SUPeRB
Sistema Uniformizado de Pesquisa de Referências Bibliográficas

Luís Miguel Cabral

28 de Maio de 2007

Orientado Por:
Professor Doutor Eugénio Oliveira (FEUP)
Doutora Diana Santos (SINTEF)

índice da apresentação

O que é o SUPeRB?

Sistema Uniformizado de Pesquisa de Referências Bibliográficas

- É um assistente automático na pesquisa de informação bibliográfica
  - Permite a pesquisa e processamento de informação bibliográfica
  - Permite uma melhor interacção por parte de vários tipos de utilizadores
    - Utilizadores que apenas pesquisam
    - Utilizadores que contribuem
    - Gestor de um recurso

Informação bibliográfica (1)

- Referência bibliográfica

  Texto em linguagem *quase* natural ou num formato específico que permite identificar um documento

[Marrafa & Ribeiro 2001]
Palmira Marrafa & António Ribeiro. "Quantitative Evaluation of Machine Translation Systems: Sentence Level". In *Proceedings of the MT Summit VIII: Fourth ISLE workshop* (Santiago de Compostela, 22 de Setembro de 2001), pp. 39-43. http://www.eamt.org/summitVIII/papers/marrafa.pdf

Informação bibliográfica (2)

- Elemento bibliográfico

  São partes que compões a referência bibliográfica e que identificam propriedades do documento tal como o autor, o título, a conferência, data, local, etc.

[Marrafa & Ribeiro 2001]
Palmira Marrafa & António Ribeiro, "Quantitative Evaluation of Machine Translation Systems: Sentence Level", In *Proceedings of the MT Summit VIII: Fourth ISLE workshop*, (Santiago de Compostela, 22 de Setembro de 2001), pp. 39-43, http://www.eamt.org/summitVIII/papers/marrafa.pdf

□ Elementos bibliográficos

5

Informação bibliográfica (3)

- Formato bibliográfico

  Texto num formato estruturado, onde cada elemento bibliográfico está devidamente identificado e delimitado.
  - EndNote
  - RIS
  - BibTeX

```
@inproceedings{1141121239,
    author ={Palmira Marrafa and António Ribeiro},
      title ={Quantitative Evaluation of Machine Translation Systems: Sentence Level},
      year ={2001},
      booktitle ={Proceedings of the MT Summit VIII: Fourth ISLE workshop},
      pages ={39-43},
      location ={Santiago de Compostela},
      url ={\url{ http://www.eamt.org/summitVIII/papers/marrafa.pdf}}
}
```

6

Fontes da informação

- Fontes estruturadas

  Acesso a repositórios que contêm informação bibliográfica devidamente processada e à qual é possível aceder aos dados devidamente identificados, através de protocolos próprios
- Fontes genéricas

  Páginas html e documentos (doc, ps, pdf, txt, ppt)

7

Índice da apresentação

- Introdução
- **Motivação**
- Contribuições
- Especificação do SUPeRB
  - Fontes
  - Arquitectura
  - Tarefas do SUPeRB
- Métodos de avaliação
- Linhas de investigação futura

8

Motivação para o desenvolvimento do SUPeRB

FEUP

- Facilitar o acesso a referências e a documentação científica
- A informação encontra-se dispersa na Web, em bases de dados bibliográficas e repositórios, páginas Web e documentos na Web.
- Motivar a participação de utilizadores
  - Permitindo a fácil introdução de informação bibliográfica

9

Catálogo de publicações da Linguateca

FEUP

A Linguateca é um centro de recursos - distribuído - para o processamento computacional da língua portuguesa

O catálogo de publicações da Linguateca, é um dos recursos que visa disponibilizar informação bibliográfica no âmbito do processamento computacional da língua portuguesa

- Cerca de 1344 publicações (cerca de 280 publicações da Linguateca), 600 das quais em português.
- Catálogo possui muitos processos manuais para confirmação e inserção de informação

10

Objectivos da tese

FEUP

Criar um sistema de pesquisa e processamento de informação bibliográfica

- Capaz de executar determinadas tarefas vitais no processamento de referências bibliográficas
- Colmatar as limitações do processamento automático com supervisão humana
- Melhorar o catálogo de publicações da Linguateca

11

Problemas tratados (1)

FEUP

- Ao procurar referências bibliográficas por toda a Web coloca-se o problema de "Como **pesquisar na Web?**"
- Ao obter dados da Web, é necessário **filtrar** a informação relevante
- **Extrair** a informação dos **vários formatos** distintos e converter essa informação para um formato legível

12

Problemas tratados (2)

