



PUC

Série: Monografias em Ciência da Computação

Nº 3/82

INDEXAÇÃO AUTOMÁTICA BASEADA EM MÉTODOS LINGÜÍSTICOS E
ESTATÍSTICOS E SUA APLICABILIDADE À LINGUA PORTUGUESA

Alexandre Andreevsky

Vitoriano Ruas

Departamento de Informática

PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO DE JANEIRO

RUA MARQUÊS DE SÃO VICENTE, 225 - CEP-22453

RIO DE JANEIRO - BRASIL

Departamento de Informática
Biblioteca

PUC/RJ - DEPARTAMENTO DE INFORMÁTICA

Série : Monografias em Ciência da Computação, Nº 3/82

Editor : Marco A. Casanova

Maio, 1982

M/5380

SETOR DE DOCUMENTAÇÃO E INFORMAÇÃO	
CÓDIGO / REGISTRO	DATA
5582	20/07/82
D. PT.º DE INFORMÁTICA	

INDEXAÇÃO AUTOMÁTICA BASEADA EM MÉTODOS LINGUÍSTICOS
E ESTATÍSTICOS E SUA APLICABILIDADE À LINGUA PORTUGUESA*

Alexandre Andreewski**

Vitoriano Ruas

* Trabalho parcialmente financiado pela FINEP.

** Centre National de La Recherche Scientifique, Université de Paris Sud, France.

ABSTRACT

This paper deals with the automatic indexing based on linguistic and statistical methods, whose aim is to allow the processing of documents in natural language.

We describe the main lines of a system called SPIRIT, that uses such methods, and that was developed for the French Languages by a group of researchers of the CNRS including the first author.

We finally consider some basic aspects of the applicability of those methods to the Portuguese Language.

RESUMO

Considera-se neste trabalho a indexação automática usando o processamento de documentos em linguagem natural. Isto é obtido com o auxílio de métodos linguísticos combinados com métodos estatísticos que permitem uma indexação ponderada.

A título ilustrativo descreve-se, em suas linhas gerais, um sistema de indexação desse gênero denominado SPIRIT, o qual foi desenvolvido por uma equipe do CNRS francês para o idioma local. Enfim, são tratados aspectos essenciais de sua adaptação à língua portuguesa.

PALAVRAS-CHAVE

Ambigüidade, análise sintática, entropia, estatística, filtros, indexação automática, indexação ponderada, Linguística, matrizes de precedência, método de aprendizado, proximidade, relações léxico-semânticas.

KEYWORDS

Ambiguity, automatic indexing, entropy, filters, linguistics, method of learning, precedence matrix, proximity, semantic relations, statistics, syntactical analysis, weighed indexing.

SUMÁRIO

1. INTRODUÇÃO.....	1
2. Componentes do Sistema.....	1
3. Fluxogramas de Processamento	3
3.1 - Tratamento de um Corpus.....	4
3.2 - Tratamento de uma Questão.....	5
4. Análise Sintática.....	7
5. O Método de Aprendizado.....	9
6. Relações Lexico-Semânticas.....	14
7. A Função de Entropia.....	16
8. Cálculo da Proximidade de um Documento com a pergun ta.....	17
9. O Problema da Adaptação do Sistema à Língua Portu - guesa.....	19
10. Conclusão.....	21
Bibliografia.....	22
Apêndice.....	23

1 - INTRODUÇÃO

Define-se indexação automática como a técnica de processamento eletrônico de documentos que visa a recuperação dos mesmos a partir de informações relativas ao seu conteúdo. Trata-se mais especificamente de obter os documentos que contêm o maior número de informações relativas a uma dada pergunta do usuário.

Vamos considerar neste trabalho técnicas de indexação automática baseadas em métodos linguísticos e estatísticos, com o objetivo de processar os documentos em linguagem natural. Tomamos como referência o sistema SPIRIT*, que é um sistema de indexação automática desse tipo, desenvolvido pelo primeiro autor em colaboração com P. Biquet, F. Debili, C. Fluhr e B. Pouderoux do Centre National de la Recherche Scientifique (CNRS) francês. Ele permite assim o armazenamento e a interrogação em linguagem natural, e com os tratamentos linguísticos a todos os níveis dos textos introduzidos no sistema, aliados a tratamentos estatísticos, permite ainda a realização de uma indexação ponderada dos documentos. Desta forma, em resposta a uma pergunta formulada ao sistema, também em linguagem natural, os documentos - resposta são classificados segundo um critério de proximidade semântica. As únicas intervenções manuais são as que dizem respeito à correção dos erros tipográficos, que, aliás, são detectados automaticamente pelo sistema.

2 - COMPONENTES DO SISTEMA

O sistema SPIRIT consiste nas componentes seguintes:

- 1º) Um dicionário (com + 250.000 formas em francês) que permite a análise morfológica dos textos. Em parti

* Système Syntaxique et Probabiliste d'Indexation et de Recherche d'Informations Textuelles.

cular, ele permite o reconhecimento da sinonímia, das variações paradigmáticas de uma palavra, tais como as formas conjugadas dos verbos, as variações em gênero e número de adjetivos, substantivos, etc, além de expressões idiomáticas como "por causa de". Além disso ele fornece todos os valores gramaticais de uma dada palavra como por exemplo "para", que tanto pode ser um verbo conjugado como uma preposição:

- 29) Algoritmos de análise sintática: Lembrando que entende-se por sintaxe o conjunto de regras que estabelecem as configurações de categorias de palavras consideradas corretas, a análise sintática é fundamental para determinar a categoria correta no texto de uma palavra ambígua como "para".

OBSERVAÇÃO: Trata-se portanto de um nível inferior de análise sintática, sendo que os níveis mais elevados são menos importantes para o sistema SPIRIT.

- 39) Algoritmos de análise semântica: Lembra-se que, de uma maneira geral, a semântica trata do conjunto de sistemas conceituais da língua. No sistema SPIRIT ela se reduz à identificação correta da relação palavra-designado que tenta-se determinar em função do contexto. Este último é elevado em conta graças às relações ditas lexico-semânticas tais como sujeito-verbo, verbo-complemento, substantivo-complemento, substantivos-adjetivo, etc, as quais são obtidas automaticamente por métodos ditos de "filtragem". Desta forma, por exemplo, "papel de carta" e "papel de vilão" serão automaticamente identificados como dois conceitos diferentes

