

## Indexação assistida por computador de documentos textuais em língua portuguesa

<sup>1</sup> João Sequeira

<sup>2</sup> Maria Teresa Balesteros

É hoje uma evidência comumente aceite que foi graças ao advento da informática e sobretudo ao desenvolvimento das comunicações, que se tornou possível o modelo social e económico em que assenta a chamada Sociedade da Informação.

A necessidade de acesso rápido à informação estratégica é neste modelo um factor de vantagem comparativa. Essa constatação levou a que surgissem, a partir da década de sessenta, em face do já então previsível crescimento acelerado da quantidade de documentos produzidos (explosão documental) e sobretudo pelo desenvolvimento das formas de transmissão e acesso à informação a partir das redes informáticas, organizações (CDIs) e pessoas (Documentalistas) cuja função passou de simples *guardiões* dos documentos a agentes do processo de tratamento e disponibilização da informação.

A descrição documental tradicional assente basicamente na catalogação e classificação dos documentos revelavam-se então já insuficientes; Tornavam-se necessários sistemas de acesso rápido e fiável ao seu conteúdo. As tarefas de resumo e indexação ganharam no seio da comunidade arquivística e bibliotecária importância crescente e ocupam ainda hoje nas bibliotecas e arquivos, um conjunto muito vasto de técnicos e consomem enormes recursos financeiros.

A complexidade e morosidade dos processos manuais de indexação e resumo, assentando fundamentalmente em mão-de-obra qualificada e portanto melhor remunerada, transforma os produtos documentais em bens de grande valor acrescentado e consequentemente em produtos caros não acessíveis à generalidade dos consumidores de informação.

Por outro lado a explosão documental facilitada pela capacidade de distribuição e acesso decorrente do acesso às redes de comunicação, exige aos Centros de Documentação e Informação capacidades de tratamento documental, cada vez menos compatíveis com o seu tratamento pelos processos tradicionais.

A verdade é que não é mais possível travar o “caos” informativo existente na maioria das organizações e sobretudo nas actuais redes de informação ( veja-se o enorme “ruído” presente na maioria dos actuais motores de pesquisa existentes na INTERNET ), sem recorrer por um lado às técnicas de tratamento documental normalizadoras bem como à utilização por esses técnicos de sistemas de indexação da informação automáticos e sobretudo de sistemas “*inteligentes*”, capazes eles próprios com reduzida intervenção humana de “*compreender*” o conteúdo dos documentos e proceder à sua indexação.

---

<sup>1</sup> Licenciado em informática, assistente universitário na Universidade Autónoma de Lisboa e Chefe de Departamento de Informação Documental da Direcção de Arquivos e Documentação da Radiotevisão Portuguesa, SA ( RTP).

Email: jsequeira@mail.rtp.pt

<sup>2</sup> Licenciada em Informática e Chefe de Serviço de Documentação Escrita da Direcção de Arquivos e Documentação da Radiotevisão Portuguesa, SA ( RTP).

Email: balesteros@mail.rtp.pt

### **Quais as vantagens reais para os CDI da automatização da análise de conteúdo dos documentos?**

- A **Rapidez** com que os CDI passariam a disponibilizar a informação é talvez a vantagem mais óbvia.
- **Economia** - Sabemos por outro lado que a tarefa de indexação exige profissionais qualificados e detentores de múltiplas competências, tanto no âmbito das técnicas documentais como no que diz respeito à compreensão das matérias tratadas nos documentos. Um perito com tal perfil nem sempre é fácil de encontrar e demora tempo a formar. Ao reduzir o número de peritos necessários e o tempo de formação de cada um, estas serão, certamente, vantagens económicas não desprezíveis.
- **Homogeneidade e Coerência** - Ao permitir reduzir a multiplicidade de critérios (inevitável na indexação humana) conseguiremos sistemas documentais mais homogêneos e coerentes.
- **Especialização** - Por último, é necessário ter em conta que determinados ramos do conhecimento evoluem tão rapidamente que é cada vez mais difícil aos documentalistas manter-se permanentemente actualizados. Uma vantagem adicional seria assim a partilha por todos os técnicos dos vários contributos individuais.

## **Tipos de Sistemas de Indexação Automática**

A constatação da necessidade de sistemas de indexação automática não é, como se disse, nova. Os primeiros sistemas surgiram na década de 70 nos EUA e na Europa, mas a sua implementação era grandemente estrangida pela capacidade dos equipamentos e pela investigação que dava então os primeiros passos. Alguns desses conceitos estão já hoje presentes nos sistemas de pesquisa em bases de dados. A grande revolução é no entanto só hoje possível, com o desenvolvimento da chamada *Inteligência Artificial*.

