

Processamento de Linguagens

LCC (2º ano)

Trabalho Prático nº 1 — 3ª semana
(Lex)

Ano lectivo 08/09

1 Objectivos e Organização

Este trabalho prático tem como principais **objectivos**:

- aumentar a experiência de uso do ambiente linux, da linguagem imperativa C (para codificação das estruturas de dados e respectivos algoritmos de manipulação), e de algumas ferramentas de apoio à programação;
- aumentar a capacidade de escrever *Expressões Regulares (ER)* para descrição de *padrões de frases*;
- desenvolver, a partir de ERs, sistemática e automaticamente *Processadores de Linguagens Regulares*, que filtrem ou transformem textos;
- utilizar *geradores de filtros/processadores de texto*, como o Flex

Para o efeito, esta folha contém 2 enunciados, dos quais deverá resolver pelo menos um. O programa desenvolvido será apresentado aos membros da equipa docente, totalmente pronto e a funcionar (acompanhado do respectivo relatório de desenvolvimento) e será defendido por todos os elementos do grupo (3 alunos), em data a marcar.

O **relatório** a elaborar, deve ser claro e, além do respectivo enunciado, da descrição do problema, das decisões que lideraram o desenho e a implementação, deverá conter exemplos de utilização (textos fontes diversos e respectivo resultado produzido). Como é de tradição, o relatório será escrito em L^AT_EX ou NuWeb (Literate Programming).

2 Enunciados

Para sistematizar o trabalho que se lhe pede em cada uma das propostas seguintes, considere que deve, em qualquer um dos casos, realizar a seguinte lista de tarefas:

1. Especificar os padrões de frases que quer encontrar no texto-fonte, através de ERs.

2. Identificar as acções semânticas a realizar como reacção ao reconhecimento de cada um desses padrões.
3. Identificar as Estruturas de Dados globais que possa eventualmente precisar para armazenar temporariamente a informação que vai extraindo do texto-fonte ou que vai construindo à medida que o processamento avança.
4. Desenvolver um Processador de Texto para fazer o reconhecimento dos padrões identificados e proceder à transformação pretendida, com recurso ao Gerador Flex.

2.1 WikictionaryPT — Um dicionário de sinónimos e antónimos em português

O Wikcionário é um projecto colaborativo para produzir um dicionário poliglota em português, com significados, etimologias e pronúncia. Wikcionário é um complemento léxico para todo o conteúdo aberto da enciclopédia Wikipédia. Uma das vantagens deste Wikcionário é o formato em que se encontra disponível — XML (eXtensible Markup Language), facilitando o seu processamento e transformação.

Neste trabalho pretende-se que analise este formato particular do Wikcionário de forma a familiarizar-se com o seu conteúdo e poder executar as tarefas abaixo descritas.

Listing 1: Fragmento do WikictionaryPT

```

1 <page>
2   <title>atordoar</title>
3   <id>42546</id>
4   <revision>
5     <id>293478</id>
6     <timestamp>2007-08-25T21:42:18Z</timestamp>
7     <contributor>
8       <username>Marcot</username>
9       <id>3079</id>
10    </contributor>
11    <comment>Pron</comment>
12    <text xml:space="preserve">{{-pt-}}
13  ==Pronúncia==
14  {{{Áudio|Pt-br-atordoar.ogg|Português (BR)}}}
15  ==Verbo==
16  '''a.tor.do.ar''' '''transitivo direto'''
17  #(''e pronominal'') [[confundir]] os sentidos ou o raciocínio,
18  geralmente por efeito de [[som]], possivelmente forte ou
19  surpreendente, ou apenas por alguma [[pancada]],
20  [[surpresa]] ou forte [[emoção]], ou ainda por [[embriaguez]]
21  # [[perturbar]] os ouvidos
22  # causar grande [[surpresa]]
23
24  ==Sinonímia==
25  #[[abalar]], [[aturdir]], [[confundir]], [[perturbar]]
26  #[[atroar]], [[azucrinar]], [[ensurdecer]]
27  #[[abalar]], [[surpreender]]

