

UNIVERSIDADE FEDERAL DO ESPÍRITO SANTO
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

CARIBE ZAMPIROLI DE SOUZA

**MEDIDA DE CERTEZA NA CATEGORIZAÇÃO MULTI-RÓTULO DE
TEXTO E SUA UTILIZAÇÃO COMO ESTRATÉGIA DE PODA DO
RANKING DE CATEGORIAS**

VITÓRIA
2010

CARIBE ZAMPIROLI DE SOUZA

**MEDIDA DE CERTEZA NA CATEGORIZAÇÃO MULTI-RÓTULO DE
TEXTO E SUA UTILIZAÇÃO COMO ESTRATÉGIA DE PODA DO
RANKING DE CATEGORIAS**

Dissertação apresentada ao Programa de Pós-Graduação em Informática do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para obtenção do Grau de Mestre em Informática.

Orientadora: Profa. Dra. Claudine Santos Badue Gonçalves

VITÓRIA
2010

BIBLIOTECA

CARIBE ZAMPIROLI DE SOUZA

**MEDIDA DE CERTEZA NA CATEGORIZAÇÃO MULTI-RÓTULO DE
TEXTO E SUA UTILIZAÇÃO COMO ESTRATÉGIA DE PODA DO
RANKING DE CATEGORIAS**

Dissertação submetida ao programa de Pós-Graduação em Informática do Centro Tecnológico da Universidade Federal do Espírito Santo, como requisito parcial para a obtenção do Grau de Mestre em Informática.

Aprovada em 27 de agosto de 2010.

COMISSÃO EXAMINADORA

Profa. Dra. Claudine Santos Badue Gonçalves - Orientador
Universidade Federal do Espírito Santo

Prof. Dr. Alberto Ferreira De Souza – Co-orientador
Universidade Federal do Espírito Santo

Prof. Dr. Elias de Oliveira
Universidade Federal do Espírito Santo

Prof. Dr. Wagner Meira Jr.
Universidade Federal de Minas Gerais

EPÍGRAFE

“A maior de todas as torres começa aqui no solo.” (Provérbio Chinês)

DEDICATÓRIA

Dedico este trabalho aos meus pais Carlos e Fátima que me guiaram pelos caminhos corretos e que de muitas formas me incentivaram e ajudaram para que fosse possível a concretização deste trabalho.

AGRADECIMENTOS

Agradeço primeiramente a Deus pelo sol que ilumina nossos dias ofertando-nos claridade para guiarmos nossos passos; e por todas as oportunidades de crescimento e amadurecimento.

Aos meus pais pela vida, pela segurança dos primeiros passos, pelo direcionamento na vida, pelo abraço amigo e palavras de conforto.

À minha orientadora Prof. Dr. Claudine Badue pelo suporte teórico e confiável no decorrer do projeto, paciente e dedicado fundamentais nas várias etapas de desenvolvimento deste trabalho.

À equipe do SCAE de pesquisadores pelo apoio nos estudos, em especial ao Prof. Dr. Alberto de Souza, Bruno Zanetti Melotti e Felipe Thomaz Pedroni.

Aos meus irmãos pelo carinho e pelo apoio de sempre.

À minha namorada pelo carinho, compreensão nas horas de ausência e pelas horas no celular para me tirar da frente do computador (hehehe).

Aos meus amigos Paulim e Vello pelo companheirismo e incentivo no decorrer desta caminhada.

RESUMO

Dado um documento de entrada, um sistema de categorização multi-rótulo de texto tipicamente computa graus de crença para as categorias de um conjunto pré-definido, ordena as categorias por grau de crença, e atribui ao documento as categorias com grau de crença superior a um determinado limiar de poda. Idealmente, o grau de crença deveria informar a probabilidade do documento de fato pertencer à categoria. Infelizmente, ainda não existem categorizadores que computam tais probabilidades e mapear graus de crença em probabilidades é um problema ainda pouco explorado na área de RI.

Neste trabalho, propomos um método baseado na regra de *Bayes* para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto. Propomos também uma estratégia para determinar limiares de poda baseada na medida de certeza de categorização - *bayesian cut* (BCut) - e uma variante para BCut - *position based bayesian CUT* (PBCut). Avaliamos experimentalmente o impacto dos métodos propostos no desempenho de duas técnicas de categorização multi-rótulo de texto, *k*-vizinhos mais próximos multi-rótulo (*ML-kNN*) e rede neural sem peso do tipo *VG-RAM* com correlação de dados (*VG-RAM WNN-COR*), no contexto da categorização de descrições de atividades econômicas de empresas brasileiras segundo a Classificação Nacional de Atividades Econômicas (CNAE). Investigamos também o impacto no desempenho de categorização multi-rótulo de texto de três métodos de poda comumente usados na literatura de RI - RCut, PCut, e SCut – e uma variante de RCut - RTCut. Além disso, propomos novas variantes para PCut e SCut – PCut* e SCut*, respectivamente – para tratar problemas existentes nestas abordagens. Nossos resultados experimentais mostram que, usando nosso método de geração de medidas de certeza de categorização, é possível prever o quão certo está o categorizador de que as categorias por ele preditas são de fato pertinentes para um dado documento. Nossos resultados mostram também que o uso de nossas estratégias de poda BCut e PBCut produz desempenho de categorização superior ao de todas as outras estratégias consideradas em termos de precisão.

ABSTRACT

A multi-label text categorization system typically computes degrees of belief when it comes to the categories of a pre-defined set, orders the categories by degree of belief, and attributes to the document categories with a higher degree of belief to determined threshold cut. It would be ideal if the degree of belief could inform the probability of the document be part of this category. Unfortunately, there isn't a categorization system that computes such probabilities and to map degrees of belief in probabilities is still a problem that isn't well explored in IR. In this paper we propose a method based on Bayes rules to map degrees of belief in terms of multi-label text measures of categorization. There are other contributions in this work such as an strategy to determine the limits of threshold cut based on bayesian cut (BCut) and a variant for PBCut (position based bayesian CUT).

As an experience, we evaluated the impact of the proposed methods when performing the two techniques of the multi-label text categorization. The first technique is called k-nearest neighbor multi-label (ML-KNN) and the second technique is called VG-RAM weightless Neural Networks. Theses evaluations were made in the context of the categorization of economic activities description of Brazilian enterprises, according to the Economic Activities Classification in Brazil (CNAE).

In this work we also investigated the impact in the performance of multi-label text categorization of the three cut methods commonly used in the IR literature: RCut, PCut, SCut and RTCut. Moreover, we propose a new variant for the so called PCut* and a new variant for SCut*. Finally, this work shows that the cut approach proposed, BCut and PBCut, produces a categorization performance superior to the other strategies presented in the literature of IR.

SUMÁRIO

LISTA DE FIGURAS	13
LISTA DE TABELAS	15
1 INTRODUÇÃO.....	18
1.1 Motivações.....	20
1.2 Objetivos.....	21
1.3 Contribuições.....	22
1.4 Organização da Dissertação.....	22
2 CATEGORIZAÇÃO MULTI-RÓTULO DE TEXTO	24
2.1 Categorização Multi-Rótulo de Texto	24
2.2 Representação Vetorial de Documentos.....	25
2.3 Categorizador <i>kNN</i>	28
2.3.1 Categorizador <i>kNN</i> Uni-Rótulo.....	28
2.3.2 Categorizador <i>ML-kNN</i>	29
2.4 Categorizador VG-RAM WNN.....	32
2.4.1 VG-RAM WNN.....	33
2.4.2 VG-RAM WNN-COR	36
2.5 Aplicação de Categorização Multi-Rótulo de Texto	37
2.5.1 Categorização de Atividades Econômicas	37
3 ESTRATÉGIAS DE PODA DE <i>RANKING</i> DE CATEGORIAS.....	41
3.1 Estratégia RCut.....	41
3.2 Estratégia RTCut	42
3.3 Estratégia PCut	44
3.4 Estratégia SCut	46
3.5 Novas Variantes para as Estratégias PCut e SCut	47
3.5.1 Estratégia PCut*.....	47
3.5.2 Estratégia SCut*.....	48
4 MEDIDA DE CERTEZA DE CATEGORIZAÇÃO.....	50
4.1 Uso da Regra de Bayes para o Cálculo da Medida de Certeza de Categorização	50
4.2 Uso da Medida de Certeza na Poda do <i>Ranking</i> de Categorias.....	52
4.2.1 Estratégia BCut	52
4.2.2 Estratégia PBCut.....	54
5 METODOLOGIA EXPERIMENTAL.....	56
5.1 Bases de Dados	56
5.2 Correção Ortográfica Automática.....	60
5.3 Indexação das Bases de Dados	61
5.4 Validação Cruzada.....	63
5.5 Calibração dos Categorizadores	64
5.6 Cálculo dos Parâmetros para a Medida de Certeza	68
5.7 Validação da Medida de Certeza	72
5.8 Calibração das Estratégias de Poda	72
5.8.1 Estratégia RCut	73
5.8.2 Estratégia RTCut.....	76
5.8.3 Estratégia PCut.....	79
5.8.4 Estratégia SCut.....	82
5.8.5 Estratégia BCut	82
5.8.6 Estratégia PBCut.....	85

6	RESULTADOS EXPERIMENTAIS	90
6.1	Validação da Medida de Certeza	90
6.2	Comparação entre as Estratégias de Poda	94
6.2.1	<i>Exact Match</i>	94
6.2.2	Precisão (<i>precision</i>) Orientada à Categoria	98
6.2.3	Revocação (<i>recall</i>) Orientada à Categoria	104
6.2.4	F_{β} Orientada à Categoria	110
6.2.5	Precisão (<i>precision</i>) Orientada a Documento	115
6.2.6	Revocação (<i>recall</i>) Orientada a Documento	121
6.2.7	F_{β} Orientada a Documento	126
6.2.8	<i>Test-T</i> Estatístico.....	131
7	DISCUSSÃO	141
7.1	Trabalhos Correlatos.....	141
7.2	Análise Crítica deste Trabalho.....	143
8	CONCLUSÃO E TRABALHOS FUTUROS	144
8.1	Sumário.....	144
8.2	Conclusões.....	145
8.3	Trabalhos Futuros	146
9	REFERÊNCIAS BIBLIOGRÁFICAS	147
	APÊNDICE A – PARÂMETROS OBTIDOS NO PROCEDIMENTO DE CALIBRAÇÃO DE SCUT	154
	A.1 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador ML- k NN e para a base AT100	154
	A.2 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador ML- k NN e para a base EX100	158
	A.3 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador VG-RAM WNN-COR e para a base AT100.....	159
	A.4 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador VG-RAM WNN-COR e para a base EX100.....	163
	APÊNDICE B – PROBABILIDADES $p(x/y,k)$ DE VALIDAÇÃO VERSUS $p(x/y,k)$ DE TESTE	164

LISTA DE FIGURAS

Figura 2-1 - Representação gráfica de três documentos de acordo com o modelo vetorial.	26
Figura 2-2 - Pseudocódigo do algoritmo <i>ML-k NN</i>	31
Figura 2-3 - Esquema de um neurônio artificial.	32
Figura 2-4 – Arquitetura para categorização de texto da <i>VG-RAM WNN</i> [SCAE08].	35
Figura 2-5 – Um exemplo da tabela CNAE para o nível de Subclasse.	39
Figura 5-1 – Distribuição do número de categorias por documento na base de dados VIX. ...	57
Figura 5-2 – Distribuição do número de categorias por documento na base de dados BH.	58
Figura 5-3 – Distribuição do número de categorias por documento na base de dados EX100.	59
Figura 5-4 – Distribuição do número de categorias por documento na base de dados AT100.	59
Figura 5-5 – Fluxograma do pré-processamento realizado nas Bases corrigidas anterior à indexação.	62
Figura 5-6 – Validação do <i>ML-k NN</i> segundo a métrica <i>ranking loss</i> para EX100, (a), e AT100, (b).	66
Figura 5-7 – Validação do <i>VG-RAM WNN-COR</i> na base EX100.	67
Figura 5-8 – Validação do <i>VG-RAM WNN-COR</i> na base AT100.	68
Figura 5-9 – Calibração de RCut para <i>ML-k NN</i> e para (a) AT100 e (b) EX100.	74
Figura 5-10 – Calibração de RCut para <i>VG-RAM WNN-COR</i> para (a) AT100 e (b) EX100.	75
Figura 5-11 - Calibração de RTCut para <i>ML-k NN</i> para (a) AT100 e (b) EX100.	77
Figura 5-12 - Calibração de RTCut para <i>VG-RAM WNN-COR</i> para (a) AT100 e (b) EX100.	78
Figura 5-13 - Calibração de PCut para <i>ML-k NN</i> e para (a) AT100 e (b) EX100.	80
Figura 5-14 - Calibração de PCut para <i>VG-RAM WNN-COR</i> e para (a) AT100 e (b) EX100.	81
Figura 5-15 - Calibração de BCut para <i>ML-k NN</i> e para (a) AT100 e (b) EX100.	83
Figura 5-16 - Calibração de BCut para <i>VG-RAM WNN-COR</i> e para (a) AT100 e (b) EX100.	84
Figura 5-17 - Calibração de PBCut para <i>ML-k NN</i> e para (a) AT100 e (b) EX100.	86
Figura 5-18 - Calibração de RCut para <i>VG-RAM WNN-COR</i> e para (a) AT100 e (b) EX100.	87
Figura 6-1 - Resultado da métrica <i>exact-match</i> para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	96
Figura 6-2 - Resultado da métrica <i>macro – precision^c</i> para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	100
Figura 6-3 - Resultado da métrica <i>micro – precision^c</i> para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	103
Figura 6-4 - Resultado da métrica <i>macro – recall^c</i> para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	106
Figura 6-5 - Resultado da <i>micro – recall^c</i> para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	108
Figura 6-6 - Resultado da métrica <i>macro – F₁^c</i> para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	111

Figura 6-7 - Resultado da métrica <i>micro</i> – F_1^c para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	113
Figura 6-8 - Resultado da métrica <i>macro</i> – $precision^d$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	117
Figura 6-9- Resultado da métrica <i>micro</i> – $precision^d$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	119
Figura 6-10 - Resultado da métrica <i>macro</i> – $recall^d$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	122
Figura 6-11 - Resultado da métrica <i>micro</i> – $recall^d$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	124
Figura 6-12 - Resultado da métrica <i>macro</i> – F_1^d para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	127
Figura 6-13 - Resultado da métrica <i>micro</i> – F_1^d para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.	129

LISTA DE TABELAS

Tabela 2-1 - Exemplo de tabela-verdade de um neurônio da <i>VG-RAM WNN</i> [SCAE08].....	34
Tabela 2-2 - Exemplo de tabela-verdade de uma rede neural <i>VG-RAM WNN-COR</i> [SCAE08].	36
Tabela 2-3 – Apresentação sumária da Tabela CNAE-Subclasses, Versão 1.1.....	38
Tabela 3-1 – Exemplo de poda de <i>ranking</i> de categorias utilizando <i>RCut</i>	42
Tabela 3-2 – Exemplo de poda de <i>ranking</i> de categorias utilizando a estratégia <i>RTCut</i>	44
Tabela 3-3 – Exemplo de poda de <i>ranking</i> de categorias utilizando a estratégia <i>PCut</i>	45
Tabela 3-4 – Exemplo de poda de <i>ranking</i> de categorias utilizando a estratégia <i>PCut*</i>	48
Tabela 4-1 – Exemplo de poda de <i>ranking</i> de categorias utilizando a estratégia <i>BCut</i>	53
Tabela 4-2 – Exemplo de poda de <i>ranking</i> de categorias utilizando a estratégia <i>BCut*</i>	55
Tabela 5-1 – Validação para <i>VG-RAM WNN-COR</i> na EX100 para 32x32 neurônios.	67
Tabela 5-2 – Sumário das escolhas dos parâmetros dos categorizadores na validação para EX100 e AT100.....	68
Tabela 5-3 – Sumário dos valores escolhidos para o parâmetro de <i>RCut</i>	76
Tabela 5-4 – Sumário das escolhas dos parâmetros da estratégia de poda <i>RTCut</i>	79
Tabela 5-5 – Sumário das escolhas dos parâmetros da estratégia de poda <i>PCut</i>	82
Tabela 5-6 – Sumário das escolhas dos parâmetros da estratégia de poda <i>BCut</i>	85
Tabela 5-7 – Parâmetro obtidos na calibração da estratégia de poda <i>PBCut</i> segundo <i>ML- k NN</i> para AT100.	88
Tabela 5-8 - Parâmetro obtidos na calibração da estratégia de poda <i>PBCut</i> segundo <i>VG-RAM WNN-COR</i> para AT100 e EX100.	88
Tabela 5-9 – Sumário das escolhas dos parâmetros da estratégia de poda <i>PCut</i>	89
Tabela 6-1 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=1$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	92
Tabela 6-2 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	92
Tabela 6-3 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	93
Tabela 6-4 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	93
Tabela 6-5 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	94
Tabela 6-6 – Tabela de contingência da categoria c_i	98
Tabela 6-7 – Tabela de contingência do documento d_j	115
Tabela 6-8 - Resultado do <i>Test-t</i> para o categorizador <i>ML- k NN</i> e para a base AT100. Comparação com <i>BCut</i>	133
Tabela 6-9 - Resultado do <i>Test-t</i> para o categorizador <i>ML- k NN</i> e para a base AT100. Comparação com <i>PBCut</i>	134
Tabela 6-10 - Resultado do <i>Test-t</i> para o categorizador <i>ML- k NN</i> e para a base EX100. Comparação com <i>BCut</i>	135
Tabela 6-11 - Resultado do <i>Test-t</i> para o categorizador <i>ML- k NN</i> e para a base EX100. Comparação com <i>PBCut</i>	136
Tabela 6-12 – Resultado do <i>Test-t</i> para o categorizador <i>VG-RAM WNN-COR</i> e para a base AT100. Comparação com <i>BCut</i>	137

Tabela 6-13 - Resultado do <i>Test-t</i> para o categorizador <i>VG-RAM WNN-COR</i> e para a base AT100. Comparação com PBCut.	138
Tabela 6-14 - Resultado do <i>Test-t</i> para o categorizador <i>VG-RAM WNN-COR</i> e para a base EX100. Comparação com BCut.	139
Tabela 6-15 - Resultado do <i>Test-t</i> para o categorizador <i>VG-RAM WNN-COR</i> e para a base EX100. Comparação com PBCut.	140
Tabela 9-1 – Parâmetros obtidos no procedimento de calibração de SCut para <i>ML- k NN</i> e para a base AT100.	155
Tabela 9-2 - Parâmetros obtidos no procedimento de calibração de SCut para <i>ML- k NN</i> e para a base AT100.	156
Tabela 9-3 - Parâmetros obtidos no procedimento de calibração de SCut para <i>ML- k NN</i> e para a base AT100.	157
Tabela 9-4 - Parâmetros obtidos no procedimento de calibração de SCut para <i>ML- k NN</i> e para a base AT100.	158
Tabela 9-5 - Parâmetros obtidos no procedimento de calibração de SCut para <i>ML- k NN</i> e para a base EX100.	158
Tabela 9-6 - Parâmetros obtidos no procedimento de calibração de SCut para <i>VG-RAM WNN-COR</i> e para a base AT100.	160
Tabela 9-7 - Parâmetros obtidos no procedimento de calibração de SCut para <i>VG-RAM WNN-COR</i> e para a base AT100.	161
Tabela 9-8 - Parâmetros obtidos no procedimento de calibração de SCut para <i>VG-RAM WNN-COR</i> e para a base AT100.	162
Tabela 9-9 - Parâmetros obtidos no procedimento de calibração de SCut para <i>VG-RAM WNN-COR</i> e para a base AT100.	163
Tabela 9-10 - Parâmetros obtidos no procedimento de calibração de SCut para <i>VG-RAM WNN-COR</i> e para a base EX100.	163
Tabela 9-11 – Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=1$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	165
Tabela 9-12 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	166
Tabela 9-13 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	166
Tabela 9-14 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	167
Tabela 9-15 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	167
Tabela 9-16 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=1$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	169
Tabela 9-17 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	169
Tabela 9-18 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	170
Tabela 9-19 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	170
Tabela 9-20 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	171
Tabela 9-21 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=1$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	172
Tabela 9-22 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	173

Tabela 9-23 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	173
Tabela 9-24 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	174
Tabela 9-25 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do <i>ranking</i> em cada um dos 20 intervalos observados de f	174

1 INTRODUÇÃO

Com o advento da comunicação, um grande volume de informação - crescente a taxas exponenciais - trafega pela *World Wide Web* e pelas *Intranets* corporativas espalhadas em todo o mundo. Apenas a quantidade de dados textuais disponíveis na *Web* é estimada ser da ordem de bilhões de documentos de texto (<http://www.worldwidewebsite.com/>). Isto dispara a necessidade de ferramentas eficientes para gerenciar, recuperar, e filtrar informação dessas grandes bases de dados textuais.

Categorização de texto, a atividade de rotular textos em linguagem natural com categorias temáticas a partir de um conjunto pré-definido [Sebastiani02], é uma dessas ferramentas importantes para a gestão de dados sob a forma de texto. Contudo, a categorização manual é um processo demorado e custoso, o que limita sua aplicabilidade. Conseqüentemente, existe um grande interesse no meio acadêmico e industrial em desenvolver técnicas para categorização automática de texto [Sebastiani02].

Categorização automática de texto é ainda um problema computacionalmente muito desafiador para as comunidades de Recuperação de Informação (RI), tanto no contexto acadêmico quanto no industrial. A maioria dos trabalhos sobre categorização de texto na literatura está focada nos problemas de categorização de texto com um uni-rótulo (*single-label*), nos quais cada documento pode ter um único rótulo (ou pertencer a uma única categoria) [Sebastiani02]. Entretanto, em problemas do mundo real, a categorização multi-rótulo (*multi-label*), na qual os documentos podem receber mais de um rótulo, é freqüentemente necessária [McCallum99, Schapire00, Clare01, Elisseff02, Comité03, Ueda03, Boutell04, Kazawa05, Zhang06, Zhang07].

Diversas técnicas têm sido propostas para atacar o problema de categorização multi-rótulo, tais como árvores de decisão (*decision trees* [Clare01, Comité03]), máquinas de vetores de suporte (*support vector machines* - SVM [Elisseff02, Boutell04, Kazawa05]), redes neurais (*neural networks* [Romero04, Zhang06, DeSouza09a, DeSouza09b]), *k*-vizinhos mais próximos (*k-nearest neighbors* - ML-*k*NN [Zhang07]), *boosting* [Schapire99], e muitas delas especificamente para categorização multi-rótulo de texto [McCallum99, Schapire99, Ueda03, Gao04, Romero04, Zhang06, Zhang07, DeSouza09a, DeSouza09b].

Dado um documento de entrada d_j , um sistema de categorização multi-rótulo de texto tipicamente computa um valor real $f(d_j, c_i)$ para cada categoria c_i de um conjunto pré-definido.

INTRODUÇÃO

Este valor $f(d_j, c_i)$ indica o grau de crença com que o sistema atribui a categoria c_i ao documento d_j . O sistema ordena as categorias por grau crença, formando um *ranking* de categorias para o documento de entrada. As categorias c_i posicionadas no *ranking* acima de um determinado limiar de poda τ_i são então atribuídas ao documento de entrada d_j , ou seja, c_i é predita para d_j se $f(d_j, c_i) \geq \tau_i$.

Idealmente, o grau de crença $f(d_j, c_i)$ computado por um categorizador deveria informar qual é a probabilidade do documento d_j de fato pertencer à categoria c_i . Infelizmente, ainda não existem categorizadores que computam tais probabilidades e mapear graus de crença em probabilidades é um problema ainda pouco explorado na área de RI.

Neste trabalho, propomos um método para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto. Nosso método é baseado na regra de *Bayes*, que permite alterar as probabilidades *a priori* tendo em conta novas evidências de forma a obter as probabilidades *a posteriori*. Em nosso método, as probabilidades *a priori* são estimadas empiricamente, através de experimentos de calibração, e a regra de *Bayes* é utilizada para produzir as probabilidades *a posteriori* de interesse, que denominamos “medida de certeza de categorização”. Ou seja, em nossa abordagem, dado um documento de entrada d_j , um categorizador computa $f(d_j, c_i)$ para cada categoria c_i e, usando resultados experimentais prévios e a regra de *Bayes*, uma medida de certeza da categorização de d_j em c_i é estimada.

Neste trabalho, propomos também uma estratégia para determinar limiares de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto descrita acima, a qual denominamos *bayesian cut* (BCut). Na estratégia de poda BCut, um único limiar de poda, τ , para todas as categorias c_i é escolhido de modo a maximizar o desempenho de categorização, i.e., sua habilidade de atribuir todas e apenas as categorias pertinentes a um dado documento. Um único limiar de poda pode produzir bom desempenho para todas as categorias devido à nossa metodologia de mapear graus de crença em medidas de certeza de categorização – o limiar de poda, τ , está associado à probabilidade da categorização estar correta, independente da categoria c_i . Além disso, propomos uma variante para BCut que utiliza diferentes limiares de poda τ_p para diferentes posições p do *ranking*, a qual denominamos *position based bayesian cut* (PBCut). A estratégia de poda PBCut pode produzir um desempenho superior ao de BCut, porque a medida de certeza de categorização em uma dada categoria diminui à medida que a posição da categoria no *ranking* aumenta.

Avaliamos experimentalmente o impacto dos métodos propostos no desempenho de duas técnicas de categorização multi-rótulo de texto, k -vizinhos mais próximos multi-rótulo

INTRODUÇÃO

(*multi-label k-nearest neighbors - ML-k NN*) [Zhang07] e rede neural sem peso do tipo *VG-RAM* com correlação de dados (*data correlated virtual generalizing random access memory weightless neural networks - VG-RAM WNN-COR*) [Aleksander98, Badue08, DeSouza08, DeSouza09a, DeSouza09b], no contexto da categorização de descrições de atividades econômicas de empresas brasileiras segundo a Classificação Nacional de Atividades Econômicas (CNAE) [CNAE03]. Investigamos também o impacto no desempenho de categorização multi-rótulo de texto de três métodos de poda comumente usados na literatura de RI [Yang01, Lee02, Fan07]: (i) RCut, baseada na posição das categorias no *ranking*; (ii) PCut, baseada na popularidade das categorias no conjunto de treinamento; (iii) SCut, baseada no grau de crença com que o sistema atribui as categorias aos documentos; e (iv) uma variante de RCut - RTCut [Yang01]. Ademais, propomos novas variantes para PCut e SCut – PCut* e SCut*, respectivamente – para tratar problemas existentes nestas abordagens. Em nossa análise experimental, utilizamos as métricas mais relevantes de avaliação de desempenho de categorização multi-rótulo de texto empregadas pela comunidade de RI: *exact match* [Kazawa05], *precision* [Sebastiani02, Manning08], *recall* [Sebastiani02, Manning08], e F_1 [Sebastiani02, Manning08]. Nossos resultados experimentais mostram que, usando nosso método de geração de medidas de certeza de categorização, é possível prever o quão certo está o categorizador de que as categorias por ele preditas são de fato pertinentes para um dado documento. Nossos resultados mostram também que uso o de nossas estratégias de poda BCut e PBCUT produz desempenho de categorização superior ao de todas as outras estratégias de poda consideradas em termos das métricas *precision* e *exact match*.

1.1 Motivações

Dado um documento de entrada d_j , um sistema de categorização multi-rótulo de texto tipicamente computa um valor real $f(d_j, c_i)$ para cada categoria c_i de um conjunto pré-definido. Este valor $f(d_j, c_i)$ indica o grau de crença com que o sistema atribui a categoria c_i ao documento d_j e, idealmente, deveria informar a probabilidade de d_j de fato pertencer a c_i . Infelizmente, ainda não existem categorizadores que computam tais probabilidades e mapear graus de crença em probabilidades é um problema ainda pouco explorado na área de RI. Assim, a principal motivação para o desenvolvimento deste trabalho foi desenvolver um

INTRODUÇÃO

método para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto, tal medida facilitaria a compreensão do operador do sistema.

O sistema de categorização multi-rótulo de texto tipicamente ordena as categorias por grau crença, formando um *ranking* de categorias para o documento de entrada. As categorias c_i posicionadas no *ranking* acima de um determinado limiar de poda τ_i são então atribuídas ao documento de entrada d_j , ou seja, c_i é predita para d_j se $f(d_j, c_i) \geq \tau_i$. Estratégias para determinar limiares de poda para o *ranking* de categorias é um tópico de pesquisa pouco explorado na área de RI. Assim, outra motivação para o desenvolvimento deste trabalho foi desenvolver uma estratégia de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto.

A motivação para este trabalho surgiu durante o desenvolvimento do Sistema Computacional de Codificação Automática de Atividades Econômicas (SCAE). Tal sistema se propõe a categorizar automaticamente, segundo a CNAE, descrições, na forma de texto livre, de atividades econômicas de empresas brasileiras.

A CNAE lista todas as atividades econômicas legalmente reconhecidas no Brasil. Correntemente, a CNAE contempla 1.301 atividades econômicas, cada uma possuindo um código específico. Empresas podem ser categorizadas dentro de um ou mais códigos; ou seja, categorizar empresas segundo a CNAE é um problema de categorização multi-rótulo. Devido à grande quantidade de categorias, este é um problema complexo e incomum na literatura.

1.2 Objetivos

Ainda não existem categorizadores que computam a probabilidade de um dado documento de entrada d_j de fato pertencer a uma categoria c_i de um conjunto pré-definido. Por esta razão, o principal objetivo deste trabalho foi (i) desenvolver um método para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto. Foi também objetivo deste trabalho (ii) desenvolver uma estratégia para determinar limiares de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto, (iii) e avaliar experimentalmente o impacto dos métodos propostos no desempenho da categorização multi-rótulo de texto.

1.3 Contribuições

As principais contribuições deste trabalho foram:

- Elaboração de um método para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto;
- Elaboração de uma estratégia para determinar limiares de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto;
- Elaboração de novas variantes para estratégias comumente utilizadas na literatura para tratar problemas existentes nestas abordagens;
- Implementação dos métodos para mapeamento dos graus de crença em medidas de certeza de categorização e determinação de limiares de poda para o *ranking* de categorias baseada nas medidas de certeza de categorização;
- Avaliação experimental do impacto dos métodos propostos no desempenho da categorização multi-rótulo de texto.

1.4 Organização da Dissertação

Após esta introdução, esta dissertação está organizada da seguinte forma:

- O Capítulo 2 discute a categorização multi-rótulo de texto, apresentando (i) uma definição de categorização multi-rótulo de texto, (ii) a representação do conteúdo do documento por um vetor de pesos de termos, (iii) os métodos de categorização multi-rótulo de texto usados neste trabalho; e (iv) o problema de categorização multi-rótulo de atividades econômicas utilizado como estudo de caso;
- O Capítulo 3 apresenta os três métodos de poda de *ranking* de categorias comumente usados na literatura de RI e avaliados neste trabalho, além de suas variantes;
- O Capítulo 4 propõe um método para mapear graus de crença em medidas de certeza de categorização baseada na regra de Bayes e uma estratégia para determinar limiares de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto;

INTRODUÇÃO

- O Capítulo 5 descreve nossa metodologia experimental, apresentando (i) as bases de dados usadas neste trabalho, (ii) o pré-processamento das bases de dados, (iii) a validação cruzada empregada na avaliação do desempenho dos categorizadores; (iv) a calibração dos categorizadores, (v) os parâmetros do método baseado na regra de *Bayes* para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto, (vi) o procedimento de validação das medidas de certeza de categorização multi-rótulo de texto, e (vii) a calibração das estratégias de poda do *ranking* de categorias;
- O Capítulo 6 descreve nossos resultados experimentais, apresentando (i) a avaliação da medida de certeza de categorização multi-rótulo de texto; e (ii) a análise do impacto das estratégias de poda no desempenho dos categorizadores multi-rótulo de texto;
- O Capítulo 7 discute este trabalho de pesquisa, apresentando trabalhos correlatos e uma análise crítica desta dissertação;
- Finalmente, o Capítulo 8 apresenta nossas conclusões e direções para trabalhos futuros.

2 CATEGORIZAÇÃO MULTI-RÓTULO DE TEXTO

Neste capítulo, apresentamos uma definição de categorização multi-rótulo de texto e descrevemos os métodos de categorização de texto k -vizinhos mais próximos multi-rótulo (*multi-label k -nearest neighbors* - ML- k NN) [Zhang07] e rede neural sem peso do tipo VG-RAM com correlação de dados (*data correlated virtual generalizing random access memory weightless neural networks* – VG-RAM WNN-COR) [Aleksander98, Badue08, DeSouza08, DeSouza09a, DeSouza09b]. Apresentamos, também, o domínio do problema de descrições de atividades econômicas de empresas brasileiras segundo a Classificação Nacional de Atividades Econômicas (CNAE) [CNAE03], e como essas descrições de atividades são representadas internamente, segundo o modelo vetorial [Salton75, Baeza99], nas técnicas de categorização multi-rótulo de texto. O conteúdo deste capítulo foi fundamentalmente extraído de [Melotti09].

2.1 Categorização Multi-Rótulo de Texto

Sejam D um domínio de documentos e $C = \{c_1, \dots, c_{|c|}\}$ um conjunto de categorias pré-definido. Na categorização multi-rótulo de texto, os documentos de D podem ser categorizados dentro de uma ou mais categorias de C .

Seja $\Omega = \{d_1, \dots, d_{|\Omega|}\} \subset D$ um *corpus* inicial de documentos previamente categorizados manualmente por especialistas no domínio dentro de subconjuntos de C . Em sistemas automáticos para categorização multi-rótulo, um subconjunto de Ω , denominado conjunto de treinamento (e calibração), $TV = \{d_1, \dots, d_{|TV|}\}$, pode ser utilizado para treinar (e calibrar) categorizadores implementados segundo técnicas de aprendizado de máquina [Sebastiani02] (neste trabalho empregamos somente categorizadores automáticos baseados em técnicas de aprendizado de máquina). O conjunto de teste, $Te = \{d_{|TV|+1}, \dots, d_{|\Omega|}\} = \Omega - TV$, por outro lado, consiste dos documentos não empregados no treinamento dos sistemas de categorização e somente submetidos a estes em fase de teste. Depois de ser treinado (e calibrado) com TV , um sistema de categorização pode ser utilizado para prever o conjunto de categorias de cada documento em Te .

Sistemas automáticos para categorização multi-rótulo tipicamente implementam uma função $f : D \times C \rightarrow \mathfrak{R}$ que retorna o grau de crença para cada par $\langle d_j, c_i \rangle \in D \times C$, ou seja, um número entre 0 e 1 que, a grosso modo, representa evidência de que o documento de teste d_j deve ser categorizado dentro da categoria c_i . A função $f(.,.)$ pode ser transformada em uma função ranqueadora $r(.,.)$, tal que, se $f(d_j, c_i) > f(d_j, c_k)$, então $r(d_j, c_i) < r(d_j, c_k)$, e se $f(d_j, c_i) < f(d_j, c_k)$, então $r(d_j, c_i) > r(d_j, c_k)$. Esta forma de usar o categorizador de texto é conhecida como “categorização orientada a documento” (“*document-pivoted categorization*” [Sebastiani02]), que consiste em, dado um documento d_j , encontrar todas as categorias $c_i \in C$ pertinentes a d_j . Alternativamente, outra forma de usar o categorizador é, dada uma categoria $c_i \in C$, encontrar todos os documentos d_j associados a c_i , conhecida como “categorização orientada a categoria” (“*category-pivoted categorization*” [Sebastiani02]). Neste trabalho, avaliamos categorização orientada a documento (ver Seções 2.3.2 e 2.4.2).

Seja C_j o conjunto de categorias pertinentes (categorias especificadas pelos especialistas no domínio) ao documento de teste d_j e \hat{C}_j o conjunto de categorias previstas para d_j por um categorizador automático. Um bom categorizador automático tenderá a posicionar as categorias de C_j em posições mais elevadas no *ranking* do que aquelas que não pertencem a C_j . As categorias c_i cujo grau de crença é superior ao limiar de poda τ_i são então previstas para o documento de teste d_j , isto é, $\hat{C}_j = \{c_i \mid f(d_j, c_i) \geq \tau_i\}$. Diferentes limiares τ_i são tipicamente escolhidos para diferentes categorias c_i .

2.2 Representação Vetorial de Documentos

Os documentos, em seu formato original (texto livre), usualmente não podem ser tratados diretamente por técnicas de aprendizado de máquina empregadas na construção de categorizadores automáticos de texto. Na maioria das técnicas de aprendizado de máquina, cada documento do conjunto Ω é representado por um vetor de números na representação ponto-flutuante; esta forma de representação de documentos é conhecida na literatura como representação vetorial de documentos [Salton75, Baeza99]. Cada elemento deste vetor

quantifica a frequência com que um termo, pertencente a um vocabulário de termos conhecidos pelo categorizador, aparece em TV (*bag-of-words representation* – [Baeza99, Sebastiani02]). Um termo é simplesmente uma ou mais palavras cujo significado, ou semântica, é representativo para o documento [Baeza99, Sebastiani02].

Formalmente, no modelo vetorial de representação de documentos [Salton75, Baeza99], os documentos são representados por vetores no espaço \mathfrak{R}^n , onde n representa o número de termos do vocabulário de termos conhecidos pelo categorizador. Cada documento d_j do conjunto Ω é representado por um vetor de pesos $\vec{d}_j = \langle w_{1j}, w_{2j}, \dots, w_{|T|j} \rangle$, onde T é o conjunto dos termos que ocorrem pelo menos uma vez nos documentos de TV e w_{kj} representa o peso do termo t_k do documento d_j ; a ordem dos termos em \vec{d}_j é a mesma para qualquer j [Sebastiani02].

A Figura 2-1 mostra um exemplo de um *corpus* formado pelo conjunto de documentos $\Omega = \{d_1, d_2, d_3\}$, representados vetorialmente por meio de vetores tridimensionais, onde cada dimensão está associada aos pesos dos termos do conjunto $T = \{t_1, t_2, t_3\}$ nos documentos. O documento d_1 é representado pelo vetor $\vec{d}_1 = \langle w_{11}, w_{21}, w_{31} \rangle$, d_2 por $\vec{d}_2 = \langle w_{12}, w_{22}, w_{32} \rangle$ e d_3 por $\vec{d}_3 = \langle w_{13}, w_{23}, w_{33} \rangle$.




Figura 2-1 - Representação gráfica de três documentos de acordo com o modelo vetorial.

Para determinar o peso w_{kj} do termo t_k no documento d_j , diversas formulações podem ser utilizadas. Empregamos a função de ponderação conhecida como *tfidf* (*term frequency, inverse document frequency*), definida por [Sebastiani02]:

$$tfidf(t_k, d_j) = \#(t_k, d_j) * \log\left(\frac{|TV|}{\#TV(t_k)}\right) \quad (2.1)$$

onde $\#(t_k, d_j)$ representa o número de vezes que o termo t_k ocorre no documento d_j , chamada de frequência do termo (*term frequency – tf*); $\#TV(t_k)$ denota o número de documentos do conjunto TV em que o termo t_k ocorre; e o termo $\log\left(\frac{|TV|}{\#TV(t_k)}\right)$ é chamado de frequência inversa do documento (*inverse document frequency – idf*).

A função *tfidf* codifica a intuição de que (i) quanto mais freqüente um termo em um documento, maior é a importância semântica dele para o documento, e (ii) quanto mais freqüente um termo no conjunto de documentos TV , menor é o poder de discriminação dele. Esta formulação leva em consideração apenas a ocorrência dos termos, não considerando a ordem na qual eles aparecem nos documentos e o papel sintático que eles possuem. É importante observar que os pesos dos termos são mutuamente independentes, isto é, o peso w_{kj} calculado para o par (t_k, d_j) não diz nada a respeito do peso $w_{k+1,j}$ calculado para o par (t_{k+1}, d_j) [Baeza99].

Para que os pesos estejam no intervalo $[0, 1]$ e para que os documentos sejam representados por vetores de mesma magnitude, os pesos calculados por *tfidf* são freqüentemente normalizados pela função de normalização de co-seno, definida por [Sebastiani02]:

$$w_{kj} = \frac{tfidf(t_k, d_j)}{\sqrt{\sum_{s=1}^{|T|} (tfidf(t_s, d_j))^2}} \quad (2.2)$$

O procedimento de transformar os textos dos documentos em uma forma que possa ser interpretada pelas técnicas de categorização de texto é chamado de indexação (*indexing*). A função de indexação *tfidf* foi escolhida para ser utilizada neste trabalho por ser a mais empregada na literatura [Sebastiani02], ou seja, as técnicas de categorização multi-rótulo

examinadas neste trabalho têm como entrada documentos (ou descrições de atividades econômicas) representados por vetores cujos pesos dos termos são calculados pela função *tfidf*. Estas técnicas são apresentadas nas seções a seguir.

2.3 Categorizador *kNN*

A técnica *k*-vizinhos mais próximos (*k-nearest neighbor – kNN*) é baseada em exemplos (*instance-based* [Mitchell97]), isto é, nenhum modelo é criado para extrair as características de um documento e associá-las a um conjunto de categorias na base de treinamento. Métodos baseados em exemplo são, algumas vezes, referenciados como métodos de aprendizado “preguiçosos” (*lazy learning methods*) porque eles somente processam a base de treinamento ao receber uma nova requisição de categorização para um novo documento [Mitchell97].

