

Segundo HAREM Workshop
PROPOR 2008: International Conference on
Computational Processing of Portuguese Language

Sistema SeRELeP para o reconhecimento de relações

Mírian Bruckschen
mirian.bruckschen@gmail.com

Renata Vieira
renata.vieira@pucrs.br

José Guilherme Camargo de Souza
joseguilhermecs@gmail.com

Aveiro, setembro de 2008

Roteiro

- Introdução
- Sistema SeRELeP
 - Visão geral
 - Reconhecimento de relações
 - Resultados e discussão
- Discussão sobre a trilha ReReIEM
- Considerações finais

Com o crescimento e evolução do número de esforços no se-
recentemente, havia pouca
português. Além disso, a
e subjetivo, dado que não

Neste contexto, surgem
Reconhecedores de Entidades
objetivo bastante especí-
mencionadas, com nome pr

Na tentativa de ampliar
Processamento de Linguagem
avaliação, referente ao
de Relações entre Entida

No que refere-se à identifi-
de correferência), este
atenção de diversos espe-
aplicabilidade nas impor-
construção automática de

Neste trabalho, é apresen-
recebe como entrada texto
Tiger2XCES e faz inferên-
linguísticas. Já existem
detalhe neste trabalho,

O restante do documento
básicos e trabalhos rela-
sistema projetado e des-
preliminares; e a seção
trabalho.

Introdução

- Oportunidade de participação no Segundo HAREM¹ (HAREM, 2007)
 - Trilha de reconhecimento de relações entre EMs² e experiência do grupo sobre correferência

¹ HAREM é uma Avaliação de Reconhecedores de Entidades Mencionadas

² Entidades Mencionadas

Visão geral (1/3)

- Sistema SeRELeP⁶
 - Desenvolvido em Python
 - Objetivo: reconhecer relações entre EMs previamente identificadas pelo PALAVRAS
 - Entrada: arquivos do *corpus* pré-processados pelo analisador PALAVRAS e o conversor Tiger2XCES
 - SeRELeP *Tools*: pacote associado que realiza tarefas de conversão entre ferramentas
 - Saída: arquivos anotados com EMs e suas relações

⁶ Sistema de Reconhecimento de RELações entre EMs da Língua Portuguesa

Visão geral (2/3)