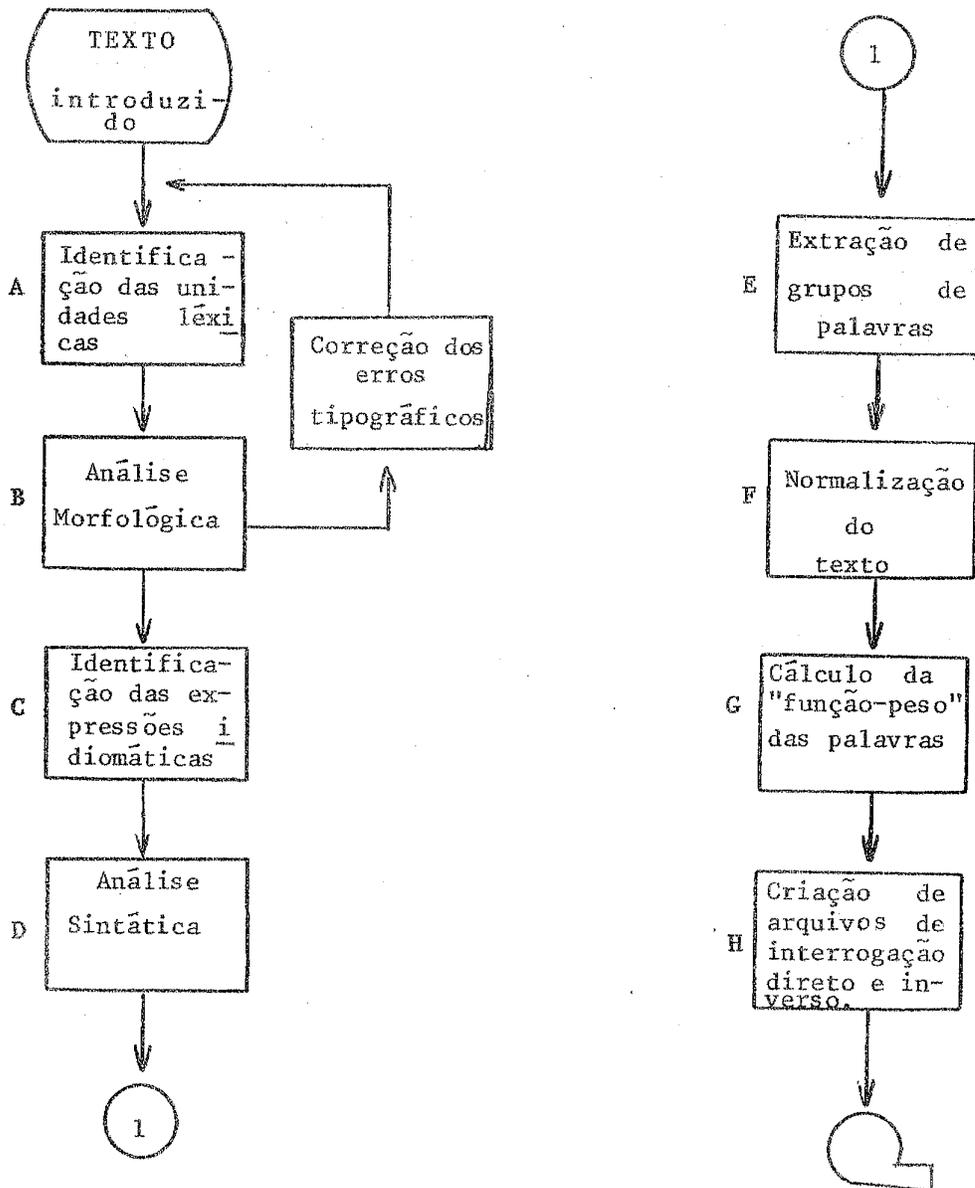
3 - FLUXOGRAMAS DE PROCESSAMENTO DE UM CORPUS* E DE UMA QUESTÃO

A cada etapa do processamento com o sistema SPIRIT representado no fluxograma abaixo, associamos uma letra que permitirá a referência à mesma no resto do artigo. Exceto as etapas D, E, G e I, que constituem, juntamente com as hipóteses de trabalho que se adotou, tratamentos específicos do sistema SPIRIT, as demais são comuns a todos os sistemas de indexação automática, a menos de variações não essenciais.

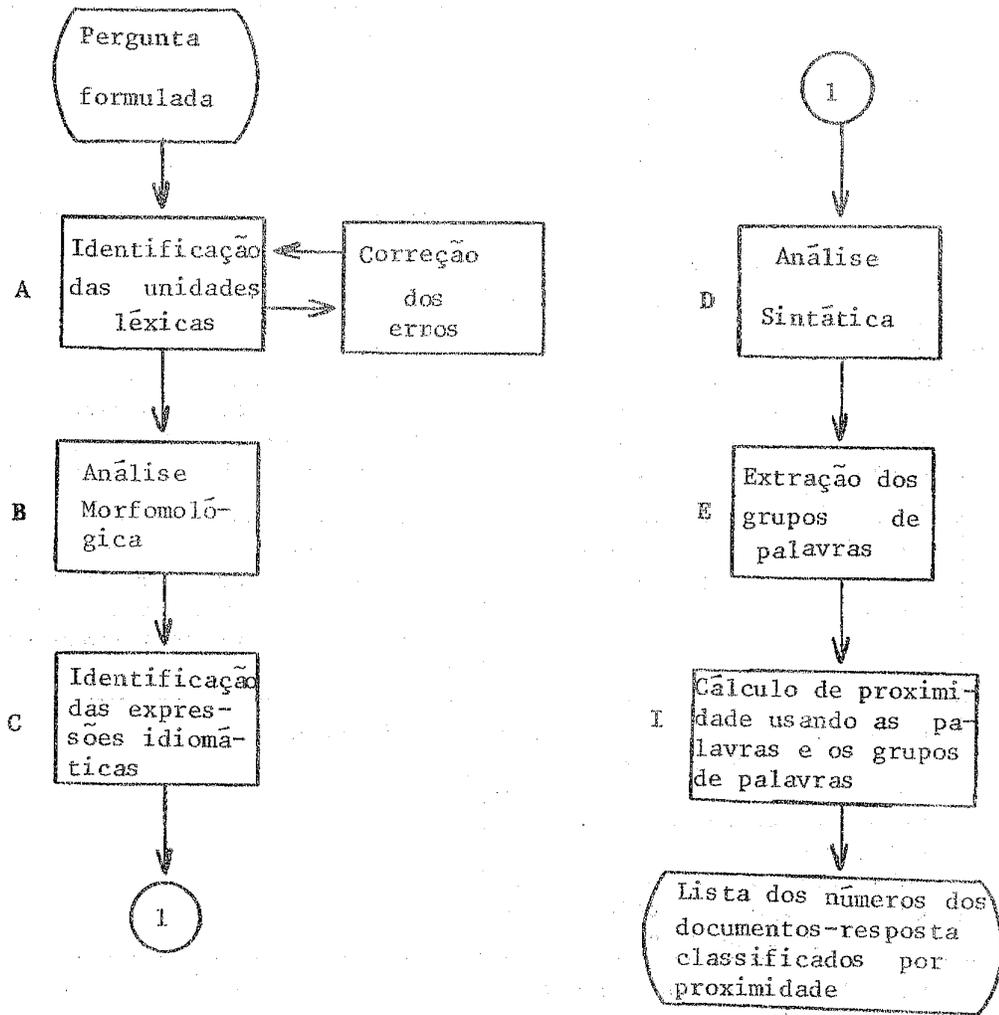
Vamos então nos deter em explicações sobre os pontos D, G e I. Sobre o ponto E daremos apenas alguns aspectos essenciais, já que sua descrição pormenorizada exige considerações bastante extensas, para as quais nos referimos a [1] e a [2]. Salientamos entretanto, que mesmo sem levar em conta a análise semântica, é possível obter respostas bastante pertinentes e satisfatórias.

