

CINTIL
Corpus Internacional do Português

Convenções de Etiquetação

Versão 6.0

24/06/2005

Florbela Barreto, António Horta Branco, Amália Mendes,
Fernanda Bacelar Nascimento e João Silva.

Universidade de Lisboa



1 Formato de ficheiros

Character set ISO-8859-1

Quebras de linha DOS

Formato .txt

2 Segmentação

De frases e parágrafos

Frases separadas por quebra de linha (= cada frase numa linha).
Parágrafos separados por duas quebras de linha (= uma linha entre parágrafos).

De lexemas

Tokens separados por espaço em branco:
um exemplo > um exemplo

Contracções são expandidas, ficando uma marca ('_') no primeiro token da expansão:

'da' -> 'de_ a'
consigo -> com_ si
pela -> por_ a

Marcação do espaçamento em torno da pontuação e de símbolos:
(marca de espaço à esquerda: '*'; marca de espaço à direita: '*/')

5.3 > 5 . 3
1. 2 > 1 .*/ 2
8 . 6 > 8 *.*/ 6

Clíticos separados do verbo (mantêm o hífen). Marcação de alternância vocálica com '#', com '-CL-' no posição de mesóclise:

deu-se-lho -> deu -se -lho
vê-las -> vê# -las
afirmá-lo-ia -> afirmá#-CL-ia -lo

Separação da preposição 'de' do verbo 'haver' (mantêm o hífen)
há-de -> há -de

Separação de finais especiais que marcam terminações alternativas
Caro(a) amigo(a) > Caro (a) amigo (a)

3 Anotação prosódica

O subcorpus oral inclui 2 símbolos para a anotação prosódica, seguindo o modelo de anotação dos projectos CHAT/CHILDES.

O símbolo “/”, precedido e seguido de espaço, assinala uma quebra prosódica não final.

O símbolo “//”, precedido e seguido de espaço, assinala uma quebra prosódica final.

O símbolo “?” assinala uma quebra prosódica final em contextos interrogativos.

4 Etiquetação morfo-sintáctica

Símbolo '/' à direita do lema, ou imediatamente à direita do token quando não há lema. Etiqueta à direita de '/':

com/PREP
viu/VER/V

Em locuções (lexemas multi-palavra), etiqueta prefixada de 'L'. Em cada token da locução, a etiqueta repete-se seguida de numeração:

de_LCJ1 maneira_LCJ2 a_LCJ3 que_LCJ4

Outros tokens recebem uma única etiqueta categorial.

Conjunto de etiquetas

Etiquetas são acrónimos das designações em inglês das categorias.

Etiqueta	Categoria	Exemplos
ADJ	Adjectives	bom, brilhante, eficaz, ...
ADV	Adverbs	hoje, já, sim, felizmente, ...
CARD	Cardinals	zero, dez, cem, mil, ...
CJ	Conjunctions	e, ou, tal como, ...
CL	Clitics	o, lhe, se, ...

CN	Common Nouns	computador, cidade, ideia, ...
DA	Definite Articles	o, os, ...
DEM	Demonstratives	este, esses, aquele, ...
DFR	Denominators of Fractions	meio, terço 簞 décimo, %, ...
DGTR	Roman Numerals	VI, LX, MMIII, MCMXCIX, ...
DGT	Digits	0, 1, 42, 12345, 67890, ...
DM	Discourse Marker	olá...
EADR	Electronic Addresses	http://www.di.fc.ul.pt , ...
EOE	End of Enumeration	etc
EXC	Exclamatives	que, quanto, ...
GER	Gerunds	sendo, afirmando, vivendo, ...
GERAUX	Gerunds as auxiliary verbs	tendo, havendo
IA	Indefinite Articles	uns, umas, ...
IND	Indefinites	tudo, alguém 𩶛 ninguém 𩶛 ...
INF	Infinitive	ser, afirmar, viver, ...
INFAUX	Infinitive auxiliary verb	ter, havermos, ...
INT	Interrogatives	quem, como, quando, ...
ITJ	Interjection	bolas, caramba, ...
LTR	Letters	a, b, c, ...
MGT	Magnitude Classes	unidade, dezena, dúzia, resma, ...
MTH	Months	Janeiro, Dezembro, ...
NP	Noun Phrases	idem, ...
ORD	Ordinals	primeiro, centésimo, penúltimo, ...
PADR	Part of Address	Rua, av., rot., ...
PNM	Part of Name	Lisboa, António, João 躉 ...
PNT	Punctuation Marks	., ?, (, ...
POSS	Possessives	meu, teu, seu, ...
PPA	Past Participles not in compound tenses	sido, afirmados, vivida, ...
PP	Prepositional Phrases	algures, ...
PPT	Past Participle in compound tenses	sido, afirmado, vivido, ...
PREP	Prepositions	de, para, em redor de, ...
PRS	Personals	eu, tu, ele, ...
QNT	Quantifiers	todos, muitos, nenhum, ...
REL	Relatives	que, cujo, tal que, ...
STT	Social Titles	Presidente, dr., prof., ...