- É necessário **processar** e extrair a informação relevante (bibliográfica)
- É necessário **correlacionar a informação** obtida
- É necessário **validar** os dados antes de os tornar públicos
- **Integrar** a informação recolhida num recurso publico

13

Índice da apresentação

- Introdução
- Motivação
- **Contribuições**
- Especificação do SUPeRB
  - Fontes
  - Arquitectura
  - Tarefas do SUPeRB
- Métodos de avaliação
- Linhas de investigação futura

14

Contribuições da tese

- Propôs-se uma arquitectura que permite ultrapassar as barreiras previstas, que integre métodos e tecnologias existentes
- Desenvolveu-se a arquitectura, aplicando-a ao catálogo da Linguateca
- Apresentou-se um método de avaliação para módulos específicos do sistema

15

Índice da apresentação

- Introdução
- Motivação
- Contribuições
- **Especificação do SUPeRB**
  - **Fontes**
  - Arquitectura
  - Tarefas do SUPeRB
- Métodos de avaliação
- Linhas de investigação futura

16

Fontes estruturadas

- Repositórios e bases de dados bibliográficas online
  - DBLP
  - Citeseer
  - Editoras (Springer, IEEE)
- Motores de pesquisa bibliográficos
  - Google scholar
  - Microsoft Live Academic
- Gestores bibliográficos online
  - Citeulike
  - Bibsonomy

17

Fontes genéricas

Páginas html ou documentos que se encontrem na Web.

- Páginas de conferências
- Páginas de instituições
- Páginas pessoais (investigadores)
- Páginas Web de repositórios

18

O que se obtém das fontes

- A informação que se encontra disponível pode não ser exacta
  - Pode ser inconsistente com os dados inseridos pelo utilizador
  - Pode conter informação irrelevante
  - Pode conter informação errada
  - Pode omitir determinada informação
  - Contém redundâncias

19

Vantagens/Desvantagens

Repositórios e bases de dados bibliográficas online

- Vantagens
  - **Alta fiabilidade**
  - **Processo de pesquisa e processamento automáticos**
  - Facilitar meios de conversão para formatos exportáveis
  - Interacção com outros sistemas
- Desvantagens
  - Limitados a áreas / eventos científicos específicos
  - Sistemas automáticos podem gerar erros ou produzir informação escassa
  - Não permitem introdução de dados

20

Vantagens/Desvantagens (2)

Motores de pesquisa bibliográficos (Google Scholar, Microsoft Live Academic)

- Vantagens
  - Processo de pesquisa e processamento automáticos
  - Facilitar meios de conversão para formatos exportáveis
  - **Interacção com outros sistemas e com a Web em geral**
- Desvantagens
  - Sistemas automáticos podem gerar erros ou produzir informação escassa
  - Não permitem introdução de dados
  - **Apenas interfaces para utilizadores**

21

Vantagens/Desvantagens (3)

Gestores bibliográficos (CiteULike, Bibsonomy)

- Vantagens
  - Facilitar meios de conversão para formatos exportáveis
  - **Permite a introdução de informação bibliográfica**
  - **Maior supervisão humana**
  - **Partilha de informação entre utilizadores**
  - **Permite a classificação de utilizadores**
- Desvantagens
  - Não permite a pesquisa fora do sistema
  - A introdução de informação não possui meios de verificação
  - Não oferece garantias de fiabilidade

22

Vantagens/Desvantagens (4)

Fontes genéricas (Através de motores de pesquisa genéricos)

- Vantagens
  - **Um conjunto mais extenso de informação**
  - Informação em primeira mão
- Desvantagens
  - Baixa fiabilidade
  - Apenas de leitura
  - Informação apresentada em linguagem quase natural o que leva á necessidade de métodos adicionais para extrair a informação relevante

23

Índice da apresentação

- Introdução
- Motivação
- Contribuições
- **Especificação do SUPeRB**
  - Fontes
  - **Arquitectura**
  - Tarefas do SUPeRB
- Métodos de avaliação
- Linhas de investigação futura