No essencial podem caracterizar-se três tipos de sistemas de indexação assistida, a saber:

### **I. Sistemas não selectivos**

- A. A indexação é feita palavra a palavra, sendo tidas em conta todas as palavras não-vazias ( i.e., com conteúdo semântico ) presentes no documento.
- B. São sistemas amplamente divulgados, relativamente simples de implementar, utilizados para possibilitar a pesquisa a bases de dados em texto integral.
- C. Estes sistemas colocam alguns problemas ao nível da pesquisa documental que se relacionam com a não selectividade da indexação, problemas de sinonímia e polissemia, não-normalização das formas gramaticais, e decomposição de termos compostos representativos de conceitos, em unitermos pouco ou nada significativos.
- D. Para reduzir o impacto de alguns destes problemas, as linguagens de interrogação incluem, para além da possibilidade de utilizar operadores booleanos, outras funcionalidades como a truncatura (ao permitir a pesquisa de termos a partir de um radical, minimiza-se o problema da não-normalização das formas gramaticais) e a pesquisa de referências próximas e adjacentes permitindo (em muitos casos recuperar termos compostos).
- E. Para além disso, alguns incluem ainda uma normalização da linguagem natural, permitindo o tratamento de: variantes (**oiro = ouro**), erros ortográficos (**açoreano = açoriano**), erros de digitação (**documento = document**) e formas flexionadas (**feminino = masculino, plural = singular**).

### **II. Sistemas selectivos**

- A. Apenas são tidos em conta certos termos: aqueles que forem considerados pelo algoritmo do sistema como os mais representativos do conteúdo do documento. Podem utilizar os termos presentes no próprio documento ( linguagem natural ) ou uma linguagem controlada.

### **III. Indexação assistida por computador**

- A. A indexação é feita em duas fases:
  - 1. uma fase de pré-indexação automática, em que o sistema analisa um texto e lhe associa um conjunto de descritores, normalmente extraídos de uma lista de autoridade ou de um tesouro;
  - 2. e uma fase de diálogo entre o sistema e o documentalista, em que a lista de descritores proposta na fase precedente é validada.

B. De acordo com os trabalhos já desenvolvidos podemos concluir que estes sistemas se dividem em dois grandes grupos:

1. sistemas de orientação probabilística e
2. sistemas de orientação linguística

#### **Indexação assistida de orientação probabilística - SINTEX (Système d'Indexation de Textes)**

Este sistema prevê uma fase de pré-aprendizagem no decurso da qual é analisado um conjunto de cerca de 4000 documentos indexados e classificados manualmente. É durante esta fase que são criados automaticamente a maioria dos ficheiros em que o sistema se baseia. Estes ficheiros são essencialmente de dois tipos: léxicos (de palavras, de descritores e de domínios) e ficheiros de correspondência ponderada (entre descritores e palavras, entre descritores e descritores, entre descritores e domínios, etc.).

A pré-indexação automática compreende duas fases: reconhecimento das palavras do texto e classificação e indexação do documento por consulta aos ficheiros de correspondência ponderada.

#### **Indexação assistida de orientação linguística - ALEXDOC**

O sistema baseia-se em: dados (tesauro e dicionário base da língua) e regras (de derivação morfológica, de reestruturação de termos compostos, regras sintáticas - para resolver a ambiguidade criada pelas palavras homógrafas, regras de transformação semântica e regras de reconhecimento de frases.

O processo de indexação compreende essencialmente as seguintes fases:

- Identificação de frases
- Identificação de cada uma das palavras, por consulta do tesauro e do dicionário base da língua e por aplicação das regras de derivação morfológica
- Resolução de ambiguidades
- Identificação de termos compostos
- Aplicação das regras de transformação semântica
- Eliminação de não descritores
- Eliminação de descritores simples que fazem parte de descritores compostos
- Adição de termos genéricos, ao primeiro nível, de cada descritor retido
- Validação da indexação proposta

Estes sistemas ainda não se encontram muito divulgados e muitos dos que existem estão ainda em fase experimental.

Este estado de coisas tem a ver com o facto de que para indexar um texto é necessário compreendê-lo.

Entramos aqui num domínio particular da Inteligência Artificial:

*o Processamento da Linguagem Natural ou Engenharia da Linguagem.*

Esta é uma área de investigação que constitui o tronco comum a múltiplas aplicações práticas. Um dos primeiros campos de aplicação da investigação levada a cabo nesta área foi a tradução automática. A partir dos anos 50/60 foi desenvolvido um grande trabalho nesta matéria e, neste momento, estes sistemas já têm grande utilização.