O *kNN* tradicional é utilizado na literatura em contextos uni-rótulo, mas o problema em que estamos interessados é multi-rótulo. Para empregar o categorizador *kNN* em problemas multi-rótulo, ele precisa ser alterado. A seção 2.3.1 apresenta o *kNN* uni-rótulo e a seção 2.3.2 o *k*-vizinhos mais próximos multi-rótulo (*multi-label k-nearest neighbor – ML-kNN*) proposto por Zhang e Zhou (2007).

2.3.1 Categorizador *kNN* Uni-Rótulo

O algoritmo *kNN* é muito simples: dado um documento de teste d_j , o sistema busca, empregando uma métrica de distância, os k vizinhos (documentos) mais próximos a d_j no conjunto de treinamento, TV , e escolhe a categoria c_i a ser atribuída a d_j dentre as categorias desses k vizinhos [Yang99]. Várias métricas de distância podem ser utilizadas, mas a mais freqüente é o co-seno do ângulo entre o vetor que representa d_j , \vec{d}_j , e cada documento d_m de TV , \vec{d}_m [Sebastiani02]:

$$\cos(\vec{d}_j, \vec{d}_i) = \frac{\vec{d}_j \cdot \vec{d}_i}{|\vec{d}_j| \times |\vec{d}_i|} \quad (2.3)$$

O valor do co-seno do ângulo entre o vetor de d_j e o de cada vizinho d_n é usado como o grau de crença do categorizador de que a categoria de d_n deve ser atribuída a d_j . A partir deste grau de crença, duas estratégias podem ser utilizadas para predizer uma categoria a d_j : maioria dos votos (*majority votes*) e a soma dos co-senos (similaridades) (*similarity score summing*) [Baoli03, Yavuz98, Yang99]. Na primeira, a categoria mais freqüente, entre as dos k vizinhos mais próximos, é a escolhida. Na segunda, a categoria com a maior soma dos co-senos, entre as dos k vizinhos mais próximos, é a escolhida.

2.3.2 Categorizador *ML-kNN*

O *Multi-Label k-Nearest Neighbor (ML-k NN)* [Zhang07] é um categorizador multi-rótulo baseado no algoritmo k NN uni-rótulo. Dado um documento de teste d_j , o *ML-k NN* identifica os k documentos da base de treinamento mais similares a d_j utilizando a métrica de distância co-seno (Equação (2.3)). Posteriormente, o algoritmo identifica a freqüência de cada categoria nestes k documentos. Utilizando esta informação, o *ML-k NN* prediz um conjunto de categorias para d_j utilizando o *maximum a posteriori principle* (MAP) [Sparacino00].

Formalmente, dado o documento $d_m \in TV$ e o conjunto de categorias pertinentes de d_m , $C_m \subseteq C$, podemos definir: (i) o vetor de categorias de d_m , \vec{y}_{d_m} , de tamanho igual $|C|$, onde $\vec{y}_{d_m}(c_i)$ recebe 1 se $c_i \in C_m$ e zero caso contrário; e (ii) o conjunto dos k vizinhos mais próximos a d_m no conjunto de treinamento TV , $N(d_m)$.

Durante a fase de treinamento, baseado no conjunto de categorias associadas aos documentos d_m pertencentes a $N(d_m)$, um vetor de contagem de associação (*membership counting vector* [Zhang07]), \vec{C}_{d_m} , de tamanho igual $|C|$, é computado segundo a Equação (2.4) para cada $d_m \in TV$:

$$\vec{C}_{d_m}(c_i) = \sum_{a \in N(d_m)} \vec{y}_a(c_i) \quad (2.4)$$

O vetor \vec{C}_{d_m} sumariza a vizinhança de d_m em TV com respeito às categorias associadas aos documentos em $N(d_m)$.

Na fase de teste, para cada documento d_j em Te , o $ML-k NN$ primeiramente identifica os k vizinhos mais próximos à d_j , $N(d_j)$, no conjunto TV . Seja $H_1^{c_i}$ um evento no qual a categoria c_i está associada a d_j ; $H_0^{c_i}$ um evento no qual a categoria c_i não está associada a d_j ; e $E_n^{c_i}$ ($n \in \{0,1,\dots,k\}$) um evento no qual existem exatamente n documentos associados à categoria c_i . Baseado no vetor de contagem de associação de d_j , \vec{C}_{d_j} , o vetor de categorias \vec{y}_{d_j} pode ser determinado pelo MAP , conforme Equação (2.5):

$$\vec{y}_{d_j}(c_i) = \arg \max_{b \in \{0,1\}} P(H_b^{c_i} | E_{\vec{C}_{d_j}(c_i)}^{c_i}) \quad (2.5)$$

Pela regra de *Bayes*, a Equação (2.5) pode ser reescrita conforme Equação (2.6):

$$\vec{y}_{d_j}(c_i) = \arg \max_{b \in \{0,1\}} \frac{P(H_b^{c_i})P(E_{\vec{C}_{d_j}(c_i)}^{c_i} | H_b^{c_i})}{P(E_{\vec{C}_{d_j}(c_i)}^{c_i})} \quad (2.6)$$

Eliminando o denominador $P(E_{\vec{C}_{d_j}(c_i)}^{c_i})$, pois é independente de $P(H_b^{c_i})$, temos a equação final para a obtenção do vetor de categorias previstas para d_j :

$$\vec{y}_{d_j}(c_i) = \arg \max_{b \in \{0,1\}} P(H_b^{c_i})P(E_{\vec{C}_{d_j}(c_i)}^{c_i} | H_b^{c_i}) \quad (2.7)$$

A Equação (2.7) mostra que, para determinar o vetor de categorias previstas \vec{y}_{d_j} , toda a informação sobre as probabilidades *a priori*, $P(H_b^{c_i})$, e *a posteriori*, $P(E_{\vec{C}_{d_j}(c_i)}^{c_i} | H_b^{c_i})$, são

necessárias. Na verdade, essas probabilidades podem ser estimadas a partir da frequência das categorias no conjunto de treinamento. A Figura 2-2 mostra o pseudocódigo do *ML-k NN* [Zhang07].

```

 $[\vec{y}_{d_i}, \vec{r}_{d_i}] = ML-KNN(TV, k, d_j, s)$ 

%Computa a probabilidade a priori  $P(H_b^{c_i})$ 
(1) para  $c_i \in C$  faça
(2)  $P(H_1^{c_i}) = (s + \sum_{i=1}^{TV} \vec{y}_{x_i}(c_i)) / (sx2 + |TV|)$ ;  $P(H_0^{c_i}) = 1 - P(H_1^{c_i})$ ;

%Computa a probabilidade a posterior  $P(E_{C_{d_j}(c_i)}^{c_i} | H_b^{c_i})$ 
(3) Identifica  $N(x_i)$ ,  $i \in \{1, 2, \dots, |TV|\}$ ;
(4) para  $c_i \in C$  faça
(5) para  $j \in \{0, 1, \dots, k\}$  faça
(6)  $c[j] = 0$ ;  $c'[j] = 0$ ;
(7) para  $l \in \{0, 1, 2, \dots, |TV|\}$  faça
(8)  $\vec{\delta} = C_{x_l}(c_i) = \sum_{a \in N(x_l)} \vec{y}_a(c_i)$ ;
(9) se  $(\vec{y}_{x_l}(c_i) == 1)$  então  $c[\delta] = c[\delta] + 1$ ;
(10) senão  $c'[\delta] = c'[\delta] + 1$ ;
(11) para  $j \in \{0, 1, \dots, k\}$  faça
(12)  $P(E_j^{c_i} | H_1^{c_i}) = (s + c[j]) / (sx(k+1) + \sum_{p=0}^k c[p])$ ;
(13)  $P(E_j^{c_i} | H_0^{c_i}) = (s + c'[j]) / (sx(k+1) + \sum_{p=0}^k c'[p])$ ;

%Computa  $\vec{y}_{d_i}$  e  $\vec{r}_{d_i}$ 
(14) Identifica  $N(d_j)$ ;
(15) para  $c_i \in C$  faça
(16)  $\vec{C}_{d_i}(c_i) = \sum_{a \in N(d_i)} \vec{y}_a(c_i)$ ;
(17)  $\vec{y}_{d_i}(c_i) = \arg \max_{\delta \in \{0, 1\}} P(H_b^{c_i}) P(E_{C_{d_j}(c_i)}^{c_i} | H_b^{c_i})$ ;
(18)  $\vec{r}_{d_i}(c_i) = P(H_1^{c_i} | E_{C_{d_j}(c_i)}^{c_i}) = (P(H_1^{c_i}) P(E_{C_{d_j}(c_i)}^{c_i} | H_1^{c_i})) / P(E_{C_{d_j}(c_i)}^{c_i})$ ;
    
```

Figura 2-2 - Pseudocódigo do algoritmo *ML-k NN*.

Os parâmetros de entrada do algoritmo são TV , k , d_j e s . O parâmetro s controla a suavização da probabilidade a priori e, neste trabalho, optamos em utilizar o valor $s=1$ (suavização Laplaciana [Zhang07]). De acordo com a Figura 2-2, os passos (1) e (2) calculam a probabilidade *a priori*, $P(H_b^{c_i})$. Os passos de (3) a (13) estimam a probabilidade *a posteriori*, $P(E_{C_{d_j}(c_i)}^{c_i} | H_b^{c_i})$, onde $c[j]$ contabiliza o número de documentos entre os k documentos similares no conjunto de treinamento que possuem a categoria c_i . Correspondentemente, $c'[j]$ contabiliza o número de documentos entre os k documentos similares no conjunto de treinamento que não possuem a categoria c_i . Finalmente, os passos

(14) a (18) são a predição do algoritmo, isto é, a atribuição de um grau de crença para cada categoria $c_i \subseteq C$ referente ao documento de teste d_j , $f(., c_i)$.

2.4 Categorizador VG-RAM WNN

Uma rede neural artificial é um modelo de computação inspirado na forma como a estrutura paralela e densamente conectada do cérebro dos mamíferos processa as informações. Mais formalmente, as redes neurais artificiais são sistemas paralelos distribuídos compostos por unidades de processamento simples, chamados de nós, que calculam determinadas funções matemáticas (normalmente não-lineares) [Haykin99]. Essas unidades são dispostas em uma ou mais camadas e interligadas por um número de conexões, chamadas de sinapses.

Essencialmente, um neurônio artificial é composto por um conjunto de sinapses, um somador e uma função de transferência (ou função de ativação) [Haykin99]. Conforme a Figura 2-3, cada sinapse do neurônio k está associada aos pesos $\{w_{k1}, w_{k2}, \dots, w_{km}\}$. Especificamente, ao ser apresentada uma informação ao neurônio, $\{x_1, x_2, \dots, x_m\}$, cada elemento da informação é multiplicado pelo peso w_{kj} da sinapse, e o resultado de cada entrada é somado, ou seja, é realizada uma soma ponderada da informação de entrada pelo Somador. O resultado da soma passa por uma Função de ativação, $\varphi(\cdot)$, que computa a saída y_k do neurônio em função da saída do Somador.




Figura 2-3 - Esquema de um neurônio artificial.

Redes neurais sem peso (*weightless neural networks* - WNN), também conhecidas como redes neurais baseadas em *Random Access Memories* (RAM), não armazenam conhecimento em suas conexões, mas em memórias do tipo RAM dentro dos nodos da rede, ou neurônios. Estes neurônios operam com valores de entrada binários e usam RAM como tabelas-verdade: as sinapses de cada neurônio coletam um vetor de bits da entrada da rede, que é usado como o endereço da RAM, e o valor armazenado neste endereço é a saída do neurônio. O treinamento pode ser feito em um único passo e consiste basicamente em armazenar a saída desejada no endereço associado com o vetor de entrada do neurônio.

Apesar da sua notável simplicidade, as WNN são muito efetivas como ferramentas de reconhecimento de padrões, oferecendo treinamento e teste rápidos, e fácil implementação. No entanto, se a entrada da rede for muito grande, o tamanho da memória dos neurônios da WNN torna-se proibitivo, dado que tem de ser igual a 2^n , onde n é o tamanho da entrada.

As redes *Virtual Generalizing RAM* (VG-RAM) são redes neurais baseadas em RAM que somente requerem capacidade de memória para armazenar os dados relacionados ao conjunto de treinamento. Os neurônios VG-RAM armazenam os pares entrada-saída observados durante o treinamento, em vez de apenas a saída. Na fase de teste, as memórias dos neurônios VG-RAM são pesquisadas mediante a comparação entre a entrada apresentada à rede e todas as entradas nos pares entrada-saída aprendidos. A saída de cada neurônio VG-RAM é determinada pela saída do par cuja entrada é a mais próxima da entrada apresentada – a função de distância adotada pelos neurônios VG-RAM é a distância de *Hamming*, isto é, o número de bits diferentes entre dois vetores de bits de tamanho igual. Se existir mais do que um par na mesma distância mínima da entrada apresentada, a saída do neurônio é escolhida aleatoriamente entre esses pares.

2.4.1 VG-RAM WNN

A Tabela 2-1 ilustra a tabela-verdade de um neurônio VG-RAM com três sinapses (X_1 , X_2 e X_3). Esta tabela-verdade contém três pares entrada-saída que foram armazenados durante a fase de treinamento (*par #1*, *par #2* e *par #3*). Durante a fase de teste, quando um vetor de entrada é apresentado à rede, o algoritmo de teste VG-RAM calcula a distância entre este vetor de entrada e cada entrada dos pares entrada-saída armazenados na tabela-verdade. No exemplo da Tabela 2-1, a distância de *Hamming* entre o vetor de entrada (*input*)

e o *par* #1 é dois, porque ambos os bits X_2 e X_3 não são semelhantes aos bits X_2 e X_3 do vetor de entrada. A distância do *par* #2 é um, porque X_1 é o único bit diferente. A distância do *par* #3 é três. Portanto, para este vetor de entrada, o algoritmo avalia a saída do neurônio, Y , como “*categoria 2*”, pois é o valor de saída armazenado no *par* #2.

Tabela 2-1 - Exemplo de tabela-verdade de um neurônio da VG-RAM WNN [SCAE08].

Tabela-verdade	X_1	X_2	X_3	Y
<i>par</i> #1	1	1	0	<i>categoria 1</i>
<i>par</i> #2	0	0	1	<i>categoria 2</i>
<i>par</i> #3	0	1	0	<i>categoria 3</i>
	↑	↑	↑	↓
vetor de entrada	1	0	1	<i>categoria 2</i>

Para categorizar documentos de texto usando uma VG-RAM WNN, um documento é representado por um vetor multidimensional $V = \{v_1, v_2, \dots, v_{|V|}\}$, onde cada elemento v_i corresponde a um peso associado a um termo específico do vocabulário de interesse. Uma VG-RAM WNN de uma única camada (Figura 2-4) é utilizada, de forma que as sinapses $X = \{x_1, x_2, \dots, x_{|X|}\}$ de seus neurônios são conectadas aleatoriamente à entrada da rede $N = \{n_1, n_2, \dots, n_{|N|}\}$, que tem o mesmo tamanho de um vetor que representa um documento, isto é, $|N| = |V|$. Note que $|X| < |V|$ (nossos experimentos demonstraram que $|X| < |V|$ provê melhor desempenho). Cada sinapse x_i de um neurônio forma uma célula *Minchinton* com a próxima x_{i+1} ($x_{|X|}$ forma uma célula *Minchinton* com x_1) [Mitchell98]. O tipo de célula *Minchinton* usada retorna 1 se a sinapse x_i da célula é conectada a um elemento de entrada n_j cujo valor é maior do que aquele do elemento n_k ao qual a sinapse x_{i+1} é conectada (isto é, $n_j > n_k$); caso contrário, ela retorna zero.




Figura 2-4 – Arquitetura para categorização de texto da VG-RAM WNN [SCAE08].

Durante a fase de treinamento, para cada documento no conjunto de treinamento, o vetor correspondente V é conectado à entrada N da VG-RAM WNN e as saídas $O = \{o_1, o_2, \dots, o_{|O|}\}$ dos neurônios a uma das categorias do documento. Todos os neurônios da VG-RAM WNN são então treinados para retornar como saída esta categoria com este vetor de entrada. O treinamento para este vetor de entrada é repetido para cada categoria associada ao documento correspondente. Durante a fase de teste, para cada documento de teste, a entrada é conectada ao vetor correspondente e o número de neurônios retornado para cada categoria é contabilizado. A saída da rede é computada dividindo-se a contagem de cada categoria pelo número de neurônios da rede.

A saída da rede é reorganizada como um vetor cujo tamanho é igual ao número de categorias existentes. O valor de cada elemento deste vetor varia entre 0 e 1 e representa a porcentagem de neurônios que exibiram a categoria correspondente como saída (a soma dos valores de todos os elementos deste vetor é sempre 1). Desta forma, a saída da rede reorganizada deste modo implementa a função $f(.,.)$, que apresenta valores no domínio dos números reais e que mapeia a múltipla pertinência de um documento frente a um dado conjunto de categorias existentes. Finalmente, um valor limiar τ_i para cada categoria c_i pode ser usado com a função $f(.,.)$, a fim de definir o conjunto de categorias a serem atribuídas a um documento de teste d_j : se $f(d_j, c_i) \geq \tau_i$, então c_i é atribuída a d_j .

2.4.2 VG-RAM WNN-COR

Enquanto numa *VG-RAM WNN* cada neurônio é treinado para retornar como saída uma única categoria para cada vetor de entrada, numa *VG-RAM WNN* com Correlação de Dados (*VG-RAM WNN-COR* [DeSouza08, DeSouza09b]) cada neurônio pode ser treinado para retornar como saída um conjunto de categorias para cada vetor de entrada. A Tabela 2-2 ilustra a tabela-verdade de uma *VG-RAM WNN-COR* com três sinapses X_1 , X_2 e X_3 e três pares entrada-saída armazenados durante a fase de treinamento (*par #1*, *par #2* e *par #3*). Semelhante à *VG-RAM WNN*, quando um vetor de entrada é apresentado à rede na fase de teste, o algoritmo de teste da *VG-RAM WNN-COR* computa a distância entre este vetor de entrada e cada entrada dos pares entrada-saída na tabela-verdade. No exemplo da Tabela 2-2, a distância de *Hamming* entre o vetor de entrada (*input*) e os pares #1, #2, e #3 é dois, um e três, respectivamente. Como o *par #2* da tabela-verdade é o mais próximo da entrada da rede, a saída do neurônio da *VG-RAM WNN-COR* é dada pelas categorias 1 e 3, isto é, o valor de Y representa ambas as categorias, 1 e 3.

Tabela 2-2 - Exemplo de tabela-verdade de uma rede neural VG-RAM WNN-COR [SCAE08].

Tabela-verdade	X_1	X_2	X_3	Y
<i>par #1</i>	1	1	0	<i>categoria 1</i>
<i>par #2</i>	0	0	1	<i>categoria 1; categoria 3</i>
<i>par #3</i>	0	1	0	<i>categoria 1; categoria 2; categoria 3</i>
	↑	↑	↑	↓
vetor de entrada	1	0	1	<i>categoria 1; categoria 3</i>

Para categorizar documentos de texto usando uma *VG-RAM WNN-COR*, a mesma configuração da *VG-RAM WNN*, ilustrada na Tabela 2-2, é usada. Na fase de treinamento, para cada documento no conjunto de treinamento, o vetor correspondente V é conectado à entrada da *VG-RAM WNN-COR*, N , e as saídas dos seus neurônios, O , ao conjunto de categorias atribuído ao documento. Cada neurônio da *VG-RAM WNN-COR* é treinado para retornar como saída este conjunto com este vetor de entrada. Durante a fase de teste, para cada documento de teste, o vetor correspondente V é conectado à entrada da rede, N . A função $f(.,.)$ é computada ao dividir o número de votos para cada categoria pelo número total de categorias retornadas pela rede. O número de votos para cada categoria é obtido ao contar suas ocorrências em todos os conjuntos retornados pelos neurônios da rede.

A implementação de rede neural *VG-RAM WNN-COR* explora a correlação das categorias associadas a cada documento para melhorar o desempenho da categorização multi-rótulo de texto. Resultados experimentais apresentados em [DeSouza08, DeSouza09b] mostram que a implementação *VG-RAM WNN-COR* tem um desempenho global superior ao da *VG-RAM WNN* em termos das métricas mais relevantes de avaliação de desempenho de categorização multi-rótulo de texto empregadas pela comunidade de RI. Por esta razão, neste trabalho, utilizamos a implementação *VG-RAM WNN-COR* [DeSouza08, DeSouza09b] para avaliar a estratégia de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto.

2.5 Aplicação de Categorização Multi-Rótulo de Texto

Devido ao aumento da disponibilidade do número de documentos de texto no formato digital, e pela conseqüente necessidade de organizá-los, a categorização de texto tornou-se uma das técnicas chave para manipular e organizar dados no formato texto [Sebastiani02]. Hoje em dia, a categorização de texto pode ser aplicada em diversos problemas, tais como: organização de documentos, filtragem de texto, geração automatizada de metadados, desambiguação do sentido da palavra, categorização de páginas Web baseados em um catálogo hierárquico, entre outras. No entanto, existem muitas outras importantes aplicações às quais pouca atenção tem sido dada. Um exemplo é a categorização de atividades econômicas baseada na descrição das atividades econômicas realizadas por uma empresa [Badue08, Ciarelli08, Ciarelli09, DeSouza07, DeSouza08, DeSouza09a, DeSouza09b, Oliveira08a, Oliveira08b]. Neste trabalho, verificamos o impacto da nossa estratégia de poda para o *ranking* de categorias, baseada na medida de certeza de categorização multi-rótulo de texto, utilizando bases de texto contendo descrições de atividades econômicas de empresas brasileiras.

2.5.1 Categorização de Atividades Econômicas

A categorização de companhias de acordo com as respectivas atividades exercidas é uma etapa importante do processo de obtenção de informação para a realização de análises estatísticas das atividades econômicas de uma cidade ou país. Com as companhias

categorizadas, é possível realizar uma análise estruturada de cada setor da economia, auxiliando empresas e governos em suas decisões.

Para facilitar e melhorar a qualidade de categorização das empresas de acordo com as atividades econômicas, o governo brasileiro está criando uma biblioteca digital centralizada com as declarações de propósitos de todas as empresas no país. Esta biblioteca vai ajudar as três esferas de governo – federal, os 27 Estados, e os mais de 5.000 municípios brasileiros – na tarefa de categorizar as empresas de acordo com a lei Brasileira vigente.

A categorização oficial das atividades econômicas adotada pelos órgãos da administração federal é baseada na Classificação Nacional de Atividades Econômicas (CNAE). A CNAE foi desenvolvida tendo como referência a *International Standard Industrial Classification of All Economic Activities - ISIC*, 3ª revisão, das Nações Unidas. A *ISIC* é uma padronização internacional definida pelas Nações Unidas para a disseminação das estatísticas econômicas no mundo. A partir da elaboração da CNAE foi derivada outra classificação, a CNAE-FISCAL, ou CNAE-Subclasses [CNAE03], que é um detalhamento das Classes da CNAE para uso nos cadastros da administração pública, em especial da administração tributária, nas três esferas do governo. A Tabela 2-3 apresenta sumariamente a CNAE-Subclasses Versão 1.1.

Tabela 2-3 – Apresentação sumária da Tabela CNAE-Subclasses, Versão 1.1.

Seções	Divisões	Grupos	Classes	Subclasses	Denominação
A	2	7	25	91	Agricultura, pecuária, silvicultura e exploração florestal
B	1	1	2	11	Pesca
C	4	7	14	42	Indústrias extrativas
D	23	104	286	395	Indústrias de transformação
E	2	4	7	8	Produção e distribuição de eletricidade, gás e água
F	1	6	16	43	Construção
G	3	19	72	223	Comércio; Reparação de veículos automotores, objetos pessoais e domésticos
H	1	2	7	16	Alojamento e alimentação
I	5	14	29	76	Transporte, armazenagem e comunicações
J	3	11	27	65	Intermediação financeira, seguros, previdência complementar e serviços relacionados
K	5	24	38	80	Atividades imobiliárias, aluguéis e serviços prestados às empresas
L	1	3	10	10	Administração pública, defesa e seguridade social
M	1	4	10	17	Educação
N	1	3	9	35	Saúde e serviços sociais
O	4	11	26	69	Outros serviços coletivos, sociais e pessoais
P	1	1	1	1	Serviços domésticos
Q	1	1	1	1	Organismos internacionais e outras instituições extraterritoriais
Total	59	222	580	1.183	

A CNAE-Subclasses é uma tabela hierárquica de descrição de atividades econômicas com os respectivos códigos associados. Conforme a Tabela 2-3 mostra, a CNAE-Subclasses 1.1 está organizada hierarquicamente em 5 níveis: Seção, Divisão, Grupo, Classe e Subclasse, contendo 17 Seções, 59 Divisões, 222 Grupos, 580 Classes e 1.183 Subclasses. O campo Denominação representa a descrição textual do código de Seção. Cada código nos níveis Divisão, Grupo, Classe e Subclasse também está associado a uma denominação [CNAE03].

Os códigos da CNAE-Subclasses são constituídos por 7 dígitos, sendo os 5 primeiros dígitos referentes ao nível de Classe e os dois últimos referentes ao detalhamento de cada Classe CNAE. Por exemplo, a Figura 2-5 apresenta o nível de Subclasse da Seção A para o código 0111-2/01 com a denominação “CULTIVO DE ARROZ”. Como podemos perceber, a Classe é identificada pelo código 0111-2 e pela denominação “CULTIVO DE CEREAIS PARA GRAOS”.

CNAE-FISCAL 1.1

Hierarquia		
Seção:	A	AGRICULTURA, PECUARIA, SILVICULTURA E EXPLORAÇÃO FLORESTAL
Divisão:	01	AGRICULTURA, PECUARIA E SERVIÇOS RELACIONADOS
Grupo:	011	PRODUÇÃO DE LAVOURAS TEMPORARIAS
Classe:	0111-2	CULTIVO DE CEREAIS PARA GRAOS
Subclasse	0111-2/01	CULTIVO DE ARROZ

[Lista de Atividades...](#)
Notas Explicativas:
Esta subclasse compreende:

O cultivo de arroz

Esta subclasse compreende também:

O beneficiamento do arroz em estabelecimento agrícola, quando complementar ao cultivo
 A produção de semente para plantio de arroz, quando complementar ao cultivo

Esta subclasse não compreende:

O beneficiamento do arroz, em estabelecimento nao agrícola (1551-2/01)
 O beneficiamento do arroz, realizado por terceiros, em estabelecimento agrícola (0161-9/05)
 A produção de óleo de arroz em bruto (1531-8/00)
 O serviço de colheita realizado por terceiros (0161-9/04)
 A produção de sementes certificadas de arroz (0119-8/17)
 O serviço de preparação de terreno de cultivo realizado por terceiros (0161-9/99)

Figura 2-5 – Um exemplo da tabela CNAE para o nível de Subclasse.

Os códigos Subclasse também carregam a identificação dos níveis de Divisão e Grupo. Por exemplo, para o código 0111-2/01 (Figura 2-5), os dois primeiros dígitos, 01, identificam o nível de Divisão, com a denominação “AGRICULTURA, PECUARIA E

SERVIÇOS RELACIONADOS”, e os três primeiros, 011, o de Grupo, com a denominação “PRODUÇÃO DE LAVOURAS TEMPORARIAS”.

Além da denominação do código de um determinado nível, existem notas explicativas para agregar mais informação àquele nível. No caso do nível de Subclasse, as notas explicativas mostram o que a Subclasse compreende (“Esta subclasse compreende:”), o que ela compreende também (“Esta subclasse compreende também:”), e o que ela não compreende (“Esta subclasse não compreende:”).

Atualmente, em muitos órgãos usuários, a determinação de quais códigos devem ser atribuídos a cada empresa - a codificação em CNAE-Subclasses - é feita manualmente por codificadores humanos treinados para tal e apoiados por ferramentas computacionais de busca em versões eletrônicas da tabela CNAE-Subclasses. O codificador (ou categorizador) humano treinado deve associar/combinar a descrição da atividade da empresa com a informação na tabela CNAE-Subclasses e com seu conhecimento, fruto de seus vários anos de educação e experiência profissional, para atribuir códigos CNAE-Subclasse.

Conforme as características apresentadas anteriormente, o problema de categorização de atividades econômicas consiste em dada uma descrição textual do propósito de uma empresa, categorizá-la em um ou mais dos 1.183 possíveis códigos (ou categorias) CNAE-Subclasse. O grande número de possíveis categorias torna este problema complexo quando comparado com outros apresentados na literatura [Sebastiani02]. Neste contexto, é de grande interesse uma ferramenta para produzir uma medida de certeza para as categorias preditas para um dado documento de entrada. Dessa forma, o sistema de categorização pode ser acionado por um operador humano, no caso de ser obtida uma medida de certeza abaixo de um determinado limiar pré-definido. Por essa razão, escolhemos este problema de categorização para este trabalho.

3 ESTRATÉGIAS DE PODA DE *RANKING* DE CATEGORIAS

Neste capítulo, apresentamos três métodos de poda de *ranking* de categorias comumente usados na literatura de RI [Yang01, Lee02, Fan07]: (i) RCut, baseada na posição das categorias no *ranking*; (ii) PCut, baseada na popularidade das categorias no conjunto de treinamento; (iii) SCut, baseada no grau de crença com que o sistema atribui as categorias aos documentos; e (iv) uma variante de RCut - RTCut [Yang01]. Além disso, propomos novas variantes para PCut e SCut – PCut* e SCut*, respectivamente – para tratar problemas existentes nestas abordagens.

3.1 Estratégia RCut

A estratégia de poda RCut [Yang01], baseada na posição das categorias no *ranking* (*ranking based*), para cada documento de teste d_j , ordena as categorias por grau de crença e atribui as t categorias a partir do topo do *ranking* para d_j . O valor do parâmetro t (um número inteiro entre 1 e $|C|$) pode ser especificado pelo usuário ou automaticamente ajustado para otimizar o desempenho “global” do categorizador em um conjunto de calibração (o valor de t é automaticamente ajustado ao variá-lo até que o desempenho global do categorizador seja otimizado para o conjunto de validação). RCut com $t = 1$ é comumente usada pela comunidade de aprendizado de máquina em problemas uni-rótulo, nos quais um documento tem uma única categoria [Joachims98].

A Tabela 3-1 apresenta um exemplo de poda de *ranking* de categorias utilizando a estratégia RCut. Na Tabela 3-1, a coluna “Posição” indica a posição das categorias no *ranking* retornado pelo categorizador *VG-RAM WNN-COR* para um dado documento de teste d_i ; a coluna “Categorias preditas a d_i ” mostra os identificadores das categorias no *ranking* retornado pelo categorizador para d_i ; a coluna “Graus de crença para d_i ” mostra os graus de crença com que o categorizador atribuiu as categorias a d_i ; e a coluna “Categorias pertinentes a d_i ” mostra a lista de categorias de fato pertinentes a d_i . As colunas 5, 6, e 7 são análogas às colunas 2, 3, e 4, porém, estão associadas ao documento de teste d_j . Finalmente, a coluna

“Parâmetro t ” mostra o valor do parâmetro t otimizado para um conjunto de validação. No exemplo da Tabela 3-1, as $t=2$ categorias a partir do topo do *ranking* são atribuídas aos documentos de teste.

Tabela 3-1 – Exemplo de poda de *ranking* de categorias utilizando RCut

Posição	Categorias previstas para d_i	Grau de crença d_i	Categorias pertinentes d_i	Categorias previstas para d_j	Grau de crença d_j	Categorias pertinentes d_j	Parâmetro t
1	C9	0,109859	C3	C58	0,333576	C1	$t = 2$
2	C8	0,100939	C7	C89	0,307021	C58	
3	C7	0,089202	C9	C59	0,302292		
4	C14	0,069484	C54	C78	0,003638		
5	C10	0,053991		C90	0,003638		
6	C54	0,045541		C20	0,003274		
7	C11	0,039906		C76	0,002183		
8	C67	0,039906		C56	0,001819		
9	C13	0,025822		C63	0,001819		
10	C12	0,022066		C18	0,001455		

Como pode ser observado na Tabela 3-1, a estratégia RCut não é adequada para problemas nos quais os diferentes documentos têm diferentes números de categorias pertinentes, uma vez que RCut atribui o mesmo número de categorias a todos os documentos [Yang01].

3.2 Estratégia RTCut

RCut impõe um compromisso duro entre as métricas de avaliação de desempenho revocação (*recall*) e precisão (*precision*), ao retornar ou um grande número de categorias ou pequeno número de categorias. Para atenuar esse compromisso, Yang (2001) propôs a estratégia de poda RTCut, que atribui graus de crença sintéticos às categorias computados a partir de suas posições no *ranking* e de seus graus de crença para um dado documento. Estes graus de crença sintéticos são computados por:

$$s(d_j, c_i) = r(d_j, c_i) + \frac{f(d_j, c_i)}{\max_{c' \in C} \{f(c' | d_j)\} + 1} \quad (3-1)$$

onde d_j é o documento de teste, $r(d_j, c_i)$ é a posição da categoria c_i no *ranking* retornado para d_j , $f(d_j, c_i)$ é o grau de crença original de que a categoria c_i deve ser atribuída a d_j , e $\max_{c' \in C} \{f(c' | d_j)\}$ retorna o grau de crença de valor máximo atribuído a uma determinada categoria $c' \in C$ no *ranking* retornado para d_j . Para cada documento de teste, a estratégia RTCut ordena as categorias pelo grau de crença sintético e atribui ao documento as categorias com grau de crença sintético superior a um determinado limiar τ . O valor do parâmetro τ pode ser especificado pelo usuário ou automaticamente ajustado para otimizar o desempenho “global” do categorizador em um conjunto de calibração.

A Tabela 3-2 apresenta um exemplo de poda de *ranking* de categorias utilizando a estratégia RTCut. Na Tabela 3-2, a coluna “Posição” indica a posição das categorias no *ranking* retornado pelo categorizador *VG-RAM WNN-COR* para um dado documento de teste d_i ; a coluna “Categorias preditas a d_i ” mostra os identificadores das categorias no *ranking* retornado pelo categorizador para d_i ; a coluna “Graus de crença originais” mostra os graus de crença com que o categorizador atribuiu as categorias a d_i ; a coluna “Categorias preditas a d_i por RTCut” mostra os identificadores das categorias no *ranking* retornado pela estratégia RTCut; a coluna “Graus de crença sintéticos” mostra os graus de crença sintéticos atribuídos às categorias pela estratégia RTCut; a coluna “Categorias pertinentes a d_i ” mostra a lista de categorias de fato pertinentes a d_i ; e, finalmente, a coluna “Parâmetro τ ” mostra o valor do parâmetro τ otimizado para um conjunto de validação. No exemplo da Tabela 3-2, as categorias com grau de crença sintético superior ao limiar $\tau = 2,4$ são atribuídas aos documentos de teste.

Tabela 3-2 – Exemplo de poda de *ranking* de categorias utilizando a estratégia RTCut.

Posição	Ranking Original		Ranking Sintético		Categorias pertinentes	Parâmetro τ
	Categorias previstas para d_i	Grau de crença d_i	Categorias previstas para d_i	Grau de crença d_i		
1	C9	0,109859	C9	1,09898465	C3	$\tau = 2,4$
2	C8	0,100939	C8	2,09094759	C7	
3	C7	0,089202	C7	3,08037237	C9	
4	C14	0,069484	C14	4,06260615	C54	
5	C10	0,053991	C10	5,04864672		
6	C54	0,045541	C54	6,04103314		
7	C11	0,039906	C11	7,03595592		
8	C67	0,039906	C67	8,03595592		
9	C13	0,025822	C13	9,02326602		
10	C12	0,022066	C12	10,0198818		

RTCut preserva a ordem das categorias no *ranking*, mas permite a distinção entre categorias com a mesma posição nos *rankings* atribuídos a diferentes documentos. Ao podar o *ranking* no grau de crença sintético, ao invés da posição da categoria no *ranking*, compromissos entre revocação e precisão de granularidade mais fina podem ser alcançados [Yang01].

3.3 Estratégia PCut

A estratégia de poda PCut [Yang01], baseada na popularidade das categorias no conjunto de treinamento (*proportion-based*), (i) recebe como entrada as categorizações do conjunto de teste que consiste, para cada $\langle d_j, c_i \rangle \in Te \times C$, dos graus de crença $f(d_j, c_i)$ de que o documento de teste d_j deve ser categorizado dentro da categoria c_i . Dada uma categoria c_i , PCut (ii) ordena os documentos de teste por grau de crença $f(., c_i)$ (gerando um *ranking* de documentos para c_i) e (iii) categoriza os $k_i = p(c_i) * x * |C|$ documentos do topo do *ranking* dentro de c_i , onde $p(c_i)$ é a probabilidade *a priori* (estimada utilizando um conjunto de treinamento) de um documento arbitrário pertencer a c_i e x é um parâmetro cujo valor (um número real) pode ser especificado pelo usuário ou automaticamente ajustado para otimizar o desempenho “global” do categorizador em um conjunto de calibração. PCut foi usada em várias avaliações publicadas de categorizadores probabilísticos, tais como *Naive Bayes*,

decision tree (DTree), *kNN*, e métodos de regressão *linear least squares fit* (LLSF) [Lewis92, Lewis94, Yang99].

A Tabela 3-3 apresenta um exemplo de poda de *ranking* de categorias utilizando a estratégia PCut. Na Tabela 3-3, a coluna “Documentos preditos para c_1 ” mostra os documentos de teste d_j categorizados dentro da categoria c_1 e seus respectivos graus de crença $f(d_j, c_1)$; a coluna “Limiar k_1 ” mostra o valor do limiar de poda k_1 (para a categoria c_1) otimizado para um conjunto de validação; a coluna “Documentos preditos para c_2 ” mostra os documentos de teste d_j categorizados dentro da categoria c_2 e seus respectivos graus de crença $f(d_j, c_2)$; a coluna “Limiar k_2 ” mostra o valor do limiar de poda k_2 (para a categoria c_2) otimizado para um conjunto de validação; e assim por diante. No exemplo da Tabela 3-3, os $k_1 = 5$ documentos do topo do *ranking* da categoria c_1 são categorizados dentro de c_1 , os $k_2 = 7$ documentos do topo do *ranking* de c_2 são categorizados dentro de c_2 , e assim por diante.

Tabela 3-3 – Exemplo de poda de *ranking* de categorias utilizando a estratégia PCut

Documentos preditos c_1		Limiar k_1	Documentos preditos c_2		Limiar k_2	...	Documentos preditos c_m		Limiar k_m
d3	0,22089	$k_1 = 5$	d9	0,29516	$k_2 = 7$		d2	0,29516	$k_m = 3$
d2	0,09801		d6	0,18523		d7	0,13241		
d4	0,04759		d3	0,15627		d4	0,13180		
d7	0,02379		d10	0,14825		d1	0,10809		
d9	0,01927		d8	0,13180		d8	0,029912		
d1	0,016781		d4	0,08187		d10	0,023793		
d5	0,014276		d2	0,05495		d9	0,022434		
d10	0,012237		d7	0,024176	d5	0,018611			
d8	0,011557		d5	0,019231	d6	0,014316			
d6	0,008792		d10	0,018681	d3	0,012169			

A estratégia de poda PCut é a única que utiliza a distribuição de categorias observada no conjunto de treinamento para ganhar um controle global das atribuições das categorias aos documentos no conjunto de teste [Yang01]. Isto dá a PCut poder adicional, mas sacrifica a habilidade de categorização *online*, porque os graus de crença dos documentos de teste devem ser acumulados antes de PCut ser aplicada. Diferente do PCut, as categorizações realizadas por RCut para cada documento de teste são independentes entre si; isto torna RCut mais adequado para categorização *online*. Além disso, PCut assume que a distribuição das

categorias através dos documentos permanece constante – esta é uma boa suposição apenas para certos domínios de documentos.

3.4 Estratégia SCut

A estratégia de poda SCut [Yang01], baseada no grau de crença com que o sistema atribui as categorias aos documentos (*score-based*), ajusta automaticamente um limiar de poda τ_i para cada categoria c_i , de forma a otimizar o desempenho do categorizador para c_i em um conjunto de calibração. Diferente de RCut e PCut, nas quais um único parâmetro (t ou x) é usado para otimizar o desempenho “global” do categorizador na média, SCut otimiza o desempenho “local” do categorizador para categorias individuais sem garantir um ótimo global. SCut foi usada em avaliações de muitos categorizadores, incluindo Ripper, *first order inductive learner* (FOIL), Winnow, *exponentiated gradient* (EG), kNN, *LLSF* e Rocchio [Cohen96, Lewis96, Yang99, Yang01].

Os limiares de poda em SCut são ajustados para otimizar o desempenho do sistema para o conjunto de calibração, enquanto os limiares de poda em PCut dependem apenas das probabilidades das categorias no conjunto de treinamento [Yang01]. Por isso, SCut é mais suscetível a *overfit*, fenômeno pelo qual um categorizador é ajustado também às características contingentes do conjunto treinamento ao invés de apenas as características constitutivas das categorias [Sebastiani02].

A otimização por categoria em SCut torna essa estratégia particularmente efetiva quando o desempenho do sistema em categorias raras é a função alvo a ser otimizada. RCut e PCut, por outro lado, com apenas um único parâmetro (t ou x) a ser ajustado, serão em geral menos efetivas para otimizar o desempenho do sistema em categorias raras.

