

OTHERO, Gabriel de Ávila. Algumas considerações sobre a importância da continuidade tópica na classificação automática de documentos digitais. *Revista Virtual de Estudos da Linguagem – ReVEL*. V. 2, n. 3, agosto de 2004. ISSN 1678-8931 [www.revel.inf.br].

## **ALGUMAS CONSIDERAÇÕES SOBRE A IMPORTÂNCIA DA CONTINUIDADE TÓPICA NA CLASSIFICAÇÃO AUTOMÁTICA DE DOCUMENTOS DIGITAIS**

**Gabriel de Ávila Othero<sup>1</sup>**

`gabriel_othero@terra.com.br`

### **Introdução**

Hoje em dia, empresas, universidades e centros de pesquisa estão utilizando cada vez mais documentos digitais – tais como livros virtuais, artigos on-line, bancos virtuais de teses etc. Além de resolver o problema do espaço físico (criando, em contrapartida, o problema do espaço virtual), o uso de textos digitais possibilita o intercâmbio praticamente instantâneo de documentos entre instituições de qualquer ponto do planeta. Cada vez mais estão aparecendo bibliotecas inteiras na rede, contendo exclusivamente livros virtuais (ou e-books)<sup>2</sup>, além de *sites* de jornais e revistas que disponibilizam todos seus textos on-line<sup>3</sup>.

No entanto, à medida que mais documentos digitais vão surgindo na rede e entrando no dia-a-dia de empresas e instituições acadêmicas, surge um grande desafio: conseguir classificar e organizar esses documentos digitais de maneira eficiente. Utilizar para isso uma classificação manual pode ser bastante dispendioso, lento e oneroso para as

---

<sup>1</sup> Aluno do Programa de Pós-graduação em Letras, área de Linguística Aplicada, pela Pontifícia Universidade Católica do Rio Grande do Sul; bolsista de pesquisa do CNPq.

<sup>2</sup> Veja Virtualbooks ([www.virtualbooks.com.br](http://www.virtualbooks.com.br)) e Project Gutenberg ([www.gutenberg.net](http://www.gutenberg.net)), por exemplo.

<sup>3</sup> Veja o *site* dos jornais Folha de S. Paulo ([www1.folha.uol.com.br/fsp/](http://www1.folha.uol.com.br/fsp/)) e Zero Hora ([www.zh.com.br](http://www.zh.com.br)), por exemplo.

instituições. Uma tarefa e – um desafio – que se apresenta para os pesquisadores da área de Processamento de Linguagem Natural (PLN) e da Linguística Computacional é a classificação automática de documentos digitais. Afinal, uma vez estando no computador, por que não utilizar *softwares* que façam o penoso trabalho de ler toda uma obra antes de classificá-la de acordo com o tema ou assunto? Ou seja, já que temos livros e documentos virtuais, por que não termos também classificadores virtuais e programas que possam trabalhar como verdadeiros “bibliotecários digitais”?

Os classificadores automáticos ou semi-automáticos parecem ser a chave para solucionar o problema de se lidar com enormes quantidades de textos e documentos digitais. Além de serem ágeis e rápidos, programas desse tipo em geral não representam grandes custos para instituições, empresas, ou mesmo para usuários particulares. No entanto, a classificação automática ainda está em seus estágios iniciais, uma vez que ela tenha surgido para solucionar um problema relativamente recente, da era digital.

Neste trabalho, discutiremos a importância que estudos em sintaxe funcional sobre manutenção de tópico no discurso podem ter para aplicações em PLN, especificamente com relação aos classificadores automáticos de textos e documentos digitais. Na seção 1, analisaremos os métodos empregados nos trabalhos de classificação automática de textos digitais apresentados em Langie (2003) e Langie & Lima (2003), tentando mostrar que, se fossem desenvolvidos alguns recursos que levassem em conta teorias funcionais sobre a manutenção de tópicos discursivos no processo de classificação automática, a precisão dos classificadores automáticos de texto poderia ser ainda mais acurada.

Na seção 2, veremos como se dá a manutenção tópica no discurso, baseando-nos nas ideias de Givón (1979, 1992) e Ariel (1988), principalmente, e iremos propor que essas teorias sejam levadas em consideração no desenvolvimento de programas que classifiquem textos digitais quanto ao tema ou assunto. Mostraremos que palavras importantes na manutenção tópica (em especial os pronomes pessoais do caso reto) são subestimados ou mesmo ignorados por programadores no desenvolvimento de ferramentas de classificação automática de textos.