```

```

28 |=====Etimologia=====
29 |
30 |*''controversa''
31 |**do Espanhol ''[[atolondrar]]'', relacionado ao Latim
32 |''[[tonitrus]]'' ([[trovão]]) pela suposta forma ''atordonare''
33 |**do Espanhol ''[[aturdir]]''
34 |
35 |=====Conjugação=====
36 |*''regular''
37 |{{conj.pt.oar|atord}}
38 |
39 |[[Categoria:Verbo_(Português)]]
40 |
41 |[[fr:atordoar]]
42 |[[hy:atordoar]]</text>
43 |</revision>
44 |</page>

```

As tarefas que deverá executar neste trabalho prático serão faseadas por semanas da seguinte forma:

- 1ª semana** Analise o documento XML correspondente ao Wictionary português¹ e faça a contagem das categorias (verbos, advérbios, substantivos, adjetivos, pronomes — pessoais, possessivos, demonstrativos, etc) que ocorrem no documento. No final, deverá produzir um documento em formato HTML com as categorias e respectivas contagens.
- 2ª semana** Complete o seu processador da 1ª semana de modo a filtrar o significado, bem todos os sinónimos e antónimos (caso existam), dos verbos que aparecem no documento. Deverá ainda produzir um documento HTML com tal informação.
- 3ª semana** Finalize o seu processador acrescentando a funcionalidade de pesquisa. Sempre que o utilizador introduza um verbo a pesquisar deverá mostrar o significado e respectivos sinónimos/antónimos. Como facilidade extra, poderá mostrar os significados/antónimos na forma de um grafo, recorrendo para tal à linguagem Dot do GraphViz²

2.2 BibTeXPro — Um processador de BibTeX

BibTeX é uma ferramenta de formatação de referências (ou citações) bibliográficas feitas em documentos LaTeX. BibTeX foi criada por Oren Patashnik e Leslie Lamport em 1985 com o objectivo de facilitar a separação da base de dados bibliográfica do texto principal do documento.

Listing 2: Exemplo de entrada em BibTeX

```

1 |@InProceedings{CPBFH07e,
2 |  author = {Daniela da Cruz and Maria João Varanda Pereira

```

¹Disponível em <http://download.wikimedia.org/ptwiktionary/20080304/ptwiktionary-20080304-pages-articles.xml.bz2>.

²Disponível em <http://www.graphviz.org>. Poderá ainda usar uma das ferramentas que processam Dot disponíveis em <http://www.graphviz.org/Resources.php>.

```

3         and Mário Béron and Rúben Fonseca and
4         Pedro Rangel Henriques},
5     title =    {Comparing Generators for Language-based Tools},
6     booktitle = {Proceedings of the 1.st Conference on Compiler
7                 Related Technologies and Applications, CoRTA'07
8                 — Universidade da Beira Interior, Portugal},
9     year =    {2007},
10    editor =   {},
11    month =   {Jul},
12 }

```

De modo a familiarizar-se com o formato do BibTeX poderá consultar o ficheiro `lp.bib` disponível em <http://www.di.uminho.pt/~prh/lp.bib> e ainda a página oficial do formato referido (<http://www.bibtex.org/>).

As tarefas que deverá executar neste trabalho prático serão faseadas por semanas da seguinte forma:

- 1^a semana** Analise o documento BibTeX referido acima e faça a contagem das categorias (`phDThesis`, `misc`, `InProceeding`, etc), que ocorrem no documento. No final, deverá produzir um documento em formato HTML com as categorias e respectivas contagens.
- 2^a semana** Complete o seu processador da 1^a semana de modo a filtrar, para cada entrada, a respectiva chave, autores, título, ano e mês. Deverá ainda produzir um documento HTML com tal informação.
- 3^a semana** Finalize o seu processador acrescentando a funcionalidade de pesquisa. Sempre que o utilizador introduza um palavra (nome de autor ou ano da publicação) a pesquisar deverá mostrar a respectiva chave, autores e título da publicação. Como facilidade extra, poderá mostrar os autores que normalmente com o autor em causa na forma de um grafo, recorrendo para tal à linguagem Dot do GraphViz³

³Disponível em <http://www.graphviz.org>. Poderá ainda usar uma das ferramentas que processam Dot disponíveis em <http://www.graphviz.org/Resources.php>.