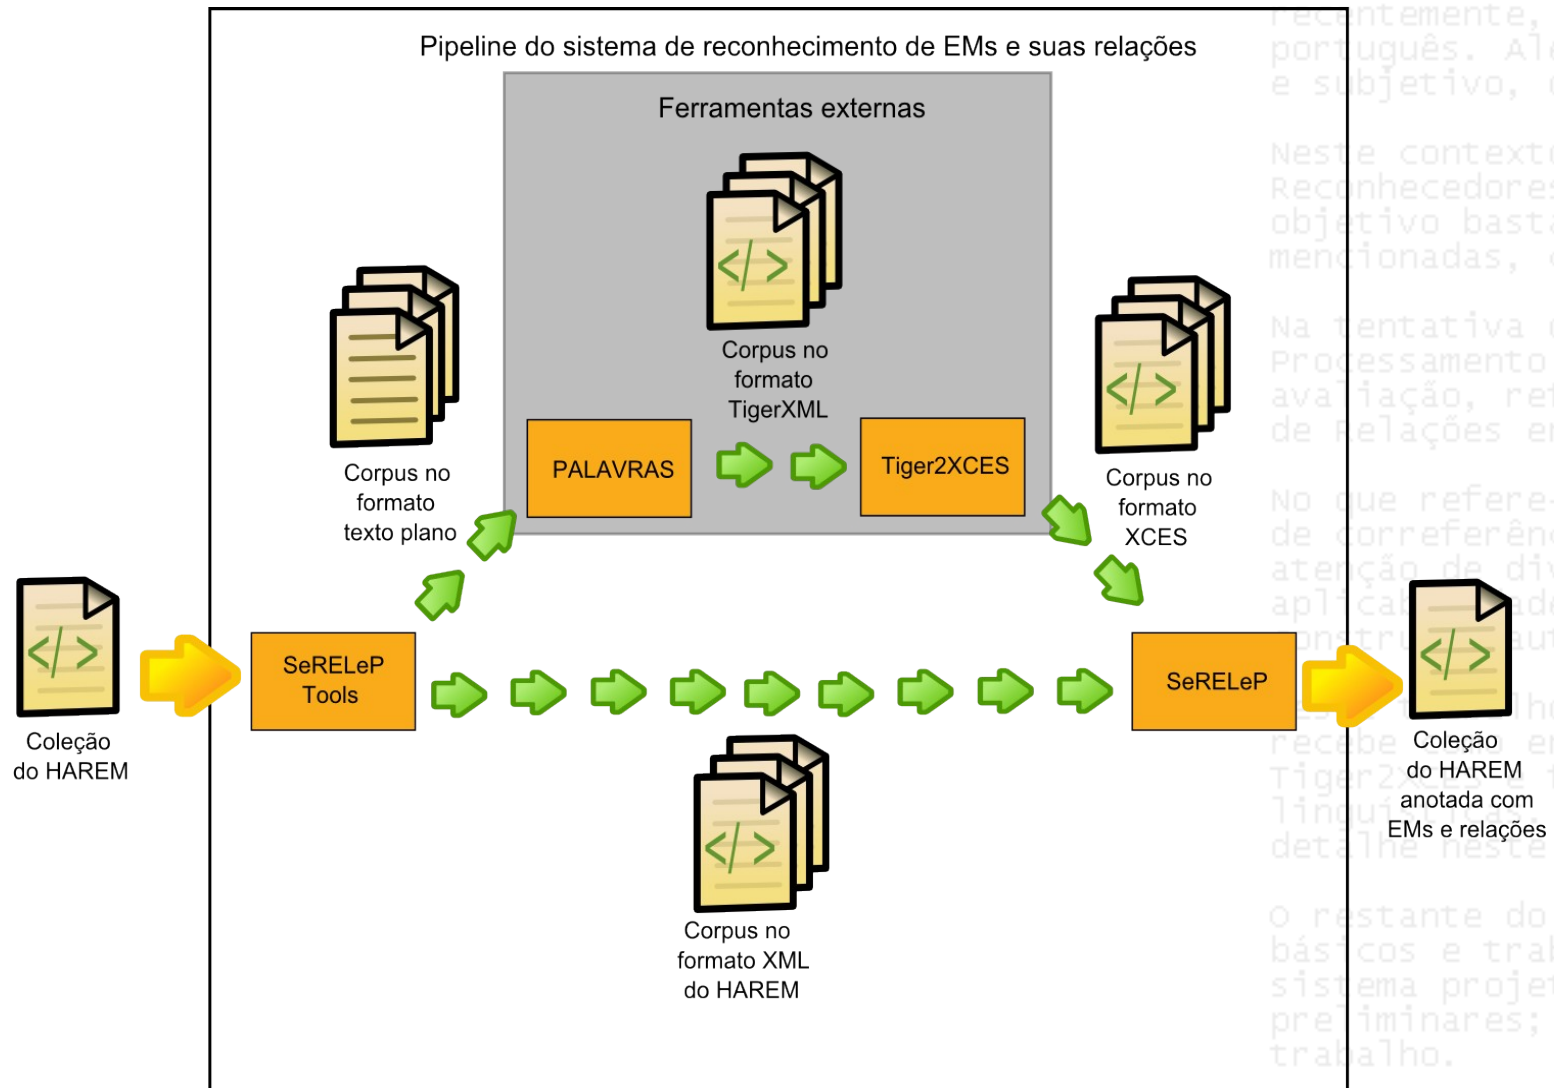


Figura 1. Processo de anotação automática de EMs e relações da coleção do HAREM

Sistema SeRELeP

Visão geral (3/3)

<DOC DOCID="cha-6282">

De Lisboa para Cascais e de novo para Lisboa, a mulher do Presidente da República Francesa, Danielle Mitterrand, passou ontem um dia ocupado na divulgação da versão portuguesa do «Passaporte Europeu contra o Racismo», um documento pessoal em que cada um se compromete simbolicamente a «resistir a qualquer acto de racismo». Recebida de manhã por Maria Barroso, que deu o seu patrocínio a esta iniciativa da Civitas, associação

<DOC DOCID="cha-6282">

De <EM ID="cha-6282-EM_1">Lisboa para Cascais e de novo para <EM ID="cha-6282-EM_2" COREL="cha-6282-EM_1" TIPOREL="ident">Lisboa, a mulher do <EM ID="cha-6282-EM_3">Presidente da República Francesa, <EM ID="cha-6282-EM_4">Danielle Mitterrand, passou ontem um dia ocupado na divulgação da versão portuguesa do «<EM ID="cha-6282-EM_5">Passaporte Europeu contra o Racismo», um documento pessoal em que cada um se compromete simbolicamente a «resistir a qualquer acto de racismo». Recebida de manhã por <EM ID="cha-6282-EM_6">Maria Barroso, que deu o seu patrocínio a esta iniciativa da <EM ID="cha-6282-EM_7" COREL="cha-6282-EM_12" TIPOREL="ocorre_em">Civitas,

