

Olga Craveiro<sup>1,2</sup>, Joaquim Macedo<sup>3</sup>, Henrique Madeira<sup>2</sup>

(<sup>1</sup>) ESTG, Instituto Politécnico de Leiria

(<sup>2</sup>) CISUC, DEI, Universidade de Coimbra

(<sup>3</sup>) DI, Universidade do Minho

# PorTexTO

## Sistema para anotação/extracção de expressões temporais

Encontro do Segundo HAREM  
Aveiro, 7 de Setembro de 2008

# Resumo

- Motivação
- Características
- Arquitectura
- Funcionamento
- Exemplo
- Conclusões e Trabalho Futuro

# Motivação

- Identificação das expressões temporais (entidades mencionadas temporais) mais utilizadas em textos de língua portuguesa
- Algoritmo simples e rápido que possa ser utilizado em ambientes de tempo real

# PorTexTO

- Designação “*PORTuguese Temporal Expressions TOol*”
- Utiliza padrões de expressões temporais
  - Padrões criados através de identificação das co-ocorrências
  - A definição dos padrões é feita com REGEX
- Processamento do texto é realizado frase a frase, em que a divisão das frases é realizada com o atomizador da Linguateca (módulo Perl Lingua::PT::PLNbase)

# Arquitectura

## REGEX

```
[Dd]e (oc_DATA\d{1,5})( do ano passado)?  
[Dd]esde há (anos|décadas|dias|meses|semanas|séculos)  
[Nn]o (mês|ano) (passado|anterior|seguinte)  
[Ee]m (oc_MES\d{15})(?: (deste ano)|passado|último|(do ano passado))?  
(...)
```

## Palavras chave

### Temporais

amanhã  
ano  
anos  
anteontem  
anualmente  
cedo  
década  
Dezembro  
(...)

## PorTexTO Anotador

## Corpus

(...) Foi uma violência anunciada: o líder do Sinn Fein -- o braço político do IRA -- falara poucos dias antes num «`show' espectacular» como resposta à iniciativa anglo-irlandesa lançada pelos primeiros-ministros da Grã-Bretanha e da República da Irlanda com a sua «declaração» de 15 de Dezembro do ano passado. Mas a campanha terrorista foi só parte da resposta. (...)

## Corpus anotado

(...) Foi uma violência anunciada: o líder do Sinn Fein -- o braço político do IRA -- falara poucos dias antes num «`show' espectacular» como resposta à iniciativa anglo-irlandesa lançada pelos primeiros-ministros da Grã-Bretanha e da República da Irlanda com a sua «declaração» <EM ID="2" CATEG="TEMPO" TIPO="TEMPOCALEND" SUBTIPO="DATA">de 15 de Dezembro do ano passado</EM>. Mas a campanha terrorista foi só parte da resposta. (...)

# Funcionamento (1)

- REGEXs criadas com base nas co-ocorrências existentes em **palavras de referência**
- Palavras de referência utilizadas:
  - Meses do ano, dias da semana, estações do ano
  - Festividades: **Natal, Páscoa, Carnaval, Entrudo**
  - Medidas temporais: **década, período, século, ano, ...**

Palavras Temporais  
de referência

Janeiro  
Primavera  
Natal  
década  
(...)


PorTexTO  
*Processador de  
co-ocorrências*

REGEX

[Dd]e (oc\_DATA\d{1,5})( do ano passado)?  
[Dd]esde há (anos|décadas|dias|meses|semanas|séculos)  
[Nn]o (mês|ano) (passado|anterior|seguinte)  
[Ee]m (oc\_MES\d{15})(?: (deste ano)|passado|último|(do ano  
passado))?  
(...)

# Funcionamento (2)

- Processamento realizado frase a frase



# Exemplo (1)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)

Frase = “A missão científica  
da nave foi concluída  
em 30 de abril de 2002.”

Ler nova frase →

Pode conter  
EM temporais ?

S

Tem dígitos?

S

Marcar  
datas, horas, anos

N

N

Marcar  
dias da semana, meses

Anotar EM temporais


Substituir marcas

# Exemplo (2)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)

Frase = “A missão científica  
da nave foi concluída  
em 30 de **abril** de 2002.”




# Exemplo (3)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)


Frase = “A missão científica da nave foi concluída em **30** de abril de 2002.”



# Exemplo (4)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)




Frase = “A missão científica da nave foi concluída em **oc\_DATA12**.”

# Exemplo (5)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)




Frase = “A missão científica da nave foi concluída em oc\_DATA12.”

# Exemplo (6)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)




**Frase** = “A missão Científica da nave foi concluída <EM ID="41" CATEG="TEMPO" TIPO="TEMPO\_CALEND" SUBTIPO="DATA"> em oc\_DATA12 </EM>.”

# Exemplo (7)

## Corpus anotado

(...) A missão científica da nave foi concluída <EM ID="41" CATEG="TEMPO" TIPO="TEMPOCALEND" SUBTIPO="DATA">em 30 de abril de 2002</EM>. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)



# Exemplo (8)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)

Frase = “Depois disso,  
o satélite deixou de ter  
sua órbita corrigida.”

Ler nova frase →

Pode conter  
EM temporais ?

S

Tem dígitos?

S

Marcar  
datas, horas, anos

N

Marcar  
dias da semana, meses

Anotar EM temporais

Substituir marcas

# Exemplo (9)

## Corpus

(...) A missão científica da nave foi concluída em 30 de abril de 2002. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)

Frase = “Depois disso,  
o satélite deixou de ter  
sua órbita corrigida.”

Ler nova frase

Pode conter  
EM temporais?

N

S

Tem dígitos?

N

S

Marcar  
datas, horas, anos

Marcar  
dias da semana, meses

Anotar EM temporais

Substituir marcas

## Corpus anotado

(...) A missão científica da nave foi concluída <EM ID="41" CATEG="TEMPO" TIPO="TEMPO\_CALEND" SUBTIPO="DATA">em 30 de abril de 2002</EM>. Depois disso, o satélite deixou de ter sua órbita corrigida. (...)

# Conclusões e Trabalho Futuro

- A simplicidade e a rapidez do sistema foram conseguidas na participação do HAREM
- Os resultados excederam as expectativas, tratando-se de um sistema ainda prematuro
  - Participação somente na categoria TEMPO
  - Precisão  $\approx 70\%$
  - Abrangência  $\approx 55\%$
  - Tempo de execução  $\approx 00:03:20$

# Conclusões e Trabalho Futuro

- Ainda há muito para fazer!
  - Alargar o processamento a expressões temporais complexas (com mais de uma referência temporal), de modo a melhorar a abrangência do sistema
  - Ultrapassar o limite de  $n=2$ , na determinação das co-ocorrências
  - Tornar mais automatizada a criação dos padrões das expressões temporais
  - Testar o sistema em outras línguas

Obrigada.

olga.craveiro@gmail.com