Diferente de PCut (e similar a RCut), as categorizações realizadas por SCut para cada documento de teste são independentes entre si: uma vez que os limiares por categoria são otimizados (*offline*) para o conjunto de validação, as categorizações para cada documento de teste são independentes entre si. Isto torna SCut e Rcut mais adequados para categorização *online* do que PCut.

3.5 Novas Variantes para as Estratégias PCut e SCut

Nesta seção, propomos modificações para as estratégias de poda PCut e SCut - PCut* e SCut*, respectivamente - para resolver dois problemas que não foram ainda tratados pela literatura: (i) a inadequabilidade de PCut para sistemas de categorização de texto *online*; (ii) a observação, durante o processo de calibração dos limiares de poda de SCut, de intervalos de valores de limiares que produzem desempenho de categorização constante para algumas categorias.

3.5.1 Estratégia PCut*

Como visto na Seção 3.3, a estratégia PCut não é adequada para sistemas de categorização de texto *online*. Entretanto, de acordo com resultados experimentais publicados por Yang (2001), PCut lida melhor com categorias raras do que RCut e SCut e exibe um compromisso mais suave entre revocação e precisão. Dadas estas vantagens, neste trabalho, propomos uma variante da estratégia PCut para sistemas de categorização de texto *online*, a qual denominamos PCut*.

A estratégia de poda PCut* ajusta automaticamente um limiar de poda τ_i para cada categoria c_i , de forma a otimizar o desempenho do categorizador para c_i em um conjunto de calibração. Para isso, PCut* (i) recebe como entrada as categorizações de um conjunto de calibração, Va , que consiste, para cada par $\langle d_j, c_i \rangle \in Va \times C$, dos graus de crença $f(d_j, c_i)$ de que o documento de calibração d_j deve ser categorizado dentro da categoria c_i e, dada uma categoria c_i , (ii) ordena os documentos por grau de crença $f(., c_i)$ (gerando um *ranking* de documentos para c_i), e (iii) categoriza os $k_j = p(c_i) * x * |C|$ documentos do topo do *ranking* dentro de c_i , onde $p(c_i)$ é a probabilidade *a priori* de um documento de treinamento pertencer a c_i e x é um parâmetro cujo valor (um número inteiro) é automaticamente ajustado para otimizar o desempenho “global” do categorizador de um subconjunto do conjunto de calibração. O limiar de poda para a categoria c_i , τ_i , recebe o valor do grau de crença $f(d_j, c_i)$ de que o documento de calibração d_j na posição k_j do *ranking* de documentos de c_i deve ser categorizado dentro de c_i . Quando um documento de teste d_j for submetido ao

sistema de categorização, as categorias c_i cujo grau de crença é superior ao limiar de poda τ_i são então preditas para d_j .

A Tabela 3-4 apresenta um exemplo de poda de *ranking* de categorias utilizando a estratégia PCut*. Na Tabela 3-4, a coluna “Documentos preditos para c_1 ” mostra os documentos de teste d_j categorizados dentro da categoria c_1 e seus respectivos graus de crença $f(d_j, c_1)$; a coluna “Limiar τ_1 ” mostra o valor do limiar de poda τ_1 (para a categoria c_1) otimizado para um conjunto de calibração; a coluna “Documentos preditos para c_2 ” mostra os documentos de teste d_j categorizados dentro da categoria c_2 e seus respectivos graus de crença $f(d_j, c_2)$; a coluna “Limiar τ_2 ” mostra o valor do limiar de poda τ_2 (para a categoria c_2) otimizado para um conjunto de calibração; e assim por diante. No exemplo da Tabela 3-4, os documentos do *ranking* da categoria c_1 com grau de crença superior ao limiar $\tau_1 = 0,08$ são categorizados dentro de c_1 , os documentos do *ranking* de c_2 com grau de crença superior ao limiar $\tau_2 = 0,13$ são categorizados dentro de c_2 , e assim por diante.

Tabela 3-4 – Exemplo de poda de *ranking* de categorias utilizando a estratégia PCut*.

Documentos preditos para c_1		Limiar τ_1	Documentos preditos para c_2		Limiar τ_1	...	Documentos preditos para c_m		Limiar τ_m
d3	0,220889	$\tau_1 = 0,08$	d9	0,29516	$\tau_2 = 0,13$		d2	0,29516	$\tau_m = \tau$
d2	0,098011		d6	0,185229		d7	0,132414		
d4	0,047585		d3	0,156271		d4	0,131802		
d7	0,023793		d10	0,148252		d1	0,10809		
d9	0,019267		d8	0,131802		d8	0,029912		
d1	0,016781		d4	0,081868		d10	0,023793		
d5	0,014276		d2	0,054945		d9	0,022434		
d10	0,012237		d7	0,024176		d5	0,018611		
d8	0,011557		d5	0,019231		d6	0,014316		
d6	0,008792		d10	0,018681		d3	0,012169		

3.5.2 Estratégia SCut*

A estratégia de poda SCut ajusta automaticamente um limiar de poda τ_i para cada categoria c_i , de forma a otimizar o desempenho local do categorizador para c_i em um conjunto de calibração. O valor de τ_i é automaticamente ajustado ao variá-lo até que o desempenho do categorizador para a categoria c_i seja otimizado para o conjunto de validação.

Em nossos experimentos de calibração, observamos que, para algumas categorias c_i , o desempenho do categorizador para c_i permaneceu constante em um dado intervalo de valores (números reais) crescentes de τ_i . Neste caso, testamos duas implementações para a estratégia SCut. Na primeira, SCut tradicional, o limiar de poda para a categoria c_i recebe o valor mínimo do intervalo de valores crescentes de τ_i , para o qual o desempenho do categorizador para c_i permaneceu constante. Na segunda, o limiar de poda para a categoria c_i recebe o valor mínimo daquele intervalo. Dessa forma, os valores dos limiares calibrados por SCut* são maiores do que aqueles calibrados por SCut. Conseqüentemente, SCut* é mais efetiva do que SCut para otimizar o desempenho do sistema em termos de precisão e menos efetiva em termos de revocação.

4 MEDIDA DE CERTEZA DE CATEGORIZAÇÃO

Neste capítulo, propomos um método para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto e duas estratégias para determinar limiares de poda para o *ranking* de categorias baseada na medida de certeza de categorização.

4.1 Uso da Regra de Bayes para o Cálculo da Medida de Certeza de Categorização

Seja F o conjunto dos intervalos não sobrepostos e adjacentes dos valores retornados pela função $f(d_j, c_i)$, que retorna o grau de crença do categorizador de que o documento de teste d_j deve ser categorizado dentro da categoria c_i (Seção 2.1). A probabilidade de um categorizador automático prever corretamente uma categoria c_i para o documento de teste d_j , considerando que ele predisse c_i com grau de crença $f(d_j, c_i)$ dentro de um intervalo $y \in F$ e posicionou c_i na posição $k = r(d_j, c_i)$ do *ranking* de categorias, pode ser enunciada como $p(x/y, k)$, onde:

- a variável aleatória x pode assumir dois valores: 1, se o categorizador predisse uma categoria c_i pertinente a d_j ; ou 0, se o categorizador predisse uma categoria c_i não pertinente a d_j ;
- a variável aleatória y pode assumir valores específicos $y \in F$, que representam os intervalos não sobrepostos e adjacentes dos valores retornados pela função f ;
- a variável aleatória k pode assumir $|C|$ valores $\{1, 2, \dots, |C|\}$, que representam a posição de c_i no *ranking* de categorias.

A probabilidade de interesse, $p(x | y, k)$, é a probabilidade do categorizador prever corretamente qualquer categoria c_i , para qualquer documento de teste d_j , dentre os casos em que o categorizador predisse c_i com grau de crença dentro de um intervalo y e posicionou c_i na posição k do *ranking*. Em outras palavras, $p(x | y, k)$ é o percentual dos documentos de teste categorizados corretamente dentre todos os documentos que foram categorizados com grau de

crença dentro de um intervalo y , ao considerar as categorias posicionadas na posição k do *ranking*.

Desconsiderando por enquanto a variável k , então temos uma quantidade de interesse desconhecida x (predição correta ou incorreta). A informação de que dispomos sobre x é observada probabilisticamente através de $p(x)$. Entretanto, podemos agregar mais informação a $p(x)$ observando uma quantidade aleatória F (conjunto dos intervalos não sobrepostos e adjacentes dos valores retornados pela função $f(d_j, c_i)$) relacionada com x . A distribuição amostral $p(y|x)$ define esta relação (probabilidade de um intervalo y acontecer dado que a predição esta correta para qualquer categoria c_i). A idéia de que após observar $F = y$ a quantidade de informação sobre x aumenta é intuitiva e o teorema de Bayes é a regra de atualização utilizada para quantificar este aumento de informação.

$$p(x|y) = \frac{p(y|x)p(x)}{p(y)} \quad (4-1)$$

Para um valor fixo de y , a função $p(y|x)$ fornece a verossimilhança de cada um dos possíveis valores de x , enquanto $p(x)$ é chamada distribuição a priori de x . Estas duas fontes de informação, priori e verossimilhança, são combinadas levando à distribuição a posteriori de x , $p(x/y)$.

Pela Regra de *Bayes*, a probabilidade de interesse ($p(x|y,k)$) levando em consideração a variável k é dada por:

$$p(x|y,k) = \frac{p(y|x,k)p(x|k)}{p(y|k)} \quad (4-2)$$

Podemos utilizar a regra de *Bayes* para computar $p(x|y,k)$. Através de experimentos de validação, podemos obter amostras experimentais que permitem calcular os valores aproximados dos termos da regra de *Bayes* dos quais $p(x|y,k)$ depende, i.e.:

- $p(y|x,k)$ é a probabilidade do categorizador prever qualquer categoria c_i , para qualquer documento de teste d_j , com grau de crença dentro de um intervalo y , dentre os casos em que o categorizador predisse c_i corretamente e posicionou c_i na posição k do *ranking*. Em outras palavras, $p(y|x,k)$ é o percentual dos documentos de teste categorizados com grau de crença dentro de um intervalo y dentre todos os documentos que foram categorizados corretamente, ao considerar as categorias posicionadas na posição k do *ranking*;

- $p(x|k)$ é a probabilidade do categorizador prever corretamente qualquer categoria para qualquer documento de teste, dado que as categorias foram posicionadas na posição k do *ranking*;
- $p(y|k)$ é a probabilidade do categorizador prever qualquer categoria com grau de crença dentro de um intervalo y , dado que as categorias foram posicionadas na posição k do *ranking*.

As probabilidades $p(x|y,k)$ podem ser usadas para mapear graus de crença $f(d_j, c_i)$ em medidas de certeza de categorização da seguinte forma. Se o categorizador predisse a categoria c_i para o documento d_j com grau de crença $f(d_j, c_i)$ dentro de um intervalo y , e posicionou a categoria c_i na posição $r(d_j, c_i)$ do *ranking*, então a medida de certeza para essa predição pode ser expressa por $p(x/y,k)$, onde $y \subset f(d_j, c_i)$ e $k = r(d_j, c_i)$.

4.2 Uso da Medida de Certeza na Poda do *Ranking* de Categorias

Nesta seção, propomos uma estratégia para determinar limiares de poda para o *ranking* de categorias baseada na medida de certeza de categorização, a qual denominamos *bayesian cut* (BCut). Propomos também uma variante para BCut que usa diferentes limiares de poda para diferentes posições do *ranking*, a qual denominamos *position based bayesian cut* (PBCut).

4.2.1 Estratégia BCut

A estratégia de poda *bayes cut* (BCut), baseada na medida de certeza de categorização descrita na Seção 4.1, para cada documento de teste d_j , (i) ordena as categorias por grau de crença $f(d_j, c_i)$; (ii) mapeia o grau de crença $f(d_j, c_i)$ das p categorias do topo do *ranking* (as categorias no *ranking* em posições inferiores a p são desconsideradas) em uma medida de certeza de categorização $p(x|y,k)$ (Seção 4.1); e atribui a d_j as categorias c_i com medida de certeza $p(x|y,k)$ superior a um determinado limiar τ . BCut é parametrizada por p e τ . O parâmetro p denota o número de posições do *ranking* de categorias consideradas para obter amostras experimentais que permitem calcular os valores aproximados dos termos da regra de Bayes, $p(y|x,k)$, $p(x|k)$ e $p(y|k)$ (Seção 4.1). Os termos da regra de Bayes

diminuem (tendendo a zero) com o aumento do número de posições do *ranking* de categorias consideradas. O valor do parâmetro τ (um número real entre 0 e 1) é automaticamente ajustado para otimizar o desempenho “global” do categorizador em um conjunto de calibração, considerando apenas as p categorias do topo do *ranking* retornado para os documentos.

A Tabela 4-1 apresenta um exemplo de poda de *ranking* de categorias utilizando a estratégia BCut. Na Tabela 4-1, a coluna “Categorias preditas a d_i ” mostra os identificadores das categorias no *ranking* retornado pelo categorizador para d_i ; a coluna “Graus de crença” mostra os graus de crença com que o categorizador atribuiu as categorias a d_i ; a coluna “Categorias preditas a d_i por BCut” mostra os identificadores das categorias no *ranking* retornado pela estratégia BCut; a coluna “Medidas de certeza” mostra as medidas de certeza de categorização atribuídos às categorias pela estratégia BCut; e, finalmente, a coluna “Parâmetro τ ” mostra o valor do parâmetro τ otimizado para um conjunto de validação. No exemplo da Tabela 4-1, as categorias com medidas de certeza de categorização superior ao limiar $\tau = 0,59$ são atribuídas aos documentos de teste.

Tabela 4-1 – Exemplo de poda de *ranking* de categorias utilizando a estratégia BCut.

Ranking Original		Ranking Probabilístico		Parâmetro τ
Categorias preditas a d_i	Graus de Crença d_i	Categorias preditas a d_j	$p(x/y)$	
d58	0,333576	d58	0,970967	$\tau = 0,59$
d89	0,307021	d89	0,712908	
d59	0,302292	d59	0,467745	
d78	0,003638	d78	0,000000	
d90	0,003638	d90	0,003205	
d20	0,003274	d20	0,000000	
d76	0,002183	d76	0,000000	
d56	0,001819	d56	0,000000	
d63	0,001819	d63	0,000000	

A estratégia BCut é mais efetiva, do que todas as outras estratégias de poda consideradas, para otimizar o desempenho do sistema em termos de precisão. A razão é que BCut poda o *ranking* de categorias na medida de certeza de categorização, ou seja, na probabilidade da categorização estar correta.

4.2.2 Estratégia PBCut

A estratégia de poda PBCut, uma variante de BCut, aplica diferentes limiares de poda τ_p para diferentes posições p do *ranking*, ou seja, para cada documento de teste d_j , PBCut atribui a d_j a categoria c_i na posição p do *ranking* somente se sua medida de certeza $p(x|y, k)$ for superior a um determinado limiar τ_p . PBCut é parametrizada por p (similar ao parâmetro p de BCut descrito na Seção 4.2.1) e τ_p . O valor do parâmetro τ_p (um número real entre 0 e 1) é automaticamente ajustado para otimizar o desempenho “global” do categorizador em um conjunto de calibração, considerando apenas as p categorias do topo do *ranking* como resposta para os documentos. A calibração dos diferentes limiares τ_p é processada através de p iterações. Na primeira iteração, o valor de τ_1 é ajustado ao variá-lo até que o desempenho global do categorizador seja otimizado para o conjunto de validação, considerando apenas a primeira categoria do topo do *ranking* como resposta para os documentos. Na segunda iteração, o valor de τ_1 é fixado no valor ótimo encontrado através da primeira iteração e o valor de τ_2 é então ajustado ao variá-lo até que o desempenho do categorizador seja otimizado, considerando apenas as 2 primeiras categorias do topo do *ranking*, e assim por diante.

A Tabela 4-2 apresenta um exemplo de poda de *ranking* de categorias utilizando a estratégia PBCut. Na Tabela 4-2, a coluna “Categorias preditas a d_i ” mostra os identificadores das categorias no *ranking* retornado pelo categorizador para d_i ; a coluna “Graus de crença” mostra os graus de crença com que o categorizador atribuiu as categorias a d_i ; a coluna “Categorias preditas a d_i por PBCut” mostra os identificadores das categorias no *ranking* retornado pela estratégia PBCut; a coluna “Medidas de certeza” mostra as medidas de certeza de categorização atribuídos às categorias pela estratégia PBCut; e, finalmente, a coluna “Parâmetros τ_p ” mostra os valores dos parâmetros τ_p para cada posição p do *ranking* otimizados para um conjunto de validação. No exemplo da Tabela 4-2, são atribuídas ao documento de teste as categorias na posição $p = 1$ do *ranking* com medidas de certeza de categorização superior ao limiar $\tau_1 = 0,79$, $p = 2$ com medidas de certeza superior a $\tau_2 = 0,58$, e $p = 3$ com medidas de certeza superior a $\tau_3 = 0,44$.

Tabela 4-2 – Exemplo de poda de *ranking* de categorias utilizando a estratégia BCut*.

Ranking Original		Ranking Probabilístico		
Categorias preditas a d_i	Graus de Crença d_i	Categorias preditas a d_j	$p(x/y)$	Parâmetro τ_i
d58	0,333576	d58	0,970967	$\tau_1=0,79$
d89	0,307021	d89	0,712908	$\tau_2=0,58$
d59	0,302292	d59	0,467745	$\tau_3=0,44$
d78	0,003638	d78	0,000000	$\tau_4=-1,0$
d90	0,003638	d90	0,003205	$\tau_5=-1,0$
d20	0,003274	d20	0,000000	$\tau_6=-1,0$
d76	0,002183	d76	0,000000	$\tau_7=-1,0$
d56	0,001819	d56	0,000000	$\tau_8=-1,0$
d63	0,001819	d63	0,000000	$\tau_9=-1,0$

A medida de certeza de categorização em uma categoria diminui à medida que a posição da categoria no *ranking* aumenta. Por esta razão, ao escolher diferentes limiares de poda para diferentes posições do *ranking*, a estratégia de poda PBCut pode produzir um desempenho superior ao de BCut em termos de precisão.

5 METODOLOGIA EXPERIMENTAL

Neste capítulo, descrevemos nossa metodologia experimental. Apresentamos as bases de dados empregadas em nossa avaliação experimental, compostas por descrições textuais de atividades econômicas de empresas brasileiras, e a correção ortográfica e a indexação dessas bases de dados. Apresentamos também a abordagem de validação cruzada empregada na avaliação do desempenho dos categorizadores e o ajuste (calibração) dos parâmetros dos categorizadores. Além disso, apresentamos o cálculo dos parâmetros do método baseado na regra de *Bayes* para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto, o procedimento empregado para validar as medidas de certeza de categorização, e, finalmente, o ajuste (calibração) dos parâmetros das estratégias de poda do *ranking* de categorias. O conteúdo das seções 5.1 a 5.5 foi fundamentalmente extraído de [Melotti09].

5.1 Bases de Dados

O conjunto de dados empregado em nossa avaliação experimental é composto de descrições textuais de atividades econômicas de empresas brasileiras. Todas essas descrições foram manualmente categorizadas em uma ou mais atividades econômicas por funcionários públicos Brasileiros treinados nesta tarefa. A lei brasileira determina que todas as empresas devem apresentar uma descrição textual das suas atividades econômicas para órgãos do governo para que elas sejam categorizadas de acordo com a tabela oficial de atividades econômicas, Tabela CNAE-Subclasse [CNAE03]. Chamamos de documento a descrição textual das atividades econômicas de uma empresa categorizadas em uma ou mais categorias da tabela CNAE-Subclasses.

Neste trabalho, contamos com descrições de atividades econômicas de empresas das cidades de Vitória – Espírito Santo e Belo Horizonte – Minas Gerais. A base de dados de Vitória, chamada de VIX, possui 3.281 documentos referentes a empresas da localidade categorizados em 764 diferentes categorias CNAE-Subclasse. O número médio de categorias por documento é 4,3 (desvio padrão de 5,6).

A Figura 5-1 apresenta o histograma do número de documentos com um determinado número de categorias. No gráfico da Figura 5-1, o eixo horizontal representa o Número de categorias por documento e o eixo vertical o Número de documentos. De 1 a 35 categorias por documento, as barras do gráfico indicam exatamente o número de documentos com o respectivo número de categorias. De 36 categorias por documento em diante, só aparecem no eixo horizontal do gráfico os números de categorias por documento para os quais há documentos na base VIX.




Figura 5-1 – Distribuição do número de categorias por documento na base de dados VIX.

O número de categorias por documento varia de 1 a 109, sendo que mais de 800 documentos possuem apenas uma categoria e apenas um documento possui 109 categorias. Como a Figura 5-1 mostra, a maior parte dos documentos da base VIX possui de 1 a 7 categorias por documento (87,53%).

A base de dados de Belo Horizonte, chamada BH, possui 88.000 documentos categorizados em 1.002 diferentes categorias CNAE-Subclasse. O número médio categorias por documento é 2,0 (desvio padrão de 1,7). A Figura 5-2 apresenta o histograma da base BH.




Figura 5-2 – Distribuição do número de categorias por documento na base de dados BH.

Na base BH, o número de categorias por documento varia entre 1 e 27, sendo que quase 50000 documentos possuem apenas uma categoria e apenas um documento possui 27 categorias. Como a Figura 5-2 mostra, a maior parte dos documentos da base BH possui entre 1 e 3 categorias.

A partir das bases VIX e BH, geramos duas bases de dados que utilizamos para treinar, validar, testar e avaliar o impacto dos tipos de *ranking* nos categorizadores. A primeira base gerada, chamada de EX100 (EXatamente 100), possui exatamente 100 exemplares de documentos de cada categoria. Ela é composta de 6.911 documentos selecionados aleatoriamente da união de VIX e BH; 105 categorias diferentes ocorrem na base EX100, isto é, existem exatamente 100 documentos na base categorizados dentro de cada uma destas 105 categorias. O número médio de categorias por documento é 1,52 (desvio padrão de 0,79).

As características da EX100 permitem avaliar o impacto dos *rankings* Ordinal Aleatório, Denso, Padrão e Modificado no desempenho dos categorizadores nos casos onde as categorias estão aproximadamente uniformemente distribuídas na base de treinamento. A Figura 5-3 apresenta o histograma da base EX100. Conforme a figura mostra, o número de categorias por documento varia de 1 a 6, sendo que mais de 4.000 documentos possuem apenas uma categoria e 9 documentos possuem 6 categorias. A maior parte dos documentos desta base possui entre 1 e 2 categorias (89,22%).




Figura 5-3 – Distribuição do número de categorias por documento na base de dados EX100.

Na segunda base gerada, chamada de AT100 (ATé 100), cada categoria ocorre em até 100 diferentes documentos, isto é, existem entre 1 e 100 exemplares de documentos de cada categoria. Ela é composta de 10.495 documentos selecionados aleatoriamente da união de VIX e BH; 692 categorias diferentes ocorrem na base AT100. O número médio de categorias por documentos é 1,49 (desvio padrão de 0,86). As características de AT100 permitem avaliar o impacto de cada tipo de *ranking* no desempenho dos categorizadores nos casos onde existem categorias raras.

A Figura 5-4 apresenta o histograma da base AT100. Conforme a figura mostra, o número de categorias por documento varia de 1 a 12, sendo que mais de 7.000 documentos possuem apenas uma categoria e um documento possui 12 categorias. A maior parte dos documentos desta base possui entre 1 e 2 categorias.




Figura 5-4 – Distribuição do número de categorias por documento na base de dados AT100.

Além das bases EX100 e AT100, utilizamos a própria tabela CNAE-Subclasse, chamada de CNAE, para treinar os categorizadores. A tabela CNAE-Subclasse possui 1183 Subclasses. Cada uma destas Subclasses possui um pequeno texto com sua denominação (ver Seção 2.5.1, pág. 37). Este texto foi utilizado, juntamente com o código CNAE correspondente, como documento de treinamento. Foram utilizados apenas os documentos cujas categorias ocorrem nas bases EX100 ou AT100. Então, temos duas bases CNAE: uma para a base EX100, chamada CNAE_EX100, com 105 documentos (códigos CNAE-Subclasse), e outra para a AT100, chamada CNAE_AT100, com 692 documentos. Estas bases foram usadas porque, no caso de problema de categorização em CNAE, esta informação estará sempre disponível e verificamos que utilizá-la melhora o desempenho dos categorizadores.

5.2 Correção Ortográfica Automática

Antes da geração das bases (EX100 e AT100) para os experimentos de *10-fold cross-validation*, realizamos o procedimento de correção ortográfica automática das bases VIX, BH e CNAE. Foi adotada a correção automática ao invés da manual em função do grande número de documentos existentes nas bases.

A correção ortográfica está relacionada a dois principais problemas: a detecção de erro, que é o processo de encontrar uma palavra errada; e a correção de erro, que é o processo de sugerir palavras corretas para substituir uma palavra errada encontrada [Martins04]. Atualmente, existem corretores ortográficos para diversos idiomas. Dentre os existentes para o Português escolhemos o *GNU Aspell* [Aspell08] por ter código aberto e, assim, permitir a customização necessária para seu uso no SCAE [SCAE08].

A ferramenta *Aspell* faz uso de um dicionário para propor uma lista de palavras corretas para uma palavra errada. Basicamente, a ferramenta calcula a distância entre a palavra errada e cada uma das palavras existentes no dicionário, sendo que a de menor distância é colocada no topo da lista de sugestões, ou seja, a topo da lista é a considerada correta. O valor da distância é considerado pelo *Aspell* como uma pontuação (*score*).

Em testes preliminares de correção ortográfica automática, percebemos que em muitas situações a palavra correta estava na lista de sugestões do *Aspell*, mas não se encontrava no topo. Visando melhorar o desempenho, utilizamos uma lista auxiliar de palavras com as

respectivas frequências [Crowell03]. Esta lista foi gerada a partir das palavras existentes nos documentos da base VIX corrigida manualmente.

O novo *score*, que chamamos de *rank*, é calculado a partir do *score* atribuído pelo *Aspell* e a frequência da palavra (*FP*) existente na lista auxiliar, conforme Equação (5.1). Então, para que o *Aspell* retorne uma palavra correta dada uma errada, o mesmo escolhe a de menor *rank*.

$$rank = \frac{score}{1 + \ln(FP)} \quad (5.1)$$

Mais detalhes sobre o corretor ortográfico automático empregado em [SCAE08].

5.3 Indexação das Bases de Dados

O procedimento de indexação é realizado após o pré-processamento das bases corrigidas, que envolve [Sebastiani02]: *Análise léxica*; *Remoção de stopwords* (artigos, preposições, etc.); e *Redução de dimensionalidade*. A Figura 5-5 apresenta graficamente o fluxograma do pré-processamento, que está também definido/implementado na ferramenta SCAE.




Figura 5-5 – Fluxograma do pré-processamento realizado nas Bases corrigidas anterior à indexação.

Na *Análise léxica*, os textos dos documentos são convertidos em um conjunto de palavras, que são candidatas a serem adotadas como termos dos documentos. Para isso, as palavras do texto dos documentos são separadas pelos caracteres de espaço e pontuação, ou seja, esses caracteres são delimitadores das palavras dos documentos. Por exemplo, considere o texto “*Cultivo de arroz,banana em 1995.*”. O resultado da análise léxica são as palavras “*cultivo*”, “*de*”, “*arroz*”, “*banana*” e “*em*”. Note que os caracteres de dígitos são removidos e palavras maiúsculas são convertidas em minúsculas.

Stopwords são palavras que não possuem informação relevante para a discriminação dos documentos de interesse [Baeza99]. Possíveis classes gramaticais de palavras candidatas a *stopwords* são: artigo, conjunção, contração, interjeição, preposição e pronome. A *Remoção de stopwords* tem como objetivo remover palavras que não contribuem para a categorização dos documentos. Com isso, o número de palavras a serem consideradas é reduzido. Em nossos experimentos, removemos apenas preposição do conjunto *TV* (Seção 2.1, pág. 24). Escolhemos remover apenas preposições porque, em testes preliminares, foi a opção em que os categorizadores apresentaram os melhores desempenhos de categorização.

Após a *Análise léxica* e a *Remoção de stopwords*, aplicamos o pré-processamento *Redução de dimensionalidade* (*dimensionality reduction – DR*) com o objetivo de reduzir a dimensionalidade (o número de termos) do espaço vetorial de representação dos documentos. Para isso, usamos a técnica conhecida como lematização (*lemmatization*) [Manning08], em

que as palavras dos documentos são transformadas na sua forma canônica, ou lema, isto é, o singular de um substantivo ou o infinitivo de um verbo [Antiqueira05, Cherman07]. Para implementar a lematização, utilizamos o dicionário do SCAE, que possui a forma canônica de mais de 1.200.000 de palavras do Português [SCAE08].

As palavras canônicas do conjunto TV que sobrevivem à Análise léxica, Remoção de *stopwords*, e Redução de dimensionalidade são denominadas termos. Chamamos o conjunto de termos presentes em TV, ou seja, o conjunto de palavras de interesse, de *Lexicon*. Com o *Lexicon*, transformamos (ou seja, indexamos) cada documento d_j de nossas bases em sua forma vetorial, $\vec{d}_j = \langle w_{1j}, w_{2j}, \dots, w_{|T|j} \rangle$, conforme discutido na Seção 2.2. Chamamos de Train and Test Vector (TTV) um documento na forma vetorial.

5.4 Validação Cruzada

Em problemas do mundo real, o conjunto de dados disponível para avaliar o desempenho das técnicas de categorização é limitado. Mas, para obtermos uma estimativa confiável do desempenho dos categorizadores desejamos treiná-los e testá-los com tantos documentos quanto possível. Existem muitas técnicas para tratar desse problema, mas a mais empregada na literatura, e que utilizamos neste trabalho, é a técnica *n-fold cross-validation* [Picard84].

Em *n-fold cross-validation*, o conjunto de dados é dividido em n partições mutuamente exclusivas de tamanhos aproximadamente iguais chamadas de *folds*. $n-1$ *folds* são usados para treinar, e o *fold* remanescente é usado para testar os categorizadores. Esse processo é repetido n vezes, cada vez considerando um *fold* diferente para teste. O desempenho reportado do categorizador multi-rótulo de texto segundo as métricas de avaliação de desempenho é a média dos valores das métricas obtidos em cada um dos n *folds*.

A repetição do processo de treinamento e teste permite atenuar a influência de uma amostra de treinamento e teste não representativa, tornando assim a avaliação de desempenho menos tendenciosa e mais confiável. Em experimentos da literatura, o n escolhido é frequentemente igual a 10, pois testes extensivos sobre numerosas bases, com diferentes técnicas de categorização, têm mostrado que 10 é um número apropriado de *folds* para se obter uma estimativa confiável de desempenho [Witten05, pág. 150].

Em nossos experimentos, os 6.911 documentos da base de dados EX100 foram divididos em 10 *folds*, sendo 9 de 691 documentos e um de 692, e os 10.495 documentos da AT100 foram divididos também em 10 *folds*, sendo 9 de 1049 documentos e um de 1054. Nos experimentos com a base EX100, os categorizadores empregados foram treinados com 9 *folds* e com todos os documentos da CNAE_EX100, e testados com o décimo *fold*; enquanto que, nos experimentos com a base AT100, os categorizadores empregados foram treinados com 9 *folds* e com todos os documentos da CNAE_AT100, e testados com o décimo *fold*.

O tamanho médio do *Lexicon* para os experimentos com CNAE_EX100 e EX100 é 3609,8 termos (desvio padrão de 21,17 por conta dos diferentes *folds*), enquanto que, com CNAE_AT100 e AT100, é 5377,6 termos (desvio padrão de 19,45).

5.5 Calibração dos Categorizadores

Os categorizadores apresentados no Capítulo 2 possuem parâmetros intrínsecos que devem ser ajustados (calibrados) com o objetivo de conseguir o melhor desempenho para uma determinada base de dados. Tipicamente, antes de realizar os experimentos de 10-*fold cross-validation*, os parâmetros dos categorizadores são calibrados com uma parte dos dados separada especificamente para a calibração, conhecida com dados de validação. Terminada a calibração dos categorizadores, os dados de validação são agregados aos dados de treinamento [Sebastiani02, Witten05].

Para a calibração de cada categorizador precisamos de dados para seu treinamento e teste com o objetivo de ajuste de parâmetros. O ajuste de parâmetros é feito segundo os seguintes passos:

1. os parâmetros do categorizador são ajustados para um conjunto de valores inicial
2. o categorizador é treinado com uma parte dos dados de validação
3. o categorizador é testado com o restante dos dados de validação
4. seu desempenho medido segundo métrica específica e anotado
5. os parâmetros do categorizador são reajustados para um novo conjunto de valores
6. os passos de 2 a 5 são repetidos várias vezes e os parâmetros que produziram o melhor desempenho são escolhidos

Nos nossos experimentos de calibração, escolhemos como conjunto de dados de validação os documentos de treinamento de um dos *folds* das bases de dados empregadas (EX100 ou AT100). Dividimos este conjunto de dados em 10 partes, onde as nove primeiras são utilizadas no treinamento (passo 2, acima) e a décima no teste (passo 3) dos categorizadores; testamos com apenas uma das 10 partes por conta dos custos computacionais envolvidos. A métrica empregada nos experimentos de calibração (passo 4) foi a *ranking loss*. Nos experimentos de calibração, todos os documentos da CNAE_EX100 e CNAE_AT100 são utilizados durante a fase de treinamento.

O categorizador *ML-k NN* possui apenas um parâmetro, isto é, k (ver seções 2.3 e 2.3.2). O categorizador *ML-k NN* foi calibrado examinando seu desempenho para ambas as bases com os seguintes valores de k : 2, 4, 6, 8, 10, 12, 14, 18, 20, 22, 24, 26, 28, 30, 40, 50, 100, 500, 1000 e 5000. A Figura 5-6 mostra os resultados obtidos no passo 4 do procedimento de calibração do *ML-k NN* para as bases de dados EX100 (Figura 5-6(a)) e AT100 (Figura 5-6(b)). Nestas figuras, o eixo vertical representa o valor da métrica *ranking loss* para os diversos valores de k , e eixo horizontal os valores de k .




Figura 5-6 – Validação do *ML-k NN* segundo a métrica *ranking loss* para EX100, (a), e AT100, (b).

Conforme a Figura 5-6(a) mostra, para a base de dados EX100, este categorizador apresentou melhor desempenho segundo a métrica escolhida para $k = 100$ (ponto mais claro na Figura 5-6(a)). O mesmo ocorre com a base de dados AT100 (Figura 5-6(b)). Assim, o valor $k = 100$ foi escolhido para todos os demais experimentos com o categorizador *ML-k NN*.

O categorizador *VG-RAM WNN-COR* possui dois parâmetros: número de neurônios ($|O|$) e número de sinapses ($|X|$). Para os dois categorizadores a calibração foi realizada com números de neurônio igual a 32, 64, 128, 256, 512 e 1024, e número de sinapses igual 256, 512, 1024 e 2048 para as bases de dados EX100 e AT100.

A Figura 5-7 e a Figura 5-8 apresentam os resultados do processo de validação do *VG-RAM WNN-COR* para as bases EX100 e AT100, respectivamente.




Figura 5-7 – Validação do *VG-RAM WNN-COR* na base EX100.

Conforme mostra a Figura 5-7, este categorizador apresentou melhor desempenho segundo a métrica escolhida para 1024 (32x32) neurônios, mas, mais uma vez, não está claro na figura qual o melhor número de sinapses. Como mostra a Tabela 5-1, o melhor número de sinapses é 512. Assim, para a base de dados EX100, os valores $|O| = 32 \times 32$ e $|X| = 512$ foram escolhidos para todos os demais experimentos com o categorizador *VG-RAM WNN-COR*.

Tabela 5-1 – Validação para *VG-RAM WNN-COR* na EX100 para 32x32 neurônios.

Sinapses	Ranking loss
256	0,024758
512	0,020754
1024	0,021162
2048	0,022277

De acordo com a Figura 5-8, o *VG-RAM WNN-COR* apresentou melhor desempenho segundo a métrica *ranking loss* para 1024 (32x32) neurônios e 1024 sinapses. Assim, para a

base de dados AT100, os valores $|O| = 32 \times 32$ e $|X| = 1024$ foram escolhidos para todos os demais experimentos com o categorizador *VG-RAM WNN-COR*.




Figura 5-8 – Validação do *VG-RAM WNN-COR* na base AT100.

A Tabela 5-2 resume os parâmetros escolhidos para cada categorizador (primeira coluna à esquerda) para as bases de dados EX100 (coluna do meio) e AT100 (última coluna à direita).

Tabela 5-2 – Sumário das escolhas dos parâmetros dos categorizadores na validação para EX100 e AT100.

Categorizador	Bases de dados	
	EX100	AT100
ML- k NN	$k = 100$	$k = 100$
VG-RAM WNN-COR	$ O = 32 \times 32$ $ X = 512$	$ O = 32 \times 32$ $ X = 1024$

5.6 Cálculo dos Parâmetros para a Medida de Certeza

Os parâmetros (termos da regra de *Bayes*) do nosso método para mapear graus de crença em medidas de certeza de categorização (Seção 4.1) são específicos de uma dada

técnica de categorização e de uma dada base de documentos. Nos experimentos realizados para obter os parâmetros de nossa modelagem Bayesiana da certeza na categorização, empregamos os categorizadores *ML-kNN* e *VG-RAM WNN-COR* e os conjuntos de dados EX100 e AT100 (Seção 5.1). Particionamos as bases EX100 e AT100 em 10 subconjuntos de 691 e 1049 documentos, respectivamente (o último tem 692 e 1054, respectivamente). Para estimar os termos da regra de Bayes ($p(x/k)$, $p(y/k)$ e $p(y/x,k)$), para cada uma das bases EX100 e AT100 e para cada um dos categorizadores *ML-kNN* e *VG-RAM WNN-COR*, realizamos uma série de 10 experimentos de calibração. Nestes experimentos, usamos os primeiros 9 dos 10 subconjuntos mencionados acima. Dividimos esses 9 subconjuntos novamente em 10 subconjuntos, e usamos os primeiros nove para treinamento e o último para calibração. Este processo foi repetido 10 vezes com subconjuntos para treinamento e calibração diferentes. Os valores dos termos da regra de Bayes ($p(x/k)$, $p(y/k)$ e $p(y/x,k)$) foram calculados com base nos resultados das categorizações de todos os documentos nesses 10 experimentos de calibração.

Para avaliarmos os resultados dos categorizadores *ML-kNN* e *VG-RAM WNN-COR*, utilizamos a métrica *one-error(k)*, que retorna 0 (zero), se a categoria na posição k do *ranking* pertence ao conjunto de categorias pertinentes ao documento de teste, ou 1 (um), caso contrário. Para cada posição k do *ranking*, particionamos uniformemente os valores de grau de crença $f(d_j, c_i)$ (Seção 4.1) observados na calibração em 20 intervalos. Dessa forma, para cada posição k do *ranking* considerada, $p(y/k)$ é praticamente igual para os diferentes intervalos y . É válido mencionar que os 20 intervalos são diferentes para cada posição k do *ranking* considerada.

```

1 Algoritmo: Cálculos dos Parâmetros para Medida Certa na Categorização
2 CONST INTER 20
3 CONST POS 6

4 obter_intervalo ( predicao )
5 inicio
6   para  $i = 0; i < \text{INTER}; i = i + 1$ 
7     inicio
8       se grau_crenca(predicao)  $\in F[i]$ 
9         return  $i$ ;
10    fim
11 fim.

12 verificar_classe_pertinete(  $d_i$ , predicao )
13 inicio
14   se predicao pertinente  $d_i$ 
15     retorna 1;
16   retorna 0;
17 fim.

18 inicio

   % Treinamento do categorizador
19 CATEGORIZADOR (TV);

   %Acumulando os valores para o caçulo da regra de Bayes por posição do ranking categorias e intervalo y
20 para  $i = 0; i \leq |Te|; i = i + 1$ 
21   inicio
22     % Categorizador retorna ranking de categorias e graus de crença
23      $r_i = \text{CATEGORIZADOR} (Te [i]);$ 
24     para  $pos = 0; pos < |C|; pos = pos + 1$ 
25       inicio
26          $y = \text{obter\_intervalo}( r_i[pos] );$ 
27          $count\_prediction = count\_prediction + 1;$ 
28          $a_{y\_k}[y][pos] = a_{y\_k}[y][pos] + 1;$ 
29         se verificar_classe_pertinete (  $Te [i], r_i[pos]$  ) entao
30           inicio
31              $a_{x\_k}[pos] = a_{x\_k}[pos] + 1;$ 
32              $a_{y\_x\_k}[y][pos] = a_{y\_x\_k}[y][pos] + \text{verificar\_classe\_pertinete} (Te [i], r_i[pos] );$ 
33           fim
34         fim
35       fim
36     fim

   % Calculando os termos da regra de Bayes para cada posição do ranking de categorias e intervalo y.
37 para  $pos = 0; pos < POS; pos = pos + 1$ 
38   inicio
39      $p_{x\_k}[pos] = a_{x\_k}[pos] / count\_prediction;$ 
40     para  $y = 0; y < \text{INTER}; y = y + 1$ 
41       inicio
42          $p_{y\_k}[y][pos] = a_{y\_k}[y][pos] / count\_prediction;$ 
43          $p_{y\_x\_k}[y][pos] = a_{y\_x\_k}[y][pos] / count\_prediction;$ 
44       fim
45     fim
46   fim.