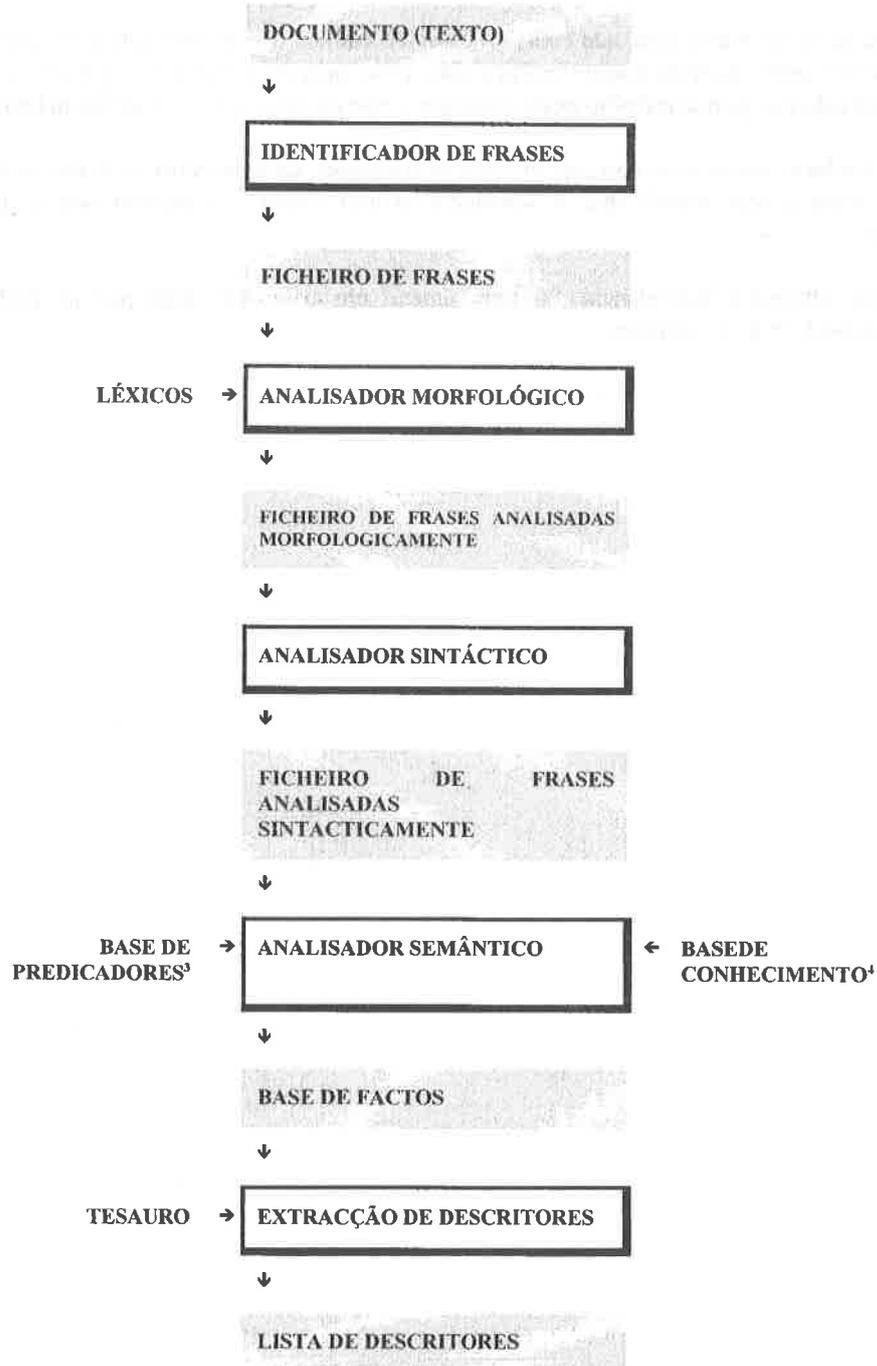
Embora a tradução automática não seja um processo simples, qualquer erro de tradução é detectável com relativa facilidade dada a redundância que a linguagem natural encerra. O mesmo não se passa com a indexação automática.

A indexação elimina a redundância, faz uma síntese: um artigo de várias páginas pode ficar reduzido a uma pequena quantidade de descritores.

Posta a questão teórica importa agora apresentar o trabalho de investigação em que nos encontramos envolvidos, tendente a incorporar alguns destes conceitos num protótipo de um **Indexador Automático para a Língua Portuguesa (IndeLiP)**, assente em critérios linguísticos e explicitar a sua arquitectura.

## Estrutura do IndeLiP

### (Detalhe do módulo de indexação)



<sup>3</sup> A sua função é permitir a resolução de algumas ambiguidades

<sup>4</sup> A sua função é produzir inferências

## Identificador de Frases

O seu objectivo consiste em identificar as unidades mínimas de comunicação que irão constituir a base de todo o processamento posterior. A sua implementação não constitui problema computacional. Trata-se apenas de reconhecer os conjuntos de caracteres que constituem as palavras, agrupá-las em frases através do reconhecimento dos sinais de pontuação que normalmente indicam o fim de uma frase (ponto, ponto de interrogação, ponto de exclamação, etc.) e tratar as excepções relativamente à utilização desses sinais.

Em termos computacionais um texto é uma lista de listas com a seguinte representação:

(( Frase 1 ) ( Frase 2 ) .... ( Frase n ) )

## Analizador Morfológico

O Analizador Morfológico é na realidade o módulo inicial de processamento do texto. A sua função consiste em classificar morfológicamente as unidades lexicais básicas (palavras).

O seu objectivo último é o de facilitar na fase de aprendizagem a construção do Léxico Básico da Língua, a partir da leitura e processamento de uma apreciável quantidade de textos num dado domínio do conhecimento.

Na prática a sua principal característica consiste em, a partir do reconhecimento de uma palavra, propor ao analisador sintáctico uma ou várias Classificações Morfológicas possíveis para a palavra. A Análise morfológica de uma palavra é assim uma operação descontextualizada da sua posição numa determinada frase. Essa operação de desambiguação é feita posteriormente, na fase ou fases seguintes de processamento (Análise Sintáctica ou até na Análise Semântica).

