



Procura-PALavras (P-PAL): Da constituição do corpus à base lexical

Ana **Costa**⁴, Ana Paula **Soares**¹, Álvaro **Iriarte**², João Filipe **Machado**⁴
Alberto **Simões**³, José João de **Almeida**³, Montserrat **Comesaña**¹ & Patrícia **França**²

¹Escola de Psicologia, Universidade do Minho, ²Instituto de Letras e Ciências Humanas, Universidade do Minho, ³Escola de Engenharia, Universidade do Minho, ⁴Centro de Investigação em Psicologia, Universidade do Minho



Conteúdos



1. Contextualização
2. Aplicações
3. Caracterização
4. O corpus
5. Problemas
 - a) O sistema de anotação
 - b) O sistema de lematização
6. O interface



Contextualização

- Construção de uma ferramenta rápida e versátil que disponibilize propriedades objectivas (lexicais e/ou sublexicais) e subjectivas das palavras do Português Europeu (PE)
- A investigação depende da análise, controlo e/ou manipulação das propriedades linguísticas em tarefas de desempenho
- Ausência de bases lexicais põe em causa a realização de estudos com falantes do Português Europeu

No PE as bases lexicais existentes são escassas e limitadas:

- **PORLEX (Gomes & Castro, 2003)**
 - Informação lexical de tipo gráfico, fonológico, fonético, morfo-sintático e de vizinhança para um total de 29.238 palavras
 - Informação de frequência para $\approx 5\%$ das entradas lexicais (importadas de um corpus oral de pequenas dimensões - Português Fundamental)
- **CORLEX (Bacelar do Nascimento et al, 2000)**
 - Informação de frequência absoluta para 26.980 lemas e 140.976 formas (extraídas de um sub-corpus do *Corpus* de Referência do Português Contemporâneo (CRPC) do Centro de Linguística da Universidade de Lisboa)
 - Informação morfo-sintática

- **frequência lexical:** ocorrência das palavras por milhão de palavras, logarítmica (base 10)
- **informação estrutural:** informação de tipo linguístico determinada pela análise da própria palavra (ex. extensão da palavra em letras e fones, classe gramatical)
- **informação derivada:** informação que resulta da análise da relação da palavra com as restantes do léxico tanto a nível lexical (ex. vizinhança), como sublexical (ex. bigramas, bifones, sílabas)
- **informação subjectiva:** informação que reflecte as experiências dos indivíduos com o uso da própria língua (ex. familiaridade, imaginabilidade, concreteza, valência)



Aplicações




Universidade do Minho, Escola Psicologia
Grupo de Investigação Psicolinguística

- **Linguística:** estudos sobre a língua (ex., análise empírica das características ortográficas, fonológicas e morfo-sintáticas do PE)
- **PLN:** construção de ferramentas lexicográficas e instrumentos de análise linguística (ex. silabificação)
- **Psicolinguística:** Estudo da arquitectura funcional e do processamento linguístico humano

Critérios de selecção:

- Corpora existentes do PE
- Disponíveis livremente
- Anotados



Linguateca

Corlex



O Corpus




Figura 1: Distribuição dos corpora do P-PAL por género e tipo linguísticos

Tamanho total do corpus – 227.770.752 palavras

Diferentes corpora



1. Diferentes sistemas de anotação
2. Diferentes sistemas de lematização

Corpora da Linguateca			CORLEX		P-PAL		
Nomes próprios e comuns			Nome		Nome		
	ART	Def.				Artigo	Def.
		Indef.					Indef.
DET (Artigos Pronomes Adjectivos)	Relativo Interrog.		ART	Def. Indef.	DET	Demonstrativo Possessivo Indef. Relativo Interrogativo	
Pronome Pessoal			PRON	Pessoal Demonst. Indefinido Possessivo Interrog. Relativo	PRON	Pessoal Demonstrativo Indefinido Possessivo Interrogativo Relativo	
Especificador (Pronomes Adjectivos)	Demonst. Possessivo Interrogativo Relativo						

Corpora da Linguateca			CORLEX	P-PAL	
Adjectivo			Adjectivo	Adjectivo	
Verbo	Principal	Intransit. Transitivo Transit. dir.	Verbo	Verbo	
	Copulativo	vK e vtK			
Preposição			Preposição	Preposição	
Advérbio			Advérbio	Advérbio	Interrog.
Conjunção	Subordinativa		Conjunção	Conjunção	Subordinativa
	Coordenada				Coordenada
Interjeição			Interjeição	Interjeição	
Contracção			Contracção		
Itens multilexicais (não hifenizados)			Elemento de Locução		

Tabela 1: O sistema morfo-sintáctico do P-Pal

Diferentes corpora



1. Diferentes sistemas de anotação
2. Diferentes sistemas de lematização

	Linguateca	Corlex	P-Pal
Nomes	Masc. e fem. singular	Masc. singular	Masc. singular
Preposições	Invariável	Invariável	Invariável
Conjunções	Invariável	Invariável	Invariável
Advérbios	Invariável	Invariável	Invariável
Interjeições	Invariável	Invariável	Invariável
Verbos	Infinitivo Pessoal	Infinit. pessoal	Infinit. pessoal
Adjectivos	Masculino singular (excepto adjectivos com função de nome)	Masc. singular	Masc. singular
Pronomes possessivos, relativos, interrogativos e demonstrativos	Masculino singular (pronomes pessoais têm como lema o pronome pessoal recto: eu é lema de me, ele lema de lhe)	Masculino e feminino singular	Masculino e feminino singular (tal como os determinantes)