## **1. Sobre a Classificação Automática de Textos**

A Classificação Automática de Textos (CT), como vimos, poderá ajudar instituições que lidam com grandes quantidades de documentos digitais. Programas automáticos ou semi-automáticos de classificação de documentos poderão auxiliar bibliotecas virtuais e convencionais, além de refinar grandes sites de busca como o Yahoo!<sup>4</sup> e o Google<sup>5</sup>.

De acordo com Sebastiani (2002)<sup>6</sup>, a CT pode ser definida da seguinte forma:

A categorização de textos é a tarefa de atribuir um valor booleano {T, F} para cada par  $(d_j, c_i) \in D \times C$ , onde  $D = \{d_1, \dots, d_{|D|}\}$  é um conjunto de documentos e  $C = \{c_1, \dots, c_{|C|}\}$  é um conjunto pré-definido de categorias.

Em outras palavras, a classificação automática consiste em classificar um documento digital em uma determinada categoria, de acordo com critérios estabelecidos *a priori* por programadores humanos. Essa classificação geralmente respeita uma estrutura hierárquica, utilizando “uma árvore de categorias, permitindo que os documentos sejam classificados tanto nas folhas quanto nos nodos intermediários” (Langie & Lima, 2003: 3).

Langie & Lima (2003: 2) explicam que,

com a utilização de uma estrutura hierárquica de categorias, o processo de classificação pode ser decomposto em subprocessos menores, nos quais a quantidade de variáveis envolvidas é reduzida. Conforme Koller e Sahami, em [Koller,1997]<sup>7</sup>, categorias que se encontram próximas, dentro da estrutura hierárquica, possuem, em geral, mais características em comum do que outras categorias.

Dessa forma, uma palavra como *lingüista* pode não ser muito esclarecedora para ajudar a classificar um texto entre as categorias *Sintaxe*, *Semântica* ou *Fonologia*, mas poderá ser um bom atributo para diferenciar textos entre categorias maiores, como *História*, *Medicina* ou *Lingüística Aplicada*.

Veja um exemplo de uma árvore de categorias utilizada por Langie & Lima (2003: 5):

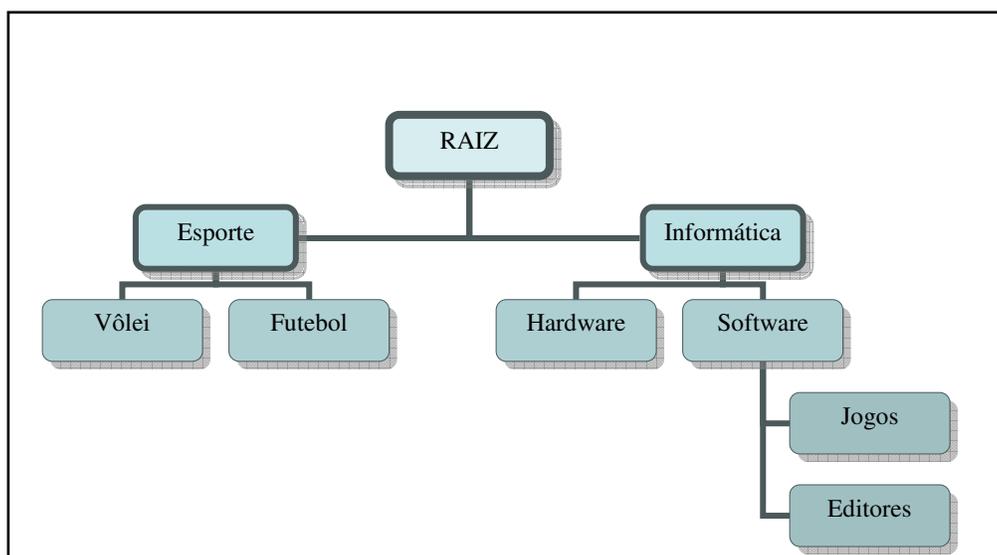
---

<sup>4</sup> www.yahoo.com

<sup>5</sup> www.google.com

<sup>6</sup> SEBASTIANI, F. (2002). Machine learning in automated text categorization. *ACM Computing Surveys* 34, 1, apud Langie (2003: 6).