```

Figura 5-9 - Pseudocódigo para calcular os parâmetros da medida de certeza

A Figura 5-9 mostra o pseudocódigo para calcular os parâmetros da medida de certeza

Os parâmetros de entrada do algoritmo são TV , Te , INTER, POS. O parâmetro INTER informa em quantos intervalos o conjunto F (veja na seção 4.1) será particionado, formando os intervalos y . O parâmetro POS informa quantas posições do *ranking* de categorias que será avaliado, ou seja, até que posição do *ranking* será computado os parâmetros para o cálculo da medida de certeza do categorizador. De acordo com a Figura 5-9, o passo (1) define o nome do algoritmo, os passos (2) e (3) definem o valor dos parâmetros INTER e POS. Os passos de (4) a (11) definem uma função chamada obter_intervalo que computa em qual intervalo $y \in F$ a predição do categorizador se encaixa. Os passos (12) a (17) definem uma função chamada verificar_classe_pertinente que verificar se a predição é correta retornando 1 e 0, caso contrário. Os passos (19) a (34) são repetidos 10 vezes para cada conjunto de treinamento e teste. Desta forma, executamos um treinamento com nove partes e com uma partição não utilizada no treinamento para calibrar, esse procedimento é repetido 10 vezes. Computamos as seguintes ocorrências e acumulamos em variáveis os seguintes resultados:

1. Acumulamos em a_{y_k} : o número de predições com grau de crença que se encaixam dentro do intervalo $y \in F$, observadas na posição k do *ranking* de categorias (para as 10 repetições).
2. Acumulamos em a_{x_k} : o número de predições corretas observadas na posição k do *ranking* de categorias (para as 10 repetições).
3. Acumulamos em $a_{y_x_k}$: o número de predições com grau de crença que se encaixam dentro do intervalo $y \in F$ do conjunto de predições corretas observadas na posição k do *ranking* de categorias (para as 10 repetições).

Os passos (35) a (41) computam as seguintes probabilidades: $p(y|k)$, $p(x|k)$ e $p(y|x,k)$ (veja seção 4.1) utilizadas para calcular a medida de certeza do categorizador. Como pode ser observado, para cada posição do *ranking* de categorias computamos uma medida de certeza para a predição correspondente.

Os valores dos termos da regra de *Bayes* ($p(x/k)$, $p(y/k)$ e $p(y/x,k)$) obtidas através dos experimentos de calibração e o valor da medida de certeza são apresentados na Seção 6.1.

5.7 Validação da Medida de Certeza

Nos experimentos realizados para validar nossa modelagem Bayesiana da certeza na categorização, particionamos as bases EX100 e AT100 em 10 subconjuntos de 691 e 1049 documentos, respectivamente (o último tem 692 e 1054, respectivamente). Para cada uma das bases EX100 e AT100, utilizamos os 9 primeiros subconjuntos para treinar o categorizador e o último subconjunto para testá-lo. O objetivo deste experimento de teste é avaliar se o valor de $p(x/y,k)$ calculado analiticamente (a partir dos termos da Regra de *Bayes* observados nos 10 experimentos de validação) é uma boa estimativa para o valor de $p(x/y,k)$ observado empiricamente. Com esse experimento, verificamos que a nossa abordagem estima corretamente o valor de $p(x/y,k)$, ou seja, o valor de $p(x/y,k)$ calculado analiticamente é similar ao valor de $p(x/y,k)$ observado empiricamente.

A comparação entre os valores de $p(x/y,k)$ calculados analiticamente (por meio da regra de *Bayes* a partir das estimativas de $p(x/k)$, $p(y/k)$ e $p(y/x,k)$ obtidas nos experimentos de calibração) com os valores de $p(x/y,k)$ estimados empiricamente (a partir dos experimentos de teste) são apresentados na Seção 6.1.

5.8 Calibração das Estratégias de Poda

As estratégias de poda apresentadas no Capítulo 3 possuem parâmetros que devem ser ajustados (calibrados) com o objetivo de conseguir o melhor desempenho para uma determinada base de dados. Tipicamente, antes de realizar os experimentos de *10-fold cross-validation*, os parâmetros das estratégias de poda são calibrados com uma parte dos dados separada especificamente para a calibração, a qual denominamos dados de calibração. Os dados de calibração são adicionados aos dados de treinamento nos experimentos de teste [Sebastiani02, Witten05].

Nos nossos experimentos de calibração das estratégias de poda, escolhemos como conjunto de dados de validação os documentos de treinamento de um dos *folds* das bases de dados empregadas (EX100 ou AT100). Dividimos este conjunto de dados em 10 partes, onde as nove primeiras são utilizadas no treinamento e a décima no teste (validação) dos categorizadores; testamos com apenas uma das 10 partes por conta dos custos computacionais

envolvidos. Nos experimentos de calibração, todos os documentos da CNAE_EX100 e CNAE_AT100 são utilizados durante a fase de treinamento. A métrica empregada nos experimentos de calibração foi a $macro - F_1^c$. Escolhemos esta métrica porque as estratégias de poda publicadas na literatura foram avaliadas em termos desta métrica.

A seguir, apresentamos os resultados da calibração dos parâmetros das estratégias de poda avaliadas neste trabalho.

5.8.1 Estratégia RCut

A estratégia de poda RCut possui apenas um parâmetro, isto é, t (Seção 3.1). RCut foi calibrada examinando seu desempenho para ambas as bases com os seguintes valores de $t = 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, 15, 16, 17, 18, 19$ e 20 .

A Figura 5-10 mostra os resultados obtidos do procedimento de calibração de RCut para o categorizador $ML-kNN$ e para as bases de dados AT100 (Figura 5-10(a)) e EX100 (Figura 5-10(b)). A Figura 5-11 mostra os resultados obtidos do procedimento de calibração de RCut para o categorizador $VG-RAM WNN-COR$ e para as bases de dados AT100 (Figura 5-11(a)) e EX100 (Figura 5-11(b)). Nestas figuras, o eixo vertical representa o valor da métrica $macro - F_1^c$ para os diversos valores de t , e eixo horizontal os valores de t .





Figura 5-10 – Calibração de R_{Cut} para ML-*k* NN e para (a) AT100 e (b) EX100.




Figura 5-11 – Calibração de RCut para *VG-RAM WNN-COR* para (a) AT100 e (b) EX100.

Conforme a Figura 5-10(a) mostra, para o categorizador *ML-kNN* e para a base de dados AT100, a estratégia RCut apresentou melhor desempenho com $t = 4$. Assim, o valor $t = 4$ foi escolhido para todos os demais experimentos com o categorizador *ML-kNN* e a base AT100. Já para a base EX100 (Figura 5-10(b)), RCut apresentou melhor desempenho com $t = 2$. Assim, o valor $t = 2$ foi escolhido para todos os demais experimentos com o categorizador *ML-kNN* e a base EX100.

Conforme a Figura 5-11(a) mostra, para o categorizador *VG-RAM WNN-COR* e para a base de dados AT100, a estratégia RCut apresentou melhor desempenho com $t = 2$. O mesmo ocorre com a base EX100 (Figura 5-11(b)). Assim, o valor $t = 2$ foi escolhido para todos os demais experimentos com o categorizador *VG-RAM WNN-COR* e as bases AT100 e EX100.

A Tabela 5-3 sumariza os valores escolhidos para o parâmetro de R_Cut para cada categorizador (primeira coluna à esquerda) e para as bases AT100 (coluna do meio) e EX100 (última coluna à direita).


Tabela 5-3 – Sumário dos valores escolhidos para o parâmetro de R_Cut.

Categorizador	Bases de dados	
	AT100	EX100
ML- <i>k</i> NN	$\tau = 4$	$\tau = 2$
VG-RAM WNN-COR	$\tau = 2$	$\tau = 2$


5.8.2 Estratégia R_Cut

A estratégia de poda R_Cut possui apenas um parâmetro, isto é, τ (ver Seção 3.2). Após transformar o *ranking* de categorias em um *ranking* sintético aplicando a Equação ((3-1), a estratégia de poda R_Cut foi calibrada examinando seu desempenho para as ambas as bases com o valor de início $\tau = 0.0$, variando em 0.01 até o valor limite 10.0.

A Figura 5-12 mostra os resultados obtidos do procedimento de calibração de R_Cut para o categorizador *ML-k NN* e para as bases de dados AT100 (Figura 5-12 (a)) e EX100 (Figura 5-12 (b)). A Figura 5-13 mostra os resultados obtidos do procedimento de calibração de R_Cut para o categorizador *VG-RAM WNN-COR* e para as bases de dados AT100 (Figura 5-13 (a)) e EX100 (Figura 5-13 (b)). Nestas figuras, o eixo vertical representa o valor da métrica *macro* – F_1^c para os diversos valores de τ , e eixo horizontal os valores de τ .




(a)




(b)

Figura 5-12 - Calibração de RTCut para $ML-k NN$ para (a) AT100 e (b) EX100.



(a)



(b)

Figura 5-13 - Calibração de RTCut para VG-RAM WNN-COR para (a) AT100 e (b) EX100.

Conforme a Figura 5-12(a) mostra, para o categorizador *ML-kNN* e para a base de dados AT100, a estratégia RTCut apresentou melhor desempenho com $\tau = 4,28$. Assim, o valor $t = 4,28$ foi escolhido para todos os demais experimentos com o categorizador *ML-kNN* e a base AT100. Já para a base EX100 (Figura 5-12(b)), RTCut apresentou melhor desempenho com $\tau = 2,33$. Assim, o valor $\tau = 2,33$ foi escolhido para todos os demais experimentos com o categorizador *ML-kNN* e a base EX100.

Conforme a Figura 5-13(a) mostra, para o categorizador *VG-RAM WNN-COR* e para a base de dados AT100, a estratégia RTCut apresentou melhor desempenho com $\tau = 2,61$. Assim, o valor $\tau = 2,61$ foi escolhido para todos os demais experimentos com o categorizador

VG-RAM WNN-COR e a base AT100. Já para a base EX100 (Figura 5-13 (b)), RTCut apresentou melhor desempenho com $\tau = 2,63$. Assim, o valor $\tau = 2,63$ foi escolhido para todos os demais experimentos com o categorizador *VG-RAM WNN-COR* e a base EX100.

A Tabela 5-4 sumariza os valores escolhidos para o parâmetro de RTCut para cada categorizador (primeira coluna à esquerda) e para as bases AT100 (coluna do meio) e EX100 (última coluna à direita).


Tabela 5-4 – Sumário das escolhas dos parâmetros da estratégia de poda RTCut.

Categorizador	Bases de dados	
	AT100	EX100
ML- <i>k</i> NN	$\tau = 4,28$	$\tau = 2,33$
VG-RAM WNN-COR	$\tau = 2,61$	$\tau = 2,63$


5.8.3 Estratégia PCut

A estratégia de poda PCut possui um parâmetro de ajuste, a saber, x , (ver Seção 3.3). PCut foi calibrada examinando seu desempenho para as ambas as bases com os seguintes valores de $x = 1, 2, 3, 4, 5, 6, 7, 8, 9$ e 10 .

A Figura 5-14 mostra os resultados obtidos do procedimento de calibração de PCut para o categorizador *ML-*k* NN* e para as bases de dados AT100 (Figura 5-14(a)) e EX100 (Figura 5-14(b)). A Figura 5-15 mostra os resultados obtidos do procedimento de calibração de PCut para o categorizador *VG-RAM WNN-COR* e para as bases de dados AT100 (Figura 5-15(a)) e EX100 (Figura 5-15(b)). Nestas figuras, o eixo vertical representa o valor da métrica $macro - F_1^c$ para os diversos valores de x , e eixo horizontal os valores de x .




(a)




(b)

Figura 5-14 - Calibração de PCut para *ML-kNN* e para (a) AT100 e (b) EX100.



(a)



(b)

Figura 5-15 - Calibração de PCut para VG-RAM WNN-COR e para (a) AT100 e (b) EX100.

Conforme a Figura 5-14(a) mostra, para o categorizador *ML-kNN* e para a base de dados AT100, a estratégia PCut apresentou melhor desempenho com $x = 4$. Assim, o valor $x = 4$ foi escolhido para todos os demais experimentos com o categorizador *ML-kNN* e a base AT100. Já para a base EX100 (Figura 5-14(b)), PCut apresentou melhor desempenho com $x = 10$. Assim, o valor $x = 10$ foi escolhido para todos os demais experimentos com o categorizador *ML-kNN* e a base EX100.

Conforme a Figura 5-15(a) mostra, para o categorizador *VG-RAM WNN-COR* e para a base de dados AT100, a estratégia PCut apresentou melhor desempenho com $x = 4$. Assim, o valor $x = 4$ foi escolhido para todos os demais experimentos com o categorizador *VG-RAM*

WNN-COR e a base AT100. Já para a base EX100 (Figura 5-15(b)), PCut apresentou melhor desempenho com $x = 11$. Assim, o valor $x = 11$ foi escolhido para todos os demais experimentos com o categorizador *VG-RAM WNN-COR* e a base EX100.

A Tabela 5-5 sumariza os valores escolhidos para o parâmetro de PCut para cada categorizador (primeira coluna à esquerda) e para as bases AT100 (coluna do meio) e EX100 (última coluna à direita).

Tabela 5-5 – Sumário das escolhas dos parâmetros da estratégia de poda PCut.

Categorizador	Bases de dados	
	AT100	EX100
ML- k NN	$\tau = 4$	$\tau = 10$
VG-RAM WNN-COR	$\tau = 4$	$\tau = 11$

5.8.4 Estratégia SCut


A estratégia de poda SCut possui um parâmetro de ajuste para cada categoria c_j , a saber, τ_j , (ver Seção 3.4). A estratégia de poda SCut foi calibrada examinando seu desempenho para as ambas as bases com o valor de início $\tau_j = 0.0$, variando em 0.01 até o valor limite 1.0. para cada categoria c_j .

O APÊNDICE A apresenta os parâmetros obtidos no procedimento de calibração de SCut para os categorizadores *ML- k NN* e *VG-RAM WNN-COR* e para as bases de dados AT100 e EX100. A Tabela 9-1, Tabela 9-2, Tabela 9-3, Tabela 9-4 e Tabela 9-5 mostram os resultados obtidos do procedimento de calibração do SCut para o categorizador *ML- k NN* e para as bases de dados EX100 e AT100. Tabela 9-6, Tabela 9-7, Tabela 9-8, Tabela 9-9 e Tabela 9-10 mostram os resultados obtidos do procedimento de calibração do SCut para o categorizador *VG-RAM WNN-COR* e para as bases de dados EX100 e AT100.


5.8.5 Estratégia BCut

A estratégia de poda BCut possui apenas um parâmetro, isto é, τ (ver Seção 4.2.1). Após transformar o *ranking* original em um *ranking* probabilístico, a estratégia de poda BCut foi calibrada examinando seu desempenho para ambas as bases com o valor de início $\tau = 0.0$, variando em 0.01 até o valor limite 1.00.

A Figura 5-16 mostra os resultados obtidos do procedimento de calibração de BCut para o categorizador *ML-k NN* e para as bases de dados AT100 (Figura 5-16(a)) e EX100 (Figura 5-16(b)). A Figura 5-17 mostra os resultados obtidos do procedimento de calibração de BCut para o categorizador *VG-RAM WNN-COR* e para as bases de dados AT100 (Figura 5-17(a)) e EX100 (Figura 5-17(b)). Nestas figuras, o eixo vertical representa o valor da métrica $macro - F_1^c$ para os diversos valores de τ , e eixo horizontal os valores de τ .



(a)



(b)

Figura 5-16 - Calibração de BCut para *ML-k NN* e para (a) AT100 e (b) EX100.




Figura 5-17 - Calibração de BCut para VG-RAM WNN-COR e para (a) AT100 e (b) EX100.

Conforme a Figura 5-16(a) mostra, para o categorizador *ML-k NN* e para a base de dados AT100, a estratégia BCut apresentou melhor desempenho com $\tau = 0,03$. Assim, o valor $\tau = 0,03$ foi escolhido para todos os demais experimentos com o categorizador *ML-k NN* e a base AT100. Já para a base EX100 (Figura 5-16(b)), BCut apresentou melhor desempenho com $\tau = 0,22$. Assim, o valor $\tau = 0,22$ foi escolhido para todos os demais experimentos com o categorizador *ML-k NN* e a base EX100.

Conforme a Figura 5-17(a) mostra, para o categorizador VG-RAM WNN-COR e para a base de dados AT100, a estratégia BCut apresentou melhor desempenho com $\tau = 0,13$. Assim, o valor $\tau = 0,13$ foi escolhido para todos os demais experimentos com o categorizador VG-RAM WNN-COR e a base AT100. Já para a base EX100 (Figura 5-17(b)), BCut apresentou

melhor desempenho com $\tau = 0,36$. Assim, o valor $\tau = 0,36$ foi escolhido para todos os demais experimentos com o categorizador *VG-RAM WNN-COR* e a base EX100.

A Tabela 5-6 sumariza os valores escolhidos para o parâmetro de BCut para cada categorizador (primeira coluna à esquerda) e para as bases AT100 (coluna do meio) e EX100 (última coluna à direita).


Tabela 5-6 – Sumário das escolhas dos parâmetros da estratégia de poda BCut.

Categorizador	Bases de dados	
	AT100	EX100
ML- <i>k</i> NN	$\tau = 0,03$	$\tau = 0,22$
VG-RAM WNN-COR	$\tau = 0,13$	$\tau = 0,36$


5.8.6 Estratégia PBCut

A estratégia de poda PBCut possui um parâmetro para cada posição do *ranking* avaliada, isto é, τ_i (ver Seção 4.2.2). A estratégia de poda PBCut foi calibrada examinando seu desempenho para as ambas bases com o valor de início $\tau_i = 0,0$, variando em $0,01$ até o valor limite $1,00$ para cada posição do *ranking*.

A Figura 5-18 mostra os resultados obtidos do procedimento de calibração de PBCut para o categorizador *ML-*k* NN* e para as bases de dados AT100 (Figura 5-18(a)) e EX100 (Figura 5-18(b)). A Figura 5-19 mostra os resultados obtidos do procedimento de calibração de PBCut para o categorizador *VG-RAM WNN-COR* e para as bases de dados AT100 (Figura 5-19(a)) e EX100 (Figura 5-19(b)). Nestas figuras, o eixo vertical representa o valor da métrica *macro* – F_1^c para os diversos valores de τ_i , e eixo horizontal os valores de τ_i .



(a)



(b)

Figura 5-18 - Calibração de PBCut para *ML-k NN* e para (a) AT100 e (b) EX100.




Figura 5-19 - Calibração de PBCut para VG-RAM WNN-COR e para (a) AT100 e (b) EX100.

Conforme a Figura 5-18(a) mostra, para o categorizador *ML-k NN* e para a base de dados AT100, a estratégia PBCut apresentou melhor desempenho com τ_i igual aos valores mostrados na Tabela 5-7 (coluna AT100). Assim, os valores dos parâmetros da Tabela 5-7 (coluna AT100) foram escolhidos para todos os demais experimentos com o categorizador *ML-k NN* e a base AT100. Já para a base EX100 (Figura 5-18(b)), PBCut apresentou melhor desempenho com τ_i igual aos valores mostrados na Tabela 5-7 (coluna EX100). Assim, os valores dos parâmetros da Tabela 5-7 (coluna EX100) foram escolhidos para todos os demais experimentos com o categorizador *ML-k NN* e a base EX100.

Tabela 5-7 – Parâmetro obtidos na calibração da estratégia de poda PBCut segundo *ML-k NN* para AT100 e EX100.

AT100	EX100
$\tau_1 = 0,00$	$\tau_1 = 0,00$
$\tau_2 = 0,12$	$\tau_2 = 0,17$
$\tau_3 = 0,09$	$\tau_3 = 0,25$
$\tau_4 = 0,13$	$\tau_4 = 0,22$
$\tau_5 = 0,16$	$\tau_5 = 0,13$
$\tau_6 = -1,00$	$\tau_6 = 0,10$

Conforme a Figura 5-19 (a) mostra, para o categorizador *VG-RAM WNN-COR* e para a base de dados AT100, a estratégia PBCut apresentou melhor desempenho com τ_i igual aos valores mostrados na Tabela 5-8 (coluna AT100). Assim, os valores dos parâmetros da Tabela 5-8 (coluna AT100) foram escolhidos para todos os demais experimentos com o categorizador *VG-RAM WNN-COR* e a base AT100. Já para a base EX100 (Figura 5-19 (b)), PBCut apresentou melhor desempenho com τ_i igual aos valores mostrados na Tabela 5-8 (coluna EX100). Assim, os valores dos parâmetros da Tabela 5-8 (coluna EX100) foram escolhidos para todos os demais experimentos com o categorizador *VG-RAM WNN-COR* e a base EX100.

Tabela 5-8 - Parâmetro obtidos na calibração da estratégia de poda PBCut segundo *VG-RAM WNN-COR* para AT100 e EX100.

AT100	EX100
$\tau_1 = 0,00$	$\tau_1 = 0,35$
$\tau_2 = 0,13$	$\tau_2 = 0,23$
$\tau_3 = 0,15$	$\tau_3 = 0,36$
$\tau_4 = 0,20$	$\tau_4 = 0,23$
$\tau_5 = 0,00$	$\tau_5 = -1,00$
$\tau_6 = -1,00$	$\tau_6 = -1,00$

A Tabela 5-9 sumariza os parâmetros escolhidos para a estratégia de poda PBCut sob os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para as bases de dados AT100 (coluna do meio) e EX100 (última coluna à direita).

Tabela 5-9 – Sumário das escolhas dos parâmetros da estratégia de poda PBCut.

Categorizador	Bases de dados	
	AT100	EX100
<i>ML-kNN</i>	$\tau_1 = 0,00$	$\tau_1 = 0,00$
	$\tau_2 = 0,12$	$\tau_2 = 0,17$
	$\tau_3 = 0,09$	$\tau_3 = 0,25$
	$\tau_4 = 0,13$	$\tau_4 = 0,22$
	$\tau_5 = 0,16$	$\tau_5 = 0,13$
	$\tau_6 = -1,00$	$\tau_6 = 0,10$
<i>VG-RAM WNN-COR</i>	$\tau_1 = 0,00$	$\tau_1 = 0,35$
	$\tau_2 = 0,13$	$\tau_2 = 0,23$
	$\tau_3 = 0,15$	$\tau_3 = 0,36$
	$\tau_4 = 0,20$	$\tau_4 = 0,23$
	$\tau_5 = 0,00$	$\tau_5 = -1,00$
	$\tau_6 = -1,00$	$\tau_6 = -1,00$

6 RESULTADOS EXPERIMENTAIS

Neste capítulo, apresentamos nossos resultados experimentais. Avaliamos se o valor da medida de certeza de categorização, calculado analiticamente pelo nosso método por meio da regra de *Bayes*, é uma boa estimativa para o valor da medida de certeza de categorização observada empiricamente. Analisamos também o impacto da nossa estratégia de poda de *ranking* de categorias, *BCut*, e sua variante, *PBCut*, no desempenho das técnicas de categorização multi-rótulo de texto, *k*-vizinhos mais próximos multi-rótulo (multi-label *k*-nearest neighbors - *ML-k NN*) [Zhang07] e rede neural sem peso do tipo *VG-RAM* com correlação de dados (*data correlated virtual generalizing random access memory weightless neural networks* – *VG-RAM WNN-COR*) [Aleksander98, Badue08, DeSouza08, DeSouza09a, DeSouza09b], no contexto da categorização de descrições de atividades econômicas de empresas brasileiras segundo a Classificação Nacional de Atividades Econômicas (CNAE) [CNAE03]. Ademais, analisamos o impacto no desempenho dos categorizadores *ML-k NN* e *VG-RAM WNN-COR* de três métodos de poda comumente usados na literatura de RI [Yang01, Lee02, Fan07]: (i) *RCut*, baseada na posição das categorias no *ranking*; (ii) *PCut*, baseada na popularidade das categorias no conjunto de treinamento; (iii) *SCut*, baseada no grau de crença com que o sistema atribui as categorias aos documentos; e (iv) suas variantes *RTCut*, proposta por Yang (2001), e *PCut** e *SCut**, propostas neste trabalho. O desempenho dos categorizadores foi medido em termos das métricas de avaliação de desempenho de categorização multi-rótulo de texto: *exact match* [Kazawa05], *precision* [Sebastiani02, Manning08], *recall* [Sebastiani02, Manning08], e F_1 [Sebastiani02, Manning08].

6.1 Validação da Medida de Certeza

A comparação entre os valores de $p(x/y,k)$ calculados analiticamente (por meio da regra de *Bayes* a partir das estimativas de $p(x/k)$, $p(y/k)$ e $p(y/x,k)$ obtidas nos experimentos de calibração) com os valores de $p(x/y,k)$ estimados empiricamente são apresentados nesta seção para o categorizador *VG-RAM WNN-COR* e a base de dados EX100. Os valores da medida de

certeza para *VG-RAM WNN-COR* e a base de dados AT100 e *ML-k NN* e as bases AT100 e EX100 são apresentados no APÊNDICE B.

A Tabela 6-1, Tabela 6-2, Tabela 6-3, Tabela 6-4 e Tabela 6-5 apresentam a comparação entre os valores de $p(x/y,k)$ calculados analiticamente (por meio da regra de *Bayes* a partir das estimativas de $p(x/k)$, $p(y/k)$ e $p(y/x,k)$ obtidas nos experimentos de validação) com os valores de $p(x/y,k)$ estimados empiricamente para o categorizador *VG-RAM WNN-COR* e a base EX100 a partir dos experimentos de teste para $k = 1, 2, 3, 4$ e 5 , i.e., primeira, segunda, ..., e quinta posição do *ranking*, respectivamente. Nessas tabelas, a coluna Intervalo mostra cada um dos 20 intervalos de valores de f observados nos experimentos de validação, a coluna Validação mostra os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de *Bayes* com os resultados dos experimentos de validação, e a coluna Teste mostra os valores de $p(x/y,k)$ estimados empiricamente a partir dos experimentos de teste.

Como pode ser observado na Tabela 6-1, Tabela 6-2, Tabela 6-3, Tabela 6-4 e Tabela 6-5, os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de *Bayes* são muito próximos aos valores de $p(x/y,k)$ estimados empiricamente, o que demonstra que, usando nossa metodologia, é possível prever no teste com o último *fold* (não visto pelo *VG-RAM WNN-COR* durante o treinamento) o quão certo está o *VG-RAM WNN-COR* quanto à primeira categoria no seu *ranking* de saída ser pertinente para um dado documento. É importante destacar que esta medida de certeza vai de 0% a 100% – uma medida facilmente compreensível para um operador do SCAE humano.

O sistema SCAE usa a Tabela 6-1, Tabela 6-2, Tabela 6-3, Tabela 6-4 e Tabela 6-5 da seguinte forma. Se o *VG-RAM WNN-COR* predisse a categoria c_i para o documento d_j com grau de crença $f(d_j, c_i)$ dentro de um intervalo y (dentro dos 20 intervalos observados na validação), e posicionou a categoria c_i na posição $r(d_j, c_i)$ do *ranking*, então a medida de certeza para essa predição pode ser expressa por $p(x/y,k)$, onde $y \subset f(d_j, c_i)$ e $k = r(d_j, c_i)$.

A tabela Tabela 6-1, Tabela 6-2, Tabela 6-3, Tabela 6-4 e Tabela 6-5 mostram os resultados do uso de nossa metodologia para valores de k iguais a 1, 2, 3, 4 e 5 respectivamente. Como pode ser visto nestas tabelas, também para estes valores de k é possível prever no teste com o último *fold* o quão certo está o *VG-RAM WNN-COR* quanto à categoria na posição k no seu *ranking* de saída ser pertinente para um dado documento. Note que, quanto maior o k (quanto mais abaixo no *ranking* de saída do categorizador), menos provável que a categoria atribuída pelo categorizador seja pertinente ao documento (ver

última linha das tabelas). Isso é esperado, já que, para a base de dados empregada no treinamento (EX100), é incomum existirem mais que dois códigos pertinentes a um dado documento.

Tabela 6-1 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=1$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,048906)	$p(x y,k)$	0,346155	$p(x/y,k)$	0,291667
2	(0,048906 - 0,059188)	$p(x y,k)$	0,530551	$p(x/y,k)$	0,400000
3	(0,059188 - 0,066578)	$p(x y,k)$	0,581998	$p(x/y,k)$	0,625000
4	(0,066578 - 0,073284)	$p(x y,k)$	0,672018	$p(x/y,k)$	0,500000
5	(0,073284 - 0,079183)	$p(x y,k)$	0,742759	$p(x/y,k)$	0,434783
6	(0,079183 - 0,084823)	$p(x y,k)$	0,742759	$p(x/y,k)$	0,692308
7	(0,084823 - 0,090226)	$p(x y,k)$	0,723465	$p(x/y,k)$	0,578947
8	(0,090226 - 0,095975)	$p(x y,k)$	0,784559	$p(x/y,k)$	0,480000
9	(0,095975 - 0,101643)	$p(x y,k)$	0,819937	$p(x/y,k)$	0,814815
10	(0,101643 - 0,108434)	$p(x y,k)$	0,778138	$p(x/y,k)$	0,774194
11	(0,108434 - 0,115315)	$p(x y,k)$	0,816727	$p(x/y,k)$	0,838710
12	(0,115315 - 0,122085)	$p(x y,k)$	0,836006	$p(x/y,k)$	0,880952
13	(0,122085 - 0,130695)	$p(x y,k)$	0,791657	$p(x/y,k)$	0,750000
14	(0,130695 - 0,141219)	$p(x y,k)$	0,861300	$p(x/y,k)$	0,894737
15	(0,141219 - 0,153803)	$p(x y,k)$	0,874595	$p(x/y,k)$	0,837838
16	(0,153803 - 0,171683)	$p(x y,k)$	0,900326	$p(x/y,k)$	0,878049
17	(0,171683 - 0,198192)	$p(x y,k)$	0,887452	$p(x/y,k)$	0,882353
18	(0,198192 - 0,232168)	$p(x y,k)$	0,958194	$p(x/y,k)$	0,783784
19	(0,232168 - 0,319712)	$p(x y,k)$	0,967841	$p(x/y,k)$	0,943396
20	(0,319712 - 1,000000)	$p(x y,k)$	0,970967	$p(x/y,k)$	0,933333

Tabela 6-2 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,022611)	$p(x y,k)$	0,009616	$p(x/y,k)$	0,031250
2	(0,022611 - 0,027632)	$p(x y,k)$	0,019293	$p(x/y,k)$	0,050000
3	(0,027632 - 0,032089)	$p(x y,k)$	0,054660	$p(x/y,k)$	0,037037
4	(0,032089 - 0,036620)	$p(x y,k)$	0,090033	$p(x/y,k)$	0,031250
5	(0,036620 - 0,040404)	$p(x y,k)$	0,121794	$p(x/y,k)$	0,080000
6	(0,040404 - 0,044269)	$p(x y,k)$	0,145161	$p(x/y,k)$	0,115385
7	(0,044269 - 0,047990)	$p(x y,k)$	0,170420	$p(x/y,k)$	0,000000
8	(0,047990 - 0,052008)	$p(x y,k)$	0,225080	$p(x/y,k)$	0,250000
9	(0,052008 - 0,055889)	$p(x y,k)$	0,292606	$p(x/y,k)$	0,172414
10	(0,055889 - 0,060299)	$p(x y,k)$	0,270093	$p(x/y,k)$	0,250000
11	(0,060299 - 0,064851)	$p(x y,k)$	0,331186	$p(x/y,k)$	0,270270
12	(0,064851 - 0,069875)	$p(x y,k)$	0,385853	$p(x/y,k)$	0,400000
13	(0,069875 - 0,074904)	$p(x y,k)$	0,401926	$p(x/y,k)$	0,281250
14	(0,074904 - 0,081272)	$p(x y,k)$	0,472666	$p(x/y,k)$	0,420000
15	(0,081272 - 0,087618)	$p(x y,k)$	0,479100	$p(x/y,k)$	0,375000
16	(0,087618 - 0,095580)	$p(x y,k)$	0,572346	$p(x/y,k)$	0,500000
17	(0,095580 - 0,105363)	$p(x y,k)$	0,591639	$p(x/y,k)$	0,718750
18	(0,105363 - 0,120024)	$p(x y,k)$	0,601286	$p(x/y,k)$	0,589744
19	(0,120024 - 0,152786)	$p(x y,k)$	0,559486	$p(x/y,k)$	0,564103
20	(0,152786 - 1,000000)	$p(x y,k)$	0,712908	$p(x/y,k)$	0,750000

Tabela 6-3 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,017595)	$p(x y,k)$	0,006411	$p(x/y,k)$	0,142857
2	(0,017595 - 0,020573)	$p(x y,k)$	0,009648	$p(x/y,k)$	0,038462
3	(0,020573 - 0,023336)	$p(x y,k)$	0,016076	$p(x/y,k)$	0,000000
4	(0,023336 - 0,025939)	$p(x y,k)$	0,016076	$p(x/y,k)$	0,035714
5	(0,025939 - 0,028364)	$p(x y,k)$	0,032155	$p(x/y,k)$	0,034483
6	(0,028364 - 0,030728)	$p(x y,k)$	0,045016	$p(x/y,k)$	0,035714
7	(0,030728 - 0,033007)	$p(x y,k)$	0,051448	$p(x/y,k)$	0,000000
8	(0,033007 - 0,035250)	$p(x y,k)$	0,045016	$p(x/y,k)$	0,045455
9	(0,035250 - 0,037608)	$p(x y,k)$	0,061092	$p(x/y,k)$	0,000000
10	(0,037608 - 0,040024)	$p(x y,k)$	0,083600	$p(x/y,k)$	0,038462
11	(0,040024 - 0,042752)	$p(x y,k)$	0,115756	$p(x/y,k)$	0,030303
12	(0,042752 - 0,045650)	$p(x y,k)$	0,131832	$p(x/y,k)$	0,000000
13	(0,045650 - 0,048971)	$p(x y,k)$	0,109324	$p(x/y,k)$	0,162162
14	(0,048971 - 0,052439)	$p(x y,k)$	0,183280	$p(x/y,k)$	0,111111
15	(0,052439 - 0,057078)	$p(x y,k)$	0,205788	$p(x/y,k)$	0,230769
16	(0,057078 - 0,061834)	$p(x y,k)$	0,205788	$p(x/y,k)$	0,189189
17	(0,061834 - 0,068206)	$p(x y,k)$	0,285254	$p(x/y,k)$	0,266667
18	(0,068206 - 0,077441)	$p(x y,k)$	0,351615	$p(x/y,k)$	0,156250
19	(0,077441 - 0,092551)	$p(x y,k)$	0,437299	$p(x/y,k)$	0,357143
20	(0,092551 - 1,000000)	$p(x y,k)$	0,467745	$p(x/y,k)$	0,562500

Tabela 6-4 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,014855)	$p(x y,k)$	0,000000	$p(x/y,k)$	0,000000
2	(0,014855 - 0,017219)	$p(x y,k)$	0,009647	$p(x/y,k)$	0,000000
3	(0,017219 - 0,019100)	$p(x y,k)$	0,003205	$p(x/y,k)$	0,000000
4	(0,019100 - 0,020833)	$p(x y,k)$	0,006411	$p(x/y,k)$	0,000000
5	(0,020833 - 0,022457)	$p(x y,k)$	0,012944	$p(x/y,k)$	0,000000
6	(0,022457 - 0,024081)	$p(x y,k)$	0,009616	$p(x/y,k)$	0,000000
7	(0,024081 - 0,025773)	$p(x y,k)$	0,012861	$p(x/y,k)$	0,041667
8	(0,025773 - 0,027458)	$p(x y,k)$	0,019355	$p(x/y,k)$	0,000000
9	(0,027458 - 0,029207)	$p(x y,k)$	0,028846	$p(x/y,k)$	0,037037
10	(0,029207 - 0,030888)	$p(x y,k)$	0,051447	$p(x/y,k)$	0,034483
11	(0,030888 - 0,032725)	$p(x y,k)$	0,061290	$p(x/y,k)$	0,085714
12	(0,032725 - 0,034578)	$p(x y,k)$	0,038585	$p(x/y,k)$	0,033333
13	(0,034578 - 0,036846)	$p(x y,k)$	0,048232	$p(x/y,k)$	0,064516
14	(0,036846 - 0,039273)	$p(x y,k)$	0,115015	$p(x/y,k)$	0,093750
15	(0,039273 - 0,041846)	$p(x y,k)$	0,087379	$p(x/y,k)$	0,062500
16	(0,041846 - 0,044872)	$p(x y,k)$	0,128204	$p(x/y,k)$	0,096774
17	(0,044872 - 0,048928)	$p(x y,k)$	0,125806	$p(x/y,k)$	0,131579
18	(0,048928 - 0,054723)	$p(x y,k)$	0,183279	$p(x/y,k)$	0,062500
19	(0,054723 - 0,064407)	$p(x y,k)$	0,227563	$p(x/y,k)$	0,210526
20	(0,064407 - 1,000000)	$p(x y,k)$	0,391589	$p(x/y,k)$	0,440000

Tabela 6-5 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
1	(0,000000 - 0,013276)	$p(x y,k)$	0,003205	$p(x/y,k)$	0,027027
2	(0,013276 - 0,015484)	$p(x y,k)$	0,000000	$p(x/y,k)$	0,000000
3	(0,015484 - 0,016903)	$p(x y,k)$	0,012862	$p(x/y,k)$	0,000000
4	(0,016903 - 0,018129)	$p(x y,k)$	0,003216	$p(x/y,k)$	0,000000
5	(0,018129 - 0,019425)	$p(x y,k)$	0,006431	$p(x/y,k)$	0,000000
6	(0,019425 - 0,020612)	$p(x y,k)$	0,012862	$p(x/y,k)$	0,034483
7	(0,020612 - 0,021800)	$p(x y,k)$	0,016077	$p(x/y,k)$	0,000000
8	(0,021800 - 0,023065)	$p(x y,k)$	0,000000	$p(x/y,k)$	0,030303
9	(0,023065 - 0,024476)	$p(x y,k)$	0,009616	$p(x/y,k)$	0,000000
10	(0,024476 - 0,025764)	$p(x y,k)$	0,012862	$p(x/y,k)$	0,000000
11	(0,025764 - 0,027174)	$p(x y,k)$	0,038586	$p(x/y,k)$	0,035714
12	(0,027174 - 0,028626)	$p(x y,k)$	0,022581	$p(x/y,k)$	0,068966
13	(0,028626 - 0,030175)	$p(x y,k)$	0,028939	$p(x/y,k)$	0,034483
14	(0,030175 - 0,031882)	$p(x y,k)$	0,035370	$p(x/y,k)$	0,125000
15	(0,031882 - 0,033888)	$p(x y,k)$	0,051282	$p(x/y,k)$	0,045455
16	(0,033888 - 0,036267)	$p(x y,k)$	0,048388	$p(x/y,k)$	0,060606
17	(0,036267 - 0,039041)	$p(x y,k)$	0,067308	$p(x/y,k)$	0,142857
18	(0,039041 - 0,042965)	$p(x y,k)$	0,080646	$p(x/y,k)$	0,103448
19	(0,042965 - 0,050193)	$p(x y,k)$	0,122187	$p(x/y,k)$	0,075472
20	(0,050193 - 1,000000)	$p(x y,k)$	0,248390	$p(x/y,k)$	0,294118

6.2 Comparação entre as Estratégias de Poda

Nesta seção, apresentamos a formulação das métricas de avaliação de desempenho de categorização multi-rótulo de texto empregadas neste trabalho: *exact match* [Kazawa05], *precision* [Sebastiani02, Manning08], *recall* [Sebastiani02, Manning08] e F_β [Sebastiani02, Manning08]. Estas métricas avaliam o conjunto exato de categorias \hat{C}_j , predito para o documento de teste d_j .

6.2.1 Exact Match

A métrica *exact match* (*exact-match_j*) avalia o quão freqüente todas e somente todas as categorias pertinentes estão presentes no conjunto de categorias preditas de d_j . A formulação original de Kazawa et al. [Kazawa05] é apresentada na Equação ((6.3).

$$exact - match_j = \begin{cases} 1 & \text{se } \hat{C}_j^{|C_j|} = C_j \\ 0 & \text{caso contrário} \end{cases} \quad (6.3)$$

Se o conjunto $\hat{C}_j^{|C_j|}$ é igual ao conjunto C_j , $exact - match_j = 1$, caso contrário, $exact - match_j = 0$. O desempenho global é obtido conforme Equação ((6.1). Quanto maior o valor de $exact - match$, melhor o desempenho do categorizador. O desempenho é perfeito quando $exact - match = 1$.

$$exact - match = \frac{1}{|Te|} \sum_{j=1}^{|Te|} exact - match_j \quad (6.1)$$

A Figura 6-1 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *exact match* segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para as bases AT100 e EX100. No gráfico apresentado na Figura 6-1, existem nove conjuntos de barras, um para cada categorizador empregado, onde a amplitude de cada barra indica o valor de *exact match* (média dos 10 *folds*) para cada uma das diversas estratégias de poda de *ranking* de categorias. Em cada conjunto de barras, da esquerda para a direita, a primeira barra indica a poda Ideal¹ do *ranking*, a segunda a estratégia de poda RCut, a terceira a estratégia de poda RTCut, a quarta a estratégia de poda SCut, a quinta a estratégia de poda SCut*, a sexta a estratégia de poda PCut, a sétima a estratégia de poda PCut*, a oitava a estratégia de poda BCut, a nona a estratégia de poda PBCut (ver legenda nos gráficos da figura).