O Analizador Morfológico é fundamentalmente um módulo de Consulta de um Léxico completo da Língua portuguesa, expresso numa estrutura computacional que se explicita seguidamente.

### Construção de um Léxico completo da Língua Portuguesa

A filosofia subjacente a todo o projecto é a de que se trata de construir um protótipo inteligente e assistido. Existe pois uma fase de aprendizagem do sistema.

A construção do léxico básico da língua é assim um dos objectivos dessa fase.

Internamente o Analizador Morfológico é composto por dois sub-módulos:

- Módulo de Consulta e apresentação a partir do Léxico;

- Módulo de validação de palavras novas, não existentes ainda no léxico, mas que possam ser Derivadas ou Compostas a partir de morfemas lexicais básicos da língua, já existentes no léxico.

No final do processamento o léxico é actualizado com a nova palavra, que passa assim a constituir conhecimento já adquirido pelo sistema para uso posterior.

### Estrutura do Léxico

O Léxico não é mais do que uma Base de Dados indexada por palavra, implementada fisicamente como um ficheiro binário de listas de estruturas próprias da maioria das linguagens de programação e de acordo com o seguinte formato:

( PALAVRA ( CLASSE\_1 ( RADICAL+AFIXO) ( ( FLEXÃO\_1 VALOR\_1) ... ( FLEXÃO\_N VALOR\_N )) (TRAÇO\_SEMÂNTICO1) (TRAÇO\_SEMÂNTICO\_2))

( CLASSE\_N ( RADICAL+AFIXO) ( ( FLEXÃO\_1 VALOR\_1) ... ( FLEXÃO\_N VALOR\_N )) (TRAÇO\_SEMÂNTICO\_1) ( TRAÇO\_SEMÂNTICO\_2)))

## Procedimentos de Composição e Derivação

O processo de formação das palavras é basicamente “ *um conjunto de processos morfo-sintácticos que permitem a criação de unidades novas da língua com base em morfemas lexicais. Utilizam-se assim, para formar palavras novas, os afixos de derivação ou os procedimentos de composição*<sup>5</sup>”.

### Processo de Derivação

O processo de derivação/composição faz-se através da aplicação de um conjunto de regras contidas numa base de conhecimento - BASE DE AFIKOS.

A Base de Afixos é no essencial uma base de dados de Afixos correntes da língua portuguesa (Prefixos e Sufixos) a que foram associados procedimentos de composição e regras da sua aplicação.

No essencial os Afixos são agrupados segundo a Categoria Morfológica dos Radicais a que são normalmente associados, gerando por esse processo sempre outras palavras de uma determinada Classe Morfológica.

Na implementação de um Analisador Morfológico, a grande discussão centra-se nas seguintes questões:

- Nunca é possível ter um léxico completo da língua. E será que se justifica ir tendendo para esse objectivo? O que é que custa, em termos de recursos e de tempo, manipular um léxico tendencialmente completo da língua?
- Se tivermos apenas um léxico básico da língua, teremos que recorrer amiúde ao processamento de regras de derivação e composição de palavras e de regras de reconhecimento de formas verbais. Porque não ir aproveitando esses resultados para evitar ter que repetir no futuro os mesmos processamentos?
- O léxico deve incorporar para cada entrada informação morfológica completa?

Um dado essencial nesta discussão será sempre o tipo de aplicação em que o analisador morfológico vai ser utilizado.

## Analisador Sintáctico

O objectivo é, a partir do *output* do **analisador morfológico**<sup>6</sup>, identificar, para cada frase, as várias orações e os seus termos constituintes, através da aplicação de um conjunto de regras gramaticais.

Mais uma vez o âmbito em que vai ser utilizado o analisador é uma questão essencial a ter em conta no momento de definir a sua arquitectura.

- Precisamos de uma análise sintáctica completa, ou é suficiente analisar os sintagmas nominais?
- Precisamos de validar os aspectos de concordância entre os vários elementos de uma oração, ou não?

No nosso caso, provavelmente seria suficiente o tratamento dos sintagmas nominais. Tentámos no entanto implementar um analisador sintáctico completo que poderia eventualmente ser utilizado em outras aplicações.

A primeira tentativa consistiu em seleccionar um conjunto suficientemente amplo de regras gramaticais e representá-las através de uma gramática formal (do tipo 2, independente do contexto, na classificação de Chomsky).

<sup>5</sup> Ver DUBOIS, Jean et alli. *Dictionnaire de Linguistique*: Paris, Larrousse, 1977.

<sup>6</sup> Ver Anexo 1

Primeiro problema: Se o conjunto de regras seleccionado não for suficientemente amplo, corremos o risco de fazer uma análise incorrecta ou de não conseguir reconhecer frases perfeitamente correctas do ponto de vista sintáctico. Se o conjunto de regras for mais completo, e dado que uma palavra pode pertencer a várias classes morfológicas, deparamo-nos com o problema da explosão combinatória: se os recursos da máquina permitirem, serão produzidas múltiplas análises para a mesma frase, tornando assim mais difícil escolher a apropriada.