<sup>7</sup> KOLLER, D.; SAHAMI, M. (1997). Hierarchically classifying documents using very few words. *Proceedings of ICML-97, 14th International Conference on Machine Learning*.



**Figura 1:** Exemplo de árvore de categorias

Basicamente, a tarefa de um classificador automático é “ler” os textos e classificá-los em categorias ou subcategorias pré-estabelecidas pelos programadores humanos. Durante a “leitura” do texto, o programa irá comparar uma série de palavras que aparecem no texto-alvo com as palavras que ele já conhece. A partir daí, ele irá tentar classificar este texto-alvo dentro de uma categoria, baseando-se no número de ocorrência das palavras-chave que apareceram no documento. Dentre as palavras que o classificador conhece, há palavras com mais valor semântico e outras com menor valor semântico. Isso quer dizer que algumas palavras recebem valores mais altos do que outras na escala de importância na classificação do texto: “o peso na composição dos vetores é a combinação de fatores conhecida como TFC [Salton e Buckley, 1988]<sup>8</sup>. Nessa combinação, termos mais importantes recebem peso próximo a 1 e termos menos importantes recebem valores próximos a zero” (Langie & Lima, 2003: 8).

Ainda de acordo com Langie & Lima (2003: 8), estas são as principais etapas por que passam os documentos digitais até serem classificados devidamente:

Antes de terem suas representações geradas, os documentos passam por uma etapa de *pré-processamento*. Nesta etapa os termos dos documentos são

<sup>8</sup> SALTON, G.; BUCKLEY, C. (1988). Term-Weighting Approaches in Automatic Text Retrieval. *Information Processing e Management*, Vol. 24 n. 5.

colocados em minúsculas, e caracteres de pontuação e dígitos são eliminados. Além disso, aplica-se uma seleção de atributos com a remoção de *stopwords* (artigos, advérbios, conjunções, numerais, preposições, pronomes, e verbos de ligação). A lista de *stopwords* contém 365 termos. Atributos também são selecionados com a remoção de termos cuja frequência do documento (FD) é inferior a 3. A FD de um termo *t* corresponde ao número de documentos nos quais *t* ocorre pelo menos uma vez. Conforme [Yang e Pederson, 1997]<sup>9</sup> (**sic**) o princípio da seleção de atributos usando FD é que termos raros não são informativos para predizer a categoria de um documento e também não influenciam no desempenho do classificador.

Não iremos nos concentrar no funcionamento dos classificadores automáticos de textos em si (para isso, remetemos o leitor para Langie, 2003, Langie & Lima, 2003, e Garside, Leech & McEnery, 1997). O que nos chama atenção aqui são basicamente dois fatores sobre o procedimento desses classificadores: (a) a lista das chamadas *stopwords*; e (b) o critério utilizado pelos programadores para classificar uma palavra em “relevante” ou “não-relevante” na determinação do assunto do texto.

Na lista de *stopwords*, encontram-se todas aquelas palavras que aparentemente não desempenham um papel importante na classificação automática dos textos de acordo com o tema ou assunto. São palavras que não deveriam apresentar carga semântica relevante, tendo, em geral, um papel meramente funcional no texto. Nessa lista, entram palavras como artigos, advérbios, conjunções, numerais, preposições, *pronomes*, e verbos de ligação. No entanto, como veremos na próxima seção, acreditamos firmemente que os pronomes são o principal mecanismo de manutenção tópica em um texto, tendo, por isso, um valor fundamental para qualquer classificador que se baseie no número de ocorrência de determinado objeto-de-discurso, ou entidade, no texto para proceder com a sua classificação.

Outro fator interessante, que também analisaremos na próxima seção, diz respeito ao critério de classificação das palavras em *relevantes* ou *não-relevantes*. Essa questão está intrinsecamente relacionada à anterior, já que, como veremos, um tópico discursivo é raramente repetido: normalmente ele é retomado por meio de anáforas lexicais, ou, mais frequentemente, por meio de anáforas pronominais ou elípticas.

---

<sup>9</sup> YANG, Y.; PEDERSEN, J. (1997). A Comparative Study on Feature Selection on Text Categorization. *Proceedings of ICML-97, 14th International Conference on Machine Learning*.

