
- **LINGÜÍSTICA COMPUTACIONAL III**

Coordenador(a): Bento Carlos Dias da Silva

A SEMÂNTICA VERBAL: CONTRIBUIÇÕES PARA O APERFEIÇOAMENTO DE SISTEMAS DE EXTRAÇÃO DE INFORMAÇÃO NA ERA DA WEB SEMÂNTICA

Isa Mara da Rosa Alves (UNESP), Rove Luiza de Oliveira Chishman

Sob a perspectiva da Semântica Lexical Computacional, este trabalho apresenta alguns dos resultados de um estudo descritivo de verbos do domínio jurídico realizado com o intuito de construir uma ontologia aplicável ao aperfeiçoamento de sistemas de Processamento Automático da Língua Natural (PLN), em especial, à ferramenta de busca e extração de informações na Web da Procuradoria Geral da República de Portugal (PGR-PT). Tendo em vista a interdisciplinaridade das investigações feitas, a pesquisa como um todo foi organizado em três fases: (i) fase teórica lingüístico-computacional; (ii) fase lingüística teórico-aplicada; e (iii) fase computacional. Este artigo focalizará a fase lingüística teórico-aplicada da pesquisa; porém, não deixaremos de mencionar as demais. A partir de um estudo de aplicações semelhantes com o intuito de identificar que tipo de informação lingüística se presta para a construção de uma ontologia de

domínio jurídico - fase (i) -, o objetivo deste artigo é apresentar uma proposta de descrição ontológica dos verbos do domínio jurídico com base na análise de *cópus* - fase (ii). O resultado desse estudo serviu para - na fase (iii) - estabelecer critérios para a formalização das descrições semânticas em uma ontologia com o auxílio do editor Protégé. Esta ferramenta possibilita a conversão dos dados para a linguagem padrão da Web Semântica, a *Ontology Web Language* (OWL). Das abordagens discutidas neste trabalho, as que mais se prestaram para a descrição da semântica verbal com os fins aqui desejados foram as relações lógico-semânticas, os papéis semânticos e os frames. Com o uso da ontologia proposta aqui, o sistema da PGR-PT, de simples busca por palavras-chave, estará apto a interagir com o usuário em língua natural através de pergunta e resposta de maneira eficiente.

A SUMARIZAÇÃO TEXTUAL COM BASE EM CONHECIMENTO DISCURSIVO PARA PRESERVAÇÃO DA COERÊNCIA

Eloize Rossi Marques Seno (UFSCAR), Lucia Helena Machado Rino (UFSCAR), Thiago Alexandre Salgueiro Pardo (USP)

Apresenta-se, neste resumo, o RHeSumaRST, um sumarizador automático de textos baseado na organização do discurso, visando à preservação da coerência dos sumários.

A sumarização de um texto é realizada pela aplicação de heurísticas definidas manualmente a partir do estudo de um *corpus* produzido para este fim (Pardo e Rino, 2003). Essas heurísticas podam a estrutura discursiva dos textos, que são construídas, neste trabalho, com base na *Rhetorical Structure Theory* - RST (Mann and Thompson, 1987). Nesta teoria, o discurso é representado por uma estrutura em que as proposições do texto são relacionadas por relações retóricas, diferenciando-se as proposições de acordo com sua importância.

As heurísticas visam, principalmente, à preservar a coerência dos sumários. Coerência, neste caso, é limitada à verificação das cadeias de co-referências, que, sabidamente, são um de seus aspectos principais. Para isso, as heurísticas incorporam elementos da *Veins Theory* (Cristea et al., 1998), que delimita domínios de acessibilidade referencial para cada proposição do discurso com base na estruturação RST.

Para a realização da sumarização automática, a estrutura discursiva de um texto deve ser produzida anteriormente à aplicação das heurísticas, o que é feito pelo DiZer (Pardo et al., 2004), um analisador retórico automático para o português do Brasil. Além disso, os textos devem ser anotados com suas cadeias de co-referências. Neste trabalho, utilizou-se a ferramenta MMAX (Müller and Strube, 2001) como auxílio a esta anotação.