### Processamento Preliminar

Dado que o **analisador morfológico** trata palavras, não tendo em consideração o contexto concreto, e que o **analisador sintáctico** deve, para cada palavra, escolher uma, de entre uma série de categorias morfológicas possíveis, cada frase é, numa fase preliminar do processamento, desdobrada segundo as várias combinações possíveis das categorias morfológicas a que cada palavra pode pertencer. Cada combinação constitui uma possibilidade<sup>7</sup> de classificação morfológica das palavras da frase que será validada (ou não) pela análise sintáctica.

### Implementação de uma GRAMÁTICA DA LÍNGUA PORTUGUESA

Trata-se aqui de encontrar as estruturas de dados e as técnicas de computação adequadas à representação das regras que constituem a GRAMÁTICA DA LÍNGUA PORTUGUESA e de encontrar uma forma de controlar a sua aplicação.

Numa primeira fase seleccionámos um conjunto suficientemente amplo de regras gramaticais que permitisse reconhecer o português escrito corrente e representámo-las como foi dito através de uma gramática formal (do tipo 2 na classificação de Chomsky),

$$G = \langle V_t, V_n, S, R \rangle$$

em que:

$V_t$  (vocabulário terminal) é constituído pelos símbolos representativos das categorias morfológicas e por  $\lambda$ , o símbolo vazio<sup>8</sup>;

$V_n$  (vocabulário não terminal) é constituído pelos símbolos representativos das categorias sintácticas e sintagmáticas e por outros símbolos auxiliares<sup>9</sup>;

$S$  (símbolo inicial) é o símbolo  $F$  representativo de uma frase;

$R$  é o conjunto de regras de reescrita, podendo cada regra incluir condições de aplicabilidade<sup>10</sup>.

Estas gramáticas têm as seguintes características:

- A parte esquerda de uma regra é constituída por **um e um só** elemento do vocabulário não terminal;
- A parte direita de uma regra obedece a uma única restrição - deve ser diferente da parte esquerda para evitar ciclos infinitos.

Esta última restrição levou-nos a adicionar ao vocabulário não terminal alguns símbolos auxiliares para o tratamento de estruturas de coordenação.

<sup>7</sup> Ver Anexo 2

<sup>8</sup> Ver Anexo 3

<sup>9</sup> Ver Anexo 4

<sup>10</sup> Ver Anexo 5

Este tipo de gramática é bastante utilizado em aplicações informáticas, tendo no entanto algumas limitações para representar os fenómenos linguísticos.

Problemas como o reconhecimento de constituintes descontínuos (não só ... mas também), a verificação das concordâncias e a resolução de anáforas e referências cruzadas não podem ser directamente tratados por este tipo de gramáticas.<sup>11</sup>

A tentativa de implementação deste tipo de gramática revelou-se altamente consumidora de recursos de processamento, nomeadamente de memória. Optámos então por um sistema mais pragmático de reconhecimento de padrões. O sistema faz a análise sintáctica comparando a estrutura morfológica da frase com padrões existentes *a priori*; se não encontra nenhum padrão aplicável, permite gerar um novo padrão de uma forma interactiva.

Ao nível da análise sintáctica abrem-se-nos desde logo um sem número de caminhos a explorar, nomeadamente:

- Estudar outras formas de implementação das regras gramaticais, utilizando outras ferramentas, nomeadamente ao nível do sistema operativo
- Estudar a possibilidade de integrar num mesmo sistema diversos métodos, inclusive métodos estatístico-probabilísticos.

### **Analizador Semântico**

Trata-se aqui de validar e interpretar o sentido de cada uma das frases que formam um texto, com o objectivo de produzir uma base de factos directamente utilizável no processo de indexação.

Vejamos alguns exemplos.

Ex1.:

O que é que uma frase como “*O peixe frito comeu o gato*” pode significar?

Do ponto de vista sintáctico a frase está correcta. Do ponto de vista semântico só podemos concluir uma de duas coisas: ou houve um erro e a frase correcta seria “*O gato comeu o peixe frito*” ou encontramos-nos no universo da ficção.

Como somos levados a tirar estas conclusões?

O sujeito do predicador comer deve ser uma entidade com vida, ou seja com o traço semântico [+ANIMADO].

Ex2.:

Na frase “*A Câmara de Fafe encerrou a lixeira de Passadouro*” é necessário perceber que

*A Câmara* é A Câmara Municipal do concelho de Fafe

e não A câmara de vídeo do Sr. Fafe.

Como é possível escolher a interpretação correcta?

---

<sup>11</sup> HAGÈGE, Caroline; DUARTE, Inês. - Construção de gramáticas formais para o processamento da linguagem natural. «Engenharia da Linguagem», Lisboa, Edições Colibri, 1995, p. 71-93.

Se soubermos que existe em Portugal uma localidade - FAFE que é sede de concelho e que em cada sede de concelho o órgão executivo do poder local é a Câmara Municipal poderemos, com uma grande probabilidade de não errar, escolher a primeira hipótese.

Ex3.:

Se estivermos a analisar um texto sobre a BIBLIOTECA DA FACULDADE DE CIÊNCIAS e se o termo eleito como descritor for BIBLIOTECA UNIVERSITÁRIA, é necessário que o conhecimento sobre a relação entre FACULDADE e UNIVERSIDADE permita concluir que a Biblioteca da Faculdade de Ciências é uma Biblioteca Universitária.