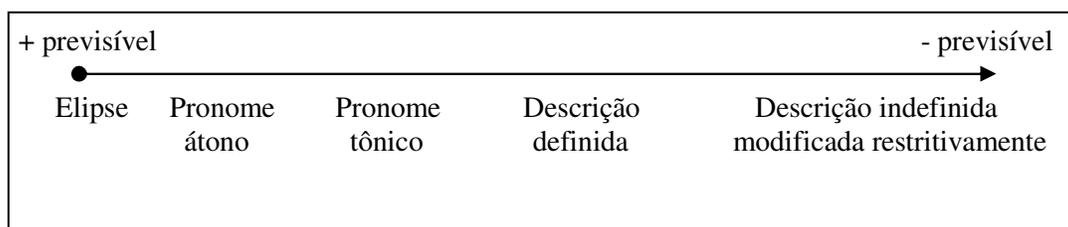
## 2. Sobre a Continuidade Tópica

Dentro do paradigma funcionalista, a sintaxe é percebida como uma estratégia de organização frasal para um determinado fim comunicativo. Nós, falantes, organizamos a informação do texto de frase em frase, por meio de expressões nominais, que podem servir de tópicos, e suas retomadas anafóricas, que funcionam normalmente para manter a continuidade tópica. Nessa organização textual, as expressões nominais nos ajudam a armazenar, arquivar e organizar a informação nova que vai “entrando”, vinda do texto, enquanto as retomadas anafóricas (principalmente através de elipse e pronomes) servirão para manter o arquivo do tópico discursivo aberto na memória de trabalho.

Ainda que haja algumas controvérsias sobre o que é ser o tópico, ou sobre se a topicalidade é escalar ou não (cf. Ariel, 1988, Givón, 1979, 1992, e Pontes, 1986), definiremos o tópico como *aquilo sobre o que se vai falar*. A essa sucinta definição, porém, devemos acrescentar uma outra, baseada nas idéias de Givón: *um tópico é caracterizado como tópico se for retomado e designado como tal em um número sucessivo de orações*.

De acordo com Barbisan & Machado (2000: 72), “os tópicos são etiquetas de arquivo para a armazenagem na memória episódica. As etiquetas são tornadas assim perceptualmente salientes pelo emissor, que nelas embasa a informação para o receptor.” Enquanto a expressão nominal “abre esses novos arquivos” em nossa memória, introduzindo novos tópicos, normalmente os pronomes servem para retomar e manter a cadeia tópica, garantindo assim a *continuidade e manutenção do tópico* no discurso.

Confira o gráfico visto em Othero (2004: 24), sobre o processo de referenciação e continuidade tópica:



**Gráfico 1:** Escalas quantitativas de identificação referencial (recursos contextuais para designar o referente)

No processo de continuidade tópica, utilizamos diversas estratégias de retomada do tópico. Ariel (1988) mostra que, apesar dessa diversidade de estratégias de manutenção tópica, a distribuição dos marcadores de topicalidade nas retomadas anafóricas não é exatamente flexível. Além disso, ela argumenta que a retomada anafórica pronominal é amplamente usada, especialmente quando o tópico tem acessibilidade máxima (ou grande) e distância mínima (ou muito curta). Diversos estudos (Ariel, 1988, Barbisan & Machado, 2000, Givón, 1992, entre outros) têm mostrado que a retomada anafórica pronominal é definitivamente a estratégia mais utilizada na manutenção tópica no discurso. Isso remete-nos imediatamente às duas questões abordadas na seção 1:

- a) A lista de *stopwords* contém pronomes, não os levando em consideração durante o processo de classificação do texto.
- b) Uma palavra é considerada relevante se ela não é rara e não se encontra na lista de *stopwords*. Porém, se um tópico (que é relevante ao texto) for retomado exclusivamente por pronomes, ele será considerado relevante? A resposta é um incrível “NÃO” para qualquer ferramenta de classificação automática de textos que não leve em conta as teorias funcionais sobre a manutenção tópica discursiva.

