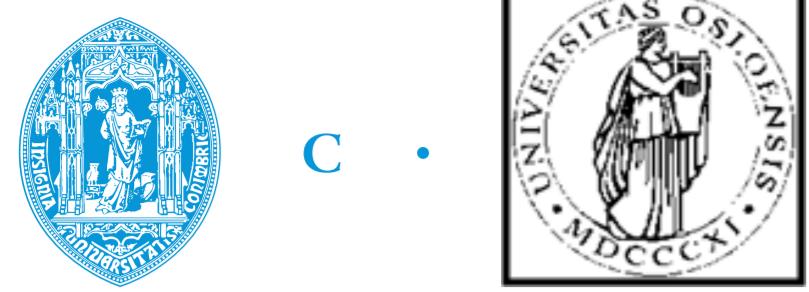


Folheador: browsing through Portuguese semantic relations



Hugo Gonçalo Oliveira & Hernani Costa & Diana Santos

{hroliv,hpcosta}@dei.uc.pt,
d.s.m.santos@ilos.uio.no

CISUC, University of Coimbra
FCCN, Linguateca
University of Oslo, Norway



MCTES MINISTÉRIO DA CIÉNCIA, TECNOLOGIA E ENSINO SUPERIOR

FCCN Fundação para a Computação Científica Nacional

Introduction

Folheador^{ab} is an (open source^c) online browser for Portuguese Lexical Knowledge Bases (LKBs)

1. Navigation through Portuguese semantic relations, acquired from different sources
2. Linked to Portuguese corpora access providers
 - ▶ observation of related words co-occurring in authentic contexts

Current LKB

Semantic relations of CARTÃO [3], extracted from:

- ▶ Public domain electronic dictionaries
 - ▶ Dicionário da Língua Portuguesa, Porto Editora (see PAPEL [4])
 - ▶ Dicionário Aberto [8]
 - ▶ Wiktionary.PT^d
 - ▶ Public domain thesauri
 - ▶ TeP [5]
 - ▶ OpenThesaurus.PT^e
- Represented as relational triples x RELATED-TO y
- ▶ About 723k triples
 - ▶ synonymy, hyponymy, part-of, member-of, causation, producer-of, purpose-of, place-of, and property-of
 - ▶ About 70k lexical items
 - ▶ 93,612 nouns, 38,409 verbs, 33,497 adjectives and 3,867 adverbs

Browsing features

- ▶ Search for all relations with one, two, or no fixed arguments, and one or no types
 - ▶ all lexical items related to a particular item
 - ▶ all relations between two lexical items
 - ▶ a sample of relations of a particular type
- ▶ Filter matching triples according to resource
- ▶ Provides the PoS of the lexical items
- ▶ Navigation through clicks on the items
- ▶ Queried item is always the first argument – relation is inverted on-the-fly
- ▶ Confidence values:
 - ▶ mere co-occurrence of the words in corpora
 - ▶ co-occurrence of the related words instantiating discriminating patterns of the particular relation
- ▶ (Partial) Graph visualisation

In **Figure 1**, search for item *computador*:

- ▶ *computador* is usually a noun (e.g. in *computador* HIPONIMO_DE *máquina*)
- ▶ But might be an adjective (e.g. in *computador* PROPRIEDADE_DO_QUE *computar*)
- ▶ *computador* HIPONIMO_DE *aparelho* results of the inversion of *computador* HIPONIMO_DE *máquina*

The use of corpora

- ▶ Folheador is connected to AC/DC [7, 6]
 - ▶ access to Portuguese corpora
 - ▶ query for all the sentences connecting the arguments of a retrieved triple
 - ▶ e.g. in **Figure 2**, sentences with *computador* and *aparelho*
- ▶ Folheador is connected to VARRA [2]
 - ▶ based on patterns that express some of the relation types
 - ▶ occurrences of a triple in AC/DC
 - ▶ designed to allow human users to classify sentences according to whether they validate the relation, are just compatible with it, or not even that.
 - ▶ e.g. in **Figure 3**, sentences for (*computador* HIPONIMO_DE *máquina*)

^aFor using Folheador, go to <http://www.linguateca.pt/Folheador/>

^bSee technical details in [1]

^cSource code on <http://code.google.com/p/folheador/>

^d<http://pt.wiktionary.org>

^e<http://openthesaurus.caixamagica.pt>

Figures



Palavra ou Termo 1: computador Termo 2: Relação a procurar: > Todas < Pesquisar

A procurar pela palavra: "computador".

Apresentados 10 resultados de 25 no total.