Para resolver estes problemas o Analisador Semântico explora e processa um conjunto de informação que se encontra armazenada

- em cada entrada do léxico, como uma lista de traços semânticos
- na base de predicadores
- na base de conhecimento

#### **Base de Predicadores**

A base de predicadores inclui, para cada predicador, a respectiva estrutura argumental, ou seja: que argumentos podem ocorrer, que argumentos devem obrigatoriamente estar presentes, qual a função semântica de cada um dos argumentos no esquema predicativo e que restrições (ao nível dos traços semânticos) existem ao desempenho dessas funções.<sup>12</sup>

Veja-se a título de exemplo um esquema predicativo possível para o verbo comprar. A acção de comprar, na sua acepção mais comum, exprime a transferência de propriedade de um objecto de uma entidade para outra. De outra forma, podemos dizer que o verbo comprar tem basicamente três argumentos: X, Y, Z

X - tem a função semântica de Agente e corresponde ao componente da frase com função sintáctica de Sujeito. Para que o Sujeito possa desempenhar esta função é necessário que o núcleo do Sintagma Nominal que o constitui tenha o traço semântico [+HUMANO].

Y - tem a função semântica de Objecto e corresponde ao componente da frase com função sintáctica de Objecto Directo.

(Z) - tem a função semântica de Origem e corresponde ao componente da frase com função sintáctica de Objecto Indirecto.

O argumento Z entre parêntesis indica que pode ser omitido.

A função da base de predicadores é sobretudo a de fornecer informação que possibilite a resolução das ambiguidades que ainda subsistam após a análise sintáctica

#### **Base de Conhecimento**

A base de conhecimento, que deve fornecer conhecimento de senso comum e conhecimento específico sobre o tema em análise, foi implementada sob a forma de uma rede semântica, cuja estrutura se exemplifica de seguida.

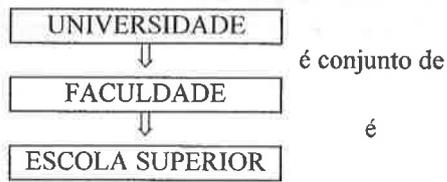
Temos a considerar fundamentalmente dois tipos de objectos: Nós e Arcos.

Os NÓS são objectos que representam um conceito sob a forma de uma ou mais palavras

Os ARCOS são objectos que relacionam nós; têm uma direcção, que identifica o nó de origem e o nó de destino, e uma etiqueta que exprime o tipo de relação existente entre esses nós.

---

<sup>12</sup> Veja-se a este propósito, BUSSE, Winfried.-Dicionário Sintáctico de Verbos Portugueses e MATEUS, Maria Helena Mira; e outros.-Gramática de Língua Portuguesa.



A função da base de conhecimento é produzir todas as inferências possíveis e adicioná-las à base de factos.

### Extractor de Descritores

A função do Extractor de Descritores é, a partir do Tesouro e da Base de Factos, seleccionar os descritores aplicáveis.

Cada descritor é internamente implementado como um conjunto de Regras que levam à sua escolha. A cada regra está associada uma probabilidade que indica a medida de aplicabilidade do descritor.

Uma regra é pois uma estrutura do tipo

SE <condição>

ENTÃO <descritor> com probabilidade <x>

## ANEXO 1

**O output do analisador morfológico é o input do analisador sintático.**

Trata-se de um ficheiro de texto constituído por frases. Uma frase é constituída por várias palavras. Cada palavra vem seguida de uma ou várias categorias morfológicas. Apresenta-se a seguir uma frase a título de exemplo.

```
((A (PREP () ()))  
  
  (ART_DEF () ((GEN F) (N SING)) ())  
  
  (PRO_PES_OB_AT () ((PES 3) (N SING) (GEN F)) ())  
  
  (PRO_DEM_VAR () ((N SING) (GEN F)) ()))  
  
(Câmara (S_COM () ((N SING) (GEN F) (GR NOR)) (ORG)))  
  
(de (PREP () ()))  
  
(Fafe (S_PRO () () (LOC)))  
  
(encerrou (VB_TD (ENCERRAR) ((N SING) (PES 3) (MD INDIC) (TP PRET_PERF)) ())  
  (VB_I (ENCERRAR) ((N SING) (PES 3) (MD INDIC) (TP PRET_PERF)) ()))  
  
(a (PREP () ()))  
  
  (ART_DEF () ((GEN F) (N SING)) ())  
  
  (PRO_PES_OB_AT () ((PES 3) (N SING) (GEN F)) ())  
  
  (PRO_DEM_VAR () ((N SING) (GEN F)) ()))  
  
(lixreira (S_COM (LIXO + EIRA) ((N SING) (GEN F) (GR NOR)) ()))  
  
(de (PREP () ()))  
  
(Passadouro (S_PRO () () (LOC))  
  (S_COM (PASSAR+DOURO) ((N SING) (GEN M) (GR NOR)) (LOC))))
```

## ANEXO 2

### Desdobramento de uma frase de *input* num conjunto de possibilidades

A frase apresentada como exemplo no ANEXO 1 é, durante o processamento preliminar, desdobrada em 64 possibilidades segundo as várias combinações das categorias morfológicas a que cada palavra pode pertencer.