* Um conjunto de documentos

3.1 - TRATAMENTO DE UM CORPUS



3.2 - TRATAMENTO DE UMA PERGUNTA EM LINGUAGEM NATURAL



Observa-se que, exceto o ponto I no fluxograma acima, todas as outras etapas do tratamento da pergunta são idênticas às do texto introduzido.

No quadro a seguir fornecemos sucintamente o objetivo e o meio usado pelo sistema SPIRIT para executar cada etapa do processamento:

	Objetivo	Meio
A	. Determinar as unidades léxicas como "guarda-chuva" e "dar" e "se" em "dar-se"	. Separadores: branco, hífen, após trofe, etc.
B	. Obter todas as categorias possíveis de uma palavra, reconhecer sinônimos e obter o representante de classe no caso de variação paradigmática de uma palavra	. Dicionário
C	. Reconhecer os grupos de palavras que correspondem a uma expressão idiomática como "por causa de"	. Dicionário
D	. Determinar a classe (categoria gramatical) correta das palavras no texto introduzido, preparar e facilitar a análise semântica.	. Regras de precedência de classes de palavras, de tipo binário, ternário, etc. (essas regras são armazenadas sob a forma de matrizes)*
E	. Extrair do texto os grupos de palavras que tem valor de conceito.	. As matrizes mencionadas acima e de, um modo geral, as relações léxicas mais importantes representadas por filtros linguísticos*
F	. Eliminar as palavras supérfluas (isto é, as que não tem valor informativo) tais como artigos, preposições, conjunções, etc. . Substituir uma palavra variação paradigmática pelo seu representante de classe.	. Dicionário
G	. Calcular o peso informativo de uma palavra.	. Contagem de frequência das palavras em cada documento. . Função de entropia*
H	. Criar os arquivos de interrogação. Direto: classificado por documento Inverso: classificado por palavra	. Classificação das palavras por ordem alfabética dentro do documento no direto, e incluindo sua entropia e os documentos em que figura no inverso

* Serão vistos de maneira mais detalhada.

4 - ANÁLISE SINTÁTICA

Ela é fundamental para levantar todas as ambigüida
des existentes numa língua, por causa do emprego de uma mes
ma palavra em funções distintas. Esse é essencialmente o fe
nômeno da homografia.

Como o computador encontrará no dicionário duas ou
mais categorias para tais palavras, será necessário levan -
tar a ambigüidade, procurando-se determinar a categoria gra
matical correta da palavra que corresponde ao seu emprego
no texto.

Vejamos um caso típico:

"Como são as travas para a sua cerca?"

Cada uma das palavras da frase acima é ambígua e,
consultando o dicionário se encontrará:

Como	: advérbio, conjunção, verbo conjugado	(3)
são	: verbo conjugado, substantivo, adjetivo	(3)
as	: artigo definido, pronome	(2)
travas	: substantivo, verbo conjugado	(2)
para	: preposição, verbo conjugado	(2)
a	: artigo definido, pronome, preposição	(3)
sua	: pronome possessivo, verbo conjugado	(2)
cerca	: substantivo, verbo conjugado, preposição*	(3)

Como seria preciso proceder para poder decidir que
categoria correta tem cada palavra na frase em termos de
processamento?

A abordagem mais chegada aos lingüistas, que prefe
rem em geral uma análise exaustiva da língua, corresponderia
a examinar todas as combinações possíveis das categorias e
a eliminar as que são falsas por comparação com uma espécie
de repertório de construções corretas da língua. Mas basta
observar um exemplo simples como a frase acima para se cons
tatar que tal procedimento conduziria ao exame de 1296 com

* Para ser rigoroso esta categoria é elemento de locação
prepositiva "cerca de".

combinações diferentes! Fica portanto evidente que tal abordagem é proibitiva do ponto de vista computacional, ainda mais porque as frases encontradas normalmente nos textos podem ser muito mais longas. Ademais, armazenar todas as combinações corretas de categorias gramaticais é completamente absurdo.

Por outro lado, é um fato incontestável que qualquer observador que conheça suficientemente a língua entende a frase acima corretamente, o que faz supor que em seu cérebro são ativados mecanismos para levantar a ambigüidade de cada palavra da cadeia, em função do contexto, isto é, das que a precedem ou a seguem. No sistema SPIRIT esse fato essencial foi levado em conta e de certa forma simulado. Na realidade, fez-se dele uma hipótese de trabalho da maneira ilustrada abaixo. Observemos que, por motivo de economia e de eficiência, somente o "contexto imediato" de cada palavra é considerado.

Seja então o exemplo:

" Tu nos deste uma grande ajuda nos momentos difíceis deste fim de mês ".

As palavras "nos" que aparecem na frase acima são ambíguas. Entretanto a presença do pronome "tu" (não ambíguo) antes da primeira e do substantivo "momentos" (não ambíguo) depois do segundo é suficiente para que se deduza que o primeiro é pronome (objeto indireto) e o segundo é a contração "em + os".

Se além disso tivéssemos que levantar a ambigüidade das palavras "deste" (além de "ajuda", etc.), constataríamos que não é preciso mais do que as "uma ou duas" palavras vizinhas para determinar suas categorias corretas.

E por esse motivo que matrizes de precedência foram introduzidas no sistema. Nessas matrizes cada linha corresponde à categoria gramatical da palavra que precede e cada coluna corresponde à categoria da palavra que sucede. Na sua forma mais simples, o termo da matriz será um ou ze

ro. No primeiro caso indica que a relação de vizinhança entre as duas categorias que correspondem à sua linha e sua coluna é verdadeira, e no segundo caso que é falsa.

Exemplo: Da frase acima concluimos que

PRONOME SUJEITO-PRONOME OBJETO INDIRETO = 1

PRONOME SUJEITO-CONTRAÇÃO PREPOSIÇÃO/ARTIGO = 0

CONTRAÇÃO PREPOSIÇÃO/ARTIGO-SUBSTANTIVO = 1

Nota-se que para podermos escrever o termo da matriz em termos de duas opções, fomos obrigados a criar duas categorias diferentes de pronomes. Na realidade o que ocorre é que em lingüística decidir entre "verdadeiro" e "falso" pode ser um procedimento demasiadamente estrito, pois pode-se estar rejeitando uma possibilidade de precedência entre categorias verdadeira, embora pouco freqüente na língua. É por isso que a alternativa 1 ou 0 foi substituída por freqüências de ocorrência da precedência calculadas em textos suficientemente longos, mas muito mais curtos dos que os que serão efetivamente submetidas ao processamento, uma vez definido um conjunto de categorias de trabalho em número razoável (um número muito grande de categorias poderia revelar pouco prático, ao passo que um número muito reduzido poderia fazer o método perder a eficiência) após estudo da língua em questão.

