

Processamento Superficial

Parte 2/3



trabalho conjunto com
João Silva
Filipe Nunes
Pedro Martins

Tecnologia da linguagem

- ❑ Aplicações específicas
 - ❑ correcção ortográfica e gramatical
 - ❑ sumarização
 - ❑ aprendizagem de línguas assistida por computador
 - ❑ resposta-a-perguntas
 - ❑ interfaces em língua natural
 - ❑ tradução assistida por computador
 - ❑ tradução automática
 - ❑ ...
- ❑ Integração e suporte a outras aplicações
 - ❑ acessibilidade por deficientes
 - ❑ recuperação de texto
 - ❑ prospecção de informação
 - ❑ eLearning
 - ❑ localização e multilinguismo
 - ❑ ...
- ❑ Web semântica
 - ❑ Anotação automática de meta-dados



Da forma ao significado

- Objectivo
 - Explicitar e associar informação linguística ao texto

- Cadeia de processamento
 - reconhecimento da fala
 - segmentação de lexemas e frases
 - anotação morfo-sintáctica
 - análise morfológica nominal
 - análise morfológica verbal
 - lematização
 - reconhecimento de entidades nomeadas
 - reconhecimento de expressões multi-palavra
 - desambiguação de acepções
 - análise sintáctica (constituência)
 - funções gramaticais
 - papéis semânticos
 - forma lógica
 - ...

- Problemas chave: ambiguidade e novidade



Segmentação de frases

❑ Dificuldades chave

- Ambiguidade e ambivalência do ponto: Sr. João
- Ambiguidade do travessão: – Eu – sussurrou – também.

❑ Abordagem

- Expressões regulares, e.g. “ponto seguido de maiúscula”
- Lista de abreviaturas

❑ Contribuição

- Cobertura exaustiva, para além de *proof-of-concept*

❑ Avaliação (Medida-F)

- Valor base: 99,31% Ferramenta: **99,94%**
 - ❑ 12 000 frases (incl. 18% diálogo)
 - ❑ Valor base: segmenta sempre que “. x”



Segmentação de lexemas

❑ Dificuldades chave

- Ambiguidade de sequências: *deste, consigo, pelas...*

❑ Abordagem

- Segmentação e anotação interpoladas
 - ❑ Manter sequências ambíguas: *deste* → *|deste|*
 - ❑ Anotação em contexto: *|deste/PREPDEM|* **ou** *|deste/V|*
 - ❑ Expansão: *|deste/PREPDEM|* → *|de/PREP|este/DEM|*

❑ Contribuição

- Primeira ferramenta a resolver sequências em contexto

❑ Avaliação

- Valor base: 98,46% Ferramenta: **99,72%**
 - ❑ Medição apenas sobre sequências ambíguas: 5450 tokens
 - ❑ Valor base: leitura mais provável



Anotação morfo-sintáctica

❑ Dificuldades chave

- Ambiguidade categorial: como ← ADV|CJ|INT|PREP|REL|V
- Novidade: concordanciador, ...

❑ Abordagem

- Métodos estado-da-arte: Aprend. p/ tranformações (TBL, Brill), Máxima entropia (MXPOST, Ratnaparkhi), Modelos de Markov (TnT, Brants)

❑ Contribuição

- Desempenho ao nível do estado-da-arte para outras línguas
- Melhores anotadores para o português (Branco e Silva, 2004)

❑ Avaliação (correção)

- Valor base (TnT): 96,37% Ferramenta (TnT): **98,52%**
 - ❑ Avaliação sobre 260K, 10% não usados para treino (x10 iterações)
 - ❑ Valor base: categoria mais provável



Traçamento nominal

❑ Dificuldades chave

- Ambiguidade de traços: pianista (f/m?), lápis (s/p?)...
- Novidade: traflemadora (f/m?; s/p?), ...

❑ Abordagem

- Subst de terminações x lista de excepções
- Explorar concordância: o lápis vs. os lápis

❑ Contribuição

- Primeira ferramenta dedicada
- Baseado em regras com léxico mínimo
- Resolução da ambiguidade em contexto

❑ Avaliação

- Valor base: 87,08% Ferramenta: **92,62%**
- Com processamento sintáctico subsequente correcto: 98,79%
 - ❑ Medição sobre anotação morfo-sintáctica correcta
 - ❑ Valor base: sem propagação de concordâncias



Lematização nominal

❑ Dificuldades chave

- Ambiguidade semântica: *ética* (*ética/o?*), *copas* (*copa/s?*)
- Novidade: *traflemadoras* (*-dor,-dora,...?*)...

❑ Abordagem

- Subst de terminações x Lista de excepções
- Minimização da lista de excepções

❑ Contribuição

- Primeira ferramenta dedicada
- Baseado em regras com léxico mínimo

❑ Avaliação

- Valor base: 87,08% Ferramenta: **97,67%**
 - ❑ Avaliação sobre 51K nominais
 - ❑ Melhoria expectável: interpolação com WSD
 - ❑ Valor base: só com regras de terminação



Lematização e traçamento verbais

❑ Dificuldades chave

- Ambiguidade de traços e/ou lema:
 - ❑ `virei(vir/Fut1s; virar/Perf1s)`, `parti(partir/Pres1s/Imp2p)`
- Novidade: `concordancear`

❑ Abordagem

- Motor de flexão: subst de terminações x lista de excepções
- Máxima verosimilhança em cascata

❑ Contribuição

- Primeira ferramenta dedicada
- Resolução da ambiguidade

❑ Avaliação

- Valor base: 88,52% Ferramenta: **95,92%**
 - ❑ Sobre 40K verbais e anotação morfo-sintáctica correcta
 - ❑ Valor base: atribuir o conjunto de traços mais provável
 - ❑ Trabalho em curso: classificador Bayesiano e SVM



Serviços online

□ Já disponíveis

■ Suite

- `lxsuite.di.fc.ul.pt`

■ Flexão nominal

- `lxinflector.di.fc.ul.pt`

■ Flexão verbal

- `lxlemmatizer.di.fc.ul.pt`

- `lxconjugator.di.fc.ul.pt`

□ Serviços online em finalização

■ Concordanciador

■ Reconhecedor de entidades nomeadas