A estrutura de cada uma destas possibilidades é semelhante à estrutura de uma frase de *input* com uma diferença: a cada palavra só corresponde uma categoria morfológica.

Durante o processamento muitas destas possibilidades serão rejeitadas por serem agramaticais, sendo retidas apenas as que correspondem a padrões sintáticos possíveis.

Exemplo de uma possibilidade:

1.

((A (PREP () ()))

(*Câmara* (S\_COM () ((N SING) (GEN F) (GR NOR)) (ORG)))

(*de* (PREP () ()))

(*Fafe* (S\_PRO () () (LOC)))

(*encerrou* (VB\_TD (ENCERRAR) ((N SING) (PES 3) (MD INDIC) (TP PRET\_PERF)) ()))

(*a* (PREP () ()))

(*lixreira* (S\_COM (LIXO + EIRA) ((N SING) (GEN F) (GR NOR)) ()))

(*de* (PREP () ()))

(*Passadouro* (S\_PRO () () (LOC)))

## ANEXO 3

### VI - VOCABULÁRIO TERMINAL

<i>s_pro</i>	-	substantivo próprio
<i>s_com</i>	-	substantivo comum
<i>s_abst</i>	-	substantivo abstracto
<i>art_def</i>	-	artigo definido
<i>art_ind</i>	-	artigo indefinido
<i>adj</i>	-	adjectivo
<i>num_car</i>	-	numeral cardinal
<i>num_ord</i>	-	numeral ordinal
<i>vb_td</i>	-	verbo transitivo directo
<i>vb_ti</i>	-	verbo transitivo indirecto
<i>vb_b</i>	-	verbo bitransitivo
<i>vb_i</i>	-	verbo intransitivo
<i>vb_lig</i>	-	verbo de ligação
<i>vb_ip</i>	-	verbo impessoal
<i>vb_aux</i>	-	verbo auxiliar
<i>prep</i>	-	preposição
<i>conj_coord</i>	-	conjunção coordenativa
<i>conj_sub</i>	-	conjunção subordinativa
<i>intj</i>	-	interjeição
<i>cont</i>	-	contração
<i>virg</i>	-	vírgula
<i>pt</i>	-	ponto
<i>pt_virg</i>	-	ponto e vírgula
<i>pt_pt</i>	-	dois pontos
<i>pt_int</i>	-	ponto de interrogação
<i>pt_excl</i>	-	ponto de exclamação
<i>ret</i>	-	reticências
<i>col</i>	-	aspas
<i>par</i>	-	parêntesis
<i>trv</i>	-	travessão
<i>λ</i>	-	vazio

## ANEXO 4

### Vn - VOCABULÁRIO NÃO-TERMINAL

F	-	FRASE
OR	-	ORAÇÃO
RF	-	RESTO DA FRASE
SU	-	SUJEITO
PRED	-	PREDICADO
SU_INV	-	SUJEITO INVERTIDO
EL_COORD	-	ELEMENTO DE COORDENAÇÃO
SN_COORD	-	SINTAGMAS NOMINAIS COORDENADOS
OR_SUBST	-	ORAÇÃO SUBORDINADA SUBSTANTIVA
SV	-	SINTAGMA VERBAL
SN	-	SINTAGMA NOMINAL
RSN	-	RESTO DE SINTAGMAS NOMINAIS COORDENADOS
EXP_VB	-	EXPRESSÃO VERBAL
COMPL_SV	-	COMPLEMENTOS DO SINTAGMA VERBAL
ESP_SN	-	ESPECIFICADORES DO SINTAGMA NOMINAL
PRE_COMPL_SN	-	PRÉ-COMPLEMENTOS DO SINTAGMA NOMINAL
NUC_SN	-	NÚCLEO DO SINTAGMA NOMINAL
POS_COMPL_SN	-	PÓS-COMPLEMENTOS DO SINTAGMA NOMINAL
VB	-	VERBO
LOC_VB	-	LOCUÇÃO VERBAL
OD	-	OBJECTO DIRECTO
OI	-	OBJECTO INDIRECTO
OBL	-	OBLÍQUO
PRED_OD	-	PREDICATIVO DO OBJECTO DIRECTO
PRED_SU	-	PREDICATIVO DO SUJEITO
X	-	Argumentos opcionais do predicador
DET	-	DETERMINANTE
QUANT	-	QUANTIFICADOR
EXP_QUAL	-	EXPRESSÃO QUALITATIVA
SADJ_COORD	-	SINTAGMAS ADJECTIVAIS COORDENADOS
S_COM_COORD	-	SUBSTANTIVOS COMUNS COORDENADOS
S_PRO_COORD	-	SUBSTANTIVOS PRÓPRIOS COORDENADOS
S_ABST_COORD	-	SUBSTANTIVOS ABSTRACTOS COORDENADOS
SPREP_COORD	-	SINTAGMAS PREPOSICIONAIS COORDENADOS
SADJ	-	SINTAGMA ADJECTIVAL
SPREP	-	SINTAGMA PREPOSICIONAL
RSADJ	-	RESTO DE SINTAGMAS ADJECTIVAIS COORDENADOS
RSCOM	-	RESTO DE SUBSTANTIVOS COMUNS COORDENADOS
RSPRO	-	RESTO DE SUBSTANTIVOS PRÓPRIOS COORDENADOS