Aliás, o uso desses textos serve para estabelecer todas as regras de precedência armazenadas no sistema e deu-se o nome de método de aprendizado ao processo correspondente. É justamente esse método, que representa assim um papel essencial no procedimento usado para a construção do sistema SPIRIT, que vamos descrever a seguir.

5. O MÉTODO DE APRENDIZADO

Esse método é uma tentativa de reproduzir automaticamente os mecanismos que se supõe serem criados no cérebro humano, quando do aprendizado de uma língua natural e que, entre outras coisas, permitem decidir se uma construção de

frase é correta ou não. Seu uso para levantar ambigüidades no sistema SPIRIT justificou-se pela qualidade dos resultados obtidos.

Procede-se da forma seguinte:

Inicialmente é preciso definir um conjunto de categorias gramaticas em função de estudos linguísticos prévios, o qual pode ser aumentado tanto incluindo novas categorias, como subdividindo as já existentes, segundo a experiência adquirida e os resultados obtidos. Na sua versão francesa atual há 176 categorias no sistema SPIRIT. O método então funciona da seguinte maneira:

- 19) fornece-se ao computador um texto de aprendizado qualquer, contendo inicialmente cerca de 5000 palavras. Esse texto deve estar resolvido gramaticalmente, o que significa que cada palavra está associada à sua categoria correta no texto.
- 29) Constrói-se um dicionário de acúmulo onde as palavras do texto de aprendizado são classificadas por ordem alfabética e seguida de todas as categorias em que aparece no dito texto.
- 39) Constrói-se a seguir um texto ambíguo que nada mais é do que o texto de aprendizado com cada palavra seguida de todas as categorias diferentes em que aparece neste último texto.
- 49) Compara-se enfim o texto ambíguo com o texto de aprendizado e obtém-se automaticamente as regras corretas de precedência (ponderadas por frequência ou não) binárias, ternárias*, etc. segundo o número de palavras envolvidas na regra.

O processamento das quatro etapas acima pode ser ob

* A experiência mostra que não é necessário construir regras de ordem superior. Na realidade são as regras ternárias que são usadas no sistema SPIRIT, por terem melhores propriedades de inferência que as binárias.

tido, por exemplo, aumentando-se o texto de aprendizado ou alterando a lista de categorias gramaticais, o que permite a obtenção progressiva ou o abandono de regras de precedência.

A título ilustrativo do método, damos abaixo um exemplo de um pequenino texto de aprendizado. Sob cada palavra aparece sua categoria gramatical correta e abaixo desta aparece sua(s) outra(s) categoria(s) no texto entre parênteses, se for o caso.

Eu	me	caso	entre	a	Páscoa
PRONPES	PRONREFL	VERBCONJ	PREP	ARTDEF	SUBST
		(CONJ)	(VERBCONJ)	(PREP)	

e	o	fim	de	maio	caso
CONJ	ARTDEF	SUBST	PREP	SUBST	CONJ
					(VERBCONJ)

entre	a	curto	prazo	para	essa	firma.
VERBCONJ	PREP	ADJ	SUBST	PREP	PRONDEM	SUBST
(PREP)	(ARTDEF)					

As palavras ambíguas neste texto são então "caso", "entre" e "a". As abreviaturas usadas para as categorias são, cremos, de interpretação evidente.

Eis o dicionário de acúmulo:

a: ARTDEF, PREP
caso: CONJ, VERBCONJ
curto: ADJ
de : PREP
e : CONJ
entre: PREP, VERBCONJ
essa: PRONDEM
eu : PRONPES

fim : SUBST
maio : SUBST
me : PRONREFL
o : ARTDEF
para : PREP
Páscoa: SUBST
prazo: SUBST

O texto ambíguo é o texto de aprendizado quando se tira os parênteses e se considera indiferentemente uma categoria ou outra para as palavras ambíguas.

Por comparação dos dois textos obtêm-se assim as regras binárias, nas quais as resoluções compatíveis aparecem sublinhadas da mesma maneira, tais como:

⋮
PRONREFL × (CONJ , VERBCONJ)
(CONJ,VERBCONJ) × (PREP,VERBCONJ)
(PREP,VERBCONJ) × (ARTDEF,PREP)
⋮

De maneira análoga, obtêm-se as regras ternárias:

⋮
(PRONREFL × (CONJ,VERBCONJ) × (PREP,VERBCONJ)
(CONJ,VERBCONJ) × (PREP,VERBCONJ) × (ARTDEF,PREP)
(PREP,VERBCONJ) × (ARTDEF,PREP) × ADJ
⋮

Nota-se que as duas últimas regras binárias apresentadas são ambíguas.

No entanto a 1^a e a 3^a regras ternárias acima levam completamente essas ambigüidades. Nota-se que a 2^a regra acima, embora ternária é ambígua. Mas tal ambigüidade por sua vez será levantada pela aplicação em cadeia das três regras ternárias seguindo o texto. Aliás, como a aplicação das regras é sempre encadeada, pode-se levantar praticamente todas as ambigüidades nos textos a serem processados, desde que o texto de aprendizado utilizado para a formação das regras

seja suficientemente longo (+ 30.000 palavras em francês foram suficientes).

Imaginemos agora que se aplica a matriz de precedência binária* correspondente às regras obtidas por aprendizado ao texto:

"Leve um peso mais leve, que sua cara não sua tanto".

Obtêm-se sucessivamente, usando-se indiferentemente a precedência e a sequência:

Leve :	VERBCONJ, ADJ	→	VERBCONJ
um :	ARTINDEF	→	VERBCONJ
peso :	SUBST, VERBCONJ	→	SUBST
:			

As setas curvas acima partem da categoria que permite levantar a ambigüidade da palavra vizinha, cuja categoria correta é indicada pela seta reta.

6. AS RELAÇÕES LEXICO-SEMÂNTICAS

Para se obter respostas ainda mais pertinentes, é conveniente extrair não somente dos textos introduzidos como também das perguntas formuladas ao sistema, os grupos de palavras que tem valor de conceito. Com esse objetivo po de-se proceder também por aprendizado da maneira seguinte :

Fornece-se ao computador análises semânticas corre tas que correspondem a uma cadeia de categorias sujeita a certas restrições pré-estabelecidas, e ao mesmo tempo usa - se as regras de precedência obtidas pela análise sintática já descrita.

Na maioria dos casos, trata-se de extrair do texto cadeias do tipo $C_1 P_1 C_2 P_2 \dots C_i P_i$, onde os P_i são palavras - vínculo tais como as preposições e os C_i são, quer catego - rias gramaticas dadas, quer grupos de palavras ou ainda ou tras cadeias com estrutura fixa. Em geral as cadeias estuda das devem-se situar entre dois separadores como os sinais de pontuação, as conjunções, etc. As cadeias-modelo $C_1 P_1 C_2 P_2 \dots C_i P_i$, que poderão ou não corresponder a um todo semântico pertinente no texto examinado, se chamam filtros lingüísti cos.

