Processamento computacional do português: o que é?

Diana Santos
SINTEF Telecom and Informatics

Plano da apresentação

Razões para a identificação desta categoria

O projecto *Processamento computacional do português*

Estado da arte e da técnica
- através do catálogo
- através da área do PLN

Processamento computacional do português

- = processamento de linguagem natural; em que a linguagem natural é o português
- Não existe PLN «geral», «independente da língua» (apesar de poderem existir técnicas e metodologias que o possam ser)
- Em geral PLN não adjectivado significa «processamento do inglês»
- Para avaliar, é preciso ter um contexto / língua em que se trabalha

Trabalhar numa língua e apresentar os resultados noutra

- Criação de «textos» incoerentes
- Baseada em hipóteses não confirmadas
  - que a estrutura dos textos é idêntica
  - que a semântica dos tempos verbais correspondentes é idêntica

Last month I bought a house. It had an aquarium. Mary offered me a red fish. John gave me his frog. My fish died yesterday. It stopped breathing. It became blue. It went to the top of the aquarium.
(COLING'92, p. 335)

O projecto Proc. Comp. do Port.

- Criado pelo MCT por altura da discussão das áreas para o Livro Branco
- Três vertentes principais:
  - Catálogo
  - Criação e disponibilização de recursos
  - Avaliação
- Futuro: criação de um centro de recursos para o processamento do português

Acção política

- Identificação de alguns problemas
- Sugestão de algumas soluções
- Criação de um portal que apresenta o proc. computacional do português, bem divulgado a nível internacional
- Estabelecimento de cooperação com actores internacionais (Bick, LDC, IMS, Davies, ...)

Trabalho realizado : Recursos

- Projecto AC/DC: criação de uma interface na Web para todos os corpora livremente acessíveis
- CETEMPúblico: criação de um corpus de 180 milhões de palavras para distribuir
- COMPARA/DISPARA: criação de uma interface na Web para corpora paralelos
  (criação do próprio corpus: Ana Frankenberg-Garcia)

Trabalho realizado: Catálogo

- Recursos
- Actores
- Publicações
- Informação interessante
- Sistema de busca
- Série de programas desenvolvidos para a manutenção e expansão do catálogo

Trabalho realizado : Avaliação

- Conjugadores de verbos
- Alinhadores

Trabalho relacionado

- Comparação de corpora
- Motores de procura em português
- Ambientes de processamento de corpora em português
- Analisador sintáctico

Sem dúvida a área mais difícil !

Futuro : Centro de recursos

Além da disponibilização crescente de recursos ...

- Organização de conferências de avaliação
- Concursos para criação de recursos
- Especificação de materiais de referência

- Novos pólos: Braga, Lisboa, ...
- Conselho consultivo internacional

A situação actual (fonte: Web)

- 25 corpora
- 170 léxicos e/ou dicionários
- 80 ferramentas
- 500 publicações
- 44 páginas pessoais
- 35 empresas
- 2-12 listas electrónicas

Uma panorâmica do PLN

- Escrita e produção de um texto
- Leitura e folheamento
- Tradução
- Aprendizagem e ensino
- Sistemas de informação
- Sistemas interactivos
- Indexação
- Entrada de dados
- Segurança e identificação

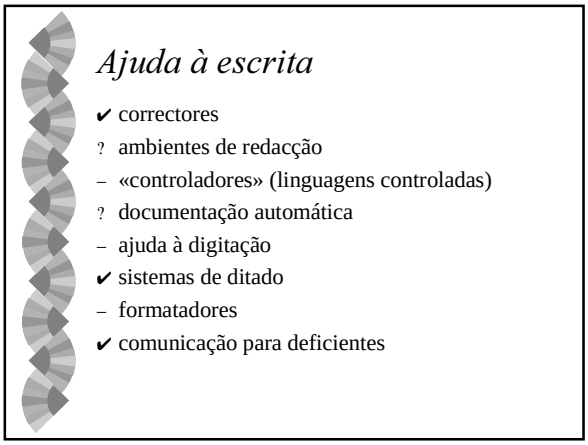
Ajuda à escrita
✔ correctores
? ambientes de redacção
– «controladores» (linguagens controladas)
? documentação automática
– ajuda à digitação
✔ sistemas de ditado
– formatadores
✔ comunicação para deficientes

