

Nos bastidores da Gramateca: uma série de serviços

ALBERTO SIMÕES E DIANA SANTOS

<http://www.linguateca.pt>

MOTIVAÇÃO

Demasiado texto anotado para podermos conhecê-lo sem ferramentas informáticas

- potenciar a procura e apresentar a repartição
- permitir comparações
- permitir análises alternativas
- visualizar sob diferentes ângulos

TEMAS DE INVESTIGAÇÃO

- Usabilidade
- Comparação de anotadores sintáticos
- Gramática baseada em corpos
- Estudo de diferenças entre teorias linguísticas

AC/DC

Acesso a corpos, disponibilização de corpos

- servindo 27 corpos diferentes, 1,5 mil milhões de palavras
- anotada com muita informação associada

Há 15 anos servindo as comunidades do processamento computacional da língua portuguesa e da linguística, graças ao PALAVRAS e ao OpenCWB (<http://cwb.sourceforge.net/>).

SERVIÇOS

- Procura** <http://www.linguateca.pt/ACDC/>
- Distribuidor** <http://www.linguateca.pt/Distribuidor/>
- Comparador** <http://www.linguateca.pt/Comparador/>
- Ordenador** <http://www.linguateca.pt/Ordenador/>
- VARRA** <http://www.linguateca.pt/VARRA/>
- Ensinador** <http://www.linguateca.pt/Ensinador/>
- Ensinador paralelo** <http://dinis2.linguateca.pt/paraensinador/>
- Rêve** <http://www.linguateca.pt/Reve/>
- Repositório GitHub** <https://github.com/linguateca>

REFERÊNCIAS

- Luís Costa, Diana Santos e Paulo Alexandre Rocha. 2014. Estudando o português tal como é usado: o serviço AC/DC. In *The 7th Brazilian Symposium in Information and Human Language Technology (STIL 2009)* (São Carlos, Brasil, 8-11 de Setembro 2009).
- Eckhard Bick. 2000. *The Parsing System "Palavras": Automatic Grammatical Analysis of Portuguese in a Constraint Grammar Framework*. Aarhus University Press.
- Cláudia Freitas, Diana Santos, Hugo Gonçalo Oliveira & Violeta Quental. 2014. VARRA: Validação, Avaliação e Revisão de Relações semânticas no AC/DC. In Simone Sarmento, Tony Berber Sardinha, Livia Pretto Mottin & Ana Maria T. Ibaños. *Pesquisas e perspectivas em linguística de corpus*, Mercado de Letras, pp. 199-232.
- Diana Santos. 2014. Corpora at Linguateca: Vision and roads taken. In Tony Berber Sardinha & Telma de Lurdes São Bento Ferreira (eds.), *Working with Portuguese Corpora*, Bloomsbury, 2014, pp. 219-236.
- Alberto Simões & Diana Santos. 2011. Ensinador: corpus-based Portuguese grammar exercises. In *Procesamiento del Lenguaje Natural*, 47, pp. 301-309.

EXEMPLOS DA SUA INVOCACÃO

Distribuição mais fina

Distribuidor

Expressão de pesquisa:

Corpo: ECH-EE Tipo de resultado: html

gen	Frequência Total	pessum	Frequência Parcial	%
M	3354	P	1344	40,07%
		S	2010	59,93%
F	3246	S	2347	72,30%
		P	899	27,70%
M/F	24	S	10	41,67%
		P	14	58,33%

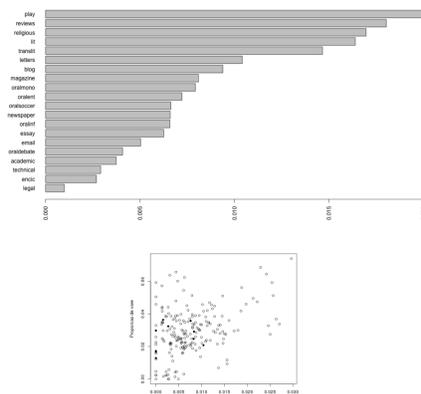
Distribuidor

Expressão de pesquisa:

Corpo: CONDIV Tipo de resultado: html

tema	Frequência Total	lema	Frequência Parcial	%
saúde	59	cor	1	1,69%
		branco	34	57,63%
		preto	1	1,69%
		negro	22	37,29%
futebol	9	branca	1	1,69%
		branco	4	44,44%
		negro	4	44,44%
		preto	1	11,11%
moda	6	branco	3	50,00%
		preto	3	50,00%

Capacidades de visualização



Comparação de procuras

Comparador

Procurar: [sema="*coragem.*"] Procurar: [sema="*coragem.*"]

Corpo: CHAVE Tipo de resultado: html

Corpo: CONDIV Tipo de resultado: html

Distribuir por: lema Distribuir por: lema

fundir numa única tabela

Limite mínimo de frequência: 50

apoiar	12623	462
herói	3901	119
determinação	2928	232
coragem	2983	160
incentivo	2803	45
incentivar	1992	90
heroína	1997	6
usar	1449	59
estimulo	1156	164
corajoso	843	33
encorajar	840	21
bravo	703	125
ousadia	707	53
incitar	610	34