SYB	Symbols	@, #, &, ...
TERMN	Optional Terminations	(s), (as), ...
UM	"um" or "uma"	um, uma
UNIT	Measurement units in abbreviated form	Kg, h, seg, Hz, Mbytes,...
VAUX	Finite "ter" or "haver" in compound tenses	temos, haveriam, ...
V	Verbs (other than PPA, PPT, INF or GER)	falou, falaria, ...
WD	Week Days	segunda, terça-feira, sábado, ...
Multi-Word Expressions		
LADV1...LADVn	Multi-Word Adverbs	de facto, em suma, um pouco, ...
LCJ1...LCJn	Multi-Word Conjunctions	assim como, já que, ...
LDEM1...LDEMn	Multi-Word Demonstratives	o mesmo, ...
LDFR1...LDFRn	Multi-Word Denominators of Fractions	por cento
LDM1...LDMn	Multi-Word Discourse Markers	pois não 燾 até logo, ...
LITJ1...LITJn	Multi-Word Interjections	meu Deus
LPRS1...LPRSn	Multi-Word Personals	a gente, si mesmo, V. Exa., ...
LPREP1...LPREPn	Multi-Word Prepositions	através de, a partir de, ...
LQD1...LQDn	Multi-Word Quantifiers	uns quantos, ...
LREL1...LRELn	Multi-Word Relatives	tal como, ...
Specific of transcriptions		
EL	Extra-linguistic	
EMP	Emphasis	
FRG	Fragment	
PL	Para-linguistic	

Particípios

/PPT em tempos compostos, com auxiliares 'ter' e 'haver'.

/PPA nas restantes ocorrências.

Distinções mais finas são também feitas ao nível da lematização (vd. abaixo).

Ocorrências de 'um' e 'uma'

Etiquetados com /UM.

Que

Ocorrências de *que*: Etiquetadas com /REL nas relativas, /INT nas interrogativas, /EXC nas exclamativas, e /CJ nos restantes casos, i.e. adverbiais, clivadas, encaixadas, comparativas e consecutivas

Exclamativos

/EXC para pronomes que encabeçam exclamativas:

Que fadiga!

Quantas etiquetas ainda para atribuir!

Verbos auxiliares

/VAUX Verbos auxiliares em tempos compostos (ocorrências de 'ter' ou 'haver' a preceder particípio passado).

Nomes próprios

/PNM em antropónimos, topónimos, títulos de obras (obras literárias, canções, pinturas, etc.), instituições, endereços, acrónimos, siglas.

Para nomes próprios multi-palavra, /PNM apenas em palavras de classes abertas:

Prof./STT Borges/PNM de/PREP Castro/PNM
Ministério/PNM de_/PREP a/DA Educação/PNM
Avenida/PADR de_/PREP a/DA Liberdade/PNM

5 Traçamento

Traços nominais

Símbolo '#' à direita de categoria, com traços à direita de '#':
gatos/GATO/CN#mp

Género e número morfológicos (semânticos são ignorados).

Estrangeirismos nominais são traçados.

Masculino: m; feminino: f.

Singular: s; plural: p.

Primeira pessoa: 1; segunda: 2; e terceira: 3:
ela/PRS#fs3

Diminutivos em *-inho*, *-zinho*, *-ito* e *-zito* etiquetados com *-dim*.
mesinha/MESA/CN#fs-dim

Superlativos (regulares em *-íssimo* ou irregulares) etiquetados com *-sup*.
normalíssimo/NORMAL/ADJ#ms-sup
o/ART#ms maior/GRANDE/ADJ#ms-sup

Comparativos (irregulares) etiquetados com *-comp*.
é/SER/V#pi-3s maior/GRANDE/ADJ#ms-comp

Classes abertas com traços nominais de género e número:
/CN : Common noun
/ADJ : Adjective
/PPA : Other Past Participles

Classes abertas com traços nominais de número e pessoa:
/VAUX : Auxiliar Verbs
/V : Verbs (other than PPA, PPT, INF or GER)
/INF : Infinitive

Classes fechadas com traços nominais de género, número e pessoa:
/PRS : Personals
/CL : Clitics

Classes fechadas com traços nominais de género e número:

/DA : Definite Article
/UM : ocorrências de "um" ou "uma"
/IA : Indefinite Articles (excepto "um" e "uma", vd. /UM)
/QNT : Quantifiers
/IND : Indefinites
/DEM : Demonstrative
/POSS : Possessive
/INT : Interrogative (excepto *que*, *quem*, *quê* e *quão*)
/REL : Relatives (excepto *que*, *quem*, e *quê*)
/EXC : Exclamatives (excepto *que* e *quê*)
/CARD : Cardinals (excepto "um" e "uma", vd. /UM)
/MGT : Magnitude classes
/ORD : Ordinals
/DFR : Denominators of fractions (excepto símbolo %)
/WD : Week Days
/MTH : Months
/UNIT : Measurement units (em forma abreviada)
/STT : Social Title
/LTR : Letter

Traços verbais

Símbolo '#' à direita de categoria.