¹ A estratégia de poda de *ranking* Ideal retorna para um dado documento d_j as $|C_j|$ categorias do topo do *ranking*, ou seja, a quantidade de categorias retornadas $|\hat{C}_j|$ é igual a quantidade de categorias realmente pertinente $|C_j|$.





Figura 6-1 - Resultado da métrica *exact-match* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-1 mostram, o valor de *exact match* do categorizador *ML-k NN* com a base AT100 (Figura 6-1(a)) é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *exact match* ao usar a estratégia de poda de *ranking* BCut e PBCut são significativamente maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut* SCut e SCut*. O mesmo ocorre com o

categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-1(a)). O valor de *exact match* com a estratégia de poda *SCut** é significativamente maior do que com a estratégia de poda *SCut* (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-1(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-1(a)). O valor de *exact match* com a estratégia de poda *PCut** é significativamente menor do que com a estratégia de poda *PCut* (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-1(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-1(a)).

Como apresentado na Figura 6-1, as barras do gráfico mostram o valor de *exact match* do categorizador *ML-k NN* com a base de dados EX100 (Figura 6-1(b)) é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *exact match* ao usar as estratégias de poda de *ranking* *BCut* e *PBCut* são significativamente maiores do que os resultados obtidos ao usar as estratégias *RCut*, *RTCut*, *PCut*, *PCut**, *SCut* e *SCut**. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-1(b)). O valor de *exact match* com a estratégia de poda *SCut** é significativamente maior do que com a estratégia de poda *SCut* (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-1(b)). O valor de *exact match* com a estratégia de poda *SCut** é menor do que com a estratégia de poda *SCut* (tradicional) com o categorizador *VG-RAM WNN-COR* com a base EX100 (Figura 6-1(b)). O valor de *exact match* com a estratégia de poda *PCut** é menor que com a estratégia de poda *PCut* (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-1(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *exact match* mostram que as estratégias de poda *BCut* e *PBCut* melhoram o desempenho desses categorizadores para ambas bases, como visto na Figura 6-1(a)(b). Isso acontece porque a estratégia *BCut* poda o *ranking* com base na probabilidade da categorização estar correta e a estratégia *PBCut* poda o *ranking* com base na probabilidade da categorização estar correta em cada posição do *ranking*, observando o decréscimo da medida de certeza a medida que a posição da categoria no *ranking* aumenta. Desta forma, as estratégias de poda *BCut* e *PBCut* são mais efetivas para otimizar o desempenho do sistema em termos da *exact match* do que as estratégias *RCut*, *RTCut*, *PCut*, *PCut**, *SCut* e *SCut**, pois conseguem podar o *ranking* de maneira a retornar um conjunto de categorias idênticos ao conjunto de categorias pertinente.

6.2.2 Precisão (*precision*) Orientada à Categoria

A métrica *precisão (precision) orientada à categoria* ($precision_i^c$) avalia a fração de documentos de teste categorizados sob a categoria c_i que são verdadeiramente associados a c_i . A formulação é apresentada na Equação (6.2).

$$precision_i^c = \frac{|\hat{C}_j^{c_i} \cap C_j|}{|\hat{C}_j^{c_i}|} \tag{6.2}$$

A métrica *precision* orientada à categoria também pode ser computada utilizando a tabela de contingência da categoria c_i (Tabela 6-6), de acordo com a Equação (6.3).

$$precision_i^c = \frac{TP_i}{TP_i + FP_i} \tag{6.3}$$

onde FP_i (falsos positivos para c_i) é o número de documentos de teste que foram incorretamente categorizados sob c_i ; TN_i (verdadeiros negativos para c_i) é o número de documentos de teste que foram corretamente não categorizados sob c_i ; TP_i (verdadeiros positivos para c_i) é o número de documentos de teste que foram corretamente categorizados sob c_i ; e FN_i (falsos negativos para c_i) é o número de documentos de teste que foram incorretamente não categorizados sob c_i .

Tabela 6-6 – Tabela de contingência da categoria c_i .

Categoria c_i		Julgamentos do especialista	
		SIM	NÃO
Julgamentos do categorizador	SIM	TP_i	FP_i
	NÃO	FN_i	TN_i

O desempenho global de *precision* orientada à categoria pode ser computado pelo método *macroaveraging* (*macro-precision^c*) e *microaveraging* (*micro-precision^c*), Equação (6.4) e Equação (6.5), respectivamente [Sebatiani2002]. O método *macroaveraging* reporta o desempenho global sobre a soma dos resultados de *precision_i^c* (Equação (6.4)), e o *microaveraging* sobre a soma das decisões individuais em termos da tabela de contingência, $\frac{TP_i}{(TP_i + FP_i)}$ (Equação (6.5)), para cada categoria c_i .

$$\text{macro-precision}^c = \frac{\sum_{i=1}^{|C|} \text{precision}_i^c}{|C|} \quad (6.4)$$

$$\text{micro-precision}^c = \frac{\sum_{i=1}^{|C|} TP_i}{\sum_{i=1}^{|C|} (TP_i + FP_i)} \quad (6.5)$$

Os métodos *macroaveraging* e *microaveraging* podem dar resultados bastante diferentes, especialmente se as generalidades das categorias são desiguais [Manning08; Sebastiani02]. A habilidade de um categorizador de se comportar bem mediante categorias com baixa generalidade é evidenciada muito mais por *macroaveraging* e do que por *microaveraging*. O método *macroaveraging* dá peso igual para cada categoria, enquanto *microaveraging* dá peso igual para cada decisão de categorização [Manning08]. Desta forma, categorias com alta generalidade dominam aquelas com baixa generalidade em *microaveraging*.

Quanto maior o valor de *macro-precision^c* e *micro-precision^c* melhor o desempenho do categorizador. O desempenho é perfeito quando *macro-precision^c* = 1 e *micro-precision^c* = 1.

A Figura 6-2 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *macro-precision^c* segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-2(a)) e EX100 (Figura 6-2(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.





Figura 6-2 - Resultado da métrica *macro – precision^c* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-2 mostram, o valor de *macro – precision^c* do categorizador *ML-k NN* com a base AT100 (Figura 6-2(a)) é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor da *macro – precision^c* ao usar a estratégia de poda de *ranking* PCut é significativamente maior do que os resultados obtidos ao


usar as estratégias R_{Cut}, R_TC_{ut}, P_{Cut}*, S_{Cut}, S_{Cut}*, B_{Cut} e P_BC_{ut}. O resultados obtidos com o categorizador *VG-RAM WNN* com a base de dados AT100 (Figura 6-2(a)) mostram um equilíbrio parcial entre as estratégias de poda R_{Cut}, R_TC_{ut}, B_{Cut} e P_BC_{ut}. O valor de *macro – precision^c* com a estratégia de poda S_{Cut}* é significativamente maior do que com a estratégia de poda S_{Cut} (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-2(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-2(a)). O valor de *macro – precision^c* com a estratégia de poda P_{Cut}* é significativamente menor do que com a estratégia de poda P_{Cut} (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-2(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-2(a)).

Como o apresentado na Figura 6-2, as barras do gráfico mostram o valor de *macro – precision^c* do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *macro – precision^c* ao usar as estratégias de poda de *ranking* B_{Cut} e P_BC_{ut} são significativamente maiores do que os resultados obtidos ao usar as estratégias R_{Cut}, R_TC_{ut}, P_{Cut}, P_{Cut}*, S_{Cut} e S_{Cut}*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-2(a)). O valor de *macro – precision^c* com a estratégia de poda S_{Cut}* é significativamente maior que com a estratégia de poda S_{Cut} (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-2 (b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-2(b)). O valor de *macro – precision^c* com a estratégia de poda P_{Cut}* é menor do que com a estratégia de poda P_{Cut} (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-2(B)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-2 (b)).


A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *macro – precision^c* mostram que as estratégias de poda B_{Cut} e P_BC_{ut} melhoram o desempenho desses categorizadores para a base de dados EX100, como visto na, Figura 6-2(b). Isso acontece porque a estratégia B_{Cut} poda o *ranking* com base na probabilidade da categorização estar correta e a estratégia P_BC_{ut} poda o *ranking* com base na probabilidade da categorização estar correta em cada posição do *ranking*, observando o decremento da medida de certeza a medida que a posição da categoria no *ranking* aumenta. Desta forma, as estratégias de poda B_{Cut} e P_BC_{ut} são mais efetivas para otimizar o

desempenho do sistema em termos da métrica *macro-precision^c* do que as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut* para estes categorizadores e para a base EX100.

A Figura 6-3 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *micro-precision^c* segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-3(a)) e EX100 (Figura 6-3(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.



(a)



(b)

Figura 6-3 - Resultado da métrica *micro – precision^c* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-3 mostram, o valor de *micro – precision^c* do categorizador *ML-k NN* com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. Os valores de *micro – precision^c* ao usar a estratégia de poda de *ranking* BCut e PBCut são maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN* com a base de dados AT100 (Figura 6-3(a)). O valor de *micro – precision^c* com a estratégia de poda SCut* é significativamente maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-3(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-3(a)). O valor de *micro – precision^c* com a estratégia de poda PCut* é significativamente menor do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-3(a)).

Com apresentado na Figura 6-3, as barras do gráfico mostram o valor de *micro – precision^c* do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *micro – precision^c* ao usar as estratégias de poda de *ranking* BCut e PBCut são significativamente maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-3(b)). O valor de *micro – precision^c* com a estratégia de poda SCut* é significativamente maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-3(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-3(b)). O valor de *micro – precision^c* com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-3(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *micro – precision^c* mostram que as estratégias de poda BCut e PBCut melhoram o desempenho desses categorizadores para ambas bases, como visto na Figura 6-3(a)(b). Isso acontece porque a estratégia BCut poda o *ranking* com base na probabilidade da categorização estar correta e a estratégia PBCut poda o *ranking* com base na

probabilidade da categorização estar correta em cada posição do *ranking*, observando o decremento da medida de certeza a medida que a posição da categoria no *ranking* aumenta. Desta forma, as estratégias de poda BCut e PBCut são mais efetivas para otimizar o desempenho do sistema em termos da métrica *micro – precision^c* do que as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*.

6.2.3 Revocação (*recall*) Orientada à Categoria

A métrica **revocação (*recall*) orientada à categoria (*recall_i^c*)** avalia a fração de documentos de teste verdadeiramente associados com a categoria c_i que são categorizados sob c_i . A formulação original é apresentada na Equação (6.6).

$$recall_i^c = \frac{|\hat{C}_j^{c_i} \cap C_j|}{|C_j|} \quad (6.6)$$

O valor de *recall_i^c* também pode ser computado em termos da tabela de contingência da categoria c_i , Tabela 6-6, conforme Equação (6.7).

$$recall_i^c = \frac{TP_i}{TP_i + FN_i} \quad (6.7)$$

O desempenho global de recall orientada à categoria é calculado pelos métodos *macro – recall^c* e *micro – recall^c*, Equação (6.8) e Equação (6.9), respectivamente. Quanto maior o valor de *macro – recall^c* e *micro – recall^c*, melhor o desempenho do categorizador. O desempenho é perfeito quando *macro – recall^c* = 1 e *micro – recall^c* = 1.

$$macro - recall^c = \frac{\sum_{i=1}^{|C|} recall_i^c}{|C|} \quad (6.8)$$

$$\text{micro-recall}^c = \frac{\sum_{i=1}^{|\mathcal{C}|} TP_i}{\sum_{i=1}^{|\mathcal{C}|} (TP_i + FN_i)} \quad (6.9)$$

A Figura 6-4 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *macro-recall*^c segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-4(a)) e EX100 (Figura 6-4(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.





Figura 6-4 - Resultado da métrica *macro – recall^c* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-4 mostram, o valor de *macro – recall^c* do categorizador *ML-k NN* com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *macro – recall^c* ao usar a estratégia de poda de *ranking* SCut é significativamente maior do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut. O mesmo ocorre com o categorizador *VG-RAM*

WNN com a base de dados AT100 (Figura 6-4(a)). O valor de *macro-recall^c* com a estratégia de poda SCut* é significativamente menor do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-4(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-4(a)). O valor de *macro-recall^c* com a estratégia de poda PCut* é significativamente maior do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-4(a)).

Com o apresentado na Figura 6-4, as barras do gráfico mostram o valor de *macro-recall^c* do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *macro-recall^c* ao usar a estratégia de poda de *ranking* SCut é significativamente maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut. O valor de *macro-recall^c* com a estratégia de poda SCut* é significativamente menor do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-4(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-4(b)). O valor de *macro-recall^c* com a estratégia de poda PCut* é maior mdo que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-4(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *macro-recall^c* mostram que a estratégia de poda SCut melhora o desempenho desses categorizadores para ambas bases, como visto na Figura 6-4 (a)(b). Isso acontece porque SCut otimiza o desempenho do categorizador por categoria, tornando-a particularmente efetiva quando o desempenho do sistema em categorias raras é a função alvo a ser otimizada. Desta forma, a estratégia de poda SCut é mais efetiva para otimizar o desempenho do sistema em termos da métrica *macro-recall^c* do que as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut.

A Figura 6-5 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *micro-recall^c* segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-5(a)) e EX100 (Figura 6-5(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.





Figura 6-5 - Resultado da *micro-recall^c* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-5 mostram, o valor de *micro-recall^c* do categorizador *ML-k NN* com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *micro-recall^c* ao usar a estratégia de poda de *ranking* SCut é significativamente maior do que os resultados obtidos ao usar as estratégias RCut,

RTCut, PCut, PCut*, SCut*, BCut e PBCut. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-5(a)). O valor de *micro-recall^c* com a estratégia de poda SCut* é significativamente menor do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-4(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-4(a)). O valor de *micro-recall^c* com a estratégia de poda PCut* com o categorizador *ML-k NN* com a base AT100 (Figura 6-4(a)) é significativamente maior do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-4(a)).

Com o apresentado na Figura 6-5, as barras do gráfico mostram o valor de *micro-recall^c* do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *micro-recall^c* ao usar a estratégia de poda de *ranking* SCut é significativamente maior do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-5(b)). O valor de *micro-recall^c* com a estratégia de poda SCut* é significativamente menor do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* e com a base EX100 (Figura 6-4(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-4(a)). O valor de *micro-recall^c* com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-4(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-4(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *micro-recall^c* mostram que a estratégia de poda SCut melhora o desempenho desses categorizadores para ambas bases, como visto na, Figura 6-5 (a)(b). Desta forma, a estratégia de poda SCut é mais efetiva para otimizar o desempenho do sistema em termos da métrica *micro-recall^c* do que as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut.

6.2.4 F_β Orientada à Categoria

A métrica F_β **orientada à categoria** ($F_{\beta_i}^c$) avalia a média harmônica ponderada de $precision_i^c$ e $recall_i^c$. A formulação original de Rijsbergen [Rijsbergen79] é mostrada na Equação (6.10).

$$F_{\beta_i}^c = \frac{(\beta^2 + 1) * precision_i^c * recall_i^c}{\beta^2 * precision_i^c + recall_i^c} \quad (6.10)$$

Na Equação (6.10), β pode ser visto como o grau relativo de importância atribuído para $precision_i^c$ e $recall_i^c$ [Sebastiani02]. Se $\beta = 0$, $F_{\beta_i}^c$ coincide com $precision_i^c$; $\beta = +\infty$, $F_{\beta_i}^c$ coincide com $recall_i^c$. Neste trabalho um valor de $\beta = 1$ é utilizado, atribuindo importância igual para $precision_i^c$ e $recall_i^c$. O desempenho global de F_1^c pode ser computado tanto por $macro-F_1^c$ (Equação (6.11)) quanto $micro-F_1^c$ (Equação (6.12)). Quanto maior o valor de $macro-F_1^c$ e $micro-F_1^c$, melhor o desempenho do categorizador. O desempenho é perfeito quando $macro-F_1^c = 1$ e $micro-F_1^c = 1$.

$$macro-F_1^c = \frac{1}{|C|} \sum_{i=1}^C F_{1_i}^c \quad (6.11)$$

$$micro-F_1^c = \frac{2 * micro-precision_i^c * micro-recall_i^c}{micro-precision_i^c + micro-recall_i^c} \quad (6.12)$$

A Figura 6-6 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica $macro-F_1^c$ segundo os categorizadores *ML-kNN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-6(a)) e EX100 (Figura 6-6(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.





Figura 6-6 - Resultado da métrica $macro - F_1^c$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-6 mostram, o valor de $macro - F_1^c$ do categorizador $ML-k NN$ com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de $macro - F_1^c$ do categorizador $ML-k NN$ com a base AT100 ao usar a estratégia de poda PCut é levemente maior do que os resultados obtidos ao usar as


estratégias RCut, RTCut, PCut*, SCut, SCut*, BCut e PBCut. O categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-6(a)) apresenta o valor de $macro - F_1^c$ equilibrado ao usar as estratégias de poda de *ranking* RCut, RTCut, SCut, SCut*, PCut, PCut*, BCut e PBCut. O valor de $macro - F_1^c$ com a estratégia de poda SCut* é maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-6(a)). O valor de $macro - F_1^c$ com a estratégia de poda SCut* é menor do que com a estratégia de poda SCut (tradicional) com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-6(a)). O valor de $macro - F_1^c$ com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-6(a)).

Com o apresentado na Figura 6-6, as barras do gráfico mostram o valor de $macro - F_1^c$ do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O categorizador *ML-k NN* com a base de dados EX100 (Figura 6-6(b)) apresenta o valor de $macro - F_1^c$ levemente equilibrado ao usar as estratégias de poda de *ranking* RCut, RTCut, SCut, SCut*, PCut e PCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-6(b)) para as estratégias de poda SCut, SCut*, PCut e PCut*, apesar da estratégia SCut ser parcialmente melhor que as demais estratégias. O valor de $macro - F_1^c$ com a estratégia de poda SCut* é menor do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-6(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-6(b)). O valor de $macro - F_1^c$ com a estratégia de poda PCut* é parcialmente maior do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-6(b)).


A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica $macro - F_1^c$ mostra que não existe uma estratégia de poda que apresente um desempenho mais efetiva para estes categorizadores e para as bases de dados AT100 e EX100 de forma geral, como visto na, Figura 6-6(a)(b). Apesar disso, a estratégia de poda SCut mostrasse mais regular ao ser avaliada sob a métrica $macro - F_1^c$ do que as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut.

A Figura 6-7 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica $micro - F_1^c$ segundo os categorizadores *ML-*

$k NN$ e $VG-RAM WNN-COR$ para a base AT100 (Figura 6-7(a)) e EX100 (Figura 6-7(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.



(a)



(b)

Figura 6-7 - Resultado da métrica $micro - F_1^c$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-7 mostram, o valor de $micro - F_1^c$ do categorizador $ML-k NN$ com a base AT100 é impactado pelo uso de estratégias de poda no

ranking de categorias. O valor de $micro - F_1^c$ ao usar as estratégias de poda de *ranking* BCut e PBCut são maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-7(a)). O valor de $micro - F_1^c$ com a estratégia de poda SCut* é maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-7(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-7(a)). O valor de $micro - F_1^c$ com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-7(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-7(a)).

Com o apresentado na Figura 6-7, as barras do gráfico mostram o valor de $micro - F_1^c$ do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O categorizador *ML-k NN* com a base de dados EX100 (Figura 6-7(b)) apresenta o valor de $micro - F_1^c$ equilibrado ao usar as estratégias de poda de *ranking* RCut, RTCut, SCut, SCut*, PCut e PCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-7(b)). O valor de $micro - F_1^c$ com a estratégia de poda SCut* é parcialmente maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-7(b)). O valor de $micro - F_1^c$ com a estratégia de poda SCut* é menor que com a estratégia de poda SCut (tradicional) com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-7 (b)). O valor de $micro - F_1^c$ com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-7(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-7(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica $micro - F_1^c$ mostram que as estratégias de poda BCut e PBCut melhoram o desempenho desses categorizadores para a base de dados AT100, como visto na Figura 6-7(a). Desta forma, as estratégias de poda BCut e PBCut são mais efetivas para otimizar o desempenho do sistema em termos da métrica $micro - F_1^c$ do que as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut* para a base AT100. A análise de desempenho dos resultados obtidos para estes categorizados e para a base EX100 apresenta equilíbrio ao empregar as estratégias de poda.

6.2.5 Precisão (*precision*) Orientada a Documento

A métrica **precisão (*precision*) orientada a documento** ($precision_j^d$) avalia a fração de categorias preditas que são pertinentes ao documento de teste d_j . A formulação é mostrada na Equação (6.13).

$$precision_j^d = \frac{|\hat{C}_j^{C_j} \cap C_j|}{|\hat{C}_j^{C_j}|} \quad (6.13)$$

O valor de $precision_j^d$ também pode ser computado usando a tabela de contingência do documento d_j (Tabela 6-7), conforme Equação (6.14).

$$precision_j^d = \frac{TP_j}{TP_j + FP_j} \quad (6.14)$$

onde FP_j (falsos positivos para d_j) é o número de categorias que foram incorretamente preditas para d_j , TN_j (verdadeiros negativos para d_j) é o número de categorias que foram corretamente não preditas para d_j ; TP_j (verdadeiros positivos para d_j) é o número de categorias que foram corretamente preditas para d_j ; e FN_j (falsos negativos para d_j) é o número de categorias que foram incorretamente não preditas para d_j .

Tabela 6-7 – Tabela de contingência do documento d_j .

Documento d_j		Julgamentos do especialista	
		SIM	NÃO
Julgamentos do categorizador	SIM	TP_j	FP_j
	NÃO	FN_j	TN_j

O desempenho global de *precision* orientada a documento é calculado pelos métodos *macro-precision*^d e *micro-precision*^d, Equação (6.15) e Equação (6.16), respectivamente. Quanto maior o valor de *macro-precision*^d e *micro-precision*^d, melhor

o desempenho do categorizador. O desempenho é perfeito quando $macro - precision^d = 1$ e $micro - precision^d = 1$.

$$macro - precision^d = \frac{\sum_{j=1}^{|Te|} precision_j^d}{|Te|} \quad (6.15)$$

$$micro - precision^d = \frac{\sum_{j=1}^{|Te|} TP_j}{\sum_{j=1}^{|Te|} (TP_j + FP_j)} \quad (6.16)$$

A Figura 6-8 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica $macro - precision^d$ segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-8(a)) e EX100 (Figura 6-8(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.





Figura 6-8 - Resultado da métrica *macro – precision^d* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-8 mostram, o valor de *macro – precision^d* do categorizador *ML-k NN* com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *macro – precision^d* ao usar as estratégias de poda de *ranking* BCut e PBCut são significativamente maiores do que os resultados obtidos ao usar as


estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN* com a base de dados AT100 (Figura 6-8(a)). O valor de *macro – precision^d* com a estratégia de poda SCut* é maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-8(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-8(a)). O valor de *macro – precision^d* com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-8(a)).

Como apresentado na Figura 6-8, as barras do gráfico mostram o valor de *macro – precision^d* do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *macro – precision^d* ao usar a estratégia de poda de *ranking* BCut e PBCut são significativamente maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-8(b)). O valor de *macro – precision^d* com a estratégia de poda SCut* é maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-8(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-8(b)). O valor de *macro – precision^d* com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-8(b)).


A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *macro – precision^d* mostram que as estratégias de poda BCut e PBCut melhoram o desempenho desses categorizadores para ambas bases, como visto na Figura 6-8(a)(b). Isso acontece porque a estratégia BCut poda o *ranking* com base na probabilidade da categorização estar correta e a estratégia PBCut poda o *ranking* com base na probabilidade da categorização estar correta em cada posição do *ranking*, observando o decremento da medida de certeza a medida que a posição da categoria no *ranking* aumenta. Desta forma, as estratégias de poda BCut e PBCut são mais efetivas para otimizar o desempenho do sistema em termos da métrica *macro – precision^d* do que as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*.

A Figura 6-9 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *micro – precision^d* segundo os categorizadores

ML-k NN e *VG-RAM WNN-COR* para a base AT100 (Figura 6-9(a)) e EX100 (Figura 6-9(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.



(a)



(b)

Figura 6-9- Resultado da métrica *micro-precision^d* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-9 mostram, o valor de *micro-precision*^d do categorizador *ML-k NN* com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *micro-precision*^d ao usar as estratégias de poda de *ranking* BCut e PBCut são significativamente maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-9(a)). O valor de *macro-precision*^d com a estratégia de poda SCut* é maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-9(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-9(a)). O valor de *macro-precision*^d com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-9(a)).

Como apresentado na Figura 6-9, as barras do gráfico mostram o valor de *micro-precision*^d do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *micro-precision*^d ao usar as estratégias de poda de *ranking* BCut e PBCut são significativamente maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-9(b)). O valor de *micro-precision*^d com a estratégia de poda SCut* é maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-9 (b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-9(b)). O valor de *micro-precision*^d com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-9(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *micro-precision*^d mostram que as estratégias de poda BCut e PBCut melhoram o desempenho desses categorizadores para ambas bases, como visto na Figura 6-9(a)(b). Isso acontece porque a estratégia BCut poda o *ranking* com base na probabilidade da categorização estar correta e a estratégia PBCut poda o *ranking* com base na probabilidade da categorização estar correta em cada posição do *ranking*, observando o decremento da medida de certeza a medida que a posição da categoria no *ranking* aumenta. Desta forma, as estratégias de poda BCut e PBCut são mais efetivas para otimizar o

desempenho do sistema em termos da métrica *micro – precision*^d do que as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*.

6.2.6 Revocação (*recall*) Orientada a Documento

A métrica **revocação (*recall*) orientada a documento** ($recall_j^d$) avalia a fração de categorias pertinentes que são preditas para o documento de teste d_j . A formulação é apresentada na Equação (6.17).

$$recall_j^d = \frac{|\hat{C}_j^{C_j} \cap C_j|}{|C_j|} \quad (6.17)$$

O valor de $recall_j^d$ pode também ser obtido em termos da tabela de contingência do documento d_j (Tabela 6-7) conforme a Equação (6.18).


$$recall_j^d = \frac{TP_j}{TP_j + FN_j} \quad (6.18)$$

O desempenho global de *recall* orientado a documento é calculado pelos métodos *macro – recall*^d e *micro – recall*^d, Equação (6.19) e Equação (6.20), respectivamente. Quanto maior o valor de *macro – recall*^d e *micro – recall*^d, melhor o desempenho do categorizador. O desempenho é perfeito quando *macro – recall*^d = 1 e *micro – recall*^d = 1.


$$macro - recall^d = \frac{\sum_{j=1}^{|Te|} recall_j^d}{|Te|} \quad (6.19)$$

$$micro - recall^d = \frac{\sum_{j=1}^{|Te|} TP_j}{\sum_{j=1}^{|Te|} (TP_j + FN_j)} \quad (6.20)$$

A Figura 6-10 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *macro-recall^d* segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-10(a)) e EX100 (Figura 6-10(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.



(a)



(b)

Figura 6-10 - Resultado da métrica *macro-recall^d* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-10 mostram, o valor de *macro-recall^d* do categorizador *ML-k NN* com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *macro-recall^d* ao usar as estratégias de poda de *ranking* SCut é significativamente maior do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com esta base, e com a base de dados AT100 (Figura 6-10). O valor de *macro-recall^d* com a estratégia de poda SCut* é menor do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-10 (a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-10 (a)). O valor de *macro-recall^d* com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-10(a)).

Como apresentado na Figura 6-10, as barras do gráfico mostram o valor de *macro-recall^d* do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *macro-recall^d* ao usar as estratégias de poda de *ranking* SCut são significativamente maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut. O valor de *macro-recall^d* com a estratégia de poda SCut* é menor que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-10(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-10(b)). O valor de *macro-recall^d* com a estratégia de poda PCut* é maior que com a estratégia de poda PCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-10(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-10(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *macro-recall^d* mostram que a estratégia de poda SCut melhor o desempenho desses categorizadores para ambas bases, como visto na Figura 6-10(a)(b). Isso acontece porque SCut otimiza o desempenho do categorizador por categoria, tornando-a particularmente efetiva quando o desempenho do sistema em categorias raras é a função alvo a ser otimizada. Desta forma, a estratégia de poda SCut é mais efetiva para otimizar o desempenho do sistema em termos da métrica *macro-recall^d* do que as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut.

A Figura 6-11 mostra de forma gráfica o impacto do uso de estratégias de poda no ranking de categorias avaliadas pela métrica *micro-recall^d* segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-11(a)) e EX100 (Figura 6-11(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.




Figura 6-11 - Resultado da métrica *micro-recall^d* para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-11 mostram, o valor de *micro-recall^d* do categorizador *ML-k NN* com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *micro-recall^d* ao usar a estratégia de poda de *ranking* SCut é significativamente maior do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut*, PCut, SCut*, BCut e PBCut. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com esta base, e com a base de dados AT100 (Figura 6-11(a)). O valor de *micro-recall^d* com a estratégia de poda SCut* é significativamente menor que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-11(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-11(a)). O valor de *micro-recall^d* com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-11(a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-11(a)).

Como apresentado na Figura 6-11, as barras do gráfico mostram o valor de *micro-recall^d* do categorizador *ML-k NN* com a base EX100 (Figura 6-11(b)) é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de *micro-recall^d* ao usar a estratégia de poda de *ranking* SCut é significativamente maior do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut. O valor de *micro-recall^d* com a estratégia de poda SCut* é menor que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-11(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-11(b)). O valor de *micro-recall^d* com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-11(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica *micro-recall^d* mostram que a estratégia de poda SCut melhor o desempenho desses categorizadores para ambas bases, como visto na Figura 6-11 (a)(b). Desta forma, a estratégia de poda SCut é mais efetiva para otimizar o desempenho do sistema em termos da métrica *micro-recall^d* do que as estratégias RCut, RTCut, PCut, PCut*, SCut*, BCut e PBCut.

6.2.7 F_β Orientada a Documento

A métrica F_β **orientada a documento** ($F_{\beta_j}^d$) avalia a média harmônica ponderada de $precision_j^d$ e $recall_j^d$. A formulação original de Rijsbergen [Rijsbergen79] é mostrada na Equação (6.21).

$$F_{\beta_j}^d = \frac{(\beta^2 + 1) * precision_j^d * recall_j^d}{\beta^2 * precision_j^d + recall_j^d} \quad (6.21)$$

Como na métrica F_β orientada à categoria, $\beta = 1$ é utilizado, atribuindo importância igual para $precision_j^d$ e $recall_j^d$. O desempenho global de F_1^d é computado pelos métodos *macro*- F_1^d (Equação (6.22)) e *micro*- F_1^d (Equação (6.23)). Quanto maior o valor de *macro*- F_1^d e *micro*- F_1^d , melhor o desempenho do categorizador. O desempenho é perfeito quando *macro*- $F_1^d = 1$ e *micro*- $F_1^d = 1$.

$$macro - F_1^d = \frac{1}{|Te|} \sum_{j=1}^{|Te|} F_{1j}^d \quad (6.22)$$

$$micro - F_1^d = \frac{2 * micro - precision_j^d * micro - recall_j^d}{micro - precision_j^d + micro - recall_j^d} \quad (6.23)$$

A Figura 6-12 mostra de forma gráfica o impacto do uso de estratégias de poda no *ranking* de categorias avaliadas pela métrica *macro*- F_1^d segundo os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a base AT100 (Figura 6-12(a)) e EX100 (Figura 6-12(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.





Figura 6-12 - Resultado da métrica $macro - F_1^d$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.


Conforme as barras do gráfico da Figura 6-12 mostram, o valor de $macro - F_1^d$ do categorizador $ML-k NN$ com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de $macro - F_1^d$ ao usar a estratégia de poda de *ranking* BCut e PBCut são significativamente maiores do que os resultados obtidos ao usar as estratégias

RCut, RTCut, PCut, PCut* SCut e SCut*. O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-12(a)). O valor de $macro - F_1^d$ com a estratégia de poda SCut* é significamente maior do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-12 (a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-12(a)). O valor de $macro - F_1^d$ com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional) com o categorizador *ML-k NN* com a base AT100 (Figura 6-12 (a)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados AT100 (Figura 6-12 (a)).


Como apresentado na Figura 6-12, as barras do gráfico mostram o valor de $macro - F_1^d$ do categorizador *ML-k NN* com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de $macro - F_1^d$ ao usar a estratégia de poda PCut é parcialmente maior do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut*, SCut, SCut*, BCut e PBCut. Já com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-12(b)) o valor de $macro - F_1^d$ ao usar a estratégia de poda SCut é significamente maior do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut, BCut e PBCut. O valor de $macro - F_1^d$ com a estratégia de poda SCut* é menor do que com a estratégia de poda SCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-12(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-12(b)). O valor de $macro - F_1^d$ com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional) com o categorizador *ML-k NN* com a base EX100 (Figura 6-12(b)). O mesmo ocorre com o categorizador *VG-RAM WNN-COR* com a base de dados EX100 (Figura 6-12(b)).

A análise do desempenho dos resultados obtidos com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica $macro - F_1^d$ mostram que as estratégias de poda BCut e PBCut melhoram o desempenho desses categorizadores para a base de dados AT100, como visto na Figura 6-12(a). O desempenho obtido com os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para a métrica $macro - F_1^d$ e para a base EX100 mostra um equilíbrio nos valores das estratégias. Apesar disso, as estratégias de poda BCut e PBCut são mais efetivas para otimizar o desempenho do sistema em termos da métrica $macro - F_1^d$ do que as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut* para a base AT100.

A Figura 6-13 mostra de forma gráfica o impacto do uso de estratégias de poda no ranking de categorias avaliadas pela métrica $micro - F_1^d$ segundo os categorizadores $ML - k NN$ e $VG - RAM WNN - COR$ para a base AT100 (Figura 6-13(a)) e EX100 (Figura 6-13(b)) respectivamente. Esta figura segue o mesmo formato da Figura 6-1.



(a)



(b)

Figura 6-13 - Resultado da métrica $micro - F_1^d$ para as bases (a) AT100 e (b) EX100. Quanto maior, melhor.

Conforme as barras do gráfico da Figura 6-13 mostram, o valor de $micro - F_1^d$ do categorizador $ML-k NN$ com a base AT100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de $micro - F_1^d$ ao usar a estratégia de poda de *ranking* BCut e PBCut são maiores do que os resultados obtidos ao usar as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*. O mesmo ocorre com o categorizador $VG-RAM WNN-COR$ com a base de dados AT100 (Figura 6-13(a)). O valor de $micro - F_1^d$ com a estratégia de poda SCut* é significativamente maior do que com a estratégia de poda SCut (tradicional) com o categorizador $ML-k NN$ com a base AT100 (Figura 6-13(a)). O mesmo ocorre com o categorizador $VG-RAM WNN-COR$ com a base de dados AT100 (Figura 6-13(a)). O valor de $micro - F_1^d$ com a estratégia de poda PCut* é menor do que com a estratégia de poda PCut (tradicional) com o categorizador $ML-k NN$ com a base AT100 (Figura 6-13(a)). O mesmo ocorre com o categorizador $VG-RAM WNN-COR$ com a base de dados AT100 (Figura 6-13(a)).

Como apresentado na Figura 6-13, as barras do gráfico mostram o valor de $micro - F_1^d$ do categorizador $ML-k NN$ com a base EX100 é impactado pelo uso de estratégias de poda no *ranking* de categorias. O valor de $micro - F_1^d$ ao usar a estratégia de poda de *ranking* mostram um equilíbrio nos resultados das estratégias RCut, RTCut, PCut, PCut*, SCut, SCut*, BCut e PBCut. O mesmo ocorre com o categorizador $VG-RAM WNN-COR$ com a base de dados EX100 (Figura 6-13(b)). O valor de $micro - F_1^d$ com a estratégia de poda SCut* é parcialmente maior do que com a estratégia de poda SCut (tradicional) com o categorizador $ML-k NN$ com a base EX100 (Figura 6-13 (b)). O valor de $micro - F_1^d$ com a estratégia de poda SCut* é menor do que com a estratégia de poda SCut (tradicional) com o categorizador $VG-RAM WNN-COR$ com a base de dados EX100 (Figura 6-13(b)). O valor de $micro - F_1^d$ com a estratégia de poda PCut* é maior do que com a estratégia de poda PCut (tradicional) com o categorizador $ML-k NN$ com a base EX100 (Figura 6-13 (b)). O mesmo ocorre com o categorizador $VG-RAM WNN-COR$ com a base de dados EX100 (Figura 6-13(b)).

A análise do desempenho dos resultados obtidos com os categorizadores $ML-k NN$ e $VG-RAM WNN-COR$ para a métrica $micro - F_1^d$ mostram que as estratégias de poda BCut e PBCut melhoram o desempenho desses categorizadores para a base de dados AT100, como visto na Figura 6-13(a). O desempenho obtido com os categorizadores $ML-k NN$ e $VG-RAM WNN-COR$ para a métrica $micro - F_1^d$ e para a base EX100 mostra um equilíbrio nos valores

das estratégias. Apesar disso, as estratégias de poda BCut e PBCut são mais efetivas para otimizar o desempenho do sistema em termos da métrica $micro - F_1^d$ para base de dados AT100 do que as estratégias RCut, RTCut, PCut, PCut*, SCut e SCut*.

Note que o desempenho dos categorizadores pelo método *microaveraging* dá resultado igual, independente de ser definida orientada à categoria ou a documento. A expansão das formulações de $micro - precision^c$ e $micro - precision^d$ é mostrada na Equação (6.24) e Equação (6.25), respectivamente.

$$micro - precision^c = \frac{\sum_{i=1}^{|C|} TP_i}{\sum_{i=1}^{|C|} (TP_i + FP_i)} = \frac{\sum_{i=1}^{|C|} \sum_{j=1}^{|Te|} TP_{ij}}{\sum_{i=1}^{|C|} \left(\sum_{j=1}^{|Te|} TP_{ij} + \sum_{j=1}^{|Te|} FP_{ij} \right)} \quad (6.24)$$

$$micro - precision^d = \frac{\sum_{j=1}^{|Te|} TP_j}{\sum_{j=1}^{|Te|} (TP_j + FP_j)} = \frac{\sum_{j=1}^{|Te|} \sum_{i=1}^{|C|} TP_{ij}}{\sum_{j=1}^{|Te|} \left(\sum_{i=1}^{|C|} TP_{ij} + \sum_{i=1}^{|C|} FP_{ij} \right)} \quad (6.25)$$

Observa-se pela Equação (6.24) e Equação (6.25), $micro - precision^c$ é igual a $micro - precision^d$. Analogamente, $micro - recall^c$ e $micro - F_1^c$ são iguais a $micro - recall^d$ e $micro - F_1^d$, respectivamente.

6.2.8 Test-T Estatístico

Para apresentar uma visão mais clara do desempenho relativo das estratégias de poda de *ranking* propostas neste trabalho com as estratégias encontradas na literatura, uma ordem parcial \succ é definida para compararmos as estratégias de poda BCut e PBCut (propostas) com as estratégias RCut, RTCut, SCut e PCut (encontradas na literatura) e também com as variantes PCut* e SCut para cada métrica de avaliação de desempenho, onde $E1 \succ E2$ significa que o desempenho da estratégia de poda E1 é significativamente melhor do que a estratégia E2 para a métrica especificada (teste t pareado ao nível de 5% de significância). Se o desempenho não é significativamente diferente, a ordem parcial $E1 \equiv E2$ é utilizada.

A

Tabela 6-8 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *ML-k NN* e para a base de dados AT100 utilizando a representação de

ordem parcial. Este sumário apresenta, a comparação (*test-t* pareado) entre a estratégia BCut e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-8 - Resultado do *Test-t* para o categorizador *ML-k NN* e para a base AT100. Comparação com BCut.

Métricas	BCut x Ideal	BCut x RCut	BCut x RTCut	BCut x SCut	BCut x SCut*	BCut x PCut	BCut x PCut*	BCut x PBCut
<i>exact match</i>	BCut > Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>macro-precision-c</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut ≡ SCut*	BCut < PCut	BCut > PCut*	BCut < PBCut
<i>micro-precision-c</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>macro-recall-c</i>	BCut > Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut > PBCut
<i>micro-recall-c</i>	BCut > Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut > SCut*	BCut > PCut	BCut < PCut*	BCut > PBCut
<i>macro-f1-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut > SCut	BCut < SCut*	BCut < PCut	BCut ≡ PCut*	BCut > PBCut
<i>micro-f1-c</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>macro-precision-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-precision-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>macro-recall-d</i>	BCut > Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut > SCut*	BCut > PCut	BCut < PCut*	BCut > PBCut
<i>micro-recall-d</i>	BCut > Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut > SCut*	BCut > PCut	BCut < PCut*	BCut > PBCut
<i>macro-f1-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-f1-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
Ordem Geral	BCut(5) < Ideal(8)	BCut(8) > RCut(5)	BCut(8) > RTCut(5)	BCut(9) > SCut(4)	BCut(10) > SCut(3)	BCut(10) > PCut(3)	BCut(8) > PCut*(4)	BCut(6) < PBCut(7)

Como a Tabela 6-8 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *ML-k NN* para a base de dados AT100. De acordo com a Tabela 6-8, a ordem geral mostra que a estratégia de poda BCut é mais apropriada para esta base de dados, categorizador e métricas.