Figura 2. Trechos de entrada e saída do *pipeline*

Reconhecimento de relações (1/3)

- O processo de reconhecimento de relações baseia-se na informação fornecida nos arquivos XCES
 - Se é EM (prop) ou não (PALAVRAS)
 - Etiquetação semântica (PALAVRAS)

Reconhecimento de relações (2/3)

- Existe uma relação da etiqueta semântica atribuída à classificação da EM no HAREM
 - Com base nessa etiquetagem, são definidas as heurísticas para reconhecimento das relações
 - Exemplo: “hum” ou “groupofficial” no PALAVRAS: PESSOA no HAREM

Reconhecimento de relações (3/3)

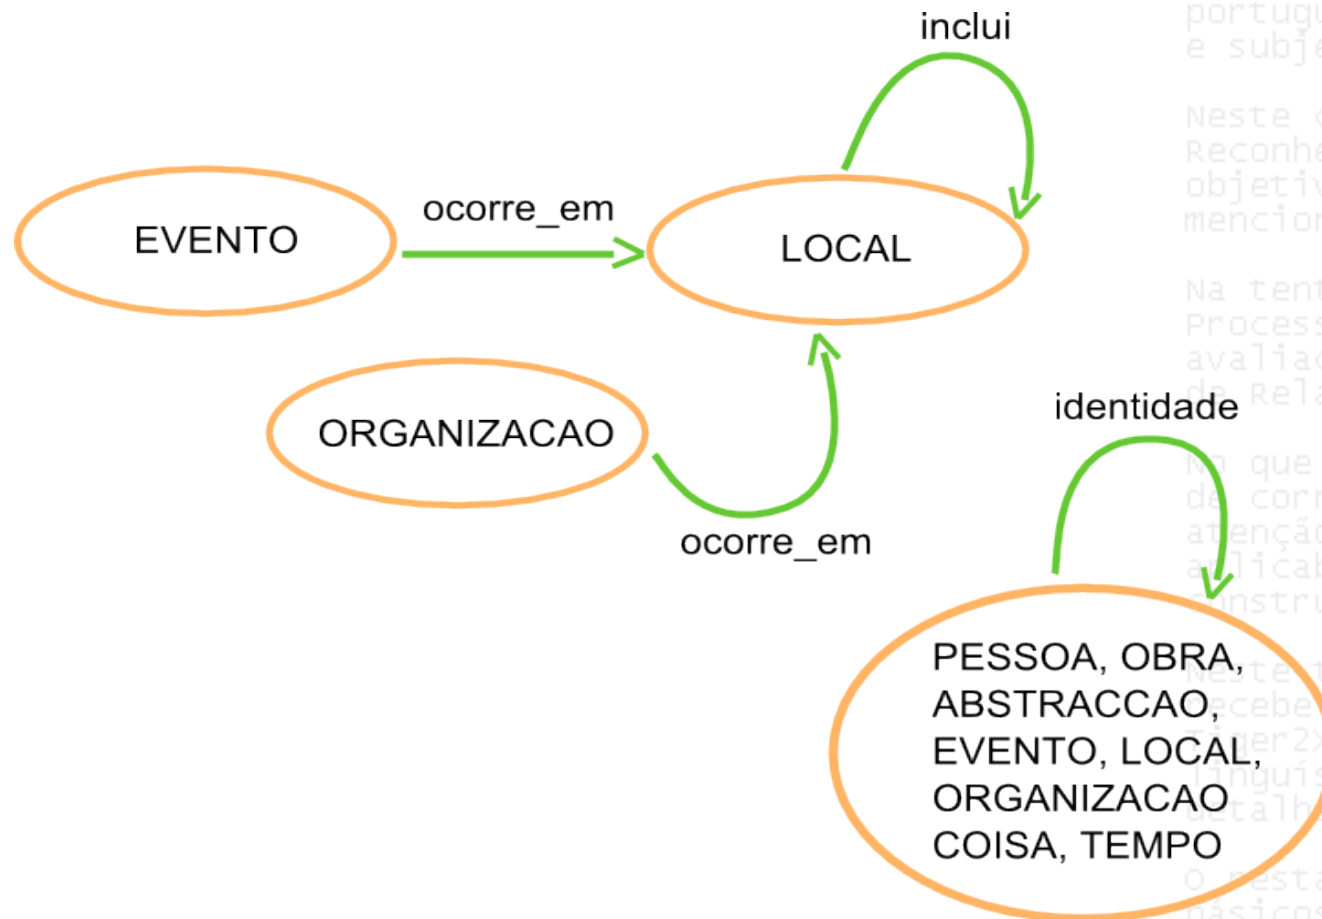


Figura 3. Relações e classes semânticas das EMs no SeRELeP

Reconhecimento das relações

- **ident**
 - *exact match*, sigla, parte do nome em caso de PESSOA (Silva e José da Silva)
- **inclui**
 - tratada entre entidades de LOCAL, procura entidades da mesma sentença que estejam na forma <entidade1> (...) em (...) <entidade2>
- **ocorre_em**
 - pedaço do nome do evento ou organização é nome de local
 - São Leopoldo Fest **ocorre em** São Leopoldo
 - entidade de local na mesma frase que evento ou organização
 - local mais próximo no texto

Resultados e discussão (1/5)

	Precisão	Abrangência	Medida F
Identificação	82%	60%	69%

Tabela 1. HAREM clássico (PALAVRAS)

Resultados e discussão (2/5)

	Precisão	Abrangência	Medida F
Aval. Relações	58%	31%	40%

Tabela 2. ReRelEM (SeRELeP) sem a relação “outra”

Resultados e discussão (3/5)

- identidade
 - 89% de **precisão**, 55% de **abrangência**, 68% de **medida F**
- inclui
 - 54% de **precisão**, 11% de **abrangência**, 18% de **medida F**
 - Poucas regras utilizadas, a baixa abrangência era esperada
- ocorre_em (localização)
 - 36% de **precisão**, 27% de **abrangência** e 31% de **medida F**
 - Um problema com relação à precisão: muitos casos marcados pelo sistema como **ocorre_em** eram **outra**, na verdade

Resultados e discussão (4/5)

- Abordagem simples
- Melhorias planejadas
 - ident
 - Nomes “similares” (*edit distance*)
 - Utilização de informação de aposto
 - Tradutores *online*
 - Wikipedia
 - Artigo na Wikipedia pt: Lisboa
 - Artigo na Wikipedia en: Lisbon
 - inclui e ocorre_em