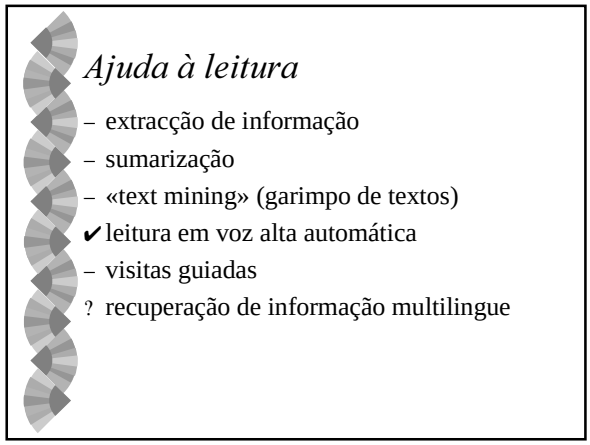
Ajuda à leitura
– extracção de informação
– sumarização
– «text mining» (garimpo de textos)
✔ leitura em voz alta automática
– visitas guiadas
? recuperação de informação multilingue

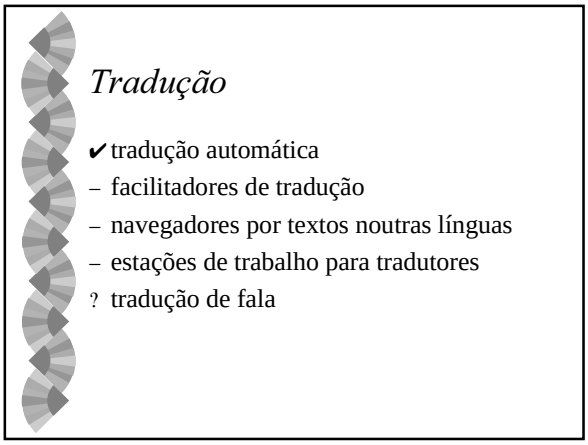
Tradução
✔ tradução automática
– facilitadores de tradução
– navegadores por textos noutras línguas
– estações de trabalho para tradutores
? tradução de fala

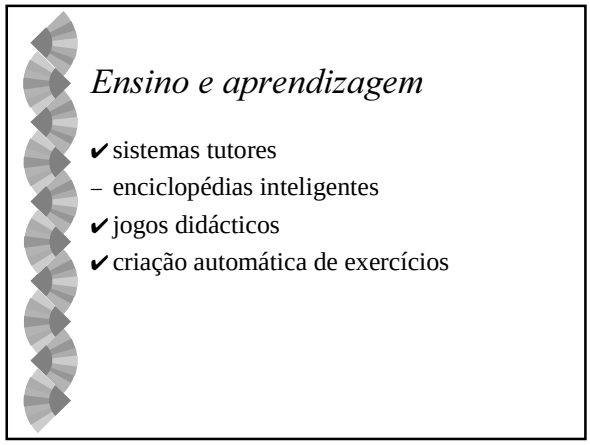
Ensino e aprendizagem
✔ sistemas tutores
– enciclopédias inteligentes
✔ jogos didácticos
✔ criação automática de exercícios

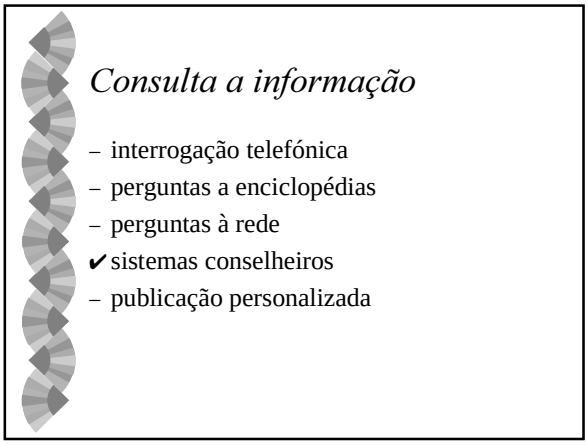
Consulta a informação
– interrogação telefónica
– perguntas a enciclopédias
– perguntas à rede
✔ sistemas conselheiros
– publicação personalizada