A Tabela 6-9 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *ML-k NN* e para a base de dados AT100 utilizando a representação de ordem parcial. Este sumário apresenta, a comparação (*test-t* pareado) entre a estratégia PBCut e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-9 - Resultado do *Test-t* para o categorizador *ML-k NN* e para a base AT100. Comparação com PBCut.

Métricas	PBCut x Ideal	PBCut x RCut	PBCut x RTCut	PBCut x SCut	PBCut x SCut*	PBCut x PCut	PBCut x PCut*	PBCut x PBCut
<i>exact match</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>macro-precision-c</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut = SCut*	PBCut < PCut	PBCut > PCut*	PBCut > BCut
<i>micro-precision-c</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>macro-recall-c</i>	PBCut = Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>micro-recall-c</i>	PBCut > Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>macro-f1-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut > SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>micro-f1-c</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>macro-precision-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-precision-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>macro-recall-d</i>	PBCut > Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>micro-recall-d</i>	PBCut > Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>macro-f1-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-f1-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
Ordem Geral	PBCut(3) < Ideal(9)	PBCut(8) > RCut(5)	PBCut(8) > RTCut(5)	PBCut(9) > SCut(4)	PBCut(7) > SCut(5)	PBCut(7) > PCut(6)	PBCut(8) > PCut*(4)	PBCut(7) > BCut(6)

Como a Tabela 6-9 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *ML-k NN* para a base de dados AT100. De acordo com a Tabela 6-9, a ordem geral mostra que a estratégia de poda PBCut é mais apropriada para esta base de dados, categorizador e métricas. Note que a estratégia de poda PBCut é mais apropriada para estas características do que a estratégia BCut.

A Tabela 6-10 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *ML-k NN* e para a base de dados EX100 utilizando a representação de ordem parcial. Este sumário apresenta, a comparação entre a estratégia BCut e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-10 - Resultado do *Test-t* para o categorizador *ML-k NN* e para a base EX100. Comparação com BCut.

Métricas	BCut x Ideal	BCut x RCut	BCut x RTCut	BCut x SCut	BCut x SCut*	BCut x PCut	BCut x PCut*	BCut x PBCut
<i>exact match</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>macro-precision-c</i>	BCut ≡ Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>micro-precision-c</i>	BCut > Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>macro-recall-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut < PBCut
<i>micro-recall-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut < PBCut
<i>macro-f1-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut < PBCut
<i>micro-f1-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut < PBCut
<i>macro-precision-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-precision-d</i>	BCut > Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>macro-recall-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-recall-d</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut < PBCut
<i>macro-f1-d</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut ≡ PCut	BCut < PCut*	BCut < PBCut
<i>micro-f1-d</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut < PBCut
Ordem Geral	Ideal(10) > BCut(2)	BCut(6) < RCut(7)	BCut(6) < RTCut(7)	BCut(6) < SCut(7)	BCut(6) < SCut(7)	BCut(6) = PCut(6)	BCut(6) < PCut*(7)	BCut(3) < PBCut(10)

Como a Tabela 6-10 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *ML-k NN* para a base de dados EX100. De acordo com a Tabela 6-10, a ordem geral mostra que a estratégia de poda BCut não é mais apropriada para ser avaliada sob todas essas estratégias.

A Tabela 6-11 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *ML-k NN* e para a base de dados EX100 utilizando a representação de ordem parcial. Este sumário apresenta, a comparação entre a estratégia PBCut e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-11 - Resultado do *Test-t* para o categorizador *ML-k NN* e para a base EX100. Comparação com PBCut.

Métricas	PBCut x Ideal	PBCut x RCut	PBCut x RTCut	PBCut x SCut	PBCut x SCut*	PBCut x PCut	PBCut x PCut*	PBCut x PBCut
<i>exact match</i>	PBCut > Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>macro-precision-c</i>	PBCut ≡ Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>micro-precision-c</i>	PBCut > Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>macro-recall-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut > BCut
<i>micro-recall-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut > BCut
<i>macro-f1-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut > BCut
<i>micro-f1-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut ≡ SCut	PBCut ≡ SCut*	PBCut ≡ PCut	PBCut < PCut*	PBCut > BCut
<i>macro-precision-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-precision-d</i>	PBCut > Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>macro-recall-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut > BCut
<i>micro-recall-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut > BCut
<i>macro-f1-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut > PCut	PBCut < PCut*	PBCut > BCut
<i>micro-f1-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut ≡ SCut	PBCut ≡ SCut*	PBCut ≡ PCut	PBCut < PCut*	PBCut > BCut
Ordem Geral	PBCut(3) < Ideal(9)	PBCut(5) < RCut(8)	PBCut(5) < RTCut(8)	PBCut(5) < SCut(6)	PBCut(5) < SCut(6)	PBCut(6) > PCut(5)	PBCut(5) < PCut*(8)	BCut(3) < PBCut(10)

Como a Tabela 6-11 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *ML-k NN* para a base de dados EX100. De acordo com a Tabela 6-11, a ordem geral mostra que a estratégia de poda PBCut não é mais apropriada para ser avaliada sob todas essas métricas.

A Tabela 6-12 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *VG-RAM WNN-COR* e para a base de dados AT100 utilizando a representação de ordem parcial. Este sumário apresenta, a comparação entre a estratégia BCut e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-12 – Resultado do *Test-t* para o categorizador *VG-RAM WNN-COR* e para a base *AT100*. Comparação com *BCut*.

Métricas	BCut x Ideal	BCut x RCut	BCut x RTCut	BCut x SCut	BCut x SCut*	BCut x PCut	BCut x PCut*	BCut x PBCut
<i>exact match</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>macro-precision-c</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-precision-c</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>macro-recall-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut < PBCut
<i>micro-recall-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut ≡ PBCut
<i>macro-f1-c</i>	BCut < Ideal	BCut ≡ RCut	BCut ≡ RTCut	BCut ≡ SCut	BCut > SCut*	BCut ≡ PCut	BCut ≡ PCut*	BCut < PBCut
<i>micro-f1-c</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>macro-precision-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut < SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-precision-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>macro-recall-d</i>	BCut > Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut > PCut*	BCut ≡ PBCut
<i>micro-recall-d</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut ≡ PBCut
<i>macro-f1-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-f1-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
Ordem Geral	BCut(1) < Ideal(12)	BCut(8) > RCut(4)	BCut(8) > RTCut(4)	BCut(8) > SCut(4)	BCut(8) > SCut(5)	BCut(8) > PCut(4)	BCut(9) > PCut*(3)	BCut(4) < PBCut(6)

Como a Tabela 6-12 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *VG-RAM WNN-COR* para a base de dados *AT100*. De acordo com a Tabela 6-12, a ordem geral mostra que a estratégia de poda *BCut* é mais apropriada para esta base de dados, categorizador e métricas.

A Tabela 6-13 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *VG-RAM WNN-COR* e para a base de dados *AT100* utilizando a representação de ordem parcial. Este sumário apresenta, a comparação entre a estratégia *PBCut* e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-13 - Resultado do *Test-t* para o categorizador *VG-RAM WNN-COR* e para a base AT100. Comparação com PBCut.

Métricas	PBCut x Ideal	PBCut x RCut	PBCut x RTCut	PBCut x SCut	PBCut x SCut*	PBCut x PCut	PBCut x PCut*	PBCut x BCut
<i>exact match</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>macro-precision-c</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-precision-c</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>macro-recall-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut > BCut
<i>micro-recall-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut ≡ BCut
<i>macro-f1-c</i>	PBCut < Ideal	PBCut ≡ RCut	PBCut ≡ RTCut	PBCut ≡ SCut	PBCut > SCut*	PBCut > PCut	PBCut ≡ PCut*	PBCut > BCut
<i>micro-f1-c</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>macro-precision-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-precision-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>macro-recall-d</i>	PBCut > Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut ≡ BCut
<i>micro-recall-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut ≡ BCut
<i>macro-f1-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-f1-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
Ordem Geral	PBCut(1) < Ideal(12)	PBCut(8) > RCut(4)	PBCut(8) > RTCut(4)	PBCut(8) > SCut(4)	PBCut(9) > SCut(4)	PBCut(9) > PCut(4)	PBCut(8) > PCut*(4)	PBCut(6) > BCut(4)

Como a Tabela 6-13 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *VG-RAM WNN-COR* para a base de dados AT100. De acordo com a Tabela 6-13, a ordem geral mostra que a estratégia de poda PBCut é mais apropriada para esta base de dados, categorizador e métricas. Note que a estratégia de poda PBCut é mais apropriada para estas características do que a estratégia BCut.

A Tabela 6-14 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *VG-RAM WNN-COR* e para a base de dados EX100 utilizando a representação de ordem parcial. Este sumário apresenta, a comparação entre a estratégia BCut e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-14 - Resultado do *Test-t* para o categorizador *VG-RAM WNN-COR* e para a base *EX100*. Comparação com *BCut*

Métricas	BCut x Ideal	BCut x RCut	BCut x RTCut	BCut x SCut	BCut x SCut*	BCut x PCut	BCut x PCut*	BCut x PBCut
<i>exact match</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>macro-precision-c</i>	BCut ≡ Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-precision-c</i>	BCut > Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>macro-recall-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut > PBCut
<i>micro-recall-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut > PBCut
<i>macro-f1-c</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut > PBCut
<i>micro-f1-c</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut < SCut	BCut > SCut*	BCut > PCut	BCut ≡ PCut*	BCut > PBCut
<i>macro-precision-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>micro-precision-d</i>	BCut > Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut < PBCut
<i>macro-recall-d</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut > PBCut
<i>micro-recall-d</i>	BCut < Ideal	BCut < RCut	BCut < RTCut	BCut < SCut	BCut < SCut*	BCut < PCut	BCut < PCut*	BCut > PBCut
<i>macro-f1-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut > SCut	BCut > SCut*	BCut > PCut	BCut > PCut*	BCut > PBCut
<i>micro-f1-d</i>	BCut < Ideal	BCut > RCut	BCut > RTCut	BCut < SCut	BCut > SCut*	BCut > PCut	BCut ≡ PCut*	BCut > PBCut
Ordem Geral	BCut(2) < Ideal(10)	BCut(8) > RCut(5)	BCut(8) > RTCut(5)	BCut(6) < SCut(7)	BCut(8) > SCut(5)	BCut(8) > PCut(5)	BCut(6) > PCut*(5)	BCut(9) > PBCut(4)

Como a Tabela 6-14 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *VG-RAM WNN-COR* para a base de dados *EX100*. De acordo com a Tabela 6-14, a ordem geral mostra que a estratégia de poda *BCut* é mais apropriada para esta base de dados, categorizador e métricas.

A Tabela 6-15 mostra um sumário dos resultados obtidos da Seção 6.2.1 à Seção 6.2.7 para o categorizador *VG-RAM WNN-COR* e para a base de dados *EX100* utilizando a representação de ordem parcial. Este sumário apresenta, a comparação entre a estratégia *PBCut* e as demais estratégias de poda apresentadas neste trabalho.

Tabela 6-15 - Resultado do *Test-t* para o categorizador *VG-RAM WNN-COR* e para a base *EX100*. Comparação com *PBCut*.

Métricas	PBCut x Ideal	PBCut x RCut	PBCut x RTCut	PBCut x SCut	PBCut x SCut*	PBCut x PCut	PBCut x PCut*	PBCut x PBCut
<i>exact match</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut < BCut
<i>macro-precision-c</i>	PBCut > Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-precision-c</i>	PBCut > Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>macro-recall-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>micro-recall-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>macro-f1-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>micro-f1-c</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>macro-precision-d</i>	PBCut < Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>micro-precision-d</i>	PBCut > Ideal	PBCut > RCut	PBCut > RTCut	PBCut > SCut	PBCut > SCut*	PBCut > PCut	PBCut > PCut*	PBCut > BCut
<i>macro-recall-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>micro-recall-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
<i>macro-f1-d</i>	PBCut < Ideal	PBCut ≡ RCut	PBCut ≡ RTCut	PBCut < SCut	PBCut ≡ SCut*	PBCut > PCut	PBCut ≡ PCut*	PBCut < BCut
<i>micro-f1-d</i>	PBCut < Ideal	PBCut < RCut	PBCut < RTCut	PBCut < SCut	PBCut < SCut*	PBCut < PCut	PBCut < PCut*	PBCut < BCut
Ordem Geral	PBCut(3) < Ideal(10)	PBCut(5) < RCut(7)	PBCut(5) < RTCut(7)	PBCut(5) < SCut(8)	PBCut(5) < SCut*(7)	PBCut(6) < PCut(7)	PBCut(5) < PCut*(7)	PBCut(4) < BCut(9)

Como a Tabela 6-15 mostra, as estratégias de poda de *ranking* impactam a maioria das métricas utilizadas para avaliar o desempenho do categorizador *VG-RAM WNN-COR* para a base de dados *EX100*. De acordo com a Tabela 6-15, a ordem geral mostra que a estratégia de poda *PBCut* não é mais apropriada para esta base de dados, categorizador e métricas.

Os resultados obtidos com as métricas que avaliam precisão mostram que, as estratégias de poda de *ranking* *BCut* e *PBCut* melhoram o desempenho dos categorizadores para as bases *AT100* e *EX100*. Além disso, as estratégias de poda de *ranking* *BCut* e *PBCut* melhoram o desempenho para a métrica *exact-match* o desempenho dos categorizadores *ML-k NN* e *VG-RAM WNN-COR* para as bases *AT100* e *EX100*.

7 DISCUSSÃO

Neste capítulo, apresentamos os trabalhos correlatos ao estudo sobre estratégias de poda de *ranking* na categorização multi-rótulo de texto. Além disso, apresentamos uma análise crítica sobre este trabalho.

7.1 Trabalhos Correlatos

O estudo sobre estratégias de poda de *ranking* tem sido pouco explorado na área de categorização automática de texto. Algoritmos de categorização tem sido o principal foco de pesquisa nessa área enquanto que estratégias de poda de *ranking* são apenas mencionadas como uma etapa sem importância na categorização de texto [Yang01].

Yang, em 2001[Yang01] apresentou um estudo sobre as estratégias de poda. Este estudo mostra uma análise do impacto de desempenho da estratégia de poda de *ranking* de um categorizador em condições diversas. Yang usou o categorizador *kNN*, cinco coleções de documentos, três estratégias de poda incluindo a estratégia baseada no *ranking* (RCut), baseada em probabilidade (PCut) e baseada no grau de crença (SCut). Além destas, Yang propôs uma nova variante da estratégia RCut, denominada RTCut. Os resultados experimentais obtidos por Yang, mostram que a escolha de uma estratégia de poda pode influenciar significativamente no desempenho do categorizador *kNN* e que o resultado da melhor estratégia poda pode variar de acordo com aplicação. Yang apresentou a estratégia SCut como a melhor estratégia para ajuste fino, mas, com o risco de *overfitting*. A estratégia de poda PCut mostrou um desempenho mais estável devido ao uso de informações sobre a distribuição das categorizas no conjunto de treinamento, com a desvantagens de não ser capaz de tomar decisões *online*. RCut é adequada para respostas *online* mas sua decisão de corte é independente da decisão do categorizador. RTCut elaborada para atenuar o compromisso entre revocação e precisão, superar RCut.

Lee, em 2002 [Lee02], propôs a estratégia de poda de *ranking* de categorias RinScut que usa o melhor das estratégias de poda SCut e RCut. A estratégia RinScut utiliza a estratégia SCut para tratar o problema de categorização multi-rótulo de texto em que um

documento pertence a várias categorias. A estratégia de poda SCut encontra diferentes τ_i para cada categoria otimizando a performance local (por categoria) enquanto que o RCut retorna a mesma quantidade de categorias para todos os documentos otimizando a performance global. Lee definiu a estratégia Rank-in-score para usar a força dessas duas estratégias. O RinScut encontra dois pontos de corte para cada categoria (S_{top} e S_{bottom}) a partir da estratégia SCut. Os graus de crença dos documentos que estiverem acima do S_{top} são retornados diretamente como resposta para cada categoria c_i . Os graus de crença que estiverem entre o S_{top} e S_{bottom} são considerados como zona de ambigüidades. Para resolver a ambigüidade é utilizado a estratégia de poda RCut para tomar a decisão final. Nos experimentos de Lee a estratégia de poda RinScut apresenta melhor desempenho para *micro* e *macro-averaged* F_1 do que os valores encontrados pela estratégia de poda SCut.

Fan, em 2007 [Fan07], apresentou uma análise sobre a estratégia de poda SCutFBR, uma heurística proposta por Yang, para o categorizador SVM (*Support Vector Machines*) empregando as bases de dados RCV1-V2, Scene, Yeast, Ohsumed e Yahoo! Directories. Os experimentos realizados por Fan foram otimizados segundo as métricas de avaliação: *macro-average F-measure*, *micro-average F-measure* e *exact match ratio*. Fan observou os seguintes aspectos em seus experimentos: limiares de poda de *ranking* muito alto/baixo ocorrem quando a base de dados está desequilibrada. Fan também descobriu que a *micro-average F-measure* é menos sensível para a otimização do que outras métricas, como por exemplo, a *macro-average*. Além disso, verificou que a otimização circular para a estratégia de poda SCutFBR deveria melhorar o desempenho da calibração, os seus resultados mostram que houve uma melhoria apenas marginal, portanto, calibrar os limiares de corte para cada categoria sem rotacionar é suficiente na prática.

Este trabalho propõe um método para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto um problema ainda pouco explorado na área de RI e propomos também duas estratégias de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto, a qual denominamos *bayes cut* (BCut) e *position bayes cut* (PBCut). Além disso, avalimos o efeito da nossa estratégia de poda sobre as métricas mais populares de avaliação de desempenho de categorização multi-rótulo de texto empregadas pela comunidade de RI.

7.2 Análise Crítica deste Trabalho

Uma das limitações deste trabalho é a falta de uma visão geral do desempenho das estratégias de poda de *ranking*, ou seja, uma análise do *test-t* para todas as possíveis combinações de estratégias de poda. Outra possível limitação é o emprego de base de dados dentro de um único domínio de problemas de categorização. Isso poderia ser resolvido pela validação dos nossos experimentos com *benchmarks* utilizados nas principais literaturas sobre categorização de texto. Isso poderia ser resolvido pela validação dos nossos experimentos com *benchmarks* utilizados nas principais literaturas sobre categorização de texto.

8 CONCLUSÃO E TRABALHOS FUTUROS

Neste capítulo apresentamos um sumário do trabalho, nossas conclusões e propostas de trabalhos futuros.

8.1 Sumário

Neste trabalho, propomos um método para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto. Nosso método é baseado na regra de *Bayes*, que permite alterar as probabilidades *a priori* tendo em conta novas evidências de forma a obter as probabilidades *a posteriori*. Propomos também, uma estratégia para determinar limiares de poda para o *ranking* de categorias baseada na medida de certeza de categorização multi-rótulo de texto descrita acima, a qual denominamos *bayesian cut* (BCut). Na estratégia de poda BCut, um único limiar de poda, τ , para todas as categorias c_i é escolhido de modo a maximizar o desempenho de categorização, i.e., sua habilidade de atribuir todas e apenas as categorias pertinentes a um dado documento. Além desta estratégia, propomos uma variante para BCut que utiliza diferentes limiares de poda τ_p para diferentes posições p do *ranking*, a qual denominamos *position based bayesian cut* (PBCut). A estratégia de poda PBCut pode produzir um desempenho superior ao de BCut, porque a medida de certeza de categorização em uma dada categoria diminui à medida que a posição da categoria no *ranking* aumenta.

Além disso, investigamos o impacto no desempenho de categorização multi-rótulo de texto de três métodos de poda comumente usados na literatura de RI [Yang01, Lee02, Fan07]: RCut, PCut, SCut e uma variante de RCut - RTCut [Yang01], também, propomos novas variantes para PCut e SCut – PCut* e SCut*, respectivamente – para tratar problemas existentes nestas abordagens. Em nossa análise experimental, utilizamos os categorizadores *ML-kNN* e *VG-RAM WNN-COR* segundo as métricas de avaliação: *exact match*, *precision*, *recall* e F_1 . Os experimentos foram realizados com duas bases de dados, contendo documentos textuais descrevendo atividades econômicas de empresas brasileiras, com características diferenciadas em termos de frequência de ocorrência das categorias: AT100 e

EX100. A base de dados EX100 contém documentos categorizados dentro de 105 categorias, onde cada categoria ocorre exatamente em 100 diferentes documentos; e a base de dados AT100 contém documentos categorizados dentro de 692 categorias, onde cada categoria ocorre em até 100 diferentes documentos.

Nossos resultados experimentais mostraram que, os valores das medidas de certeza calculados analiticamente são próximos dos valores encontrados empiricamente, além disso, as estratégias de poda baseadas na medida de certeza afetam significativamente o desempenho dos categorizadores.

8.2 Conclusões

Os resultados experimentais apresentados no Capítulo 6 - na Seção 6.1 – mostram o quão os valores das medidas de certeza (valores de $p(x/y,k)$) do categorizador calculados analiticamente por meio da regra de *Bayes* são próximos (semelhantes) aos valores de $p(x/y,k)$ estimados empiricamente, demonstrando que é possível prever o quão certo está o categorizador quanto uma categoria pertencente ao *ranking* de saída ser pertinente para um dado documento em uma posição. Após compararmos os resultados das medidas de certeza para os categorizadores *ML-k NN* e *VG-RAM WNN-COR* para as bases de dados AT100 e EX100 concluímos que nosso modelo de mapeamento de grau de crença em probabilidade pode ser utilizado para tal definição, visto que, os resultados calculados analiticamente estão muito próximos dos resultados obtidos empiricamente.

Os resultados experimentais apresentados no Capítulo 6 – na Seção 6.2 - mostram que o desempenho de um categorizador segundo uma determinada métrica é significativamente diferente (teste *t* pareado bicaudal com nível de significância 5%) dependendo da estratégia de poda de *ranking* empregada. Os experimentos realizados com a base de dados AT100 mostram que, o desempenho dos categorizadores *ML-k NN* e *VG-RAM WNN-COR* ao empregar as estratégias de poda de *ranking* BCut e PBCut é otimizado ao ser avaliados por métricas de precisão. Este comportamento é repetido ao realizar experimentos com a base de dados EX100.

Nas métricas que avaliam precisão, as estratégias de poda BCut e PBCut são mais apropriadas para este parâmetro de avaliação, pois utilizam a medida de certeza de categorização que nada mais é que a probabilidade da predição estar correta. As estratégias de

poda de *ranking* Scut e PCut * são mais apropriadas para serem empregadas às métricas que avaliam a revocação da categorização. Então, este trabalho demonstra que é possível mapear os valores de graus de crenças em valores probabilísticos na categorização automática de texto e que na definição de estratégias de poda, uma das informações que devem ser consideradas é o tipo de avaliação que o sistema de categorização será submetido.

8.3 Trabalhos Futuros

Os resultados satisfatórios obtidos neste trabalho motivam continuar as pesquisas sobre modelos para mapear graus de crença em medidas de certeza de categorização multi-rótulo de texto e sobre estratégias para determinar limiares de poda de *ranking* de categorias baseada na medida de certeza de categorização.

Uma direção para trabalho futuro seria correlacionar a estratégia de poda de *ranking* de categorias com as características das bases de dados empregadas, o que poderia levar a uma abordagem mais genérica, mais independente da base de dados. Outra direção para pesquisas futuras seria utilizar *benchmarks* de problemas de categorização em domínios diferentes daquele utilizado neste trabalho. Finalmente, outra direção para pesquisa seria utilizar outras técnicas de categorização de texto multi-rótulo, o que permitiria verificar o nível de generalização do nosso modelo de medida de certeza e das estratégias de poda de *ranking* nele baseadas.

9 REFERÊNCIAS BIBLIOGRÁFICAS

- [Aiolli08] F. Aiolli, R. Cardin, F. Sebastiani, and A. Sperduti. Preferential Text Classification: Learning Algorithms and Evaluation Measures. *Information Retrieval Journal*, pages 1386-4564, 2008.
- [Aleksander98] I. Aleksander. RAM-Based Neural Networks, chapter From WISARD to MAGNUS: a Family of Weightless Virtual Neural Machines, pages 18–30. World Scientific, 1998.
- [Antiqueira05] L. Antiqueira. Obtenção e Associação de Termos na Construção de uma Ontologia para a Área de Nanotecnologia. São Carlos: USP, 2005. 40 p. Monografia de Graduação – Instituto de Ciências Matemáticas e de Computação, USP, São Carlos, 2005.
- [Aspell08] ASPELL. GNU Aspell. Disponível: <http://aspell.net/> . Último acesso em: 20 de Agosto de 2008.
- [Badue08] C. Badue, F. Pedroni, and A. F. De Souza. Multi-Label Text Categorization using VG-RAM Weightless Neural Networks. *Proceedings of the 10th Brazilian Symposium on Neural Networks (SBRN'08)*, pp. 105-110, Salvador, Bahia, Brazil, October 2008.
- [Baeza99] R. Baeza-Yates, and B. Ribeiro-Neto. *Modern Information Retrieval*. 1. ed. New York: Addison-Wesley, 1999.
- [Baoli03] L. Baoli, Y. Shiwen, and L. Qin. An Improved k-Nearest Neighbor Algorithm for Text Categorization. In *Proceedings of the 20th International Conference on Computer Processing of Oriental Languages*, Shen Yang, China, pages 469-475, 2003.
- [Boutell04] M. R. Boutell, J. Luo, X. Shen, and C. M. Brown. Learning Multi-Label Scene Classification. *Pattern Recognition*, 37(9): pages 1757–1771, 2004.
- [Cherman07] E. Cherman, H. de Lee, D. Honorato, C. Coy, J. Fagundes, J. Góes, F. Wu. Metodologia de Mapeamento Automático de Laudos Colonoscópicos. XVI EAIC, 2007.

- [Ciarelli08] P. M. Ciarelli. Rede Neural Probabilística para a Classificação de Atividades Econômicas. Vitória: UFES, 2008. 82 p. Dissertação – Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Espírito Santo, Vitória, 2008.
- [Ciarelli09] P. M. Ciarelli, E. Oliveira, and C. Badue. Multi-Label Text Categorization Using a Probabilistic Neural Network. *International Journal of Computer Information Systems and Industrial Management Applications (IJCISIM)*, July 2009 (accepted for publication).
- [Clare01] A. Clare and R. D. King. Knowledge Discovery in Multi-Label Phenotype Data. In *Lecture Notes in Computer Science*, volume 2168, pages 42–53, 2001.
- [CNAE03] CNAE. Classificação Nacional de Atividades Econômicas – Fiscal (CNAE-Fiscal) 1.1. Instituto Brasileiro de Geografia e Estatística (IBGE), Rio de Janeiro, RJ, 2003.
- [Cohen96] W. W. Cohen and Y. Singer. Context-sensitive Learning Methods for Text Categorization. In *SIGIR'96: Proceedings of the 19th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval*, 1996. 307-315.
- [Comité03] F. D. Comité, R. Gilleron, and M. Tommasi. Learning multi-label alternating decision tree from texts and data. In *Lecture Notes in Computer Science*, volume 2734, pages 35–49. Springer, 2003.
- [Cooper68] W.S Cooper. Expected search length: A Single Measure of Retrieval Effectiveness Based on Weak Ordering Action of Retrieval Systems. *Journal of the American Society for Information Science*, 19(1), pages 30 – 41, 1968.
- [Crowell03] J. Crowell, Q.T. Zeng, S.Kogan. A Technique to Improve the Spelling Suggestion Rank in Medical Queries. *AMIA 2003 Symposium Proceedings*, page 823, 2003.
- [DeSouza07] A. F. De Souza, F. Pedroni, E. Oliveira, P. M. Ciarelli, W. F. Henrique, and L. Veronese. Automated Free Text Classification of Economic Activities using VG-RAM Weightless Neural Networks. In *7th IEEE International Conference on Intelligent Systems Design and Applications*, pages 782–787. IEEE Computer Society, 2007.

- [DeSouza08] A. F. De Souza, C. Badue, B. Z. Melotti, F. T. Pedroni, and F. L. L. Almeida. Improving VG-RAM WNN Multi-Label Text Categorization via Label Correlation. In 2nd Workshop on Intelligent Text Categorization and Clustering (WITCC'08), 8th IEEE International Conference on Intelligent Systems Design and Applications (ISDA'08), volume 01, pages 437–442. IEEE Computer Society, 2008.
- [DeSouza09a] A. F. De Souza, F. Pedroni, E. Oliveira, P. M. Ciarelli, W. F. Henrique, L. Veronese, and C. Badue. Automated Multi-label Text Categorization with VG-RAM Weightless Neural Networks. *Neurocomputing*, vol. 72, no. 10-12, pp. 2209-2217, June 2009.
- [DeSouza09b] A. F. De Souza, B. Z. Melotti, and C. Badue. Multi-Label Text Categorization with a Data Correlated VG-RAM Weightless Neural Network. *International Journal of Computer Information Systems and Industrial Management Applications (IJCISIM)*, July 2009 (accepted for publication).
- [Dunlop97] M. D Dunlop. Time Relevance and Interaction Modeling for Information Retrieval, in Proc. ACM SIGIR, pages 206-213, 1997.
- [Elisseeff02] A. Elisseeff and J. Weston. A Kernel Method for Multi-Labelled Classification. In *Advances in Neural Information Processing Systems*, volume 14, pages 681–687. MIT Press, 2002.
- [Fagin03] R. Fagin, R. Kumar, and D. Sivakumar. Comparing Top k Lists. *Proceedings of the fourteenth annual ACM-SIAM symposium on Discrete algorithms*, pages 28–36, Philadelphia, USA, 2003.
- [Fagin04] R. Fagin, R. Kumar, M. Mahdian, D. Sivakumar, and E. Vee. Comparing and Aggregating Rankings with Ties. *Proceedings of the twenty-third ACM SIGMOD-SIGACT-SIGART symposium on Principles of database systems*, pages 47-58, France, 2004.
- [Fagin06] R. Fagin, R. Kumar, M. Mahdian, D. Sivakumar, & E. Vee. Comparing partial rankings. *SIAM Journal on Discrete Mathematics*, 20(3), pages 628–648, 2006.
- [Fan07] R.-E. Fan and C.-J. Lin. A Study on Threshold Selection for Multi-Label Classification. Technical Report, National Taiwan University, 2007.

- [Gao04] S. Gao, W. Wu, C.-H. Lee, and T.-S. Chua. A MfoM Learning Approach to Robust Multiclass Multi-Label Text Categorization. In Proceedings of the 21st International Conference on Machine Learning, pages 329–336, 2004.
- [Hair05] J. F. Hair, R. E. Anderson, R. L. Tatham e W. C. Black. Análise Multivariada de Dados. Tradução por Adonai Schlup Sant'Ana e Anselmo Chavese Neto. Quinta Edição. US, 2005.
- [Hao07] X. Hao, X. Tao, C. Zhang. Yunfa Hu, An Effective Method To Improve kNN Text Classifier. Software Engineering, Artificial Intelligence, Networking, and Parallel/Distributed Computing, 2007. SNPD 2007. Eighth ACIS International Conference, vol.1, no., pages 379-384, July 30 2007-Aug. 1 2007.
- [Haykin99] S. Haykin. Redes Neurais Princípios e práticas. 2^a Edição. São Paulo, 1999.
- [Hull93] D. Hull. Using Statistical Testing in the Evaluation of Retrieval Experiments. Proceedings of the 16th annual international ACM SIGIR conference on Research and development in information retrieval, pages 329-338, USA, 1993.
- [Joachims98] Joachims. Text Categorization with Support Vector Machines: Learning with Many Relevant Features. Proceedings of the Tenth European Conference on Machine Learning (ECML'98), Springer Verlag, pages 137-142, 1998.
- [Kazawa05] H. Kazawa, T. Izumitani, H. Taira, and E. Maeda. Maximal Margin Labeling for Multi-Topic Text Categorization. In Advances in Neural Information Processing Systems 17, pages 649–656. MIT Press, 2005.
- [Lee02] K. H. Lee, J. Kay, and B. H. Kang. Lazy Linear Classifier and Rank-in-Score Threshold in Similarity-Based Text Categorization. International Conference on Machine Learning Workshop on Text Learning TextML'2002), Sydney, Australia, pages 36-43, July 8, 2002.
- [Lewis92] D. Lewis. An Evaluation of Phrasal and Clustered Representations on a Text Categorization task. In 15th Ann Int ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR'92), pages 37 50, 1992.

- [Lewis94] D. Lewis and M. Ringuette. Comparison of two Learning Algorithms for Text Categorization. In Proceedings of the Third Annual Symposium on Document Analysis and Information Retrieval (SDAIR'94), Nevada, Las Vegas, 1994. University of Nevada, Las Vegas.
- [Lewis96] D.D. Lewis et al. Training Algorithms Linear Text Classifier. In Proc. Of the 19th annual international ACM SIGIR Conference on Research and development in information retrieval SIGIR'96), pages 298–306, 1996.
- [Ludermir99] T. B. Ludermir, A. C. P. L. F. Carvalho, A. P. Braga, and M. D. Souto. Weightless Neural Models: A Review of Current and Past Works. *Neural Computing Surveys*, 2: pages 41–61, 1999.
- [Manning08] C. D. Manning, P. Raghavan, and H. Schütze. *An Introduction to Information Retrieval*. Cambridge University Press, Cambridge, England, 2008.
- [Martins04] D. Martins, and M. J Silva. Spelling Correction for Search Engine Queries. In *Book Series of Lecture Notes in Computer Science*, Vol. 3230, pages 372–383, 2004.
- [McCallum99] A. McCallum. Multi-Label Text Classification with a Mixture Model Trained by EM. In *Working Notes of the AAAI'99 Workshop on Text Learning*, pages 1–7, 1999.
- [Melotti09] Z. B. Melotti. Efeito do *Ranking* sobre Métricas de Categorização Multi-Rótulo de texto. Vitória: UFES, Dissertação - Programa de Pós-Graduação em Informática, Universidade Federal do Espírito Santos, Vitória, 2009.
- [Mitchell97] T. M. Mitchell. *Machine learning*. McGraw Hill, New York, US, 1997.
- [Mitchell98] R. J. Mitchell, J. M. Bishop, S. K. Box, and J. F. Hawker. RAM-Based Neural Networks, chapter Comparison of Some Methods for Processing Grey Level Data in Weightless Networks, pages 61–70. World Scientific, 1998.
- [Monard03] M. C. Monard & J. A. Baranauskas. Conceitos sobre Aprendizado de Máquina. In *Sistemas Inteligentes – Fundamentos e Aplicações*, S.O Rezende, Editora Manole, pages 89–114, 2003.

- [Oliveira08a] E. Oliveira, P. M. Ciarelli, A. F. De Souza, and C. Badue. Using a Probabilistic Neural Network for a Large Multi-Label Problem. Proceedings of the 10th Brazilian Symposium on Neural Networks (SBRN'08), pp. 195-200, Salvador, Bahia, Brazil, October 2008.
- [Oliveira08b] E. Oliveira, P. M. Ciarelli, and C. Badue. A Comparison Between a kNN based Approach and a PNN Algorithm for a Multi-Label Classification Problem. Proceedings of the 2nd Workshop on Intelligent Text Categorization and Clustering of the 8th International Conference on Intelligent System Design and Applications (ISDA'08), pp. 628-633, Kaohsiung City, Taiwan, November 2008.
- [Picard84] R. R. Picard, and R. D. Cook. Cross-Validation of Regression Models. Journal of the American Statistical Association, 79(387), pages 575–583, 1984.
- [Rijsbergen79] V. Rijsbergen, C. J. Information Retrieval (Second ed.). Butterworths, London, UK, 1979. Available at <http://www.dcs.gla.ac.uk/Keith>.
- [Romero04] E. Romero, L. Márquez, and X. Carreras. Margin Maximization with Feed-Forward Neural Networks: A Comparative Study with SVM and Adaboost. Neurocomputing, 57: pages 313–344, 2004.
- [Salton75] G. Salton, A. Wong, and C. Yang. A vector space model for automatic indexing. Communications of the ACM 18, 11, 613–620. Also reprinted in [Sparrck Jones and Willett 1997], pages 273–280, 1975.
- [Sbc09] Sociedade Brasileira de Computação, Grandes desafios da pesquisa em computação no Brasil 2006-2016. Último acesso em 12/08/2009.
- [SCAE08] Sistema Computacional de Codificação Automática de Atividades Econômicas (SCAE), Projeto de Classificação Automática em CNAE-Subclasses – Relato de Cumprimento de Metas No. 4. Universidade Federal do Espírito Santo, Vitória, 2008.
- [Schapire99] R. E. Schapire and Y. Singer. Improved Boosting Algorithms Using Confidence-Rated Predictions. Machine Learning, 27(3): pages 297–336, 1999.
- [Schapire00] R. E. Schapire and Y. Singer. BoosTexter: A boosting-Based System for Text Categorization. Machine Learning, 39(2/3): pages 135–168, 2000.
- [Sebastiani02] F. Sebastiani. Machine learning in automated text categorization. ACM

- Computing Surveys, 34(1): pages 1–47, 2002.
- [Sparacino00] G. Sparacino, C. Tombolato, C. Cobelli. Maximum-Likelihood versus Maximum a Posteriori Parameter Estimation of Physiological System Models: the c-peptide impulse response case study. *Biomedical Engineering, IEEE Transactions on* Volume 47, Issue 6, pages 801 – 811, June 2000.
- [Student08] Student. The Probable Error of a Mean. *Biometrika* on Volume 6, pages 1 – 25, 1908.
- [Ueda03] N. Ueda and K. Saito. Parametric Mixture Models for Multi-Label Text. In *Advances in Neural Information Processing Systems*, volume 15, pages 721–728. MIT Press, 2003.
- [Witten05] Ian H. Witten & E. Frank. *Data Mining Practical Machine Learning Tools and Techniques*. Second Edition. US, 2005.
- [Yang99] Y. Yang. An Evaluation of Statistical Approaches to Text Categorization. In *Information Retrieval*, Volume 1, pages 69-90, Hingham, US, 1999.
- [Yang01] Y. Yang. A Study of Thresholding Strategies for Text Categorization. In *Proceedings of the 24th Annual International ACM SIGIR Conference on Research and Development in Information Retrieval (SIGIR'01)*, pages 137–145, New Orleans, Louisiana, United States, 2001.
- [Yavuz98] T. Yavuz and H. Altay Guvenir. Application of k-nearest Neighbor on Feature Projections Classifier to Text Categorization. *Proceedings of ISCIS, 13th International Symposium on Computer and Information Sciences*, pages 135-142, 1998.
- [Zhang06] M.-L. Zhang, Z.-H. Zhou,. Multi-label Neural Networks with Applications to Functional Genomics and Text Categorization. *IEEE Transactions on Knowledge and Data Engineering* 18(10), pages 1338–1351, 2006.
- [Zhang07] M.-L. Zhang and Z.-H. Zhou. ML-KNN: A Lazy Learning Approach to Multi-Label Learning. *Pattern Recognition*, 40(7): pages 2038–2048, 2007.

APÊNDICE A – PARÂMETROS OBTIDOS NO PROCEDIMENTO DE CALIBRAÇÃO DE SCUT

A.1 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador ML- k NN e para a base AT100

O apêndice A apresenta os parâmetros obtidos no procedimento de calibração de SCut para os categorizadores ML- k NN e VG-RAM WNN-COR e para as bases de dados AT100 e EX100. A Tabela 9-1, Tabela 9-2, Tabela 9-3, Tabela 9-4 e

Tabela 9-5 mostram os parâmetros obtidos do procedimento de calibração do SCut aplicado ao categorizador ML- k NN para as bases de dados EX100 e AT100.

APÊNDICE A

Tabela 9-1 – Parâmetros obtidos no procedimento de calibração de SCut para *ML-k NN* e para a base AT100.