 - Consulta a bases de dados (ontologias, Wikipedia, *gazetteers*)
 - Relações de difícil tratamento somente com regras linguísticas

Resultados e discussão (5/5)

- Diferenças entre identificação e classificação
 - Vagueza, talvez?
 - A relação presente entre EMs vagas é somente **outra**
 - SeRELeP não contempla vagueza
 - “Brasil” é sempre LOCAL
 - “Brasil” sempre **inclui** “Porto Alegre” (mesmo que este se refira à seleção brasileira de futebol...)

Discussão sobre a trilha ReReIEM

- Resolução de correferência
- Relação **ident**
 - Exemplo de cadeia de correferência #1
 - Felix_Mirabel , pesquisador que liderou o grupo
 - Mirabel
 - o pesquisador
 - ele

Discussão sobre a trilha ReReIEM

- Resolução de correferência
- Relação **ident**
 - Exemplo de cadeia de correferência #2
 - pesquisadores de a Universidade de Wisconsin-Madison (EUA)
 - A equipe liderada por Yoshihiro_Kawaoka
 - Os cientistas
 - o grupo de Kawaoka

Discussão sobre a trilha ReReIEM

- Resolução de correferência
- Relação **ident**
 - Exemplo de cadeia de correferência #3
 - Brasileiros
 - Os brasileiros – Gilson Rambelli, Paulo Bava de Camargo e Flávio Rizzi, pesquisadores de o Museu de Arqueologia e Etnologia (MAE) de a USP –
 - Eles
 - os arqueólogos
 - os três brasileiros
 - os arqueólogos

Discussão sobre a trilha ReReIEM

Outras relações

- subconjunto/parte-de

- Exemplo

- a Via Láctea

- o Sol

- a Terra

- outra

- Exemplo

- a estrela

- o que sobra

Com o crescimento e evolução do número de esforços no se-
recentemente, havia pouca
português. Além disso, a
e subjetivo, dado que não

Neste contexto, surgem os
Reconhecedores de Entidades
objetivo bastante especí-
mencionadas, com nome pr

Na tentativa de ampliar o
Processamento de Linguagem
avaliação, referente ao
de Relações entre Entidades

No que refere-se à identi-
de correferência), este
atenção de diversos espe-
aplicabilidade nas impor-
construção automática de

Neste trabalho, é apresen-
recebe como entrada text
Tiger2XCES e faz inferên-
linguísticas. Já existem
detalhe neste trabalho,

O restante do documento
básicos e trabalhos rela-
sistema projetado e des-
preliminares; e a seção
trabalho.