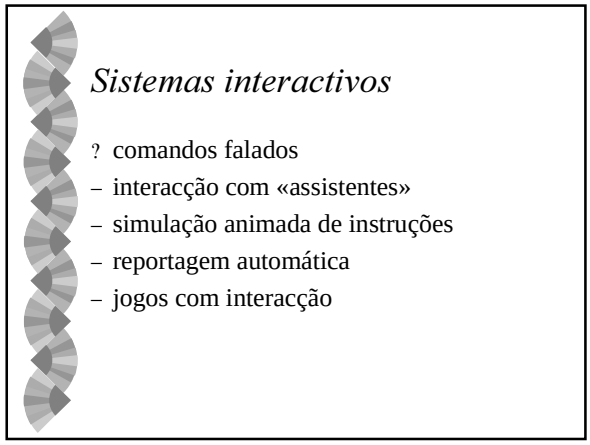
Sistemas interactivos
? comandos falados
– interacção com «assistentes»
– simulação animada de instruções
– reportagem automática
– jogos com interacção

Indexação

? criação semi-automática de tesauros
✔ indexação de grandes quantidades de material
– catalogação de imagens
? criação semi-automática de terminologias

Entrada e colecção de dados

? extracção automática de informação para as BDs internas de um sistema
– leitura óptica
– actualização de dados por fala
✔ reconhecimento de manuscritos

Segurança e identificação

? reconhecimento de assinaturas
? reconhecimento da «voz do dono»
✔ reconhecimento da língua / substracto linguístico
– identificação automática de um autor

Outros

? estudos sociológicos
– análise de uma disciplina científica
– medição do «peso» de uma dada cultura
– criação de metáforas para uma boa interface
✔ planificação do ensino de uma língua

O projecto AC/DC

- AC/DC= Acesso a corpora/Disponibilização de corpora
- Três fases
  - Separação de frases e tokenização
  - Análise sintáctica (com Eckhard Bick)
  - Junção de outra informação (com outros investigadores)
- Futuro: “test suite” e “treebank”

AC/DC: o processo

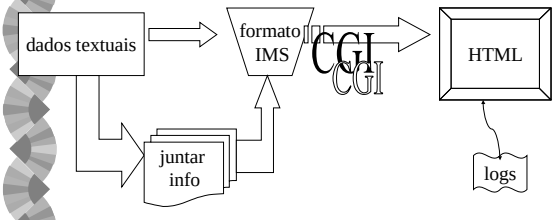

Os dados variam de texto simples a SGML
A informação que juntamos vai desde marcar os limites dos parágrafos até analisar sintacticamente o texto

ACDC: o resultado

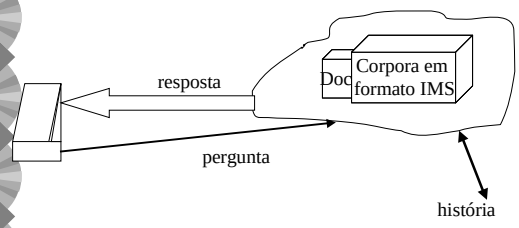

http://cgi.portugues.mct.pt/acesso/

Documentação dos corpora

Distribuir corpora na rede

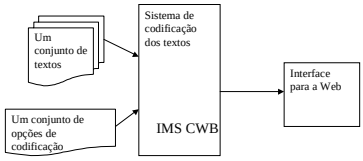

CETEMPúblico

- Grande quantidade de texto do jornal Público, distribuído aleatoriamente por extractos numerados
- Distribuído em
  - CD em formato texto
  - CDs em formato CQP
  - pelo AC/DC
- Esperança de vir a ser um corpus de referênci para avaliação de sistemas

http://cgi.portugues.mct.pt/cetempublico/

O projecto COMPARA/DISPARA

- Iniciativa de Ana Frankenberg-Garcia, implementação do nosso projecto
- *COMPARA* é um corpus paralelo português-inglês
- *DISPARA* é um sistema de distribuição de corpora paralelos na rede, que foi desenvolvido numa primeira instância para o COMPARA, mas que é para ser utilizável por todos os interessados

http://www.portugues.mct.pt/COMPARA/

Características originais do DISPARA

- Inspecção das notas de tradução (N.T.)
- Procura por tipo de alinhamento (1:2, 1:1/2, etc.)
- Panorâmica quantitativa
- Procura nas duas direcções
- Procura arbitrariamente complexa nos dois lados

Alguns pormenores sobre o COMPARA

Textos com tamanhos diferentes

Unidade de alinhamento é sempre uma frase do original

Não segue o TEI