24

Interacção com o SUPeRB

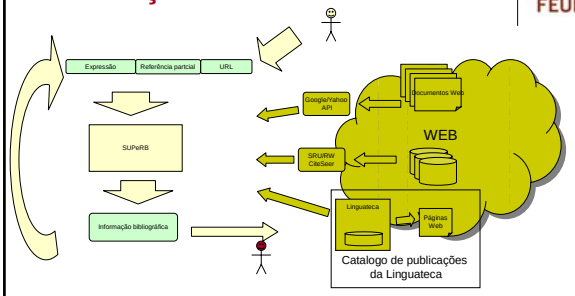

25

Arquitectura

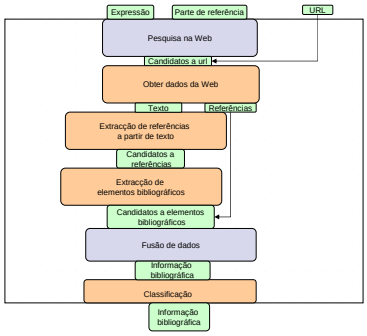

26

Arquitectura

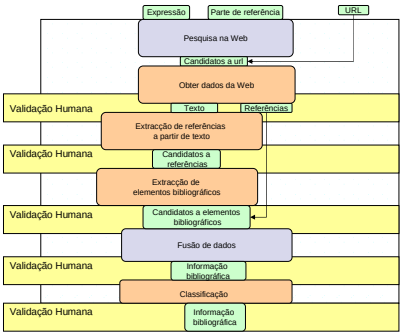

27

Índice da apresentação

- Introdução
- Motivação
- Contribuições
- **Especificação do SUPeRB**
  - Fontes
  - Arquitectura
  - **Tarefas do SUPeRB**
- Métodos de avaliação
- Linhas de investigação futura

28

Pesquisa nas fontes genéricas

FEUP

- Dada:
  - Uma expressão especifica introduzida pelo utilizador
  - Ou parte de uma referência bibliográfica
- Obter um conjunto de documentos da Web com informação relevante
- Método:
  - Acede a motores de pesquisa, através de API próprias, para obter uma lista de candidatos
- Refinamento da pesquisa
  - Adicionando palavras de carácter específico aos padrões utilizados

Pesquisa nas fontes genéricas

FEUP

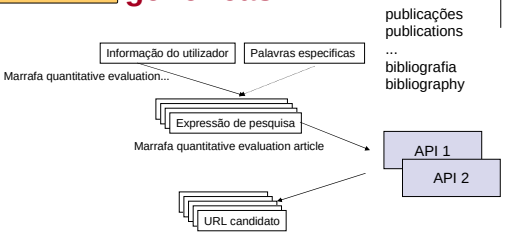

Obter dados da Web: Análise de resultados

FEUP

- Filtragem e tratamento de URL
  - Ignorar resultados
  - Obtenção da informação de repositórios bibliográficos
    - API Citeseer
    - Protocolo SRU/SRW
  - Extracção do texto de páginas e de documentos (HTML, DOC, PDF, PS, PPT, TXT) => Texto

Análise de resultados

FEUP

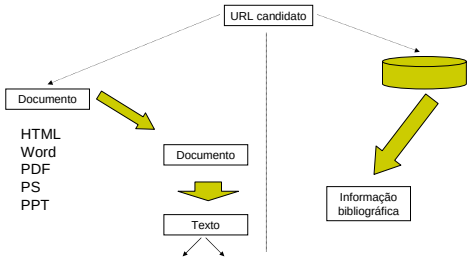

Extracção de candidatos a referências bibliográficas a partir de texto

FEUP

- Análise da estrutura e formato do documento

Tentar identificar o tipo de documento (Lista de publicações? Académico? Apresentação?)

- Identificar as zonas do texto com informação bibliográfica e extrair potencial informação relevante recorrendo a heurísticas e à análise obtida
  - Auto-referência (referência do próprio documento)
  - Blocos de referências (Listas)

Extracção de auto-referência: Exemplo

FEUP

MALINCHE: A NER system for Portuguese that reuses knowledge from Spanish

Thamar Solorio*
University of Texas at El Paso
Department of Computer Science

April 19, 2007

Abstract

Named Entity extraction is a problem that has been tackled in the NLP research community for some time now. First the hand-coded approaches, then the machine learning ones. Currently what we are looking for are methods that can be easily adapted to different domains and/or languages. In a previous work we showed how a hand-coded tagger can still be useful for NE extraction in different domains by using the output of the tagger as attributes in a machine learning task. In this work we show how the same representation of the learning task, using the same hand-coded tagger for Spanish, can be also exploited to perform NE extraction in Portuguese.