Em um estudo preliminar, verificou-se que, de fato, o RHeSumaRST preserva a coerência do sumário mais do que alguns métodos da literatura considerados importantes na área de sumarização automática.

O ESTABELECIMENTO DA CORRESPONDÊNCIA LÉXICO-CONCEITUAL ENTRE BASES RELACIONAIS DE DADOS LEXICAIS DO PORTUGUÊS E DO INGLÊS

Bento Carlos Dias da Silva (UNESP)

O objetivo deste trabalho é discutir o método de especificação da correspondência léxico-conceitual entre a base nuclear de uma rede *wordnet* em fase de construção para o português do Brasil, a base lexical da *Wordnet.Br*, e a base análoga, desenvolvida para o inglês norte-americano, a base lexical da *WordNet* de Princeton, e, por extensão à base lexical da *EuroWordNet*, que se compõe das bases construídas para um subconjunto de línguas da União Européia. Depois de breve contextualização histórica e metodológica da investigação em Tecnologias da Linguagem

Humana, contexto de pesquisa em que se insere este estudo, resumem-se os passos da compilação da rede Wordnet.Br, isto é, as etapas da montagem da base relacional de dados lexicais da rede, em que substantivos, verbos, adjetivos e advérbios são estruturados e armazenados, em módulos independentes, porém comunicantes, essencialmente em termos de uma coleção de relações paradigmáticas de significado: as relações léxico-semânticas de sinonímia e antonímia e as lógico-conceituais de hiponímia, troponímia, acarretamento, meronímia e causa. Na seqüência, apresenta-se a estratégia de mapeamento léxico-conceitual entre as redes brasileira e norte-americana. A discussão abrange os três domínios envolvidos na pesquisa e no desenvolvimento de recursos lingüísticos para o processamento automático de línguas naturais: o lingüístico, o lingüístico-computacional e o computacional. A conclusão resume os pontos principais do trabalho e salienta a contribuição do método para a automatização do processo de compilação de recursos lexicais robustos, quer para fins computacionais, quer para fins lexicográficos.

PADRÕES DE LEXICALIZAÇÃO E A INDEXAÇÃO DA BASE DA WORDNET.BR

Ariani di Felippo (UNESP)

A WordNet, desenvolvida para o inglês americano, é uma base de dados lexicais que se estrutura em conjuntos de sinônimos, os “synsets”, que visam a representar o conceito lexicalizado pelas unidades que o compõem; cada synset constitui um nó e as ligações entre os diferentes nós, representada por meio de arcos rotulados, visam a exprimir a relação léxico-semântica de antonímia e as relações lógico-conceituais de hiponímia, troponímia, meronímia, causa e acarretamento. Diante da relevância lingüística e da potencialidade tecnológica, o desenvolvimento de wordnets para diferentes línguas frutificou-se e sofisticou-se. As wordnets em construção para as línguas dos países da União Européia, por exemplo, estão aglutinadas em uma base multilíngüe, a EuroWordNet, em que os synsets das diferentes línguas que lexicalizam um conceito comum são interligados. Em uma das etapas futuras do desenvolvimento da wordnet brasileira, a Wordnet.Br, está prevista a interligação desta a wordnet americana, resultando, assim, em uma base bilíngüe que poderá ser utilizada em pesquisas lingüísticas e do PLN. Essa indexação, em especial, requer a identificação de padrões de lexicalização de conceitos (isto é, mapeamento ou associação regular entre conceitos e itens lexicais) do inglês e do português. Motivado por essa tarefa de indexação das wordnets brasileira e americana, apresenta-se neste trabalho a proposta de estudo do mapeamento dos padrões de lexicalização de conceitos codificados nos nomes concretos do inglês e do português. Além de subsidiar parte da futura indexação da Wordnet.Br a WordNet de Princeton, o trabalho ora proposto busca contribuir para o desenvolvimento de questões como o desenvolvimento de ontologias lingüísticas e conceituais e a especificação semântica dos itens lexicais. [CNPq]