A questão que queremos levantar aqui é a seguinte: como um classificador automático de documentos digitais pretende classificar textos baseando-se na frequência das palavras mais importantes e/ou relevantes que encontra no texto se, ao mesmo tempo: (a) as expressões consideradas mais importantes – os tópicos – são normalmente retomadas por anáforas pronominais<sup>10</sup> (pelo menos a curta e média distância); e (b) a ferramenta, além

---

<sup>10</sup> Não mencionaremos as retomadas por anáfora zero ou elipse (que também são muito frequentes), porque isso iria complicar e comprometer ainda mais o processamento textual dos classificadores automáticos que sequer cogitam a hipótese de trabalhar com esse tipo de retomada que está, de certa forma, “invisível” na superfície do texto.

de não reconhecer a relação anafórica pronominal, deixa todos os pronomes em uma lista de palavras raras e sem relevância, chamada de *stopwords*.

### 3. Possíveis Caminhos

Foge à proposta específica deste trabalho testar as hipóteses aqui discutidas em um trabalho prático. Para isso, necessitaríamos de mais tempo e espaço: teríamos de preparar ao menos três corpora (um de teste, um de controle e um de treinamento); explicitar os procedimentos da anotação manual (feitas por anotadores humanos) e da anotação automática (feita por classificadores automáticos); além de confrontar os resultados para averiguar a validade de nossa hipótese.

No entanto, acreditamos que esse seja o caminho necessário que as ferramentas de classificação automática de documentos digitais deverão tomar. Afinal, como sabemos, um texto não é composto por expressões nominais e sua exaustiva repetição. Ele antes é elaborado de outra maneira: o tópico é normalmente introduzido na forma de expressão nominal (normalmente um sintagma nominal indefinido) e retomado por diferentes tipos de anáfora, desde a elipse, passando pela anáfora pronominal (casos mais frequentes), até a repetição da própria expressão nominal (muitas vezes, através de uma expressão definida).

Apesar de parecer ser o caminho ideal, nossas considerações levam a um outro grande problema: o do processamento anafórico pronominal<sup>11</sup>. Esse é com certeza um verdadeiro desafio às ferramentas automáticas que trabalham com textos em linguagem natural. Porém, acreditamos firmemente que, com esforços conjuntos entre lingüistas e programadores, tais dificuldades poderão no futuro ser solucionadas. Desse trabalho, o resultado imediato será provavelmente a melhoria significativa dos classificadores automáticos de documentos digitais.

---

<sup>11</sup> Cf. De Rocha (1996), Fligelstone (1992) e Garside, Leech & McEnery (1997), especialmente o capítulo 5 – Discourse annotation: anaphoric relations in corpora.

## REFERÊNCIAS BIBLIOGRÁFICAS

1. ARIEL, M. (1988). Referring and accessibility. *Journal of Linguistics*, 24.
2. BARBISAN, L. B.; MACHADO, R. F. (2000). O tópico no texto argumentativo. *Letras de Hoje*, v. 35, n. 3.
3. COULSON, Mark. Anaphoric reference. (1996). In: GREENE, Judith; COULSON, Mark. *Language understanding: current issues*. Buckingham: Open University Press.
4. De ROCHA, M. (1996). A corpus-based study of anaphora in English and Portuguese. In: BORTLEY, S. P. & McENERY A. M. (eds.). *Corpus-based and computational approaches to discourse anaphora*, London: UCL Press.
5. FLIGELSTONE, S. (1992). Developing a scheme for annotating text to show anaphoric relations. In: LEITNER, G. (ed). *New directions in English language corpora: methodology, results, software*. Berlin: Mouton de Gruyter.
6. GARSIDE, Roger; LEECH, Geoffrey; McENERY, Anthony. (1997). *Corpus annotation: linguistic information from computer text corpora*. London / New York: Longman.
7. GIVÓN, T. (1979). From discourse to syntax: grammar as a processing strategy. In: GIVÓN, T. (ed.) *Discourse and syntax*. New York: Academic Press.
8. GIVÓN, T. (1992). The grammar of referential coherence as mental processing instructions. *Linguistics*, 30.
9. HALLIDAY, M. A. K.; HASAN, R. (1976). *Cohesion in English*. London: Longman.
10. LANGIE, L. C. (2003). *Um estudo sobre a aplicação do algoritmo kNN à categorização hierárquica de textos*. Dissertação de Mestrado. Faculdade de Informática, Pontifícia Universidade Católica do Rio Grande do Sul – PUCRS.
11. LANGIE, L. C.; LIMA, V. L. S. (2003). Classificação hierárquica de documentos textuais digitais usando o algoritmo kNN. *I Workshop em Tecnologia da Informação e Linguagem Humana*. São Carlos-SP, Brasil, 12 de outubro.
12. OTHERO, Gabriel de Ávila. (2004). *A anáfora e a tessitura do texto: um estudo do uso anafórico das descrições definidas*. Pará de Minas: Virtualbooks.