1 Introduction

Due to the many potential uses of Named Entities (NEs) in higher level NLP tasks, a lot of work has been devoted to developing accurate NE recognizers. Earlier approaches were primarily based on hand-coded knowledge, lists of gazetteers, and trigger words (e.g. [1, 18, 5, 29]). More recently, as machine learning has increased its

Extracção de auto-referência: Exemplo

FEUP

MALINCHE: A NER system for Portuguese that reuses knowledge from Spanish
Thamar Solorio
University of Texas at El Paso
Department of Computer Science
April 19, 2007
Abstract
Named Entity extraction is a problem that has been tackled in the NLP research community for some time now. First the hand-coded approaches, then the machine learning ones. Currently what we are looking for are methods that

Titulo: MALINCHE: A NER system for Portuguese that reuses knowledge from Spanish
Autor: Thamar Solorio
Instituição: University of Texas at El Paso Department of Computer Science
Data: April 19, 2007
Resumo: Named Entity extraction is a problem that has been tackled in the NLP(…)

Extracção de blocos de referências: Exemplo

FEUP

regardless of the ones determined by the hand-coded tagger.

References

[1] Douglas E. Appelt, Jerry R. Hobbs, John Bear, David Israel, Megumi Kameyama, Andy Kehler, David Martin, Karen Myers, and Mabry Tyson. SRI International FASTUS system MUC-6 test results and analysis. In *Proceedings of the Fifth Message Understanding Conference (MUC-6)*, pages 237–248, Columbia, MD, November 1995. NIST, Morgan Kaufmann Publishers.

[2] Montse Arévalo, Xavier Carreras, Lluís Màrquez, Toni Martí, Lluís Padró, and María José Simón. A proposal for wide-coverage Spanish named entity recognition. *Sociedad Española para el Procesamiento del Lenguaje Natural*, (28):63–80, May 2002.

[3] Daniel M. Bikel, Scott Miller, Richard Schwartz, and Ralph Weischedel. Nymble: a high-performance learning name-finder. In *Proceedings of the Fifth Conference on Applied Natural Language Processing*, pages 194–201, Washington, D. C., 31 March–3 April 1997. Association for Computational Linguistics.

[4] Daniel M. Bikel, Richard Schwartz, and Ralph Weischedel. An algorithm that learns what's in a name. *Machine Learning, Special Issue on Natural Language Learning*, 34(1–3):211–231, February 1999.

[5] William J. Black, Fabio Rinaldi, and David Mowatt. FACILE: Description of the NE system used for MUC-7. In *Proceedings of the 7th Message Understanding Conference, MUC-7*, Fairfax, VA, April-May 1998.

[6] Andrew Borthwick. *A Maximum Entropy Approach to Named Entity Recognition*. PhD thesis, New York University, New York, September 1999.

[7] Xavier Carreras, Lluís Màrquez, and Lluís Padró. Named entity extraction using adaboost. In Dan Roth and Antal van den Bosch, editors, *Proceedings of the Sixth Conference on Computational Natural Language Learning, CoNLL-2002*, pages 167–170, Taipei, Taiwan, August 31–September 1 2002.

[8] Xavier Carreras, Lluís Màrquez, and Lluís Padró. Named entity recognition for Catalan using only Spanish re-

Extracção de blocos de referências: Exemplo (2)

FEUP

Extracção de blocos de referências: Exemplo (2)

FEUP

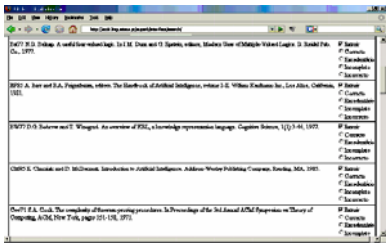

Extracção de elementos bibliográficos

FEUP

- Extrair títulos, autores, datas, locais a partir de candidatos a referências relevantes
  - Atomização
  - Classificação dos átomos através do Repositório de Elementos bibliográficos
    (REB: Pessoa, local, conferências, editoras.)
  - Identificação de padrões
    - ParaTools (*Mike Jewell*)

bibliográficos: Exemplo

FEUP

Steve Lawrence, C. Lee Giles and Kurt D. Bollacker, "Autonomous Citation Matching," Proceedings of the Third International Conference on Autonomous Agents, Seattle, Washington, May 1-5, ACM Press, New York, NY, 1999.

Steve Lawrence, C. Lee Giles and Kurt D. Bollacker, "Autonomous Citation Matching," Proceedings of the Third International Conference on Autonomous Agents, Seattle, Washington, May 1-5 ACM Press, New York NY 1999.

NOME, ?, NOME, NOME, NOME, "TITULO", CONFERENCIA, LOCAL, LOCAL, DATA, EDITORA, LOCAL, LOCAL, DATA.

NOME, NOME and NOME, "TITULO", CONFERENCIA, LOCAL, DATA, EDITORA, LOCAL, DATA.