Observa-se que os C_i e P_i podem ser contíguos ou não no texto, e caberá aos algoritmos incorporados ao siste - ma de torná-los contíguos. Esse é um problema bastante com plexo em geral, mas no caso de termos contíguos pode-se u sar técnicas simples como a de marcação com parênteses e com setas. O objetivo dos parênteses é o de agrupar pala - vras que tem um elo estreito entre si e o das setas é o de indicar as palavras-vínculo. Uma vez conhecidas as catego - rias gramaticais associadas às palavras envolvidas na cadei - a em estudo, obtêm-se as regras de formação binárias, terná - rias e de ordem superior. Como freqüentemente durante o pro cessamento essas regras criam situações contraditórias, ape la-se para a Estatística. De fato, aqui também se se deseja trabalhar com regras demasiado exclusivas, tais situações podem deturpar os resultados.

Vejamos o exemplo da cadeia:

"tratamento em hospital de um município".

Suponhamos que somente a regra seguinte se encontra armazenada:

"Da cadeia "SUBST₁ em ARTIGO SUBST₂ de ARTIGO SUBST₃"
extraí-se as relações semânticas: "SUBST₁ em ARTIGO SUBST₂"
"SUBST₂ de ARTIGO SUBST₃".

É claro que no caso do exemplo acima, obter-se-ia relações verdadeiras. Mas o que ocorreria no caso:

"tratamento em hospital de um ferimento" ?

A relação verdadeira "tratamento de um ferimento" não será identificada e em seu lugar figurará a relação falsa "hospital de um ferimento".

A melhor solução é pois a de armazenar as duas regras que tem a possibilidade de fornecer relações verdadeiras com pesos respectivos, que são calculados com base nas frequências de ocorrência no texto de aprendizado. Essas frequências, que poderão ser atualizadas a qualquer momento em função do corpus com que se vai trabalhar, permitem a tomada da decisão acertada no momento da interrogação.

Por exemplo, se a pergunta é:

"Em que casos se pode receber gratuitamente tratamento em hospital de um município de acidente automobilístico" ?

Suponhamos que se extraiu a cadeia preposicional seguinte, identificada por meio de um filtro linguístico adequado:

... tratamento em hospital de um município de acidente ...

e que se estabelece as relações : "tratamento-hospital" e "hospital-município".

A relação verdadeira "tratamento-acidente" não será extraída do texto se apenas relações contíguas são usadas (em seu lugar sairia " município de acidente"). Entretanto, com a estatística pode-se passar a seguir a uma pesquisa baseada em uma segunda regra, e a relação acima será encontrada, embora seu peso seja inferior.

7. A FUNÇÃO DE ENTROPIA

A entropia H de uma palavra normalizada* p com respeito a um conjunto d de N documentos d_1, d_2, \dots, d_N , é uma quantidade destinada a avaliar o caráter discriminativo dessa palavra, no sentido que, quanto mais sua entropia é baixa mais informativa é a palavra.

A entropia é dada por:

$$H(d/p) = - \sum_{i=1}^N P(d_i/p) \log_2 P(d_i/p)$$

onde $P(d_i/p)$ é a probabilidade de se obter o documento d_i dado que ele contém a palavra p . Tal probabilidade é dada pela fórmula de Bayes:

$$P(d_i/p) = \frac{P(p/d_i) P(d_i)}{\sum_{j=1}^N P(p/d_j) P(d_j)}$$

* Diz-se que uma palavra está normalizada se foi substituída por seu representante de classe, no caso em que ela pode ser considerada como uma variação paradigmática do mesmo.

Denotando-se por q a pergunta e por CP o cardinal ponderando,

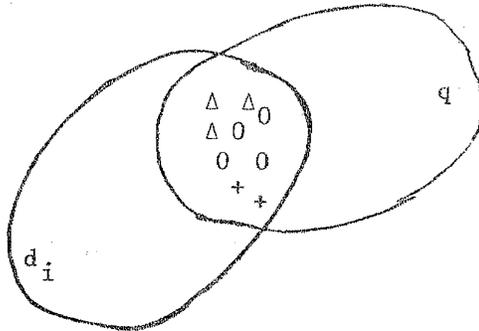
$$PROX(d_i) = \frac{CP(d_i \cap q)}{CP(d_i \cup q)}$$

onde $CP(S) = \sum_{i=1}^n [\log_2 N - H(p_i) + 1] = n + \sum_{i=1}^n [\log_2 N - H(p_i)]$

sendo que p_i é a i -ésima palavra de um conjunto S e n =cardinal de S .

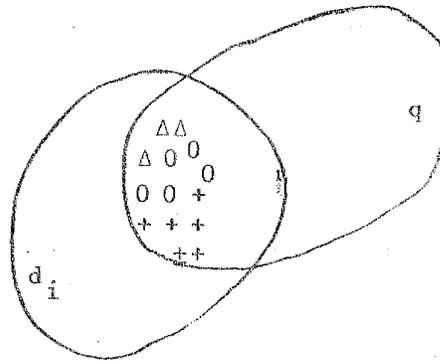
Esquemáticamente, pode-se representar o cardinal de $d_i \cap q$ com:

Sem considerar a entropia



duas palavras +
quatro palavras 0
três palavras Δ

Considerando a entropia



A figura acima indica que a palavra + é rara, ao passo que Δ pertence a todos os documentos e 0 a um número de documentos superior a um.

Denotando-se por q a pergunta e por CP o cardinal ponderando,

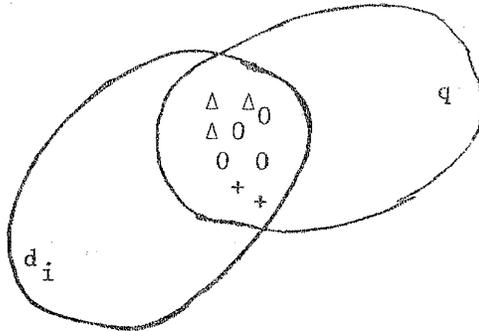
$$PROX(d_i) = \frac{CP(d_i \cap q)}{CP(d_i \cup q)}$$

onde $CP(S) = \sum_{i=1}^n [\log_2 N - H(p_i) + 1] = n + \sum_{i=1}^n [\log_2 N - H(p_i)]$

sendo que p_i é a i -ésima palavra de um conjunto S e n =cardinal de S .

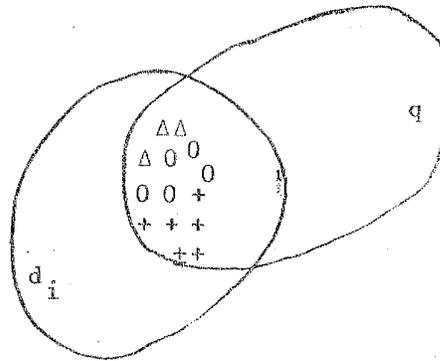
Esquemáticamente, pode-se representar o cardinal de $d_i \cap q$ com:

Sem considerar a entropia



duas palavras Δ
 quatro palavras 0
 três palavras Δ

Considerando a entropia



A figura acima indica que a palavra $+$ é rara, ao passo que Δ pertence a todos os documentos e 0 a um número de documentos superior a um.