Traços de tempo e modo à direita de '#', seguidos de '-'.

Traços de pessoa e número a seguir a '-'.

andarias/ANDAR/V#c-2s

Classes abertas com traços verbais:

/VAUX : Auxiliar Verbs
/V : Verb (other than PPA, PPT, INF or GER)

Tempo/Modo	Etiqueta
Presente do Indicativo	pi
Pretérito Perfeito do Indicativo	ppi
Pretérito Imperfeito do Indicativo	ii
Pretérito Mais que Perfeito do Indicativo	mpi
Futuro do Indicativo	fi
Condicional	c
Presente do Conjuntivo	pc

Pretérito Imperfeito do Conjuntivo	ic
Futuro do Conjuntivo	fc
Imperativo	imp

Infinitivos

- | | |
|-----------|----------------------|
| /INF#ninf | não flexionado |
| /INF#... | flexionado |
| /INF#ndef | casos indeterminados |

6 Lematização

Símbolo '/' à direita do token.

Lema entre '/' e '/'.

Lema em maiúsculas:

gatos/GATO

Apenas um lema para cada token, excepto para tokens /PPA.

Token PPA: forma no infinitivo, forma no masculino singular:

cavada/CAVAR, CAVADO/PPA

Classes cujos elementos recebem lema:

/CN, /ADJ, /V, /VAUX, /GER, /INF, /PPT e /PPA

Lemas nominais

Classes abertas com lemas nominais:

/CN, /ADJ e /PPA:

Caso geral

Lema é a forma masculina singular, se existir.

Se não, a forma masculina (plural), se existir

Se não, a forma feminina singular, se existir

Se não, a própria forma.

Palavras prefixadas

Mantém o prefixo no lema.

Palavras sufixadas

Redução para radical apenas nos diminutivos *-inho*, *-zinho*, *-ito*, e *-zito*; e nos superlativos, tanto regulares (em *-íssimo*) como irregulares, e nos comparativos (irregulares).

Femininos “irregulares”

Mantém-se a forma irregular como lema (e.g. actriz, etc)

Múltiplas grafias

O lema no vocabulário do Rebelo, se a ocorrência admitir múltiplas grafias.

Se não existir no Rebelo, segue-se a regra definida pelo Rebelo.

Se não, opta-se pelo lema da grafia mais frequente.

Abreviaturas

Lema de uma abreviatura (das classes /CN, /ADJ e /PPA) não é abreviado.

Estrangeirismos

Lema de um estrangeirismo é a ocorrência.

Lemas verbais

Classes abertas com lemas verbais:

/V, /VAUX, /GER, /INF, /PPT e /PPA.

Caso geral

Lema é forma do infinitivo não flexionado.

Palavras prefixadas

Mantém o prefixo no lema.

Múltiplas grafias

Lema no vocabulário do Rebelo, se a ocorrência admitir múltiplas grafias.

Se não existir no Rebelo, segue-se a regra definida pelo Rebelo.

Se não, opta-se pelo lema da grafia mais frequente.

Pronomes

Lema na pessoa, número e género da ocorrência (não há lematização para primeira pessoa).

Casos restantes

Não se atribui lemas aos casos restantes.

(por razões de implementação, no concordanciador online, relativamente às restantes classes, o campo do lema é preenchido com a própria forma)

7 Nomes próprios multi-palavra

Etiquetas

Atribui-se etiqueta:

- B para início da expressão
- I para restantes tokens da expressão
- O para tokens que não pertencem a expressões

Etiquetas B e I:são continuadas por

- PER caso se trate de designação de pessoa
- ORG de organização
- LOC de local
- WRK de obra (livros, filmes, quadros, etc)
- MSC restantes casos

Formato

'[' após traços de flexão se existirem

etiqueta após '['

encontrei/ENCONTRAR/V#ppi-1s [O] o/DA#ms [O]
Pres./PRESIDENTE/STT#ms [O] Jorge/PNM[B-PER]
Sampaio/PNM[I-PER]

Critérios

Os do manual das MUC:

<http://www.itl.nist.gov/iaui/894.02/related/projects/muc/proceedings/ne/task.html>