Autor: Steve Lawrence
Autor: C. Lee Giles
Autor: Kurt D. Bollacker
Titulo: Autonomous Citation Matching
Conferência: Proceedings of the Third International Conference on Autonomouns Agents
Local: Seatle, Washington
Data: May 1-5
Editora: ACM Press
Address: New York, NY
Ano: 1999

Fusão de dados

Fusão dos dados

- A fusão de dados pode ser necessária
  - Por terem sido obtidos mais do que um resultados de uma pesquisa na Web
  - Por ter sido identificado informação bibliográfica semelhante num repositório local
    - Uma referência incompleta
    - Título de uma conferência ou livro
  - É necessário então desambiguar elementos bibliográficos

41

Fusão de dados

Fusão dos dados: Exemplo

Luís Sarmento. "**Hunting Answers with RAPOSA (FOX)**", in Alessandro Nardi, Carol Peters & José Luís Vicedo (eds.), *Cross Language Evaluation Forum: Working Notes for the CLEF 2006 Workshop* (**CLEF 2006**) (Alicante, Espanha, http://www.linguateca.pt/Repositorio/Sarmento_RAPOSA.pdf

+

Hunting Answers with RAPOSA (FOX), **Luís Sarmento** Working Notes of the Cross-Language Evaluation Forum Workshop (**CLEF 2006**) Alicant, Spain, 20-22 de September 2006. http://paginas.fe.up.pt/~las/conteudo/pub/pln/CLEF_2006/Sarmento_RAPOSA.pdf

=

(**Título** Hunting Answers with RAPOSA (FOX))
(**Autor** *Luís Sarmento*)
(**Conferencia** Working Notes of the Cross-Language Evaluation Forum Workshop (CLEF 2006))
(**Editores** Editors: Alessandro Nardi, C.P. & Vicedo, J.L.)
(**Local** Alicant, Spain)
(**Data** 20-22 de September 2006)
(**URL** [http://paginas.fe.up.pt/~las/conteudo/pub/pln/CLEF_2006/Sarmento_RAPOSA.pdf])
(**URL** http://www.linguateca.pt/Repositorio/Sarmento_RAPOSA.pdf)

42

Classificação

Classificação

- Marcação manual livre pelo utilizador (*tagging*)
- Classificação interna, com base em atributos específicos do documento (conferências específicas ou tipos de documentos tal como apresentações, ou língua)

43

Classificação

Interface de classificação

44

Índice da apresentação

- Introdução
- Motivação
- Contribuições
- Especificação do SUPeRB
  - Arquitectura
  - Tarefas do SUPeRB
- **Métodos de avaliação**
- Linhas de investigação futura

45

Avaliação de extracção de referências

- Textos analisados manualmente
- Listas de referências candidatas
- Categorização nominal de cada candidato e da info. conhecida
  - certo
  - com informação excedentária
  - informação incompleta
  - falta
  - erro
- Medidas de RI: precisão, abrangência, sobregeração etc.

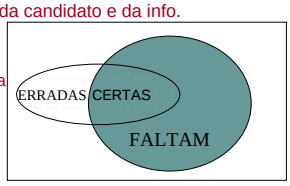

46

Avaliação de extracção de elementos

- Referências analisadas manualmente
- Lista de elementos candidatos para cada referência: de notar que em alguns campos há mais do que um elemento
- Categorização nominal por campo ou por elemento
  - correcto
  - excedentário
  - incompleto
  - em falta
  - espúrio
- Precisão por referência
- Precisão por autor

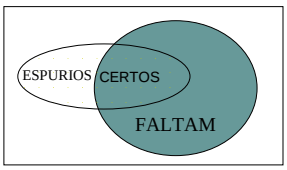

47

índice da apresentação

- Introdução
- Motivação
- Contribuições
- Especificação do SUPeRB
  - Arquitectura
  - Tarefas do SUPeRB
- Métodos de avaliação
- **Linhas de investigação futura**

48

Linhas de investigação futura

- Melhorar o conteúdo
  - Classificação automática
  - Análise de co-citações
- Aumentar as funcionalidades
  - Automatização de tarefas para permitir a actualização periódica autónomas (Sempre validadas pelo gestor)
  - Facilitar o conteúdo do recurso via serviços Web
- Usabilidade
  - Usabilidade da interface
  - Perguntas em linguagem natural

49

SUPeRB
Sistema Uniformizado de Pesquisa de Referências Bibliográficas

Luís Miguel Cabral

28 de Maio de 2007

Orientado Por:
Professor Doutor Eugénio Oliveira (FEUP)
Doutora Diana Santos (SINTEF)