)
	CAUSADOR_DA_ACCAO	n,v	39	(*gases, fumigar*)
Producer	PRODUTOR_DE	n,n	885	(*romãzeira, romã*)
	PRODUTOR_DE_ALGO_COM_PROP	n,adj	34	(*sublimação, sublimado*)
	PROP_DE_ALGO_PRODUTOR_DE	adj,n	359	(*fotógeno, luz*)
Purpose	FINALIDADE_DE	n,n	2,878	(*defesa, armadura*)
	FINALIDADE_DE_ALGO_COM_PROP	n,adj	38	(*reprodução, reprodutor*)
	ACCAO_FINALIDADE_DE	v,n	5,185	(*fazer_rir, comédia*)
	ACC_FINALIDADE_DE_ALGO_COM_PROP	v,adj	284	(*corrigir, correccional*)
Place	LOCAL_ORIGEM_DE	n,n	816	(*Japão, japonês*)
Manner	MANEIRA_POR_MEIO_DE	adv,n	1,113	(*timidamente, timidez*)
	MANEIRA_SEM	adv,n	121	(*devagar, pressa*)
	MANEIRA_SEM_ACCAO	adv,v	11	(*assiduamente, faltar*)
Property	PROP_DE_ALGO_REFERENTE_A	adj,n	3,520	(*dinâmico, movimento*)
	PROP_DO_QUE	adj,v	17,246	(*familiar, ser_conhecido*)

PAPEL

Relations specification

- General relation names (HIPERONIMIA, PARTE, CAUSA ...)
- More specific names (and inverse), according to the arguments grammatical categories

```
PARTE {
nome:nome * PARTE_DE:INCLUI;
nome:adj * PARTE_DE_ALGO_COM_PROPRIEDADE:PROPRIEDADE_DE_ALGO_QUE_INCLUI;
adj:nome * PROPRIEDADE_DE_ALGO_PARTE_DE:INCLUI_ALGO_COM_PROPRIEDADE;
}

CAUSA{
nome:nome * CAUSADOR_DE:RESULTADO_DE;
nome:verbo * CAUSADOR_DA_ACCAO:ACCAO_RESULTADO_DE;
nome:adj * CAUSADOR_DE_ALGO_COM_PROPRIEDADE:PROPRIEDADE_DE_ALGO_RESULTADO_DE;
adj:nome * PROPRIEDADE_DE_ALGO_QUE_CAUSA:RESULTADO_DE_ALGO_COM_PROPRIEDADE;
verbo:nome * ACCAO_QUE_CAUSA:RESULTADO_DA_ACCAO;
}
```

PAPEL
Extraction

- PEN* parser + semantic grammars

1

cometa, s. m.
astro geralmente constituído por núcleo, cabeleira e cauda

2

```
[RAIZ]
   [QUALQUERCOISA]
     > [astro]
     [QUALQUERCOISA]
       > [geralmente]
   [PADRAO_CONSITIUIDO]
     [VERBO_PARTE_PP]
       > [constituído]
     [PREP]
       > [por]
   [ENUM_PARTE]
     [PARTE_DE]
       > [núcleo]
     [VIRG]
       > [,]
     [ENUM_PARTE]
       [PARTE_DE]
         > [cabeleira]
       [CONJ]
         > [e]
       [PARTE_DE]
         > [cauda]
```

3

núcleo PARTE_DE cometa
cabeleira PARTE_DE cometa
cauda PARTE_DE cometa

*available through http://code.google.com/p/pen/

PAPEL

More examples

barranquenho, s. m. natural ou habitante de **Barrancos**
--> Barrancos LOCAL_ORIGEM_DE barranquenho

clarabóia, s. f. **janela** ou **fresta** por onde entra a luz num aposento
--> fresta HIPERONIMO_DE clarabóia
--> janela HIPERONIMO_DE clarabóia

vínculo, s. m. tudo o que serve para **prender** ou **atar**
--> prender ACCAO_FINALIDADE_DE vínculo
--> atar ACCAO_FINALIDADE_DE vínculo

cólera, s. f. grave doença epidémica, contagiosa, que provoca **diarreia**, **vómitos** e **cólicas**, causada por um **bacilo** (vibrião) e também designada por cólera-morbo e cólera-asiática, mordexim ou mordixim
--> diarreia RESULTADO_DE cólera
--> vómitos RESULTADO_DE cólera
--> cólicas RESULTADO_DE cólera
--> bacilo CAUSADOR_DE cólera

PAPEL
Relations adjustment

- All relations converted to the direct type
  - *manga* INCLUI *punho* >> *punho* PARTE_DE *manga*
  - *dor* RESULTADO_DE *distensão* >> *distensão* CAUSADOR_DE *dor*
- Lematization of arguments
- Relation's name correction
  - *loucura* ACCAO_QUE_CAUSA *desvario* >> *loucura* CAUSADOR_DE *desvario*