	Linguateca	Corlex	P-Pal
Palavras compostas hifenizadas	Masc. sing. ou invariáveis	Inconsistente: - abelha-mãe pertence ao lema abelha; abelha-mestra tem entrada própria - à-vontade é lema de à e vontade	- Masc. singular ou invariáveis - Palavras formadas por derivação prefixal com alteração de significado, referente ou classe gramatical
Itens multilexicais não hifenizados	Masc. sing. e invariáveis com “=”	Não incluídos	Decompostas: frequência somada a cada constituinte
Estrangeirismos	Singular	Singular	Singular

Tabela 2: A integração das bases lexicais de lemas

1. Base de dados

P-PAL SUBTLEX

2. Ferramenta



Obter palavras



Analisar palavras

Pesquisa por:

Lemas

Formas



O Interface



Universidade do Minho, Escola Psicologia
Grupo de Investigação Psicolinguística

[Voltar à aplicação](#)

[Expandir filtros](#)

[Expandir opções](#)

+ Índices de frequência lexical

+ Índices morfo-sintáticos

+ Índices ortográficos

+ Índices fonológicos

+ Índices subjectivos

[Submeter](#)

Categoria morfo-sintáctica [morf_cat] ?

Filtrar

N V ADJ PREP CONJ ADV PRON DET INT QUANT

Subcategoria morfossintáctica [morf_type] ?

Filtrar

ART_DEF ART_IND POSS SUB IND EXIS NUM_CARD NUM_MULT NUM_ORD NUM_FRAC COOR PESS
 DEM INTR REL UNI NONE

Categoria com frequência mais alta [morf_max_cat] ?

Filtrar

Percentagem de ocorrência da categoria mais alta [morf_max_d] ?

Filtrar

Frequência da categoria mais alta [morf_max_freq] ?

Filtrar

Restantes categorias da palavra [morf_others_cat] ?

Percentagem de ocorrência das restantes categorias da palavra [morf_others_d] ?

Frequência das restantes categorias [morf_others_freq] ?

Género [morf_gen] ?

Filtrar

Número [morf_num] ?

Filtrar

Estrangeirismo [morf_est] ?

Filtrar

[Voltar à aplicação](#)

A mostrar 15 de 25 registos. Resultados **insensíveis** à categoria.

lema ^	freq_corp_mil	morf_gen	morf_num
a	88046.6292		
aquela	315.9064	Feminino	
aquele	472.7943		
aquilo	172.7038		
as	0.2440	Feminino	Plural
demais	31.8713		
dessas	0.0188	Feminino	Plural
desta	0.0329	Feminino	Singular
destas	0.0422	Feminino	Plural
essa	589.0581		
esse	678.2377		
esta	1890.0555	Feminino	Singular
este	2357.9079		
isso	895.0291		
isto	340.2968		

⊖ Estrutura

Número de letras [ort_nlet] [?](#)

Média actual: 9.3002

Mínimo: Máximo:

▼ Filtrar

Estrutura Consoante/Vogal [ort_cv] [?](#)

▼ Filtrar

Letras repetidas [ort_let_rep] [?](#)

▼ Filtrar

Representação gráfica invertida [ort_inv] [?](#)

▼ Filtrar

⊖ Sílabas

Número de sílabas ortográficas do estímulo [ort_syl_num] [?](#)

▼ Filtrar

Estrutura silábica ortográfica [ort_syl_cv] [?](#)

▼ Filtrar

Divisão silábica ortográfica [ort_syl_div] [?](#)

▼ Filtrar

Número de palavras que partilham a estrutura silábica ortográfica do estímulo [ort_syl_cv_tp] [?](#)

▼ Filtrar

Soma da frequência da estrutura silábica ortográfica [ort_syl_cv_tk] [?](#)

▼ Filtrar

Frequência média da estrutura silábica ortográfica [ort_syl_cv_tk_med] [?](#)

▼ Filtrar

Número de palavras que partilham sílabas ortográficas com o estímulo [ort_syl_p_tp] [?](#)

▼ Filtrar

Média das palavras que partilham sílabas ortográficas com o estímulo [ort_syl_p_tp_med] [?](#)

▼ Filtrar

Soma das frequências das sílabas ortográficas [ort_syl_p_tk] [?](#)

▼ Filtrar

Média da frequência das sílabas ortográficas [ort_syl_p_tk_med] [?](#)

▼ Filtrar

[Voltar à aplicação](#)

A mostrar 15 de 8543 registos. Resultados insensíveis à categoria.

lema ^	freq_corp_mil	ort_nlet	ort_syl_num	ort_syl_cv	ort_syl_div	ort_syl_p_tk_med
ábaco	0.1502	5	3	V-CV-CV	'álba co	12.7305
abada	0.0375	5	3	V-CV-CV	a ba da	19.0833
abade	3.3462	5	3	V-CV-CV	a ba de	20.0955
abadia	0.9996	6	4	V-CV-CV-V	a ba 'di a	5.3473
abafar	7.2791	6	3	V-CV-CVC	a ba 'far	19.7478
abafo	0.1596	5	3	V-CV-CV	a ba fo	19.9328
abaixo	61.8278	6	3	V-CVV-CV	a 'bai x o	20.0443
abajur	0.0657	6	3	V-CV-CVC	a ba 'jur	20.2122
abalar	19.0824	6	3	V-CV-CVC	a ba 'lar	17.8825
abalo	4.9607	5	3	V-CV-CV	a ba lo	18.7072
abano	0.9433	6	3	V-CV-CVV	a ba 'no	20.1245
abandar	6.5564	6	3	V-CV-CVC	a ba 'nar	17.9997
abano	0.4130	5	3	V-CV-CV	a ba no	19.2481
abanto	0.0047	6	3	V-CVC-CV	a 'ban to	18.6200
abarca	0.1079	6	3	V-CVC-CV	a 'bar ca	18.5969

Obrigada!



<http://p-pal.di.uminho.pt/>