13. PONTES, Eunice. (1986). A noção de tópico. In: PONTES, Eunice. *Sujeito: da sintaxe ao discurso*. São Paulo: Ática; Brasília: INL, Fundação Nacional Pró-Memória.
14. SILVA, Magda Teresinha. (2003). A codificação do tópico como SN DEF em textos narrativos e em textos argumentativos. *Revista Virtual de Estudos da Linguagem – ReVEL*. Vol. 1, n. 1. [www.revel.inf.br]

## APÊNDICE

. Lista de *stopwords* utilizada por Langie (2003):

abaixo	antes	automaticamente	como
acima	ao	b	conciso
acola	aonde	basicamente	conforme
agora	aos	bastante	conosco
ai	aparentemente	bem	consequentement
ainda	apenas	bilhao	e
al	apesar	bilhoes	consigo
alem	apos	bonito	contigo
algo	apropriado	c	contra
alguem	aquela	cada	contudo
algum	aquelas	catorze	correntemente
alguma	aquele	cedo	cr
algumas	aqueles	cem	cuja
alguns	aqui	certamente	cujo
ali	aquilo	cinco	d
alias	as	cinquenta	da
ambos	assim	claramente	daquilo
andar	ate	cm	das
anteontem	atraves	com	de
anteriormente	atualmente	comigo	debaixo

definitivamente	ela	ficar	mal
defronte	elas	finalmente	mas
dela	ele	fora	me
dele	eles	frequentemente	mediante
demais	em	g	melhor
dentro	embora	geralmente	menor
depois	enquanto	h	menos
desde	entao	ha	mesmo
dessa	entre	haver	meu
dessas	entretanto	i	meus
desse	especialmente	inicialmente	mil
desses	essa	inteiramente	milhao
desta	essas	isso	milhares
destas	esse	isto	milhoes
deste	esses	j	mim
destes	esta	ja	minha
dez	estar	jamais	minhas
dezeseis	estas	jr	ml
diante	este	junto	muita
difícilmente	estes	k	muitas
diretamente	et	km	muito
disponível	etc	l	muitos
disso	eu	la	n
disto	ex	las	na
do	exatamente	lo	nada
dois	exceto	logo	nao
dos	exclusivamente	longe	naquilo
doze	f	los	necessario
durante	facilmente	m	nela
duzentos	fazer	maioria	nele
e	felizmente	mais	nem

nenhum	ontem	primeiro	sempre
nenhuma	onze	principalmente	senao
nessa	opcionalmente	prontamente	ser
nessas	os	provavelmente	sessenta
nesse	ou	q	sete
nesses	outra	quais	setecentos
nesta	outro	qual	setenta
nestas	p	qualquer	seu
neste	para	quando	seus
nestes	parecer	quanta	si
ninguem	pela	quantas	sim
nisso	pelas	quanto	so
nisto	pelo	quantos	sob
no	pelos	quarenta	sobre
nono	perante	quase	sp
normalmente	permanecer	quatorze	sua
nos	pior	quatro	suas
nossa	pois	que	subito
nossas	por	quem	t
nosso	porem	quinto	tais
nossos	porquanto	quinze	tal
novamente	porque	r	talvez
nove	portanto	rapidamente	tambem
novecentos	possivelmente	realmente	tanta
noventa	posteriormente	s	tantas
nunca	pouca	se	tanto
o	poucas	segundo	tantos
oitenta	pouco	seis	tao
oito	poucos	seiscentos	te
oitocentos	praticamente	seja	tel
onde	primeiramente	sem	ter

terceiro	x
teu	z
ti	zero
toda	a
todas	o
todavia	ÿ
todo	
todos	
tras	
tres	
treze	
trezentos	
trinta	
tu	
tua	
tudo	
u	
ultimamente	
um	
uma	
umas	
uns	
v	
varias	
varios	
vem	
vez	
vezes	
vinte	
voce	
w	