TRÍPLOS			RECURSO(S)	GRAU DE CONFIANÇA	
TERMO1	RELAÇÃO	TERMO2	<input checked="" type="button"/> todos	<input checked="" type="radio"/> OK	SIMPLES COMPOSTA
computador (nome)	HIPONIMO_DE	aparelho (nome)	wiki, papel	286	0.0
computador (nome)	HIPERONIMO_DE	servidor (nome)	wiki, papel	197	0.0
computador (nome)	HIPONIMO_DE	pessoa (nome)	da, papel	720	0.0
computador (adj)	PROPRIEDADE_DO_QUE	computar (verbo)	wiki	0	0.0
computador (nome)	HIPONIMO_DE	máquina (nome)	wiki	947	0.0
computador (nome)	SINONIMO_N_DE	calculista (nome)	wiki	0	0.0
computador (nome)	PRODUTOR_DE	resolução (nome)	wiki	65	0.0
computador (nome)	HIPERONIMO_DE	cliente (nome)	wiki	218	0.0
computador (nome)	TEM_PARTE	memória (nome)	wiki	485	0.0
computador (adj)	SINONIMO_ADJ_DE	computadora (adj)	wiki	0	0.0

2 fim >

Última atualização: 2 de Março de 2012

Perguntas, comentários e sugestões

Figure 1: Folheador's interface.

par=2530: Ela trazia irregularmente do Paraguai computadores, **aparelhos** eletrônicos e úsque .

par=2548: Em outubro, Wanderlei usou cerca de R \$ 15 mil que Márcia havia juntado com os seus contrabandos para comprar duas televisões, dois videocassetes, um **aparelho** de som, uma

filmadora e um computador .

: Para você que quer ter uma coleção de músicas para seu computador ou mesmo para ouvir no seu novo **aparelho** de MP3, não perca essa oportunidade .

: Usando o CyberTracker, um software com o qual os ecólogistas podem registrar suas observações em campo usando computadores portáteis conectados a **aparelhos** de posicionamento global (GPS), os rastreadores puderam reunir dados que comprovam a degradação da população local da espécie .

: Para você que quer ter uma coleção de músicas para seu computador ou mesmo para ouvir no seu novo **aparelho** de MP3, não perca essa oportunidade .

: Segundo a pesquisa, 16,6 % dos domicílios brasileiros têm computadores de mesa, contra 95,7 % que têm **aparelhos** de TV .

par=49126: O **aparelho** está equipado com modernos instrumentos de telecomunicações, primeiros-socorros, páraquedas e computador .

par=sauda16727: Os avanços da ecografia, enquanto tecnologia, resultam da evolução da Informática, afinal, estes **aparelhos** são computadores que analisam o som e a imagem .

Figure 2: AC/DC: some sentences returned for the related words *computador* and *aparelho*.

Relação	Procura	Exemplo
máquina HIPERONIMO_DE computador	padrões usados	par=Mais--94a-2: E também de ensinar máquinas como computadores a identificarem 'ses objetos . (NSC)
máquina HIPERONIMO_DE computador	padrões usados	par=ext328388-soc-95a-2: Máquinas como os computadores , os faxes e os videofones devem poder comunicar entre si sem falhas, o que supõe um trabalho de programação importante . (CP)

Figure 3: VARRA: sentences that exemplify the relation *computador* hyponym-of *máquina*.

Acknowledgements

Folheador was developed under the scope of Linguateca, throughout the years jointly funded by the Portuguese Government, the European Union (FEDER and FSE), UMIC, FCCN and FCT.

Hugo Gonçalo Oliveira is supported by the FCT grant SFRH/BD/44955/2008, co-funded by FSE.

References

- [1] Hernani Costa. O desenho do novo Folheador. Technical report, Linguateca, 2011.
- [2] Cláudia Freitas, Diana Santos, Hugo Gonçalo Oliveira, and Violeta Quental. VARRA: Validação, Avaliação e Revisão de Relações semânticas no AC/DC. In *Livro do IX Encontro de Linguística de Corpus*, ELC 2010, 2010.
- [3] Hugo Gonçalo Oliveira, Letícia Antón Pérez, Hernani Costa, and Paulo Gomes. Uma rede léxico-semântica de grandes dimensões para o português, extraída a partir de dicionários electrónicos. *Linguamática*, 3(2):23–38, December 2011.
- [4] Hugo Gonçalo Oliveira, Diana Santos, and Paulo Gomes. Extracção de relações semânticas entre palavras a partir de um dicionário: o PAPEL e sua avaliação. *Linguamática*, 2(1):77–93, May 2010.
- [5] Erick G. Maziero, Thiago A. S. Pardo, Ariani Di Felippo, and Bento C. Dias-da-Silva. A Base de Dados Lexical e a Interface Web do TeP 2.0 - Thesaurus Eletrônico para o Português do Brasil. In *VI Workshop em Tecnologia da Informação e da Linguagem Humana (TIL)*, pages 390–392, 2008.
- [6] Diana Santos. Linguateca's infrastructure for Portuguese and how it allows the detailed study of language varieties. *OSLA: Oslo Studies in Language*, 3(2):113–128, June 2011. Volume edited by J.B.Johannessen, Language variation infrastructure.
- [7] Diana Santos and Eckhard Bick. Providing Internet access to Portuguese corpora: the AC/DC project. In *Proceedings of 2nd LREC*, pages 205–210, Athens, Greece, 2000.
- [8] Alberto Simões and Rita Farinha. Dicionário Aberto: Um novo recurso para PLN. *Vice-Versa*, pages 159–171, December 2011.