ANEXO 5

R - ALGUNS EXEMPLOS DE REGRAS DE REESCRITA<sup>40</sup>

		CONDICÕES	OBSERVAÇÕES
F	→ OR RF		Uma frase é constituída por uma ou mais orações coordenadas.
OR	→ SU PRED		
OR	→ PRED		
OR	→ PRED SU INV		Caso de sujeito oculto, nulo ou indeterminado.
RF	→ λ	VB=vb i ∨ VB=vb <i>lig</i>	Caso de inversão do sujeito
RF	→ EL COORD OR RF		O resto da frase pode ser vazio, ou constituído por um elemento de coordenação seguido de uma ou mais orações.
SU	→ SN COORD		
PRED	→ SV		
SU INV	→ SN COORD		
SU INV	→ OR SUBST	VB=vb <i>lig</i>	
EL COORD	→ conj <i>coord</i>		
EL COORD	→ <i>virg</i>		
SN COORD	→ SN RSN		
OR SUBST	→ conj <i>sub</i> OR	conj <i>sub</i> =que se	
SV	→ EXP VB COMPL SV		
LOC VB	→ vb <i>aux</i> VB	MD VB-INF ∨ TP VB=GER ∨ TP VB=PART	
LOC VB	→ vb <i>aux prep</i> VB	MD VB-INF ∨ TP VB=GER ∨ TP VB=PART	
OD	→ SN COORD		
OD	→ OR SUBST		

<sup>40</sup> Em maiúsculas representam-se os símbolos não-terminais; em minúsculas e itálico representam-se os símbolos terminais.

## Bibliografia

- BUSSE, Winfried (coord.). - Dicionário sintático de verbos portugueses. Coimbra: Almedina, 1994. 449p. ISBN 972-40-0803-7.
- CAMARA JR., Joaquim Mattoso - Estrutura da língua portuguesa. Petrópolis: Editora Vozes, 1982. 125p.
- CUNHA, Celso; CINTRA, Luís F. Lindley. - Nova Gramática do Português Contemporâneo, 10ª ed. Lisboa: Edições Sá da Costa, 1994.
- DUBOIS, Jean et alli. *Dictionnaire de Linguistique*: Paris, Larrousse, 1977.
- GILCHRIST, Alan - The Thesaurus in Retrieval. London: Aslib, 1971. 184 p.
- HAGÈGE, Caroline; DUARTE, Inês. - Construção de gramáticas formais para o processamento da linguagem natural. «Engenharia da Linguagem», Lisboa, Edições Colibri, 1995, p. 71-93.
- HUMPHREY, Susanne M. - A knowledge-Based Expert System for Computer-Assisted Indexing. «IEEE Expert», Outono 1989.
- JUN-TAE KIM. - Semantic knowledge acquisition for information extraction from texts on parallel marker-passing computer. - University of Southern California, 1993.
- KELLER, Eric (ed.) - Fundamentals of Speech Synthesis and Speech Recognition. Basic Concepts, State of the Art and Future Challenges. Chichester: John Wiley and Sons. 1994. 379 p. (ISBN 0 471 94449 1).
- KITANO, Hiroaki - Speech-to-speech Translation. A massively Parallel Memory-Based Approach. Boston: Kluwer Academic Publishers. 1994. 193p. (ISBN 0 7923 9425 9).
- KNIGHT, G. NORMAN - The art of indexing. A guide to the indexing of books and periodicals. London: George Allen & Unwin, 1983. 218 p. (ISBN 0 04 029002 6).
- LANCASTER, F.W. - Vocabulary control for information retrieval. Arlington: Information Resources Press. 1986. (ISBN 0 87815 053 6).
- MARTINS, J. A. Legatheaux; MONTEIRO, Luís. - Linguagens formais e autómatos. Universidade Nova de Lisboa: Faculdade de Ciência e Tecnologia: Departamento de Informática, 1981.
- MATEUS, Maria Helena; e outros. - Engenharia da Linguagem. Lisboa: Edições Colibri; Faculdade de Letras da Universidade de Lisboa, 1995.
- MATEUS, Maria Helena; e outros. - Gramática da Língua Portuguesa, 4ª ed. Lisboa: Caminho, 1994.
- NINA, Nuno. - Visual Basic 3.00 for windows. Curso completo. Lisboa: FCA Editores de Informática, 1994. 288p. ISBN 972-722-024-X
- ROLE, François. - De la lettre au sens: les recherches en texte integral. «Documentaliste: Sciences de l'information». Paris: 30:3 (1993) p. 136-147.
- ROWLEY, Jennifer E. - Abstracting and Indexing. London: Clive Bingley, 1982. 155 p.
- SIBERTIN-BLANC, Martine - Nouvelles Technologies et Communication de l'information. Des besoins des utilisateurs l'ingenierie documentaires. Paris: ADBS, 1994. 277p. (ISBN 2 901046 71
- VAN SLYPE, Georges. - Les langages d'indexation: conception, construction et utilisation dans les systèmes documentaires. Paris: Les éditions d'organisation, 1987.