9. O PROBLEMA DA ADAPTAÇÃO DO SISTEMA À LÍNGUA PORTUGUESA

Para se proceder a uma adaptação do sistema SPIRIT a uma outra língua, a análise das ambigüidades existentes nessa língua, assim como a possibilidade de levantá-las por métodos de aprendizado que levem em conta as propriedades posicionais de classes de palavras, constituem aspectos essenciais.

Essa adaptação ao inglês e ao espanhol revelou-se perfeitamente factível e está sendo realizada atualmente. No intuito de iniciar uma eventual adaptação à língua portuguesa, realizamos uma pesquisa de vocabulário visando a determinação dos tipos de pares, trincas, etc. de categorias gramaticais que correspondem a uma palavra ambígua. Redigimos também um texto de aproximadamente 300 palavras, o qual, embora gramaticamente correto, contém um número deliberadamente elevado de palavras ambíguas. As categorias associadas a cada palavra desse texto foram determinadas, o que já permite a construção automática de um número apreciável de regras de precedência envolvendo um número de categorias básicas.

Quanto aos tipos de ambigüidades que se pode encontrar na língua portuguesa, observamos que como em francês, as mais freqüentes são as do tipo:

SUBSTANTIVO/ADJETIVO como "armada"

SUBSTANTIVO/VERBO CONJUGADO como "arma(s)"

ADJETIVO/VERBO PARTICÍPIO como "armado"

Além disso, após consulta de alguns textos de gramática e de dicionários, constatou-se que, considerando-se apenas as categorias de palavras usuais, há apenas cerca de 40 palavras de uso corrente que correspondem a ambigüidades de outros tipo. Esse número é da ordem do dobro se não se leva em conta acentos gráficos.

Damos abaixo o texto de aprendizado proposto, no qual as palavras ambíguas se encontram sublinhadas uma vez. Se a palavra é empregada no próprio texto em categorias diferentes ela é sublinhada duas vezes.

ESTAÇÃO DE CAÇA 1981

A partir de hoje está aberta a estação de caça na reserva da mata municipal. Um extrato do regulamento a respeito é fornecido abaixo, conforme lei federal nº 9876 aprovada a 5/7/81.

1. Antes que entre na área de caça o caçador para obrigatoriamente no posto de fiscalização, onde deve apresentar à guarda sua autorização de caça. Esta a guarda para devolvê-la ao caçador se este volta são e salvo antes do por do sol, ou caso contrário, à família da vítima.
2. Está obrigado o uso de corrente de aço de tipo A5 a ser atada à presa no pescoço com mais de uma volta e meia e não direito, caso ela seja animal perigoso não decapitado.
3. Toda presa cujo peso seja superior a 100kg ou cobra venenosa, deve ser declarada à guarda de caça se capturada viva, salvo ausência desta última.
4. Se o animal capturado morto é destinado ao curtume a declaração ao partir é obrigatória, independentemente do peso.
5. Esta fiscalização se reserva o direito de confiscar toda presa que não esteja conforme às disposições acima, caso esta o consinta.
6. Pelo não respeito de cada item deste regulamento se cobra uma multa de \$500, a ser depositada na conta corrente da administração municipal no Banco Regional, de número 6789 (a menos de acordo entre cavalheiros pois quem não tem cão caça com gato).

O regulamento completo encontra-se afixado no local da fiscalização, assim como na estação mais próxima da mesma, no quadro ao lado do banco de espera reservado aos agen

tes funerários.

Lembra-se ainda aos distintos caçadores qe não se mata ser animal sem o respeito das regras elementares qe são aplicadas por eles em caso semelhante.

Muito obrigado em nome da fauna e

FELIZ CAÇADA !

A PREFEITURA MUNICIPAL

No apêndice deste trabalho é fornecida a lista de resoluções gramaticais corretas do texto acima. Nessa lista aparecem entre parênteses as demais categorias possíveis da palavra em questão. Salienta-se entretanto que o uso dessas categorias para a construção do texto ambíguo pode acelerar a obtenção das regras de precedência, embora, como vimos no parágrafo 5, não seja esse o procedimento usado pelo sistema SPIRIT.

10. CONCLUSÃO

O simples exame do texto de aprendizado acima permite conjecturar que, como o francês, o português é posicional, no sentido que um grande número de ambigüidades podem ser levantadas tendo em conta unicamente o contexto imediato.

Observa-se de passagem que essa conclusão não se aplica a qualquer língua. De fato, citando apenas alguns exemplos, constata-se que se as propriedades posicionais são muito menos marcantes em russo* e em certas línguas asiáticas como o japonês. Aliás, no caso desta última língua, é interessante observar que quando se usa a escrita fonética, o número de ambigüidades se revela extremamente elevado. Isso obviamente torna um sistema como o SPIRIT menos eficiente.

Voltando ao português, pode-se concluir que, muito

* Língua materna do primeiro autor.

provavelmente, os métodos estatísticos e de filtragem aqui descritos serão aproximadamente os mesmos que para o francês, podendo-se com isso esperar obter resultados comparáveis. Aliás, o texto de aprendizado dado acima, permite uma inicialização do trabalho lingüístico que se faz mister para se construir para o português um sistema de indexação automática baseado na metodologia aqui apresentada. Tal trabalho consistiria então na definição de categorias gramaticais, na construção do dicionário associado e na verificação da qualidade dos resultados, e pode-se estimar que bem dirigido ocuparia cerca de dois lingüistas durante dois a três anos.

Para finalizar, gostaríamos de observar que um sistema como o SPIRIT nos parece particularmente bem adaptado a corpus normativos como os jurídicos, legislativos, médico-terapêuticos, etc.

BIBLIOGRAFIA

- 1 - Andreevsky, A., Debili, F. & Fluhr, C.; Apprentissage-syntaxe sémantique lexicale, Revue du Palais de la Découverte, Vol. 9, 83, pp. 17-40, 1980.
- 2 - Andreevsky, A., Combrisson, F. & Fluhr, C., Le problème de l'identification automatique des concepts. Note du Service de documentation du Centre d'Etudes Nucleaires de Saclay, 8 CEA-N-1816, 1975.
- 3 - Andreevsky, A., Fluhr, C., Apprentissage-Analyse automatique du langage, application à la documentation. Dunod-doduments de Linguistique quantitative, N° 21, 1973.