$\tau 1$	0,0005	$\tau 21$	0,0000	$\tau 41$	0,0013	$\tau 61$	0,0100	$\tau 81$	0,0010	$\tau 101$	0,0003	$\tau 121$	0,0059	$\tau 141$	0,0003	$\tau 161$	0,0280	$\tau 181$	0,0080
$\tau 2$	0,0003	$\tau 22$	0,0148	$\tau 42$	0,0010	$\tau 62$	0,0100	$\tau 82$	0,0010	$\tau 102$	0,0080	$\tau 122$	0,0012	$\tau 142$	0,0066	$\tau 162$	0,0290	$\tau 182$	0,0010
$\tau 3$	0,0073	$\tau 23$	0,0003	$\tau 43$	0,0056	$\tau 63$	0,0473	$\tau 83$	0,0010	$\tau 103$	0,0160	$\tau 123$	0,0005	$\tau 143$	0,0012	$\tau 163$	0,0000	$\tau 183$	0,1390
$\tau 4$	0,0003	$\tau 24$	0,0020	$\tau 44$	0,0190	$\tau 64$	0,0037	$\tau 84$	0,0001	$\tau 104$	0,0191	$\tau 124$	0,0016	$\tau 144$	0,0020	$\tau 164$	0,0040	$\tau 184$	0,0320
$\tau 5$	0,0039	$\tau 25$	0,0697	$\tau 45$	0,0010	$\tau 65$	0,0700	$\tau 85$	0,0235	$\tau 105$	0,0281	$\tau 125$	0,0002	$\tau 145$	0,0390	$\tau 165$	0,0022	$\tau 185$	0,0008
$\tau 6$	0,0286	$\tau 26$	0,0977	$\tau 46$	0,0010	$\tau 66$	0,0550	$\tau 86$	0,0031	$\tau 106$	0,0001	$\tau 126$	0,0005	$\tau 146$	0,0014	$\tau 166$	0,0015	$\tau 186$	0,0005
$\tau 7$	0,0002	$\tau 27$	0,0013	$\tau 47$	0,0012	$\tau 67$	0,0005	$\tau 87$	0,0320	$\tau 107$	0,0001	$\tau 127$	0,0003	$\tau 147$	0,0020	$\tau 167$	0,0002	$\tau 187$	0,0002
$\tau 8$	0,0010	$\tau 28$	0,0005	$\tau 48$	0,0170	$\tau 68$	0,0003	$\tau 88$	0,2710	$\tau 108$	0,0001	$\tau 128$	0,0006	$\tau 148$	0,0005	$\tau 168$	0,0043	$\tau 188$	0,0023
$\tau 9$	0,0049	$\tau 29$	0,0025	$\tau 49$	0,0006	$\tau 69$	0,0006	$\tau 89$	0,0480	$\tau 109$	0,0005	$\tau 129$	0,0013	$\tau 149$	0,0007	$\tau 169$	0,0023	$\tau 189$	0,0052
$\tau 10$	0,0317	$\tau 30$	0,0009	$\tau 50$	0,0009	$\tau 70$	0,0010	$\tau 90$	0,0193	$\tau 110$	0,0023	$\tau 130$	0,0009	$\tau 150$	0,0050	$\tau 170$	0,0081	$\tau 190$	0,0027
$\tau 11$	0,0042	$\tau 31$	0,0017	$\tau 51$	0,0001	$\tau 71$	0,0005	$\tau 91$	0,0180	$\tau 111$	0,0032	$\tau 131$	0,0127	$\tau 151$	0,0160	$\tau 171$	0,0006	$\tau 191$	0,0001
$\tau 12$	0,0012	$\tau 32$	0,0004	$\tau 52$	0,0011	$\tau 72$	0,0005	$\tau 92$	0,0034	$\tau 112$	0,0066	$\tau 132$	0,0001	$\tau 152$	0,0003	$\tau 172$	0,0151	$\tau 192$	0,0532
$\tau 13$	0,0009	$\tau 33$	0,0096	$\tau 53$	0,0252	$\tau 73$	0,0008	$\tau 93$	0,0120	$\tau 113$	0,0019	$\tau 133$	0,0011	$\tau 153$	0,0030	$\tau 173$	0,0128	$\tau 193$	0,0147
$\tau 14$	0,0034	$\tau 34$	0,0019	$\tau 54$	0,0080	$\tau 74$	0,0013	$\tau 94$	0,0320	$\tau 114$	0,0015	$\tau 134$	0,0003	$\tau 154$	0,0011	$\tau 174$	0,0070	$\tau 194$	0,0007
$\tau 15$	0,0004	$\tau 35$	0,0004	$\tau 55$	0,0286	$\tau 75$	0,0010	$\tau 95$	0,0380	$\tau 115$	0,0041	$\tau 135$	0,0013	$\tau 155$	0,0018	$\tau 175$	0,0900	$\tau 195$	0,0060
$\tau 16$	0,0001	$\tau 36$	0,0033	$\tau 56$	0,0004	$\tau 76$	0,0023	$\tau 96$	0,0026	$\tau 116$	0,0002	$\tau 136$	0,0006	$\tau 156$	0,0109	$\tau 176$	0,0014	$\tau 196$	0,0050
$\tau 17$	0,0060	$\tau 37$	0,0119	$\tau 57$	0,0095	$\tau 77$	0,0040	$\tau 97$	0,0004	$\tau 117$	0,0177	$\tau 137$	0,0048	$\tau 157$	0,0227	$\tau 177$	0,0004	$\tau 197$	0,0022
$\tau 18$	0,0013	$\tau 38$	0,0105	$\tau 58$	0,0235	$\tau 78$	0,0024	$\tau 98$	0,0076	$\tau 118$	0,2180	$\tau 138$	0,0070	$\tau 158$	0,0048	$\tau 178$	0,0320	$\tau 198$	0,0001
$\tau 19$	0,0030	$\tau 39$	0,0073	$\tau 59$	0,0015	$\tau 79$	0,0120	$\tau 99$	0,0050	$\tau 119$	0,0167	$\tau 139$	0,0141	$\tau 159$	0,0030	$\tau 179$	0,1270	$\tau 199$	0,0013
$\tau 20$	0,0118	$\tau 40$	0,0004	$\tau 60$	0,0021	$\tau 80$	0,0140	$\tau 100$	0,0001	$\tau 120$	0,2090	$\tau 140$	0,0016	$\tau 160$	0,0095	$\tau 180$	0,0235	$\tau 200$	0,0012

APÊNDICE A

Tabela 9-2 - Parâmetros obtidos no procedimento de calibração de SCut para *ML-k NN* e para a base AT100.

τ_{201}	0,0094	τ_{221}	0,1410	τ_{241}	0,0512	τ_{261}	0,0027	τ_{281}	0,0030	τ_{301}	0,0590	τ_{321}	0,1360	τ_{341}	0,0037	τ_{361}	0,0010	τ_{381}	0,0010
τ_{202}	0,0764	τ_{222}	0,0020	τ_{242}	0,0200	τ_{262}	0,0074	τ_{282}	0,0530	τ_{302}	0,0790	τ_{322}	0,0023	τ_{342}	0,0113	τ_{362}	0,0030	τ_{382}	0,0023
τ_{203}	0,0164	τ_{223}	0,0087	τ_{243}	0,0004	τ_{263}	0,0493	τ_{283}	0,0060	τ_{303}	0,0043	τ_{323}	0,0589	τ_{343}	0,0103	τ_{363}	0,1306	τ_{383}	0,0209
τ_{204}	0,0023	τ_{224}	0,0001	τ_{244}	0,0040	τ_{264}	0,0090	τ_{284}	0,0440	τ_{304}	0,0380	τ_{324}	0,0230	τ_{344}	0,0050	τ_{364}	0,0060	τ_{384}	0,0280
τ_{205}	0,0060	τ_{225}	0,0101	τ_{245}	0,0012	τ_{265}	0,0028	τ_{285}	0,0172	τ_{305}	0,0020	τ_{325}	0,0023	τ_{345}	0,0050	τ_{365}	0,0024	τ_{385}	0,0224
τ_{206}	0,0035	τ_{226}	0,0001	τ_{246}	0,0163	τ_{266}	0,0374	τ_{286}	0,0026	τ_{306}	0,0330	τ_{326}	0,0720	τ_{346}	0,0685	τ_{366}	0,0014	τ_{386}	0,0345
τ_{207}	0,0330	τ_{227}	0,0069	τ_{247}	0,0121	τ_{267}	0,0013	τ_{287}	0,0017	τ_{307}	0,0710	τ_{327}	0,1070	τ_{347}	0,0010	τ_{367}	0,0050	τ_{387}	0,0060
τ_{208}	0,0024	τ_{228}	0,0003	τ_{248}	0,0009	τ_{268}	0,0001	τ_{288}	0,0020	τ_{308}	0,0285	τ_{328}	0,0020	τ_{348}	0,0002	τ_{368}	0,0320	τ_{388}	0,0005
τ_{209}	0,0348	τ_{229}	0,0032	τ_{249}	0,0017	τ_{269}	0,0026	τ_{289}	0,0271	τ_{309}	0,0118	τ_{329}	0,0160	τ_{349}	0,0160	τ_{369}	0,0057	τ_{389}	0,1770
τ_{210}	0,0021	τ_{230}	0,0218	τ_{250}	0,0362	τ_{270}	0,0040	τ_{290}	0,0082	τ_{310}	0,0910	τ_{330}	0,1110	τ_{350}	0,0075	τ_{370}	0,0158	τ_{390}	0,0280
τ_{211}	0,0094	τ_{231}	0,0010	τ_{251}	0,0003	τ_{271}	0,0120	τ_{291}	0,0060	τ_{311}	0,0119	τ_{331}	0,1690	τ_{351}	0,0090	τ_{371}	0,0020	τ_{391}	0,0010
τ_{212}	0,0190	τ_{232}	0,0080	τ_{252}	0,0002	τ_{272}	0,0012	τ_{292}	0,0510	τ_{312}	0,0002	τ_{332}	0,2120	τ_{352}	0,0114	τ_{372}	0,0005	τ_{392}	0,0002
τ_{213}	0,0109	τ_{233}	0,0007	τ_{253}	0,0024	τ_{273}	0,0438	τ_{293}	0,0024	τ_{313}	0,1850	τ_{333}	0,0410	τ_{353}	0,2503	τ_{373}	0,0443	τ_{393}	0,0060
τ_{214}	0,0069	τ_{234}	0,0001	τ_{254}	0,0022	τ_{274}	0,0010	τ_{294}	0,0030	τ_{314}	0,1680	τ_{334}	0,1500	τ_{354}	0,0216	τ_{374}	0,0022	τ_{394}	0,0018
τ_{215}	0,0013	τ_{235}	0,0030	τ_{255}	0,0026	τ_{275}	0,0029	τ_{295}	0,0005	τ_{315}	0,1220	τ_{335}	0,0094	τ_{355}	0,0057	τ_{375}	0,0177	τ_{395}	0,0005
τ_{216}	0,0014	τ_{236}	0,0029	τ_{256}	0,0005	τ_{276}	0,0043	τ_{296}	0,0052	τ_{316}	0,0990	τ_{336}	0,0010	τ_{356}	0,0110	τ_{376}	0,0029	τ_{396}	0,0048
τ_{217}	0,0012	τ_{237}	0,0010	τ_{257}	0,0006	τ_{277}	0,0010	τ_{297}	0,0025	τ_{317}	0,2830	τ_{337}	0,0150	τ_{357}	0,0010	τ_{377}	0,0445	τ_{397}	0,0207
τ_{218}	0,0006	τ_{238}	0,0003	τ_{258}	0,0167	τ_{278}	0,0037	τ_{298}	0,0140	τ_{318}	0,0270	τ_{338}	0,0003	τ_{358}	0,0007	τ_{378}	0,0003	τ_{398}	0,0230
τ_{219}	0,0001	τ_{239}	0,0001	τ_{259}	0,0012	τ_{279}	0,0010	τ_{299}	0,0190	τ_{319}	0,3470	τ_{339}	0,0014	τ_{359}	0,0170	τ_{379}	0,0004	τ_{399}	0,0020
τ_{220}	0,0013	τ_{240}	0,0015	τ_{260}	0,0013	τ_{280}	0,0010	τ_{300}	0,1590	τ_{320}	0,0044	τ_{340}	0,0297	τ_{360}	0,0030	τ_{380}	0,0025	τ_{400}	0,0560

APÊNDICE A

Tabela 9-3 - Parâmetros obtidos no procedimento de calibração de SCut para *ML-k NN* e para a base AT100.

τ_{401}	0,0010	τ_{421}	0,1660	τ_{441}	0,0570	τ_{461}	0,0300	τ_{481}	0,0037	τ_{501}	0,0010	τ_{521}	0,0002	τ_{541}	0,0045	τ_{561}	0,0046	τ_{581}	0,0510
τ_{402}	0,0780	τ_{422}	0,1360	τ_{442}	0,0070	τ_{462}	0,0123	τ_{482}	0,0450	τ_{502}	0,0002	τ_{522}	0,0031	τ_{542}	0,0011	τ_{562}	0,1680	τ_{582}	0,2587
τ_{403}	0,0320	τ_{423}	0,1900	τ_{443}	0,0626	τ_{463}	0,0330	τ_{483}	0,0430	τ_{503}	0,0055	τ_{523}	0,0386	τ_{543}	0,0130	τ_{563}	0,0280	τ_{583}	0,1340
τ_{404}	0,1000	τ_{424}	0,2210	τ_{444}	0,0980	τ_{464}	0,0619	τ_{484}	0,0459	τ_{504}	0,0260	τ_{524}	0,0360	τ_{544}	0,3810	τ_{564}	0,3220	τ_{584}	0,1620
τ_{405}	0,0020	τ_{425}	0,0480	τ_{445}	0,0370	τ_{465}	0,0010	τ_{485}	0,0077	τ_{505}	0,1470	τ_{525}	0,0020	τ_{545}	0,0330	τ_{565}	0,0035	τ_{585}	0,0790
τ_{406}	0,0064	τ_{426}	0,0130	τ_{446}	0,0420	τ_{466}	0,0130	τ_{486}	0,0030	τ_{506}	0,0180	τ_{526}	0,1570	τ_{546}	0,0343	τ_{566}	0,1130	τ_{586}	0,0680
τ_{407}	0,2370	τ_{427}	0,0460	τ_{447}	0,0131	τ_{467}	0,0280	τ_{487}	0,0620	τ_{507}	0,0110	τ_{527}	0,0067	τ_{547}	0,0018	τ_{567}	0,1020	τ_{587}	0,0006
τ_{408}	0,0610	τ_{428}	0,1650	τ_{448}	0,0140	τ_{468}	0,0019	τ_{488}	0,1300	τ_{508}	0,0006	τ_{528}	0,0140	τ_{548}	0,2300	τ_{568}	0,1020	τ_{588}	0,0048
τ_{409}	0,0630	τ_{429}	0,1010	τ_{449}	0,1180	τ_{469}	0,1880	τ_{489}	0,0007	τ_{509}	0,0078	τ_{529}	0,0790	τ_{549}	0,1140	τ_{569}	0,1320	τ_{589}	0,1460
τ_{410}	0,2330	τ_{430}	0,2510	τ_{450}	0,0820	τ_{470}	0,1530	τ_{490}	0,1690	τ_{510}	0,0099	τ_{530}	0,0740	τ_{550}	0,1760	τ_{570}	0,1320	τ_{590}	0,0096
τ_{411}	0,0600	τ_{431}	0,0220	τ_{451}	0,1560	τ_{471}	0,0320	τ_{491}	0,0550	τ_{511}	0,0004	τ_{531}	0,0040	τ_{551}	0,2710	τ_{571}	0,1050	τ_{591}	0,0320
τ_{412}	0,0850	τ_{432}	0,0250	τ_{452}	0,0010	τ_{472}	0,0035	τ_{492}	0,1330	τ_{512}	0,0034	τ_{532}	0,0060	τ_{552}	0,2280	τ_{572}	0,1970	τ_{592}	0,0007
τ_{413}	0,0600	τ_{433}	0,0710	τ_{453}	0,0002	τ_{473}	0,0150	τ_{493}	0,2150	τ_{513}	0,0006	τ_{533}	0,1360	τ_{553}	0,3010	τ_{573}	0,0000	τ_{593}	0,0014
τ_{414}	0,1170	τ_{434}	0,1800	τ_{454}	0,0640	τ_{474}	0,0050	τ_{494}	0,0620	τ_{514}	0,0080	τ_{534}	0,0010	τ_{554}	0,3520	τ_{574}	0,0233	τ_{594}	0,1400
τ_{415}	0,0920	τ_{435}	0,0820	τ_{455}	0,0080	τ_{475}	0,0150	τ_{495}	0,0004	τ_{515}	0,0050	τ_{535}	0,0028	τ_{555}	0,0323	τ_{575}	0,0060	τ_{595}	0,0720
τ_{416}	0,1800	τ_{436}	0,0200	τ_{456}	0,0410	τ_{476}	0,0204	τ_{496}	0,0018	τ_{516}	0,0140	τ_{536}	0,0911	τ_{556}	0,0020	τ_{576}	0,0850	τ_{596}	0,2140
τ_{417}	0,0860	τ_{437}	0,0010	τ_{457}	0,0030	τ_{477}	0,0180	τ_{497}	0,0010	τ_{517}	0,0477	τ_{537}	0,0100	τ_{557}	0,0010	τ_{577}	0,1480	τ_{597}	0,0002
τ_{418}	0,1590	τ_{438}	0,0016	τ_{458}	0,0008	τ_{478}	0,0590	τ_{498}	0,0055	τ_{518}	0,1520	τ_{538}	0,0037	τ_{558}	0,2220	τ_{578}	0,0040	τ_{598}	0,0096
τ_{419}	0,2330	τ_{439}	0,0230	τ_{459}	0,0000	τ_{479}	0,0032	τ_{499}	0,0034	τ_{519}	0,0034	τ_{539}	0,0015	τ_{559}	0,0190	τ_{579}	0,0650	τ_{599}	0,0003
τ_{420}	0,0230	τ_{440}	0,0044	τ_{460}	0,0043	τ_{480}	0,0645	τ_{500}	0,0010	τ_{520}	0,0048	τ_{540}	0,0097	τ_{560}	0,0027	τ_{580}	0,2520	τ_{600}	0,0720

APÊNDICE A

Tabela 9-4 - Parâmetros obtidos no procedimento de calibração de SCut para *ML-k NN* e para a base AT100.

τ_{601}	0,0180	τ_{621}	0,1550	τ_{641}	0,0299	τ_{661}	0,1860	τ_{681}	0,0080
τ_{602}	0,1550	τ_{622}	0,1600	τ_{642}	0,0009	τ_{662}	0,0035	τ_{682}	0,0010
τ_{603}	0,0130	τ_{623}	0,0361	τ_{643}	0,0380	τ_{663}	0,0130	τ_{683}	0,0004
τ_{604}	0,0001	τ_{624}	0,0480	τ_{644}	0,0002	τ_{664}	0,0039	τ_{684}	0,1850
τ_{605}	0,0005	τ_{625}	0,0000	τ_{645}	0,0091	τ_{665}	0,0619	τ_{685}	0,0830
τ_{606}	0,0584	τ_{626}	0,0004	τ_{646}	0,0044	τ_{666}	0,0361	τ_{686}	0,0302
τ_{607}	0,0012	τ_{627}	0,0060	τ_{647}	0,1680	τ_{667}	0,0590	τ_{687}	0,0060
τ_{608}	0,0038	τ_{628}	0,0010	τ_{648}	0,0950	τ_{668}	0,0030	τ_{688}	0,0020
τ_{609}	0,0019	τ_{629}	0,1830	τ_{649}	0,0200	τ_{669}	0,0010	τ_{689}	0,0060
τ_{610}	0,0004	τ_{630}	0,0330	τ_{650}	0,1600	τ_{670}	0,0020	τ_{690}	0,0005
τ_{611}	0,1900	τ_{631}	0,0010	τ_{651}	0,0541	τ_{671}	0,0144	τ_{691}	0,0407
τ_{612}	0,0040	τ_{632}	0,1900	τ_{652}	0,0750	τ_{672}	0,0057	τ_{692}	0,0001
τ_{613}	0,0100	τ_{633}	0,0693	τ_{653}	0,0030	τ_{673}	0,0060		
τ_{614}	0,0030	τ_{634}	0,0037	τ_{654}	0,0450	τ_{674}	0,2500		
τ_{615}	0,0422	τ_{635}	0,0006	τ_{655}	0,0088	τ_{675}	0,0020		
τ_{616}	0,0010	τ_{636}	0,0010	τ_{656}	0,0050	τ_{676}	0,0050		
τ_{617}	0,0013	τ_{637}	0,0840	τ_{657}	0,0070	τ_{677}	0,0115		
τ_{618}	0,0800	τ_{638}	0,0018	τ_{658}	0,0010	τ_{678}	0,0004		
τ_{619}	0,1040	τ_{639}	0,0235	τ_{659}	0,0170	τ_{679}	0,0009		
τ_{620}	0,0010	τ_{640}	0,0037	τ_{660}	0,0140	τ_{680}	0,0020		

A.2 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador *ML-k NN* e para a base EX100

Tabela 9-5 - Parâmetros obtidos no procedimento de calibração de SCut para *ML-k NN* e para a base EX100.

τ_1	0,0870	τ_{21}	0,0410	τ_{41}	0,1570	τ_{61}	0,1910	τ_{81}	0,1870	τ_{101}	0,0910
τ_2	0,1390	τ_{22}	0,1530	τ_{42}	0,1060	τ_{62}	0,3180	τ_{82}	0,1750	τ_{102}	0,1580
τ_3	0,0940	τ_{23}	0,1610	τ_{43}	0,2370	τ_{63}	0,0610	τ_{83}	0,1880	τ_{103}	0,4740
τ_4	0,1320	τ_{24}	0,1880	τ_{44}	0,2590	τ_{64}	0,0930	τ_{84}	0,1340	τ_{104}	0,1870
τ_5	0,0960	τ_{25}	0,2640	τ_{45}	0,2440	τ_{65}	0,2200	τ_{85}	0,1120	τ_{105}	0,1870
τ_6	0,2550	τ_{26}	0,1010	τ_{46}	0,2330	τ_{66}	0,1320	τ_{86}	0,1390		
τ_7	0,0870	τ_{27}	0,0940	τ_{47}	0,0170	τ_{67}	0,1010	τ_{87}	0,1580		
τ_8	0,1140	τ_{28}	0,1360	τ_{48}	0,0800	τ_{68}	0,2010	τ_{88}	0,0980		
τ_9	0,1010	τ_{29}	0,0840	τ_{49}	0,0890	τ_{69}	0,1060	τ_{89}	0,1220		
τ_{10}	0,2320	τ_{30}	0,1210	τ_{50}	0,1350	τ_{70}	0,1350	τ_{90}	0,2390		
τ_{11}	0,0610	τ_{31}	0,1140	τ_{51}	0,0590	τ_{71}	0,0460	τ_{91}	0,1320		
τ_{12}	0,2600	τ_{32}	0,1940	τ_{52}	0,3230	τ_{72}	0,0740	τ_{92}	0,0360		
τ_{13}	0,1520	τ_{33}	0,1880	τ_{53}	0,1610	τ_{73}	0,0970	τ_{93}	0,1070		
τ_{14}	0,1490	τ_{34}	0,4050	τ_{54}	0,0630	τ_{74}	0,3160	τ_{94}	0,4390		
τ_{15}	0,0670	τ_{35}	0,1140	τ_{55}	0,2380	τ_{75}	0,1660	τ_{95}	0,1410		
τ_{16}	0,1930	τ_{36}	0,1940	τ_{56}	0,0960	τ_{76}	0,0950	τ_{96}	0,1190		
τ_{17}	0,2110	τ_{37}	0,2510	τ_{57}	0,0950	τ_{77}	0,0530	τ_{97}	0,1320		
τ_{18}	0,2080	τ_{38}	0,1850	τ_{58}	0,3190	τ_{78}	0,0550	τ_{98}	0,1670		
τ_{19}	0,1050	τ_{39}	0,1060	τ_{59}	0,3190	τ_{79}	0,1310	τ_{99}	0,2320		
τ_{20}	0,0720	τ_{40}	0,0830	τ_{60}	0,1010	τ_{80}	0,0410	τ_{100}	0,0860		

A.3 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador VG-RAM WNN-COR e para a base AT100

A Tabela 9-6, Tabela 9-7, Tabela 9-8, Tabela 9-9 e Tabela 9-10 mostram os parâmetros obtidos do procedimento de calibração do SCut aplicado ao categorizador *VG-RAM WNN-COR* para as bases de dados EX100 e AT100.

APÊNDICE A

Tabela 9-6 - Parâmetros obtidos no procedimento de calibração de SCut para VG-RAM WNN-COR e para a base AT100.

τ_1	0,0057	τ_{21}	0,0016	τ_{41}	0,0093	τ_{61}	0,0460	τ_{81}	0,0150	τ_{101}	0,0050	τ_{121}	0,0203	τ_{141}	0,0261	τ_{161}	0,0230	τ_{181}	0,0390
τ_2	0,0078	τ_{22}	0,0219	τ_{42}	0,0050	τ_{62}	0,0210	τ_{82}	0,0041	τ_{102}	0,0080	τ_{122}	0,0167	τ_{142}	0,0117	τ_{162}	0,0420	τ_{182}	0,0120
τ_3	0,0138	τ_{23}	0,0126	τ_{43}	0,0227	τ_{63}	0,0223	τ_{83}	0,0037	τ_{103}	0,0210	τ_{123}	0,0023	τ_{143}	0,0071	τ_{163}	0,0037	τ_{183}	0,0431
τ_4	0,0056	τ_{24}	0,0067	τ_{44}	0,0110	τ_{64}	0,0134	τ_{84}	0,0095	τ_{104}	0,0369	τ_{124}	0,0249	τ_{144}	0,0070	τ_{164}	0,0209	τ_{184}	0,0250
τ_5	0,0333	τ_{25}	0,0350	τ_{45}	0,0230	τ_{65}	0,0370	τ_{85}	0,0252	τ_{105}	0,0430	τ_{125}	0,0143	τ_{145}	0,0390	τ_{165}	0,0196	τ_{185}	0,0027
τ_6	0,0084	τ_{26}	0,0266	τ_{46}	0,0090	τ_{66}	0,0414	τ_{86}	0,0140	τ_{106}	0,0101	τ_{126}	0,0032	τ_{146}	0,0074	τ_{166}	0,0118	τ_{186}	0,0169
τ_7	0,0062	τ_{27}	0,0073	τ_{47}	0,0266	τ_{67}	0,0268	τ_{87}	0,1145	τ_{107}	0,0256	τ_{127}	0,0035	τ_{147}	0,0130	τ_{167}	0,0150	τ_{187}	0,0069
τ_8	0,0110	τ_{28}	0,0085	τ_{48}	0,0320	τ_{68}	0,0068	τ_{88}	0,0550	τ_{108}	0,0043	τ_{128}	0,0114	τ_{148}	0,0568	τ_{168}	0,0233	τ_{188}	0,0181
τ_9	0,0192	τ_{29}	0,0123	τ_{49}	0,0756	τ_{69}	0,0152	τ_{89}	0,0280	τ_{109}	0,0048	τ_{129}	0,0073	τ_{149}	0,0090	τ_{169}	0,0208	τ_{189}	0,0238
τ_{10}	0,0284	τ_{30}	0,0130	τ_{50}	0,0090	τ_{70}	0,0155	τ_{90}	0,0137	τ_{110}	0,0153	τ_{130}	0,0144	τ_{150}	0,0154	τ_{170}	0,0385	τ_{190}	0,0076
τ_{11}	0,0111	τ_{31}	0,0129	τ_{51}	0,0141	τ_{71}	0,0072	τ_{91}	0,0268	τ_{111}	0,0185	τ_{131}	0,1887	τ_{151}	0,0130	τ_{171}	0,0060	τ_{191}	0,0080
τ_{12}	0,0056	τ_{32}	0,0077	τ_{52}	0,0201	τ_{72}	0,0161	τ_{92}	0,0177	τ_{112}	0,0228	τ_{132}	0,0099	τ_{152}	0,0134	τ_{172}	0,0357	τ_{192}	0,0276
τ_{13}	0,0099	τ_{33}	0,0348	τ_{53}	0,0319	τ_{73}	0,0143	τ_{93}	0,0210	τ_{113}	0,0069	τ_{133}	0,0181	τ_{153}	0,0080	τ_{173}	0,0372	τ_{193}	0,0080
τ_{14}	0,0284	τ_{34}	0,0712	τ_{54}	0,0200	τ_{74}	0,0055	τ_{94}	0,0250	τ_{114}	0,0114	τ_{134}	0,0126	τ_{154}	0,0120	τ_{174}	0,0240	τ_{194}	0,0122
τ_{15}	0,0600	τ_{35}	0,0020	τ_{55}	0,0071	τ_{75}	0,0140	τ_{95}	0,0350	τ_{115}	0,0358	τ_{135}	0,0046	τ_{155}	0,0074	τ_{175}	0,0280	τ_{195}	0,0060
τ_{16}	0,0043	τ_{36}	0,0172	τ_{56}	0,0270	τ_{76}	0,0072	τ_{96}	0,0333	τ_{116}	0,0063	τ_{136}	0,0114	τ_{156}	0,0272	τ_{176}	0,0132	τ_{196}	0,0160
τ_{17}	0,0345	τ_{37}	0,0461	τ_{57}	0,0279	τ_{77}	0,0080	τ_{97}	0,0053	τ_{117}	0,0349	τ_{137}	0,0059	τ_{157}	0,0499	τ_{177}	0,0036	τ_{197}	0,0152
τ_{18}	0,0134	τ_{38}	0,0574	τ_{58}	0,0090	τ_{78}	0,1210	τ_{98}	0,0692	τ_{118}	0,0870	τ_{138}	0,0190	τ_{158}	0,0074	τ_{178}	0,0274	τ_{198}	0,0029
τ_{19}	0,0190	τ_{39}	0,0032	τ_{59}	0,0094	τ_{79}	0,0310	τ_{99}	0,0135	τ_{119}	0,0233	τ_{139}	0,0591	τ_{159}	0,0275	τ_{179}	0,0360	τ_{199}	0,0032
τ_{20}	0,0375	τ_{40}	0,0070	τ_{60}	0,0091	τ_{80}	0,0260	τ_{100}	0,0022	τ_{120}	0,0440	τ_{140}	0,0048	τ_{160}	0,0357	τ_{180}	0,0136	τ_{200}	0,0195

APÊNDICE A

Tabela 9-7 - Parâmetros obtidos no procedimento de calibração de SCut para VG-RAM WNN-COR e para a base AT100.

τ_{201}	0,0085	τ_{221}	0,0470	τ_{241}	0,0534	τ_{261}	0,0171	τ_{281}	0,0699	τ_{301}	0,0720	τ_{321}	0,0560	τ_{341}	0,0334	τ_{361}	0,0030	τ_{381}	0,0010
τ_{202}	0,0220	τ_{222}	0,0080	τ_{242}	0,1070	τ_{262}	0,0271	τ_{282}	0,0380	τ_{302}	0,0765	τ_{322}	0,0140	τ_{342}	0,0359	τ_{362}	0,0170	τ_{382}	0,0561
τ_{203}	0,0076	τ_{223}	0,0084	τ_{243}	0,0219	τ_{263}	0,0219	τ_{283}	0,1960	τ_{303}	0,0218	τ_{323}	0,0548	τ_{343}	0,0339	τ_{363}	0,0436	τ_{383}	0,0663
τ_{204}	0,0188	τ_{224}	0,0033	τ_{244}	0,0180	τ_{264}	0,0470	τ_{284}	0,0070	τ_{304}	0,0260	τ_{324}	0,0220	τ_{344}	0,0120	τ_{364}	0,0219	τ_{384}	0,0400
τ_{205}	0,0242	τ_{225}	0,0090	τ_{245}	0,0036	τ_{265}	0,0330	τ_{285}	0,1014	τ_{305}	0,0230	τ_{325}	0,0096	τ_{345}	0,0160	τ_{365}	0,0846	τ_{385}	0,0249
τ_{206}	0,0118	τ_{226}	0,0030	τ_{246}	0,0171	τ_{266}	0,0065	τ_{286}	0,0194	τ_{306}	0,0340	τ_{326}	0,0290	τ_{346}	0,0437	τ_{366}	0,0296	τ_{386}	0,0164
τ_{207}	0,0510	τ_{227}	0,0106	τ_{247}	0,0139	τ_{267}	0,0120	τ_{287}	0,0402	τ_{307}	0,0340	τ_{327}	0,0580	τ_{347}	0,0320	τ_{367}	0,0120	τ_{387}	0,0200
τ_{208}	0,0080	τ_{228}	0,0016	τ_{248}	0,0075	τ_{268}	0,0037	τ_{288}	0,0334	τ_{308}	0,0228	τ_{328}	0,0060	τ_{348}	0,0218	τ_{368}	0,0483	τ_{388}	0,0029
τ_{209}	0,0440	τ_{229}	0,0075	τ_{249}	0,0073	τ_{269}	0,0109	τ_{289}	0,0149	τ_{309}	0,0240	τ_{329}	0,0280	τ_{349}	0,0530	τ_{369}	0,0198	τ_{389}	0,0680
τ_{210}	0,0157	τ_{230}	0,0150	τ_{250}	0,1533	τ_{270}	0,0620	τ_{290}	0,0258	τ_{310}	0,0350	τ_{330}	0,0670	τ_{350}	0,0421	τ_{370}	0,0119	τ_{390}	0,0250
τ_{211}	0,0154	τ_{231}	0,0030	τ_{251}	0,0048	τ_{271}	0,0270	τ_{291}	0,0130	τ_{311}	0,0128	τ_{331}	0,0920	τ_{351}	0,0140	τ_{371}	0,0426	τ_{391}	0,0410
τ_{212}	0,0340	τ_{232}	0,0200	τ_{252}	0,0064	τ_{272}	0,0115	τ_{292}	0,0330	τ_{312}	0,0099	τ_{332}	0,1330	τ_{352}	0,0020	τ_{372}	0,0094	τ_{392}	0,0136
τ_{213}	0,0301	τ_{233}	0,0294	τ_{253}	0,0030	τ_{273}	0,0601	τ_{293}	0,0104	τ_{313}	0,0410	τ_{333}	0,0840	τ_{353}	0,0589	τ_{373}	0,0373	τ_{393}	0,0230
τ_{214}	0,0165	τ_{234}	0,0029	τ_{254}	0,0016	τ_{274}	0,0171	τ_{294}	0,0080	τ_{314}	0,0690	τ_{334}	0,0860	τ_{354}	0,0195	τ_{374}	0,0070	τ_{394}	0,0020
τ_{215}	0,0113	τ_{235}	0,0187	τ_{255}	0,0051	τ_{275}	0,0191	τ_{295}	0,0214	τ_{315}	0,0520	τ_{335}	0,0218	τ_{355}	0,0084	τ_{375}	0,0743	τ_{395}	0,0080
τ_{216}	0,0119	τ_{236}	0,0111	τ_{256}	0,0093	τ_{276}	0,0212	τ_{296}	0,0058	τ_{316}	0,0690	τ_{336}	0,0410	τ_{356}	0,0192	τ_{376}	0,0052	τ_{396}	0,0187
τ_{217}	0,0153	τ_{237}	0,0120	τ_{257}	0,0052	τ_{277}	0,0040	τ_{297}	0,0136	τ_{317}	0,0610	τ_{337}	0,0370	τ_{357}	0,0120	τ_{377}	0,0565	τ_{397}	0,0181
τ_{218}	0,0202	τ_{238}	0,0077	τ_{258}	0,0390	τ_{278}	0,0146	τ_{298}	0,0190	τ_{318}	0,0400	τ_{338}	0,0079	τ_{358}	0,0115	τ_{378}	0,0094	τ_{398}	0,0190
τ_{219}	0,0072	τ_{239}	0,0040	τ_{259}	0,0065	τ_{279}	0,0250	τ_{299}	0,0390	τ_{319}	0,0680	τ_{339}	0,0060	τ_{359}	0,0180	τ_{379}	0,0215	τ_{399}	0,0230
τ_{220}	0,0081	τ_{240}	0,0094	τ_{260}	0,0049	τ_{280}	0,0250	τ_{300}	0,0570	τ_{320}	0,0128	τ_{340}	0,0010	τ_{360}	0,0110	τ_{380}	0,0010	τ_{400}	0,0560

APÊNDICE A

Tabela 9-8 - Parâmetros obtidos no procedimento de calibração de SCut para VG-RAM WNN-COR e para a base AT100.

τ_{401}	0,0030	τ_{421}	0,0850	τ_{441}	0,0420	τ_{461}	0,0370	τ_{481}	0,0107	τ_{501}	0,0250	τ_{521}	0,0083	τ_{541}	0,0226	τ_{561}	0,0165	τ_{581}	0,0540
τ_{402}	0,0470	τ_{422}	0,0410	τ_{442}	0,0240	τ_{462}	0,1023	τ_{482}	0,0590	τ_{502}	0,0167	τ_{522}	0,0399	τ_{542}	0,0306	τ_{562}	0,0470	τ_{582}	0,1498
τ_{403}	0,0290	τ_{423}	0,0690	τ_{443}	0,0698	τ_{463}	0,0130	τ_{483}	0,0288	τ_{503}	0,0360	τ_{523}	0,0252	τ_{543}	0,0400	τ_{563}	0,0040	τ_{583}	0,0730
τ_{404}	0,0640	τ_{424}	0,0840	τ_{444}	0,0640	τ_{464}	0,0502	τ_{484}	0,0416	τ_{504}	0,0330	τ_{524}	0,0390	τ_{544}	0,0940	τ_{564}	0,1130	τ_{584}	0,0680
τ_{405}	0,0130	τ_{425}	0,0400	τ_{445}	0,0310	τ_{465}	0,0200	τ_{485}	0,0111	τ_{505}	0,0950	τ_{525}	0,0340	τ_{545}	0,0450	τ_{565}	0,0167	τ_{585}	0,0660
τ_{406}	0,0091	τ_{426}	0,0170	τ_{446}	0,0960	τ_{466}	0,0070	τ_{486}	0,0250	τ_{506}	0,0540	τ_{526}	0,1050	τ_{546}	0,0266	τ_{566}	0,0640	τ_{586}	0,0720
τ_{407}	0,1240	τ_{427}	0,0570	τ_{447}	0,0226	τ_{467}	0,0640	τ_{487}	0,0200	τ_{507}	0,0620	τ_{527}	0,0136	τ_{547}	0,0057	τ_{567}	0,0610	τ_{587}	0,0173
τ_{408}	0,0580	τ_{428}	0,0570	τ_{448}	0,0120	τ_{468}	0,0208	τ_{488}	0,0720	τ_{508}	0,0267	τ_{528}	0,0330	τ_{548}	0,0590	τ_{568}	0,0610	τ_{588}	0,0098
τ_{409}	0,0950	τ_{429}	0,0640	τ_{449}	0,1090	τ_{469}	0,0890	τ_{489}	0,0287	τ_{509}	0,1492	τ_{529}	0,0520	τ_{549}	0,0520	τ_{569}	0,0580	τ_{589}	0,0430
τ_{410}	0,0630	τ_{430}	0,0730	τ_{450}	0,0660	τ_{470}	0,0730	τ_{490}	0,1200	τ_{510}	0,0341	τ_{530}	0,1230	τ_{550}	0,0810	τ_{570}	0,0550	τ_{590}	0,0299
τ_{411}	0,0400	τ_{431}	0,1030	τ_{451}	0,0940	τ_{471}	0,0760	τ_{491}	0,1640	τ_{511}	0,0124	τ_{531}	0,0200	τ_{551}	0,1000	τ_{571}	0,0410	τ_{591}	0,1170
τ_{412}	0,0570	τ_{432}	0,0490	τ_{452}	0,0020	τ_{472}	0,0193	τ_{492}	0,0900	τ_{512}	0,0120	τ_{532}	0,0830	τ_{552}	0,1180	τ_{572}	0,0600	τ_{592}	0,0042
τ_{413}	0,0900	τ_{433}	0,0560	τ_{453}	0,0259	τ_{473}	0,0490	τ_{493}	0,0690	τ_{513}	0,0080	τ_{533}	0,0920	τ_{553}	0,0550	τ_{573}	0,0031	τ_{593}	0,0133
τ_{414}	0,0360	τ_{434}	0,0730	τ_{454}	0,0420	τ_{474}	0,0900	τ_{494}	0,0491	τ_{514}	0,0540	τ_{534}	0,0173	τ_{554}	0,0320	τ_{574}	0,0244	τ_{594}	0,0930
τ_{415}	0,0500	τ_{435}	0,0330	τ_{455}	0,0170	τ_{475}	0,0230	τ_{495}	0,0209	τ_{515}	0,0040	τ_{535}	0,0090	τ_{555}	0,0301	τ_{575}	0,0110	τ_{595}	0,0610
τ_{416}	0,0950	τ_{436}	0,0330	τ_{456}	0,0640	τ_{476}	0,0512	τ_{496}	0,0419	τ_{516}	0,0470	τ_{536}	0,1237	τ_{556}	0,0085	τ_{576}	0,0720	τ_{596}	0,0840
τ_{417}	0,0690	τ_{437}	0,0030	τ_{457}	0,0078	τ_{477}	0,0520	τ_{497}	0,0070	τ_{517}	0,0267	τ_{537}	0,0470	τ_{557}	0,0100	τ_{577}	0,1120	τ_{597}	0,1200
τ_{418}	0,0610	τ_{438}	0,0086	τ_{458}	0,0151	τ_{478}	0,0790	τ_{498}	0,0837	τ_{518}	0,0360	τ_{538}	0,0171	τ_{558}	0,0570	τ_{578}	0,0220	τ_{598}	0,0160
τ_{419}	0,0710	τ_{439}	0,0470	τ_{459}	0,0023	τ_{479}	0,0155	τ_{499}	0,0180	τ_{519}	0,0079	τ_{539}	0,0239	τ_{559}	0,0300	τ_{579}	0,0450	τ_{599}	0,0059
τ_{420}	0,3890	τ_{440}	0,0050	τ_{460}	0,0173	τ_{480}	0,0096	τ_{500}	0,0157	τ_{520}	0,0381	τ_{540}	0,2422	τ_{560}	0,0113	τ_{580}	0,0850	τ_{600}	0,0370

APÊNDICE A

Tabela 9-9 - Parâmetros obtidos no procedimento de calibração de SCut para VG-RAM WNN-COR e para a base AT100.