Corpus Summ-it

- Summ-it v3.0 – já disponível para *download*
 - 50 textos jornalísticos de ciências retirados da Folha de São Paulo
 - Composição
 - textos originais e tarjados (com informações relevantes do texto)
 - arquivos XML com anotação morfossintática (PALAVRAS)
 - **arquivos com anotação manual de correferência (MMAX)**
 - arquivos XML com anotação RST (RSTTool)
 - sumários automáticos e manuais
 - <<http://www.inf.pucrs.br/~linatural/procacosa.htm>>

Análise de resultados

- Resultados preliminares são razoáveis
 - Mas podem (e devem!) ser melhorados
- Propostas de aplicação do sistema SeRELeP
 - Geração automática de ontologias de determinado tipo de EMs e relações a partir de conjuntos de textos
 - **ident** pode auxiliar nas tarefas de resolução de correferência e enriquecimento de sumários automáticos
 - SeRELeP-Olympics
 - Geração de *hot topics* (com o auxílio da relação **ident**) para um portal de notícias sobre as Olimpíadas
 - “Cielo” e “César Cielo” se referem à mesma entidade, portanto devem aumentar o *ranking* desta entre os *hot topics*

Trabalhos futuros

- Melhorias nos algoritmos de reconhecimento de relações
 - Consulta a bases de dados externas, principalmente
- Ampliação da tarefa para incluir mais que EMs, objetivando cadeias de relações mais completas e informativas, focadas no tipo de entidade

Com o crescimento e evolução do número de esforços no setor, recentemente, havia poucas publicações em português. Além disso, o trabalho é subjetivo, dado que não há um padrão neste contexto, surgem os Reconhecedores de Entidades com um objetivo bastante específico das mencionadas, com nome próprio.

Neste contexto, surge a necessidade de ampliar o processamento de Linguagem Natural, avaliação, referente ao reconhecimento de relações entre Entidades.

Neste trabalho, é apresentada a identificação de relações (a partir de uma sequência de palavras), este trabalho tem a atenção de diversos especialistas na área de aplicabilidade nas importantes aplicações de construção automática de documentos.

Neste trabalho, é apresentada a identificação de relações (a partir de uma sequência de palavras), este trabalho tem a atenção de diversos especialistas na área de aplicabilidade nas importantes aplicações de construção automática de documentos.

O restante do documento apresenta os resultados básicos e trabalhos relacionados ao sistema projetado e desenvolvido, as conclusões preliminares; e a seção de considerações finais.

Considerações finais

Agradecimentos

- Agradecemos imensamente à organização do Segundo HAREM pela oportunidade de participação, pela atenção, paciência e pela receptividade a todos nossos comentários e sugestões

Referências

- Collovini, S.; Carbonel, T.; Fuchs, J. T.; Coelho, J. C.; Rino, L.; Vieira, R. (2007) *Summ-it: Um corpus com informações discursivas visando à sumarização automática*. In: Anais do XXVII Congresso da SBC (TIL – V Workshop em Tecnologia da Informação e Linguagem Humana).
- HAREM. (2007) *HAREM: Reconhecimento de entidades mencionadas em português*. Disponível em: http://acdc.linguateca.pt/aval_conjunta/HAREM/. Acesso em: junho de 2008.
- Norvig, P. (2008) *How to Write a Spelling Corrector*. Disponível em: <http://norvig.com/spell-correct.html>. Acesso em: agosto de 2008.
- Santos, D.; Cardoso, N. (eds.) (2007) *Reconhecimento de entidades mencionadas em português: Documentação e actas do HAREM, a primeira avaliação conjunta na área*. Linguateca, Portugal.
- Souza, J. G. C. (2007) *Resolução automática de correferência aplicada à língua portuguesa*. Monografia (Graduação). Curso de Ciência da Computação, UNISINOS. Brasil.

Segundo HAREM Workshop
PROPOR 2008: International Conference on
Computational Processing of Portuguese Language

Sistema SeRELeP para o reconhecimento de relações

Mírian Bruckschen
mirian.bruckschen@gmail.com

Renata Vieira
renata.vieira@pucrs.br

José Guilherme Camargo de Souza
joseguilhermecs@gmail.com

Aveiro, setembro de 2008