APÊNDICE

RESOLUÇÃO GRAMATICAL DO TEXTO DE APRENDIZADO

Significado de algumas siglas e símbolos não evidentes:

PRONVER	:	Pronome verbal
ELOC	:	Elemento de locução
*	:	Indica categoria a excluir se os acentos gráficos são representados.
ARTGEN	:	Artigo generalizado
A	:	ELOCPREP, (PRONVER, ART, PREP, ELOCADJ, ELOCADV, PREPART *)
partir	:	ELOCPREP, (VERINF, VERCONJ, SUBST)
de	:	ELOCPREP, (PREP, ELOCADJ, VERCONJ*)
hoje	:	ADV
está	:	VERAUX, (VERCONJ, PRONDEM*, ARTDEM*)
aberta	:	VERPARTP, (ADJ)
a	:	ART, (PRONVER, PREP, ELOCPREP, ELOCADJ, ELOCADV, PREPART*)
estação	:	SUBST
de	:	PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
caça	:	SUBST, (VERCONJ)
na	:	PREPART
reserva	:	SUBST, (VERCONJ)
da	:	PREPART, (VERCONJ*)
mata	:	SUBST, (VERCONJ)
municipal	:	ADJ
Um	:	ART, (ADJNUM)
extrato	:	SUBST, (ADJ)
do	:	PREPART, (SUBST*)
regulamento	:	SUBST
a	:	ELOCADJ, (PRONVER, ART, PREP, ELOCPREP, ELOCADV, PREPART*)
respeito	:	ELOCADJ, (SUBST, VERCONJ)
é	:	VERAUX, (VERCONJ, CONJ*)
fornecido	:	VERPARTP, (ADJ)
abaixo	:	ADV

conforme : PREP, (ADJ)
 lei : SUBST
 federal : ADJ
 Nº : ELOCADJ
 9876 : ELOCADJ, (NUMERO)
 aprovada : ADJ, (VERPARTP)
 a : PREP, (PRONVER, ART, ELOCPREP, ELOCADJ, ELOCADV,
 PREPART*)
 5/7/81 : DATA
 Antes : ELOCCONJ, (ADV, ELOCPREP)
 que : ELOCCONJ, (CONJ, PROM, ELOCPRON, PRONREL, SUBST*)
 entre : VERCONJ, (PREP)
 na : PREPART
 área : SUBST
 de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
 caça : SUBST, (VERCONJ)
 o : ART, (PRON)
 caçador : SUBST
 passa : VERCONJ, (SUBST)
 e : CONJ, (VERAUX*, VERCONJ*)
 para : VERCONJ (PREP)
 obrigatoriamente : ADV
 no : PREPART, (SUBST*)
 posto : SUBST, (VERPARTP)
 de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
 fiscalização : SUBST
 onde : PRONREL, (ADV)
 deve : VERAUX, (VERCONJ)
 apresentar : VERINF, (VERCONJ)
 ã : PREPART, (PRONVER*, ART*, PREP*, ELOCPREP*,
 ELOCADJ*, ELOCADV*)
 guarda : SUBST, (VERCONJ)
 sua : PRONPOSS, (VERCONJ)

autorização : SUBST
 de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
 caça : SUBST, (VERCONJ)
 Esta : PRONDEM, (ARTDEM, VERAUX*, VERCONJ*)
 a : PRON, (ART, PREP, ELOCPREP, ELOCADJ, ELOCADV, PREPART*)
 guarda : VERCONJ, (SUBST)
 para : PREP, (VERCONJ)
 devolvê : VERINF, (VERCONJ)
 la : VERINFPRON, (SUBST*)
 ao : PREPART
 caçador : SUBST, (ADJ)
 se : CONJ, (PRONVER, SUBST*, PRONIND)
 este : PRONDEM, (ARTDEM, SUBST)
 volta : VERCONJ, (SUBST)
 são : ADJ, (VERAUX, VERCONJ)
 e : CONJ, (VERAUX*, VERCONJ)
 salvo : ADJ, (VERPARTP, PREP)
 antes : ELOCPREP, (ELOCCONJ, ADV)
 do : ELOCPREP, (SUBST*)
 por : VERINF*, (PREP)
 do : PREPART, (SUBST*)
 sol : SUBST
 ou : CONJ
 caso : ELOCADV, (SUBST, VERCONJ, CONJ)
 contrário : ELOCADV, (SUBST, ADJ)
 ã : PREPART, (PREP*, PRON*, ART*, ELOCPREP*, ELOCADJ*,
 ELOCADV*)
 família : SUBST
 da : PREPART, (VERCONJ*)
 vítima : SUBST, (VERCONJ*)
 Está : VERAUX, (VERCONJ, PRONDEM*, ARTDEM*)
 obrigado : VERPARTP, (ADJ)
 o : ART, (PRONVER)
 uso : SUBST, (VERCONJ)
 de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
 corrente : SUBST, (ADJ)
 de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)

ação : SUBST
 de : ELOCADJ, (PREP, ELOCPREP, VERCONJ*)
 tipo : ELOCADJ, (SUBST)
 A5 : ELOCADJ
 a : PREP, (PRON, ART, ELOCPREP, ELOCADJ, ELOCADV, PREPART*)
 ser : VERAUX, (VERINF, SUBST)
 atada : VERPARTP, (ADJ)
 ã : PREPART, (PRON*, ART*, PREP*, ELOCADJ*, ELOCADV*, ELOCPREP*)
 presa : SUBST, (ADJ)
 no : PREPART, (SUBST*)
 pescoço : SUBST
 com : PREP
 mais : ADVCOMP., (ADV, ELOCCONJ, ELOCADV, SUBST)
 de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
 uma : ADJNUM, (ART)
 volta : SUBST, (VERCONJ)
 e : CONJ, (VERAUX*, VERCONJ*)
 meia : ADJ, (SUBST)
 e : CONJ, (VERAUX*, VERCONJ*)
 não : SUBST, PREPART*
 direito : ADJ, SUBST, ADV
 caso : CONJ, (SUBST, VERCONJ, ELOCADV)
 ela : PRON
 seja : VERCONJ, VERAUX
 animal : SUBST, ADJ
 perigoso : ADJ
 não : ADVNEG
 decapitado : ADJ, VERPARTP
 Toda : ARTGEN
 presa : SUBST, ADJ
 cujo : PRONREL
 peso : SUBST, (VERCONJ)
 seja : VERCONJ, (VERAUX)
 superior : ADV, (SUBST, ADJ)
 a : PREP, (PRON, ART, ELOCPREP, ELOCADJ, ELOCADV, PREPART*)