Evaluation
Synonymy

- Tep 2.0 as a golden resource
- Relations with terms that are not both in PAPEL 1.0 and Tep 2.0 are removed
  - 50% of PAPEL in TeP, 39% of TeP in PAPEL
- Expansion: (A SINONIMO_DE B) e (B SINONIMO_DE C) >> (A SINONIMO_DE
  - 19% of PAPEL in TeP, 90% of TeP in PAPEL
  - Incorrections
    - A=*ruína*, B=*queda*, C=*habilidade*
    - >> *ruína* SINONIMO_DE *habilidade*

Evaluation
Other relations

- Relations rendered to natural language patterns
- Searched on CETEMPúblico, via AC/DC

Relação	Certa?	Justificação
língua HIPERONIMO_DE *italiano*	Sim	*As **línguas latinas, como o italiano** ou o português, tornam-se mais fáceis por causa das vogais.*
arbusto PARTE_DE *floresta*	Sim	*A **floresta é um conjunto de árvores, arbustos** e ervas de várias qualidades e tamanhos.*
cólera CAUSADOR_DE *diarreia*	Sim	*A **cólera provoca fortes diarreias** e vómitos e pode levar à desidratação e, consequentemente, à morte em poucas horas.*
oliveira PRODUTOR_DE *azeitona*	Sim	*Também a quantidade e tamanho das **azeitonas produzidas por uma oliveira** biológica é inferior, já que não são utilizados compostos de azoto que ajudam a planta a crescer.*
recrutamento FINALIDADE_DE *inspecção*	Sim	*Menos de metade dos jovens entre os 20 e os 22 anos apresentaram-se às **inspecções para recrutamento**, revelou o ministro da Defesa.*
músico PARTE_DE *música*	Não	*... um espectáculo baseado na obra "Cantos de Maldoror", de Lautréamont, com **música composta pelo músico** inglês Steven Severin...*
fim FINALIDADE_DE *sempre*	Não	*Sicilia aponta **sempre para o fim** do dia, para o fim da luz.*

First evaluation results

- Results for PAPEL 1.0 + CETEMPúblico 4.0

Relação	Relações c/ args no CETEMPúblico	%	Amostra	%	Encontradas	%
Hiperonímia	40,079	63%	3,145	8%	560	18%
Meronímia	3,746	35%	2,343	63%	521	22%
Causa	557	50%	557	100%	20	4%
Produtor	414	44%	414	100%	12	3%
Finalidade	1,718	59%	1,718	100%	173	10%

- Some correct relations are not found:
  - fruto HIPERONIMO_DE alperce
  - algoritmia PARTE_DE matemática
  - ausência CAUSADOR_DE saudade
  - aquecimento FINALIDADE_DE salamandra
  - ...

Final remarks

- Starting point for future projects
  - New evalations
  - Comparison with other resources
  - Integration with other resources and methodologies
  - Usage to query corpora (through AC/DC)
- PAPEL is completely free: everybody can do what they what with it, improve it, and redistribute it!
  - There is a lot to improve
  - New versions will be available during the next months

Soon...

- Diana Santos, Anabela Barreiro, Luís Costa, Cláudia Freitas, Paulo Gomes, Hugo Gonçalo Oliveira, José Carlos Medeiros & Rosário Silva. "O papel das relações semânticas em português: Comparando o TeP, o MWN.PT e o o PAPEL". In *XXV Encontro Nacional da Associação Portuguesa de Linguística* (Lisboa, Portugal, 22-24 de Outubro de 2009).

Acknowledgements

- PAPEL was developed in the scope of Linguateca, under contract POSC/339/1.3/C/NAC, co-funded by the Portuguese Government, by the European Union (FEDER and FSE), by UMIC e by FCCN.

POS_Conhecimento
Programa Operacional Sociedade do Conhecimento

União Europeia
FEDER

UMIC
Agência para a Sociedade do Conhecimento

FCCN
Fundação para a Computação Científica Nacional

- Hugo Gonçalo Oliveira is supported by FCT, scholarship grant SFRH/BD/44955/2008.
- We would also like to thank to the R&D group of Porto Editora

Relations extracted from a Portuguese dictionary: results and first evaluation

Thank you!

Hugo Gonçalo Oliveira, Diana Santos, Paulo Gomes
hroliv@dei.uc.pt, diana.santos@sintef.no, pgomes@dei.uc.pt

University of Coimbra
Faculty of Sciences and Technology
Department of Informatics Engineering

Knowledge and Intelligent Systems Laboratory
Cognitive and Media Systems Group
Centre of Informatics and Systems of the University of Coimbra

SINTEF
Natural Language Technologies Group