Comparador

Procurar: [sema="verbo" & variante="PT"] Procurar: [sema="verbo" & variante="BR"]

Corpo: CHAVE Tipo de resultado: html

Corpo: CHAVE Tipo de resultado: html

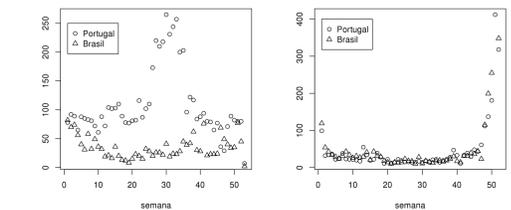
Distribuir por: semana Distribuir por: semana

fundir numa única tabela

Limite mínimo de frequência: 0

30	260	41
33	238	23
32	231	24
31	213	19
35	185	45
27	197	26
34	194	28
28	191	26
29	192	22
26	149	20
38	106	62
..

Inspeção fina de correlações



Criação de material didático

Ensinador

A procurar " [word="quandoise"]- [pos!="V.*"]- [temagr="*SUBJ"]lema" no corpus C-Oral-Brasil v. 3.2 [121 entradas.]

Seleccione as concordâncias que deseja usar.

- Ah, é, uai // 24 se n morrer antes deles. (morrer)
- Lá em casa, aviso se cê for lá. (ser)
- Se eu fizesse // 280 se eu fizesse. (fazer)
- Eu, se eu fosse cê fazia isso não, Carão // 204 se eu fosse cê matava aqui o \$ / 205 eu te avisei, Zé // 206 p' cê + CAR (ser)

Ensinador Paralelo

Eu não sei o que se passa, mas há coisa misteriosa que eu não consigo adivinhar. er. Far har holdt seg inestetligt sammen med fetter Baltasar bebo

Falou-me em criados mortos; mas eu não entendo... Jeg kunne ikke høre helt hva hun sa til meg.

Prometa partir para Coimbra logo que o _____ fazer sem já ai Teresa. behandling. Han lovet å dra til Coimbra så snart han var vis ikke ville bli utsatt for noe ubehag i hans fravær.

Um apenas adiantara coisa que não alimiar a justiça. et til. Like etter. En av dem la til. uten at det hjalp de som e vidia a ser que o mató. nas vizinhanças do local. fora startet. at småskogen i nærheten av funnstedet var hogget chapotado.

Nesta escuridade a justiça não dar passo algum. Utan flere opplysninger kunne ikke myndighetene utrette noe som helst.

Tanto ao velho como ao morgado convinha apagar algum indício que _____ envolvesse no mistério daquelas duas. Det passet både Tades og Baltasar godt at enhver opplysning som kunne blande dem inn i drapsmysteriet ble undertrykt.

Reanotação de dados anotados

Rêve

Partes do corpo

- Classifique a palavra segundo o seu sentido:
- referindo-se ao corpo humano (corpo):
 - o usando uma palavra do corpo para outros fins:
 - o corpo:faculdade
 - o corpo:outros
 - o corpo:animal
 - o corpo:partido/objeto
 - o corpo:sentimento
 - o corpo:vegetal
 - o corpo:grupo
 - o corpo:doença
 - o corpo:posição
 - o corpo:emoção
 - o corpo:lugar
 - o corpo:movimento
 - o ou não se referindo de todo ao corpo humano: 0

Se a palavra fizer parte de uma expressão maior relacionada com o corpo, indique essa conexão no campo de comentário, com o sufixo EVP, por exemplo *corpoEVP* ou *corpo: lugarEVP*.

Quando considerar que mais de uma classificação é possível, indique ambas no comentário ligadas por ...

E001-PT332: E na aula recebem-me com uma salva de palmas .	corpo:outros
E001-PT905: Eu andei com caixotes às costas , todos nós.	corpo
E003-PT24: A ferramenta é esta que tenho na mão : a colmeadeira, o lareiro e a estaca.	corpo
E103-PT39: Eu enjoo muito e como fui de carreira, ia muito "amorrinhada", uma mulher que lá atrás de mim, num sítio qualquer bateu-me nas costas e disse-me: "Saia aqui".	corpo
E105-PT91: Os guardas passaram por mim e eu levava o alforçes às costas e eles não me viram.	corpo
E133-BR-1060: Meu irmão já até levantou a mão para minha mãe, ela tem medo que ele faça alguma besteira.	corpo:outros corpo:outrosEVP, etc

AGRADECIMENTOS

A Linguateca foi financiada pelo governo português e pela União Europeia através do MCTES, a UMIC, e a FCT de 1998 até 2010, e gerida e apoiada pela infraestrutura informática da FCCN desde 2000. O trabalho mais recente foi financiado pela Universidade de Oslo. Estamos também gratos ao Research Computing Group desta universidade.