100 : ADJNUM
 Kg : SIGLA
 ou : CONJ
 cobra : SUBST, (VERCONJ)
 venenosa : ADJ
 deve : VERAUX, (VERCONJ)
 ser : VERAUX, VERINF, SUBST
 declarada : VERPARTP, (ADJ)
 à : PREPART, (PREP*, PRON*, ART*, ELCOPREP*, ELOCADJ*, ELOCADV*)
 guarda : SUBST, (VERCONJ)
 de : PREP, (ELOCOPREP, ELOCADJ, VERCONJ*)
 caça : SUBST, (VERCONJ)
 se : CONJ, (PRONVER, SUBST*, PRONIND)
 capturada : VERPARTP, (ADJ)
 viva : ADJ, (VERCONJ, INTERJ)
 salvo : PREP, (ADJ, VERPARTP)
 ausência : SUBST
 da : PREPART, (VERCONJ*)
 mesma : PRONDEM, (ADJ)
 Se : CONJ, (PRON, PRONREFL, SUBST*)
 o : ART, (PRON)
 pelo : SUBST, (PREPART)
 do : PREPART, (SUBST)
 animal : SUBST, (ADJ)
 capturado : VERPARTP, (ADJ)
 morto : ADJ, (SUBST, VERPARTP)
 é : VERCONJ, (VERAUX, CONJ*)
 destinado : ADJ, (VERPARTP)
 ao : CPREPART
 curtume : SUBST
 a : ART, (PRON, PREP, ELOCOPREP, ELOCADJ, ELOCADV, PREPART*)
 declaração : SUBST
 ao : CPREPART
 partir : SUBST, (VERINF, VERCONJ, ELOCOPREP)
 é : VERCONJ, (VERAUX, CONJ*)
 obrigatória : ADJ

independentemente : ADV
do : CPREPART, (SUBST*)
peso : SUBST, (VERCONJ)
Esta : ARTDEM, (VERBAUX, VERBCONJ, PRONDEM)
fiscalização : SUBST
se : PRONREFL, (PRONVER, CONJ, SUBST*)
reserva : VERCONJ, (SUBST)
o : ART, (PRON)
direito : SUBST, (ADJ, ADV)
de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
confiscar : VERINE, (VERCONJ)
toda : ARTGEN
presa : SUBST, (ADJ, VERPARTP)
que : PRONREL, (PRON, CONJ, ELOCCONJ, ELOCPRON, SUBST*)
não : ADVNEG
esteja : VERCONJ, (VERAUX)
conforme : ADJ, (PREP)
ãs : PREPART, (PRON*, ART*, SUBST*)
disposições : SUBST
acima : ADJ, (ELOCADV)
caso : CONJ, (SUBST, ELOCADV, VERCONJ)
esta : PRONDEM, (ARTDEM, VERAUX*, VERCONJ)
o : PRONVER, (ART)
consinta : VERCONJ
Pelo : PREPART, (SUBST)
não : ADJNEG, (ADVNEG)
respeito : SUBST, (VERCONJ, ELOCADJ)
de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
cada : ARTGEN
Ítem : SUBST
deste : PREPPRONDEM, (VERCONJ)
regulamento : SUBST
se : PRONIMP, (PRONVER, CONJ, SUBST*)
cobra : VERCONJ, (SUBST)
uma : ART, (ADJNUM)
multa : SUBST, (VERCONJ)
de : PREP, (ELOCPREP, ELOCADJ, VERCONJ*)
S : SIGLA
500 : ADJNUM

a : PREP, (PRON, ART, ELOCPREP, ELOCADJ, ELOCADV,
 PREPART*)
 ser : VERAUX, (VERINF, SUBST)
 depositada : VERPARTP, (ADJ)
 na : PREPART
 conta : SUBST, VERCONJ
 corrente : ADJ, SUBST
 da : PREPART, VERCONJ*
 administração : SUBST
 municipal : ADJ
 no : CPREPART, (SUBST*)
 banco : SUBST, (VERCONJ)
 regional : ADJ
 de : ELOCADJ, (PREP, ELOCPREP, VERCONJ*)
 número : ELOCADJ, (SUBST)
 6789 : ELOCADJ, (NUMERO)
 a : ELOCPREP, (PRON, ART, PREP, ELOCADJ, ELOCADV,
 PREPART*)
 menos : ELOCPREP, (ADV, SUBST, ELOCCONJ)
 de : ELOCPREP, (PREP, ELOCADJ, VERCONJ*)
 acordo : SUBST, (VERCONJ)
 entre : PREP, (VERCONJ)
 cavalheiros : SUBST
 pois : CONJ
 quem : PRON
 não : ADVNEG
 tem : VERCONJ, (VERAUX)
 cão : SUBST
 caça : VERCONJ, (SUBST)
 com : PREP
 gato : SUBST
 O : ART, (PRON)
 regulamento : SUBST
 completo : ADJ
 encontra : VERAUX, (VERCONJ)
 se : PRONREFL, (PRON, CONJ)
 afixado : VERPARTP, (ADJ)
 no : PREPART
 local : SUBST, (ADJ)

da : PREPART, (VERCONJ)
 fiscalização : SUBST
 assim : ELOCCONJ, (ADJ)
 como : ELECCONJ, (ADV, VERCONJ)
 na : PREPART
 estação : SUBST
 mais : ADV, (ELOCCONJ, ELOCADV, SUBST, ADVCOMP)
 próxima : ADJ
 da : PREPART
 mesma : PRONDEM, (ADJ)
 no : PREPART, SUBST*
 quadro : SUBST
 ao : ELOCPREP, (PREPART)
 lado : ELOCPREP, (SUBST)
 do : ELOCPREP, (PREPART, SUBST*)
 banco : SUBST, (VERCONJ)
 de : PREP, (ELOCPREP, ELOCADJ, VERBCONJ*)
 espera : SUBST, (VERCONJ)
 reservado : ADJ, (VERPARTP, SUBST)
 aos : PREPART
 agentes : SUBST
 funerários : ADJ
 Lembra : VERCONJ
 se : PRONIND, (PRONVER, CONJ, SUBST*)
 ainda : ADV, (ELOCCONJ)
 aos : PREPART
 distintos : ADJ, (SUBST)
 caçadores : SUBST, (ADJ)
 que : CONJ, (PRONREL, PRON, ELOCCONJ, ELOCPRON, SUBST*)
 não : ADVNEG
 se : PRONIND, (PRONVER, CONJ, SUBST*)
 mata : VERCONJ, (SUBST)
 ser : SUBST, (VERAUX, VERCONJ)
 animal : ADJ, (SUBST)
 sem : PREP
 o : ART, (PRONVER)
 respeito : SUBST, (VERCONJ)

das : PREPART
 regras : SUBST
 elementares : ADJ
 que : PRONREL, (CONJ, PRON, ELOCCONJ, ELOCPRON, SUBST*)
 são : VERAUX, (VERCONJ, ADJ, SUBST)
 aplicadas : VERPARTP, (ADJ)
 por : PREP, (VERINF)
 eles : PRON
 em : PREP, (ELOCPREP)
 caso : SUBST, (VERCONJ, CONJ, ELOCADV)
 semelhante : ADJ, (SUBST)
 Muito : ADV, (ADJ)
 obrigado : INTERJ, (ADJ, VERPARTP)
 em : ELOCPREP, (PREP)
 nome : ELOCPREP, (SUBST)
 da : ELOCPREP, (PREPART, VERCONJ*)
 fauna : SUBST
 e : CONJ, (VERAUX*, VERCONJ*)
 feliz : ADJ
 caçada : SUBST, (VERPARTP, ADJ)
 A : ART, (PRONVER, PREP, ELOCPREP, ELOCADJ, ELOCADV,
 PREPART*)
 Prefeitura : SUBST
 Municipal : ADJ