


NORMALIZAÇÃO DE TEXTOS



PALAVRAS

Quantas palavras temos na seguinte frase?

Extremamente adaptável, pode ocorrer em ambientes altamente alterados pelo ser humano.



PALAVRAS

Quantas palavras temos na seguinte frase?

Extremamente adaptável, pode ocorrer em ambientes altamente alterados pelo ser humano.

11 palavras.

13 palavras se considerarmos também os sinais de pontuação.




PALAVRAS

Na frase:

Muito longo para os que lamentam,
muito curto para os que festejam

Quantas palavras existem?

Quantas palavras diferentes existem?




PALAVRAS

Na frase:

Muito longo para os que lamentam,
muito curto para os que festejam

Quantas palavras existem? **12**

Quantas palavras diferentes existem? **8**



PALAVRAS

Na frase:

Muito longo para os que lamentam,

muito curto para os que festejam

Quantas palavras existem? **12 (tokens)**

Quantas palavras diferentes existem? **8 (tipo/vocabulário)**



PALAVRAS

Na frase:

Muito longo para os que lamentam,

muito curto para os que festejam

Quantas palavras existem? **12 (tokens)**

Quantas palavras diferentes existem? **8 (tipo/vocabulário)**

Corpus	Tokens = N	Types = $ V $
Shakespeare	884 thousand	31 thousand
Brown corpus	1 million	38 thousand
Switchboard telephone conversations	2.4 million	20 thousand
COCA	440 million	2 million
Google N-grams	1 trillion	13 million

Coletânea
sobre um
determinado
assunto.
Plural: *corpora*



PALAVRAS

No contexto de PLN, um **corpus** é um conjunto de documentos (ou de frases) geralmente **anotados** e utilizados para:

Aprendizado (análise)

Validação (verificação)



PALAVRAS



o corpus do português

Corpora

Corpus size

Compare to other corpora

Related resources

Problems

Contact us



BYU

English Português


Created by [Mark Davies](#), BYU. Funded by the US National Endowment for the Humanities (2004, 2015).

	Corpus	Size	Created	More info
1	Genre / Historical	45 million words	2006	Info
2	Web / Dialects	1 <i>billion</i> words	2016	Info
3	NOW (2012 - 2019)	1.1 <i>billion</i> words	2018	Info
4	WordAndPhrase	Top 40,000 words	2017	Info

The Corpus do Português now has two different parts:

- the (original, smaller) corpus that allows you to look at historical changes and genre-based variation
- the (new, much larger) corpus that you can use to look at dialectal variation (and have 50x as much data for Modern Portuguese).

Click on an [Info] link above for more details.



PALAVRAS

WordAndPhrase - Portuguese

≡ ⌂ ⓘ ⬇

BROWSE LIST LIST OF WORDS SEE ENTRY ANALYZE TEXT

SINGLE ENTRY: DISPLAYED IN TAB TO THE RIGHT

	RANK #	PoS	WORD	DEFINITION	MORE DEFIN	IMAGE	TOTAL	ACAD	NEWS	FIC	SPOK
1	2455	N	CERVEJA	beer, (tap)	Ling WR Rev Coll Oxf	🖼	30295	13	71	75	8



PALAVRAS

WordAndPhrase - Portuguese



WordAndPhrase

[BROWSE LIST](#)
[LIST OF WORDS](#)
[SEE ENTRY](#)
[ANALYZE TEXT](#)

BRC

SPOK	FIC	NEWS	ACAD

SINGLE ENTRY: DIS

	RANK #
1	2455

COLLOCATES

 new word with CERVEJA

(NOUN) vinho, copo, garrafa, lata, bebida, marca, cerveja, bar, refrigerante, consumo

(ADJ) gelado, artesanal, preto, especial, alcoólico, quente, escuro, barato, fresco, refrigerante

(MISC) beber, tomar, só, já, produzir, vender, consumir, até, lá, gelar

TOPICS (click to see)

beber bebida álcool bar alcoólico sabor vinho garrafa copo restaurante cervejaria consumo prato cervejeiro malte carne ingrediente consumir aroma marca comida bêbado litro chocolate molho queijo lata comer receita teor

	BRAZIL	PORTUGAL	ANGOLA	MOZAMBIQUE
CLICK BAR TO LIMIT (SEE ALL)				

[CONCORDANCE LINES](#) [PROBLEMS?](#)

 CLICK WORD TO: display new word see with CERVEJA

	GENRE		SORT	SORT	SORT	
2	PT G	hhip.org	anteriormente construídas em a região : não havendo corredores laterais a a nave , os volumes de as torres se destacam de			
3	BR G	www2.uefs.br	10 metros . 18 ? Bermas de Equilíbrio : são aterros laterais a os taludes para equilibrar o peso exercido por o maciço de			
4	BR B	futebolecialtda.com.br	antiga "» como auxiliando a defesa em a perseguição a os laterais adversários Talvez esse esquema funcione melhor com o retorno			

PALAVRAS

- Prática 1
- Prática 2



PALAVRAS

Em muitos contextos:


Uma *stopword* pode ser considerada uma **palavra irrelevante** para análise (artigos, preposições).

a ao aos aquela aquelas aquele aqueles aqui aquilo as até aí com como da das de dela delas dele deles depois do dos dá e ela elas ele eles em entre era eram essa essas esse esses esta estamos estas estava estavam este esteja estejam estejamos estes esteve estive estivemos estiver estiveram estiverem estivermos estivesse estivessem estivéramos estivéssemos estou está estávamos estão eu foi fomos for fora foram forem formos fosse fossem fui fôramos fôssemos haja hajam hajamos havemos hei houve houvemos houver houveram houverei houverem houveremos houveria houvermos houverá houverão houveríamos houvesse houvessem houvéramos houvésssemos há hão isso isto já lhe lhes lá mais mas me mesmo meu meus minha minhas muito na nas nem no nos nossa nossas nosso nossos num numa não nós o os ou para pela pelas pelo pelos por pra qual quando que quem se seja sejam sejamos sem serei seremos seria seriam será serão seríamos seu seus somos sou sua suas são só também te tem temos tenha tenham tenhamos tenho terei teremos teria teriam terá terão teríamos teu teus teve tinha tinham tive tivemos tiver tivera tiveram tiverem tivermos tivesse tivessem tivéramos tivéssemos tu tua tuas tá tém tínhamos um uma vai você vocês vos vou à às é éramos



PALAVRAS

- Prática 3




PALAVRAS

As **stopwords/stoplists** podem ser eliminadas **antes** ou **depois** do processamento/leitura do texto.

Devemos avaliar seu uso para cada aplicação.

Quais das seguintes frases seriam mais informativas?

Rio de Janeiro	Rio Janeiro
Internet das coisas	Internet coisas
Viagem para casa	Viagem casa
Vitamina a	Vitamina



PALAVRAS

...
475 outro
437 outra
420 outros
258 outras

...
471 homem
310 homens

...
145 próprio
128 própria
65 próprios
41 próprias

...
43 alegria
25 alegres
24 alegre



Thiago M. R. Dias

thiagomagela@cefetmg.br