$\tau601$	0,0246	$\tau621$	0,0930	$\tau641$	0,0619	$\tau661$	0,0780	$\tau681$	0,1247
$\tau602$	0,0610	$\tau622$	0,1080	$\tau642$	0,0209	$\tau662$	0,0128	$\tau682$	0,0020
$\tau603$	0,0590	$\tau623$	0,0240	$\tau643$	0,0360	$\tau663$	0,0100	$\tau683$	0,0050
$\tau604$	0,0270	$\tau624$	0,0500	$\tau644$	0,0249	$\tau664$	0,0115	$\tau684$	0,1570
$\tau605$	0,0652	$\tau625$	0,0023	$\tau645$	0,0147	$\tau665$	0,0586	$\tau685$	0,0750
$\tau606$	0,0740	$\tau626$	0,0062	$\tau646$	0,0131	$\tau666$	0,0286	$\tau686$	0,0103
$\tau607$	0,0116	$\tau627$	0,0440	$\tau647$	0,0440	$\tau667$	0,0230	$\tau687$	0,0103
$\tau608$	0,0190	$\tau628$	0,0490	$\tau648$	0,0440	$\tau668$	0,0250	$\tau688$	0,0200
$\tau609$	0,0100	$\tau629$	0,0930	$\tau649$	0,0470	$\tau669$	0,0170	$\tau689$	0,0222
$\tau610$	0,0255	$\tau630$	0,0500	$\tau650$	0,0730	$\tau670$	0,0030	$\tau690$	0,0113
$\tau611$	0,1160	$\tau631$	0,0100	$\tau651$	0,1465	$\tau671$	0,0195	$\tau691$	0,0020
$\tau612$	0,0290	$\tau632$	0,0500	$\tau652$	0,0300	$\tau672$	0,0269	$\tau692$	0,0035
$\tau613$	0,0150	$\tau633$	0,0429	$\tau653$	0,0100	$\tau673$	0,0150		
$\tau614$	0,0120	$\tau634$	0,0123	$\tau654$	0,0450	$\tau674$	0,0630		
$\tau615$	0,0589	$\tau635$	0,0084	$\tau655$	0,0605	$\tau675$	0,0200		
$\tau616$	0,0240	$\tau636$	0,0030	$\tau656$	0,0160	$\tau676$	0,0090		
$\tau617$	0,0176	$\tau637$	0,0730	$\tau657$	0,0170	$\tau677$	0,2038		
$\tau618$	0,1240	$\tau638$	0,0274	$\tau658$	0,0210	$\tau678$	0,0079		
$\tau619$	0,0530	$\tau639$	0,0264	$\tau659$	0,0460	$\tau679$	0,0228		
$\tau620$	0,0110	$\tau640$	0,0132	$\tau660$	0,0370	$\tau680$	0,0130		

A.4 Parâmetros obtidos no procedimento de calibração de SCut para o categorizador VG-RAM WNN-COR e para a base EX100

Tabela 9-10 - Parâmetros obtidos no procedimento de calibração de SCut para VG-RAM WNN-COR e para a base EX100.

$\tau1$	0,0660	$\tau21$	0,0390	$\tau41$	0,0560	$\tau61$	0,0740	$\tau81$	0,0860	$\tau101$	0,0590
$\tau2$	0,0600	$\tau22$	0,0500	$\tau42$	0,0880	$\tau62$	0,0660	$\tau82$	0,0800	$\tau102$	0,1070
$\tau3$	0,0370	$\tau23$	0,0460	$\tau43$	0,0750	$\tau63$	0,0770	$\tau83$	0,0890	$\tau103$	0,1010
$\tau4$	0,0750	$\tau24$	0,0690	$\tau44$	0,0660	$\tau64$	0,0620	$\tau84$	0,0390	$\tau104$	0,0550
$\tau5$	0,0700	$\tau25$	0,0710	$\tau45$	0,0830	$\tau65$	0,0780	$\tau85$	0,0520	$\tau105$	0,0770
$\tau6$	0,0550	$\tau26$	0,0760	$\tau46$	0,0840	$\tau66$	0,0690	$\tau86$	0,0850		
$\tau7$	0,0860	$\tau27$	0,0450	$\tau47$	0,0210	$\tau67$	0,0620	$\tau87$	0,0790		
$\tau8$	0,0820	$\tau28$	0,0720	$\tau48$	0,0960	$\tau68$	0,0400	$\tau88$	0,0610		
$\tau9$	0,0750	$\tau29$	0,0500	$\tau49$	0,0470	$\tau69$	0,0640	$\tau89$	0,0730		
$\tau10$	0,0510	$\tau30$	0,0540	$\tau50$	0,0570	$\tau70$	0,0720	$\tau90$	0,0930		
$\tau11$	0,0490	$\tau31$	0,0650	$\tau51$	0,0630	$\tau71$	0,0380	$\tau91$	0,0930		
$\tau12$	0,0590	$\tau32$	0,0710	$\tau52$	0,1140	$\tau72$	0,0720	$\tau92$	0,0350		
$\tau13$	0,0670	$\tau33$	0,0700	$\tau53$	0,0590	$\tau73$	0,0340	$\tau93$	0,1120		
$\tau14$	0,0680	$\tau34$	0,1500	$\tau54$	0,0410	$\tau74$	0,0580	$\tau94$	0,0650		
$\tau15$	0,0790	$\tau35$	0,0530	$\tau55$	0,0770	$\tau75$	0,0520	$\tau95$	0,0550		
$\tau16$	0,0770	$\tau36$	0,0520	$\tau56$	0,0450	$\tau76$	0,0620	$\tau96$	0,0460		
$\tau17$	0,0760	$\tau37$	0,0920	$\tau57$	0,0610	$\tau77$	0,0330	$\tau97$	0,0710		
$\tau18$	0,0800	$\tau38$	0,0700	$\tau58$	0,0620	$\tau78$	0,0570	$\tau98$	0,0980		
$\tau19$	0,0830	$\tau39$	0,0670	$\tau59$	0,0630	$\tau79$	0,0600	$\tau99$	0,1020		
$\tau20$	0,0320	$\tau40$	0,0520	$\tau60$	0,0440	$\tau80$	0,0320	$\tau100$	0,0520		

APÊNDICE B – PROBABILIDADES $P(X/Y,K)$ DE VALIDAÇÃO VERSUS $P(X/Y,K)$ DE TESTE

A Tabela 9-11, Tabela 9-12, Tabela 9-13, Tabela 9-14 e Tabela 9-15 apresentam a comparação entre os valores de $p(x/y,k)$ calculados analiticamente (por meio da regra de Bayes a partir das estimativas de $p(x/k)$, $p(y/k)$ e $p(y/x,k)$ obtidas nos experimentos de validação) com os valores de $p(x/y,k)$ estimados empiricamente (a partir dos experimentos de teste para $k = \{ 1, 2, 3, 4 \text{ e } 5 \}$, referentes as cinco primeiras posições do *ranking*) para o categorizador ML- k NN empregando a base AT100. Nas tabelas citadas acima, a coluna Intervalo mostra cada um dos 20 intervalos de valores de f observados nos experimentos de validação, a coluna Validação mostra os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de Bayes com os resultados dos experimentos de validação, e a coluna Teste mostra os valores de $p(x/y,k)$ estimados empiricamente a partir dos experimentos de teste.

Como pode ser observado na Tabela 9-11, Tabela 9-12, Tabela 9-13, Tabela 9-14 e Tabela 9-15, os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de Bayes são muito próximos aos valores de $p(x/y,k)$ estimados empiricamente, o que demonstra que, usando nossa metodologia, é possível prever no teste com o último *fold* (não visto pelo ML- k NN durante o treinamento) o quão certo está o ML- k NN quanto à primeira categoria no seu *ranking* de saída ser pertinente para um dado documento. É importante destacar que esta medida de certeza vai de 0% a 100% – uma medida facilmente compreensível para um operador do SCAE humano.

O sistema SCAE usa as tabelas Tabela 9-11, Tabela 9-12, Tabela 9-13, Tabela 9-14 e Tabela 9-15 da seguinte forma. Se o ML- k NN predisse a categoria c_i para o documento d_j com grau de crença $f(d_j, c_i)$ dentro de um intervalo y (dentro os 20 intervalos observados na validação), e posicionou a categoria c_i na posição $r(d_j, c_i)$ do *ranking*, então a medida de certeza para essa predição pode ser expressa por $p(x/y,k)$, onde $y \subset f(d_j, c_i)$ e $k = r(d_j, c_i)$.

A Tabela 9-11, Tabela 9-12, Tabela 9-13, Tabela 9-14 e Tabela 9-15 mostram os resultados do uso de nossa metodologia para valores de k iguais a 1, 2, 3, 4 e 5 respectivamente. Como pode ser visto nestas tabelas, também para estes valores de k é possível prever no teste com o último *fold* o quão certo está o ML- k NN quanto à categoria na posição k no seu *ranking* de saída ser pertinente para um dado documento. Note que, quanto

APÊNDICE B

maior o k (quanto mais abaixo no *ranking* de saída do categorizador), menos provável que a categoria atribuída pelo categorizador seja pertinente ao documento (ver última linha das tabelas). Isso é esperado, já que, para a base de dados empregada no treinamento (AT100), é incomum existirem mais que dois códigos pertinentes a um dado documento.

Tabela 9-11 – Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=1$ do *ranking* em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,155871)	$p(x y,k)$	0,122622	$p(x/y,k)$	0,204082
2	(0,155871 - 0,198844)	$p(x y,k)$	0,203393	$p(x/y,k)$	0,200000
3	(0,198844 - 0,229916)	$p(x y,k)$	0,317798	$p(x/y,k)$	0,363636
4	(0,229916 - 0,256375)	$p(x y,k)$	0,330508	$p(x/y,k)$	0,230769
5	(0,256375 - 0,280119)	$p(x y,k)$	0,341106	$p(x/y,k)$	0,431818
6	(0,280119 - 0,303212)	$p(x y,k)$	0,461866	$p(x/y,k)$	0,369565
7	(0,303212 - 0,326125)	$p(x y,k)$	0,466099	$p(x/y,k)$	0,538462
8	(0,326125 - 0,346033)	$p(x y,k)$	0,476698	$p(x/y,k)$	0,625000
9	(0,346033 - 0,366272)	$p(x y,k)$	0,489407	$p(x/y,k)$	0,533333
10	(0,366272 - 0,386598)	$p(x y,k)$	0,536022	$p(x/y,k)$	0,659091
11	(0,386598 - 0,409530)	$p(x y,k)$	0,546610	$p(x/y,k)$	0,468085
12	(0,409530 - 0,434036)	$p(x y,k)$	0,586870	$p(x/y,k)$	0,568627
13	(0,434036 - 0,457209)	$p(x y,k)$	0,593225	$p(x/y,k)$	0,627451
14	(0,457209 - 0,486895)	$p(x y,k)$	0,620766	$p(x/y,k)$	0,666667
15	(0,486895 - 0,518835)	$p(x y,k)$	0,678651	$p(x/y,k)$	0,649123
16	(0,518835 - 0,559086)	$p(x y,k)$	0,690031	$p(x/y,k)$	0,600000
17	(0,559086 - 0,607647)	$p(x y,k)$	0,707631	$p(x/y,k)$	0,711111
18	(0,607647 - 0,669649)	$p(x y,k)$	0,775432	$p(x/y,k)$	0,816327
19	(0,669649 - 0,759295)	$p(x y,k)$	0,832635	$p(x/y,k)$	0,914286
20	(0,759295 - 1,000000)	$p(x y,k)$	0,928713	$p(x/y,k)$	0,961538

APÊNDICE B

Tabela 9-12 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
1	(0,000000 - 0,046800)	$p(x y,k)$	0,029599	$p(x/y,k)$	0,020833
2	(0,046800 - 0,067131)	$p(x y,k)$	0,067797	$p(x/y,k)$	0,062500
3	(0,067131 - 0,081792)	$p(x y,k)$	0,069913	$p(x/y,k)$	0,122449
4	(0,081792 - 0,094919)	$p(x y,k)$	0,112287	$p(x/y,k)$	0,127660
5	(0,094919 - 0,107926)	$p(x y,k)$	0,112287	$p(x/y,k)$	0,043478
6	(0,107926 - 0,120012)	$p(x y,k)$	0,156781	$p(x/y,k)$	0,155556
7	(0,120012 - 0,132169)	$p(x y,k)$	0,133474	$p(x/y,k)$	0,058824
8	(0,132169 - 0,144638)	$p(x y,k)$	0,133474	$p(x/y,k)$	0,176471
9	(0,144638 - 0,155147)	$p(x y,k)$	0,220342	$p(x/y,k)$	0,191489
10	(0,155147 - 0,167371)	$p(x y,k)$	0,211867	$p(x/y,k)$	0,285714
11	(0,167371 - 0,179440)	$p(x y,k)$	0,241528	$p(x/y,k)$	0,266667
12	(0,179440 - 0,190638)	$p(x y,k)$	0,266952	$p(x/y,k)$	0,256410
13	(0,190638 - 0,204448)	$p(x y,k)$	0,300851	$p(x/y,k)$	0,259259
14	(0,204448 - 0,219379)	$p(x y,k)$	0,290255	$p(x/y,k)$	0,315789
15	(0,219379 - 0,233891)	$p(x y,k)$	0,292376	$p(x/y,k)$	0,347826
16	(0,233891 - 0,249914)	$p(x y,k)$	0,364411	$p(x/y,k)$	0,456522
17	(0,249914 - 0,271343)	$p(x y,k)$	0,404663	$p(x/y,k)$	0,574468
18	(0,271343 - 0,295373)	$p(x y,k)$	0,538137	$p(x/y,k)$	0,518519
19	(0,295373 - 0,333566)	$p(x y,k)$	0,591106	$p(x/y,k)$	0,604651
20	(0,333566 - 1,000000)	$p(x y,k)$	0,624732	$p(x/y,k)$	0,711864

Tabela 9-13 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
1	(0,000000 - 0,021835)	$p(x y,k)$	0,012685	$p(x/y,k)$	0,018182
2	(0,021835 - 0,031798)	$p(x y,k)$	0,029662	$p(x/y,k)$	0,023810
3	(0,031798 - 0,040027)	$p(x y,k)$	0,044493	$p(x/y,k)$	0,021739
4	(0,040027 - 0,047837)	$p(x y,k)$	0,055085	$p(x/y,k)$	0,040816
5	(0,047837 - 0,054814)	$p(x y,k)$	0,105932	$p(x/y,k)$	0,113636
6	(0,054814 - 0,060665)	$p(x y,k)$	0,063559	$p(x/y,k)$	0,092593
7	(0,060665 - 0,066884)	$p(x y,k)$	0,088985	$p(x/y,k)$	0,021739
8	(0,066884 - 0,073148)	$p(x y,k)$	0,105932	$p(x/y,k)$	0,057692
9	(0,073148 - 0,079471)	$p(x y,k)$	0,097459	$p(x/y,k)$	0,166667
10	(0,079471 - 0,086391)	$p(x y,k)$	0,095340	$p(x/y,k)$	0,029412
11	(0,086391 - 0,093646)	$p(x y,k)$	0,103813	$p(x/y,k)$	0,192982
12	(0,093646 - 0,100427)	$p(x y,k)$	0,135594	$p(x/y,k)$	0,090909
13	(0,100427 - 0,108284)	$p(x y,k)$	0,116528	$p(x/y,k)$	0,085714
14	(0,108284 - 0,116739)	$p(x y,k)$	0,175848	$p(x/y,k)$	0,145833
15	(0,116739 - 0,125955)	$p(x y,k)$	0,203391	$p(x/y,k)$	0,214286
16	(0,125955 - 0,136692)	$p(x y,k)$	0,199156	$p(x/y,k)$	0,255319
17	(0,136692 - 0,148551)	$p(x y,k)$	0,235172	$p(x/y,k)$	0,170732
18	(0,148551 - 0,165724)	$p(x y,k)$	0,292376	$p(x/y,k)$	0,195122
19	(0,165724 - 0,190991)	$p(x y,k)$	0,379239	$p(x/y,k)$	0,351852
20	(0,190991 - 1,000000)	$p(x y,k)$	0,410900	$p(x/y,k)$	0,379310

APÊNDICE B

Tabela 9-14 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,012437)	$p(x y,k)$	0,014800	$p(x/y,k)$	0,000000
2	(0,012437 - 0,017597)	$p(x y,k)$	0,014831	$p(x/y,k)$	0,037037
3	(0,017597 - 0,022350)	$p(x y,k)$	0,023304	$p(x/y,k)$	0,032787
4	(0,022350 - 0,026812)	$p(x y,k)$	0,019067	$p(x/y,k)$	0,025641
5	(0,026812 - 0,031215)	$p(x y,k)$	0,042373	$p(x/y,k)$	0,085106
6	(0,031215 - 0,035319)	$p(x y,k)$	0,038136	$p(x/y,k)$	0,000000
7	(0,035319 - 0,039399)	$p(x y,k)$	0,048729	$p(x/y,k)$	0,062500
8	(0,039399 - 0,043048)	$p(x y,k)$	0,067796	$p(x/y,k)$	0,075472
9	(0,043048 - 0,047127)	$p(x y,k)$	0,074153	$p(x/y,k)$	0,055556
10	(0,047127 - 0,051496)	$p(x y,k)$	0,078390	$p(x/y,k)$	0,134615
11	(0,051496 - 0,055322)	$p(x y,k)$	0,065678	$p(x/y,k)$	0,050000
12	(0,055322 - 0,060445)	$p(x y,k)$	0,091103	$p(x/y,k)$	0,068182
13	(0,060445 - 0,065048)	$p(x y,k)$	0,125001	$p(x/y,k)$	0,129630
14	(0,065048 - 0,070333)	$p(x y,k)$	0,114407	$p(x/y,k)$	0,111111
15	(0,070333 - 0,076525)	$p(x y,k)$	0,120763	$p(x/y,k)$	0,166667
16	(0,076525 - 0,083404)	$p(x y,k)$	0,148305	$p(x/y,k)$	0,236364
17	(0,083404 - 0,091928)	$p(x y,k)$	0,156780	$p(x/y,k)$	0,279070
18	(0,091928 - 0,103028)	$p(x y,k)$	0,148305	$p(x/y,k)$	0,045455
19	(0,103028 - 0,119972)	$p(x y,k)$	0,222458	$p(x/y,k)$	0,163265
20	(0,119972 - 1,000000)	$p(x y,k)$	0,257858	$p(x/y,k)$	0,354167

Tabela 9-15 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,008109)	$p(x y,k)$	0,012685	$p(x/y,k)$	0,000000
2	(0,008109 - 0,011586)	$p(x y,k)$	0,016950	$p(x/y,k)$	0,037736
3	(0,011586 - 0,014541)	$p(x y,k)$	0,014831	$p(x/y,k)$	0,000000
4	(0,014541 - 0,017468)	$p(x y,k)$	0,019027	$p(x/y,k)$	0,057143
5	(0,017468 - 0,020293)	$p(x y,k)$	0,021187	$p(x/y,k)$	0,000000
6	(0,020293 - 0,023035)	$p(x y,k)$	0,029724	$p(x/y,k)$	0,037037
7	(0,023035 - 0,026077)	$p(x y,k)$	0,029661	$p(x/y,k)$	0,000000
8	(0,026077 - 0,028816)	$p(x y,k)$	0,048729	$p(x/y,k)$	0,137255
9	(0,028816 - 0,031337)	$p(x y,k)$	0,044398	$p(x/y,k)$	0,078947
10	(0,031337 - 0,034265)	$p(x y,k)$	0,063695	$p(x/y,k)$	0,088889
11	(0,034265 - 0,037388)	$p(x y,k)$	0,050848	$p(x/y,k)$	0,019608
12	(0,037388 - 0,040463)	$p(x y,k)$	0,040255	$p(x/y,k)$	0,000000
13	(0,040463 - 0,043415)	$p(x y,k)$	0,067797	$p(x/y,k)$	0,020833
14	(0,043415 - 0,046828)	$p(x y,k)$	0,076271	$p(x/y,k)$	0,080000
15	(0,046828 - 0,051191)	$p(x y,k)$	0,052966	$p(x/y,k)$	0,063830
16	(0,051191 - 0,055682)	$p(x y,k)$	0,091101	$p(x/y,k)$	0,062500
17	(0,055682 - 0,061202)	$p(x y,k)$	0,067797	$p(x/y,k)$	0,076923
18	(0,061202 - 0,068732)	$p(x y,k)$	0,116525	$p(x/y,k)$	0,051282
19	(0,068732 - 0,079801)	$p(x y,k)$	0,154661	$p(x/y,k)$	0,145833
20	(0,079801 - 1,000000)	$p(x y,k)$	0,182388	$p(x/y,k)$	0,180000

A Tabela 9-16, Tabela 9-17, Tabela 9-18, Tabela 9-19 e Tabela 9-20 apresentam a comparação entre os valores de $p(x/y,k)$ calculados analiticamente (por meio da regra de Bayes a partir das estimativas de $p(x/k)$, $p(y/k)$ e $p(y/x,k)$ obtidas nos experimentos de validação) com os valores de $p(x/y,k)$ estimados empiricamente (a partir dos experimentos de teste para $k = \{ 1, 2, 3, 4 \text{ e } 5 \}$, referentes as 4 primeiras posições do ranking) para o

APÊNDICE B

categorizador *ML-k NN* empregando a base EX100. Nas tabelas citadas acima, a coluna Intervalo mostra cada um dos 20 intervalos de valores de f observados nos experimentos de validação, a coluna Validação mostra os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de Bayes com os resultados dos experimentos de validação, e a coluna Teste mostra os valores de $p(x/y,k)$ estimados empiricamente a partir dos experimentos de teste.

Como pode ser observado na Tabela 9-16, Tabela 9-17, Tabela 9-18, Tabela 9-19 e Tabela 9-20, os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de *Bayes* são muito próximos aos valores de $p(x/y,k)$ estimados empiricamente, o que demonstra que, usando nossa metodologia, é possível prever no teste com o último *fold* (não visto pelo *ML-k NN* durante o treinamento) o quão certo está o *ML-k NN* quanto à primeira categoria no seu *ranking* de saída ser pertinente para um dado documento. É importante destacar que esta medida de certeza vai de 0% a 100% – uma medida facilmente compreensível para um operador do SCAE humano.

A Tabela 9-16, Tabela 9-17, Tabela 9-18, Tabela 9-19 e Tabela 9-20 mostram os resultados do uso de nossa metodologia para valores de k iguais a 1, 2, 3, 4 e 5 respectivamente. Como pode ser visto nestas tabelas, também para estes valores de k é possível prever no teste com o último *fold* o quão certo está o *ML-k NN* quanto à categoria na posição k no seu *ranking* de saída ser pertinente para um dado documento. Note que, quanto maior o k (quanto mais abaixo no *ranking* de saída do categorizador), menos provável que a categoria atribuída pelo categorizador seja pertinente ao documento (ver última linha das tabelas). Isso é esperado, já que, para a base de dados empregada no treinamento (EX100), é incomum existirem mais que dois códigos pertinentes a um dado documento.

APÊNDICE B

Tabela 9-16 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=1$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,213654)	$p(x y,k)$	0,217953	$p(x/y,k)$	0,310345
2	(0,213654 - 0,253865)	$p(x y,k)$	0,398711	$p(x/y,k)$	0,270270
3	(0,253865 - 0,283170)	$p(x y,k)$	0,450167	$p(x/y,k)$	0,457143
4	(0,283170 - 0,307869)	$p(x y,k)$	0,565923	$p(x/y,k)$	0,451613
5	(0,307869 - 0,328687)	$p(x y,k)$	0,504824	$p(x/y,k)$	0,560000
6	(0,328687 - 0,347477)	$p(x y,k)$	0,614152	$p(x/y,k)$	0,600000
7	(0,347477 - 0,366800)	$p(x y,k)$	0,607723	$p(x/y,k)$	0,666667
8	(0,366800 - 0,385357)	$p(x y,k)$	0,668809	$p(x/y,k)$	0,769231
9	(0,385357 - 0,405425)	$p(x y,k)$	0,665594	$p(x/y,k)$	0,536585
10	(0,405425 - 0,424138)	$p(x y,k)$	0,649523	$p(x/y,k)$	0,681818
11	(0,424138 - 0,443853)	$p(x y,k)$	0,755622	$p(x/y,k)$	0,769231
12	(0,443853 - 0,467713)	$p(x y,k)$	0,736337	$p(x/y,k)$	0,676471
13	(0,467713 - 0,492551)	$p(x y,k)$	0,752408	$p(x/y,k)$	0,692308
14	(0,492551 - 0,521014)	$p(x y,k)$	0,752408	$p(x/y,k)$	0,620690
15	(0,521014 - 0,551039)	$p(x y,k)$	0,797422	$p(x/y,k)$	0,880000
16	(0,551039 - 0,592087)	$p(x y,k)$	0,848878	$p(x/y,k)$	0,756757
17	(0,592087 - 0,638092)	$p(x y,k)$	0,868164	$p(x/y,k)$	0,694444
18	(0,638092 - 0,695906)	$p(x y,k)$	0,929263	$p(x/y,k)$	0,964286
19	(0,695906 - 0,780403)	$p(x y,k)$	0,964634	$p(x/y,k)$	0,976744
20	(0,780403 - 1,000000)	$p(x y,k)$	0,990323	$p(x/y,k)$	1,000000

Tabela 9-17 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,044119)	$p(x y,k)$	0,006407	$p(x/y,k)$	0,025641
2	(0,044119 - 0,069430)	$p(x y,k)$	0,025725	$p(x/y,k)$	0,000000
3	(0,069430 - 0,094407)	$p(x y,k)$	0,057877	$p(x/y,k)$	0,062500
4	(0,094407 - 0,116874)	$p(x y,k)$	0,138262	$p(x/y,k)$	0,147059
5	(0,116874 - 0,133240)	$p(x y,k)$	0,163987	$p(x/y,k)$	0,076923
6	(0,133240 - 0,149573)	$p(x y,k)$	0,225081	$p(x/y,k)$	0,242424
7	(0,149573 - 0,162703)	$p(x y,k)$	0,247589	$p(x/y,k)$	0,333333
8	(0,162703 - 0,175137)	$p(x y,k)$	0,244371	$p(x/y,k)$	0,303030
9	(0,175137 - 0,187067)	$p(x y,k)$	0,305466	$p(x/y,k)$	0,290323
10	(0,187067 - 0,200746)	$p(x y,k)$	0,311901	$p(x/y,k)$	0,350000
11	(0,200746 - 0,211643)	$p(x y,k)$	0,327973	$p(x/y,k)$	0,419355
12	(0,211643 - 0,223880)	$p(x y,k)$	0,421220	$p(x/y,k)$	0,384615
13	(0,223880 - 0,236515)	$p(x y,k)$	0,382633	$p(x/y,k)$	0,375000
14	(0,236515 - 0,248824)	$p(x y,k)$	0,463025	$p(x/y,k)$	0,531250
15	(0,248824 - 0,264757)	$p(x y,k)$	0,456590	$p(x/y,k)$	0,454545
16	(0,264757 - 0,282097)	$p(x y,k)$	0,524113	$p(x/y,k)$	0,342857
17	(0,282097 - 0,303480)	$p(x y,k)$	0,559482	$p(x/y,k)$	0,466667
18	(0,303480 - 0,328872)	$p(x y,k)$	0,646302	$p(x/y,k)$	0,617647
19	(0,328872 - 0,364351)	$p(x y,k)$	0,627012	$p(x/y,k)$	0,750000
20	(0,364351 - 1,000000)	$p(x y,k)$	0,741938	$p(x/y,k)$	0,870968

APÊNDICE B

Tabela 9-18 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,018310)	$p(x y,k)$	0,009616	$p(x/y,k)$	0,000000
2	(0,018310 - 0,027769)	$p(x y,k)$	0,016077	$p(x/y,k)$	0,029412
3	(0,027769 - 0,037083)	$p(x y,k)$	0,025724	$p(x/y,k)$	0,000000
4	(0,037083 - 0,044837)	$p(x y,k)$	0,041801	$p(x/y,k)$	0,000000
5	(0,044837 - 0,053478)	$p(x y,k)$	0,057877	$p(x/y,k)$	0,033333
6	(0,053478 - 0,060969)	$p(x y,k)$	0,045017	$p(x/y,k)$	0,071429
7	(0,060969 - 0,068917)	$p(x y,k)$	0,080384	$p(x/y,k)$	0,103448
8	(0,068917 - 0,076836)	$p(x y,k)$	0,090031	$p(x/y,k)$	0,038462
9	(0,076836 - 0,085796)	$p(x y,k)$	0,106108	$p(x/y,k)$	0,093750
10	(0,085796 - 0,094922)	$p(x y,k)$	0,109325	$p(x/y,k)$	0,129032
11	(0,094922 - 0,104509)	$p(x y,k)$	0,189709	$p(x/y,k)$	0,175000
12	(0,104509 - 0,112968)	$p(x y,k)$	0,183279	$p(x/y,k)$	0,142857
13	(0,112968 - 0,122218)	$p(x y,k)$	0,192926	$p(x/y,k)$	0,322581
14	(0,122218 - 0,131435)	$p(x y,k)$	0,189709	$p(x/y,k)$	0,214286
15	(0,131435 - 0,141726)	$p(x y,k)$	0,244373	$p(x/y,k)$	0,290323
16	(0,141726 - 0,153663)	$p(x y,k)$	0,247587	$p(x/y,k)$	0,225000
17	(0,153663 - 0,166652)	$p(x y,k)$	0,276527	$p(x/y,k)$	0,333333
18	(0,166652 - 0,182104)	$p(x y,k)$	0,385852	$p(x/y,k)$	0,333333
19	(0,182104 - 0,204839)	$p(x y,k)$	0,372989	$p(x/y,k)$	0,290323
20	(0,204839 - 1,000000)	$p(x y,k)$	0,483871	$p(x/y,k)$	0,550000

Tabela 9-19 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,010632)	$p(x y,k)$	0,000000	$p(x/y,k)$	0,000000
2	(0,010632 - 0,015101)	$p(x y,k)$	0,012862	$p(x/y,k)$	0,025641
3	(0,015101 - 0,020026)	$p(x y,k)$	0,009647	$p(x/y,k)$	0,024390
4	(0,020026 - 0,024620)	$p(x y,k)$	0,019292	$p(x/y,k)$	0,031250
5	(0,024620 - 0,028993)	$p(x y,k)$	0,009647	$p(x/y,k)$	0,029412
6	(0,028993 - 0,033145)	$p(x y,k)$	0,028939	$p(x/y,k)$	0,000000
7	(0,033145 - 0,037407)	$p(x y,k)$	0,028939	$p(x/y,k)$	0,142857
8	(0,037407 - 0,041924)	$p(x y,k)$	0,045017	$p(x/y,k)$	0,088235
9	(0,041924 - 0,046791)	$p(x y,k)$	0,061093	$p(x/y,k)$	0,100000
10	(0,046791 - 0,051331)	$p(x y,k)$	0,054661	$p(x/y,k)$	0,000000
11	(0,051331 - 0,056289)	$p(x y,k)$	0,073955	$p(x/y,k)$	0,080000
12	(0,056289 - 0,062003)	$p(x y,k)$	0,093247	$p(x/y,k)$	0,121212
13	(0,062003 - 0,067422)	$p(x y,k)$	0,109325	$p(x/y,k)$	0,078947
14	(0,067422 - 0,074505)	$p(x y,k)$	0,106109	$p(x/y,k)$	0,178571
15	(0,074505 - 0,082368)	$p(x y,k)$	0,112540	$p(x/y,k)$	0,111111
16	(0,082368 - 0,090437)	$p(x y,k)$	0,102894	$p(x/y,k)$	0,151515
17	(0,090437 - 0,099790)	$p(x y,k)$	0,160772	$p(x/y,k)$	0,166667
18	(0,099790 - 0,111837)	$p(x y,k)$	0,199358	$p(x/y,k)$	0,300000
19	(0,111837 - 0,128731)	$p(x y,k)$	0,218650	$p(x/y,k)$	0,193548
20	(0,128731 - 1,000000)	$p(x y,k)$	0,370970	$p(x/y,k)$	0,419355

APÊNDICE B

Tabela 9-20 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do *ranking* em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,006329)	$p(x y,k)$	0,000000	$p(x/y,k)$	0,000000
2	(0,006329 - 0,009125)	$p(x y,k)$	0,000000	$p(x/y,k)$	0,000000
3	(0,009125 - 0,011836)	$p(x y,k)$	0,006431	$p(x/y,k)$	0,000000
4	(0,011836 - 0,014649)	$p(x y,k)$	0,012862	$p(x/y,k)$	0,000000
5	(0,014649 - 0,017253)	$p(x y,k)$	0,019293	$p(x/y,k)$	0,027027
6	(0,017253 - 0,020112)	$p(x y,k)$	0,019293	$p(x/y,k)$	0,000000
7	(0,020112 - 0,022601)	$p(x y,k)$	0,032154	$p(x/y,k)$	0,000000
8	(0,022601 - 0,025437)	$p(x y,k)$	0,028939	$p(x/y,k)$	0,000000
9	(0,025437 - 0,028076)	$p(x y,k)$	0,041800	$p(x/y,k)$	0,050000
10	(0,028076 - 0,031041)	$p(x y,k)$	0,028939	$p(x/y,k)$	0,071429
11	(0,031041 - 0,034298)	$p(x y,k)$	0,035370	$p(x/y,k)$	0,096774
12	(0,034298 - 0,037931)	$p(x y,k)$	0,054662	$p(x/y,k)$	0,125000
13	(0,037931 - 0,041624)	$p(x y,k)$	0,045016	$p(x/y,k)$	0,095238
14	(0,041624 - 0,046093)	$p(x y,k)$	0,070739	$p(x/y,k)$	0,032258
15	(0,046093 - 0,050630)	$p(x y,k)$	0,061093	$p(x/y,k)$	0,090909
16	(0,050630 - 0,056356)	$p(x y,k)$	0,048231	$p(x/y,k)$	0,068966
17	(0,056356 - 0,062987)	$p(x y,k)$	0,077170	$p(x/y,k)$	0,075000
18	(0,062987 - 0,072475)	$p(x y,k)$	0,109324	$p(x/y,k)$	0,170732
19	(0,072475 - 0,086527)	$p(x y,k)$	0,128618	$p(x/y,k)$	0,259259
20	(0,086527 - 1,000000)	$p(x y,k)$	0,222582	$p(x/y,k)$	0,289474

A Tabela 9-21, Tabela 9-22, Tabela 9-23, Tabela 9-24 e Tabela 9-25 apresentam a comparação entre os valores de $p(x/y,k)$ calculados analiticamente (por meio da regra de Bayes a partir das estimativas de $p(x/k)$, $p(y/k)$ e $p(y/x,k)$ obtidas nos experimentos de validação) com os valores de $p(x/y,k)$ estimados empiricamente (a partir dos experimentos de teste para $k = \{ 1, 2, 3, 4 \text{ e } 5 \}$, referentes as 4 primeiras posições do *ranking*) para o categorizador *VG-RAM WNN-COR* empregando a base AT100. Nas tabelas citadas acima, a coluna Intervalo mostra cada um dos 20 intervalos de valores de f observados nos experimentos de validação, a coluna Validação mostra os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de Bayes com os resultados dos experimentos de validação, e a coluna Teste mostra os valores de $p(x/y,k)$ estimados empiricamente a partir dos experimentos de teste.

Como pode ser observado na . Tabela 9-21, Tabela 9-22, Tabela 9-23, Tabela 9-24 e Tabela 9-25, os valores de $p(x/y,k)$ calculados analiticamente por meio da regra de Bayes são muito próximos aos valores de $p(x/y,k)$ estimados empiricamente, o que demonstra que, usando nossa metodologia, é possível prever no teste com o último *fold* (não visto pelo *VG-RAM WNN-COR* durante o treinamento) o quão certo está o *VG-RAM WNN-COR* quanto à primeira categoria no seu *ranking* de saída ser pertinente para um dado documento. É importante destacar que esta medida de certeza vai de 0% a 100% – uma medida facilmente compreensível para um operador do SCAE humano.

APÊNDICE B

A Tabela 9-21, Tabela 9-22, Tabela 9-23, Tabela 9-24 e Tabela 9-25 mostram os resultados do uso de nossa metodologia para valores de k iguais a 1, 2, 3, 4 e 5 respectivamente. Como pode ser visto nestas tabelas, também para estes valores de k é possível prever no teste com o último *fold* o quão certo está o *VG-RAM WNN-COR* quanto à categoria na posição k no seu *ranking* de saída ser pertinente para um dado documento. Note que, quanto maior o k (quanto mais abaixo no *ranking* de saída do categorizador), menos provável que a categoria atribuída pelo categorizador seja pertinente ao documento (ver última linha das tabelas). Isso é esperado, já que, para a base de dados empregada no treinamento (AT100), é incomum existirem mais que dois códigos pertinentes a um dado documento.

Tabela 9-21 - Probabilidades $p(x|y,k)$ de validação versus $p(x|y,k)$ de teste para a posição $k=1$ do *ranking* em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x y,k)$	
1	(0,000000 - 0,043683)	$p(x y,k)$	0,162793	$p(x y,k)$	0,156863
2	(0,043683 - 0,054221)	$p(x y,k)$	0,266383	$p(x y,k)$	0,269231
3	(0,054221 - 0,063678)	$p(x y,k)$	0,348196	$p(x y,k)$	0,454545
4	(0,063678 - 0,072280)	$p(x y,k)$	0,434325	$p(x y,k)$	0,383333
5	(0,072280 - 0,080387)	$p(x y,k)$	0,463983	$p(x y,k)$	0,550000
6	(0,080387 - 0,088538)	$p(x y,k)$	0,533896	$p(x y,k)$	0,642857
7	(0,088538 - 0,096833)	$p(x y,k)$	0,574150	$p(x y,k)$	0,607843
8	(0,096833 - 0,105029)	$p(x y,k)$	0,584747	$p(x y,k)$	0,571429
9	(0,105029 - 0,113738)	$p(x y,k)$	0,677973	$p(x y,k)$	0,705882
10	(0,113738 - 0,121858)	$p(x y,k)$	0,673734	$p(x y,k)$	0,795918
11	(0,121858 - 0,130501)	$p(x y,k)$	0,760602	$p(x y,k)$	0,764706
12	(0,130501 - 0,140014)	$p(x y,k)$	0,730931	$p(x y,k)$	0,750000
13	(0,140014 - 0,151198)	$p(x y,k)$	0,716108	$p(x y,k)$	0,654545
14	(0,151198 - 0,164800)	$p(x y,k)$	0,750005	$p(x y,k)$	0,769231
15	(0,164800 - 0,181700)	$p(x y,k)$	0,855934	$p(x y,k)$	0,843137
16	(0,181700 - 0,204285)	$p(x y,k)$	0,851695	$p(x y,k)$	0,883721
17	(0,204285 - 0,233108)	$p(x y,k)$	0,877127	$p(x y,k)$	1,000000
18	(0,233108 - 0,279846)	$p(x y,k)$	0,898308	$p(x y,k)$	0,914894
19	(0,279846 - 0,370054)	$p(x y,k)$	0,911024	$p(x y,k)$	0,880000
20	(0,370054 - 1,000000)	$p(x y,k)$	0,920323	$p(x y,k)$	0,886364

APÊNDICE B

Tabela 9-22 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=2$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,021463)	$p(x y,k)$	0,016915	$p(x/y,k)$	0,000000
2	(0,021463 - 0,027431)	$p(x y,k)$	0,048730	$p(x/y,k)$	0,023810
3	(0,027431 - 0,031852)	$p(x y,k)$	0,080510	$p(x/y,k)$	0,088889
4	(0,031852 - 0,036090)	$p(x y,k)$	0,110170	$p(x/y,k)$	0,115385
5	(0,036090 - 0,039831)	$p(x y,k)$	0,114406	$p(x/y,k)$	0,062500
6	(0,039831 - 0,043366)	$p(x y,k)$	0,120763	$p(x/y,k)$	0,152174
7	(0,043366 - 0,046864)	$p(x y,k)$	0,152543	$p(x/y,k)$	0,220000
8	(0,046864 - 0,050741)	$p(x y,k)$	0,139829	$p(x/y,k)$	0,108696
9	(0,050741 - 0,055118)	$p(x y,k)$	0,188559	$p(x/y,k)$	0,275000
10	(0,055118 - 0,059809)	$p(x y,k)$	0,235169	$p(x/y,k)$	0,258621
11	(0,059809 - 0,064968)	$p(x y,k)$	0,237290	$p(x/y,k)$	0,320755
12	(0,064968 - 0,070270)	$p(x y,k)$	0,247883	$p(x/y,k)$	0,162162
13	(0,070270 - 0,076008)	$p(x y,k)$	0,315679	$p(x/y,k)$	0,357143
14	(0,076008 - 0,083098)	$p(x y,k)$	0,336866	$p(x/y,k)$	0,395349
15	(0,083098 - 0,091246)	$p(x y,k)$	0,368646	$p(x/y,k)$	0,470588
16	(0,091246 - 0,100592)	$p(x y,k)$	0,457629	$p(x/y,k)$	0,382979
17	(0,100592 - 0,113269)	$p(x y,k)$	0,510596	$p(x/y,k)$	0,560000
18	(0,113269 - 0,130818)	$p(x y,k)$	0,534884	$p(x/y,k)$	0,428571
19	(0,130818 - 0,161165)	$p(x y,k)$	0,596608	$p(x/y,k)$	0,673469
20	(0,161165 - 1,000000)	$p(x y,k)$	0,645696	$p(x/y,k)$	0,607843

Tabela 9-23 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=3$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,015482)	$p(x y,k)$	0,010571	$p(x/y,k)$	0,043478
2	(0,015482 - 0,019578)	$p(x y,k)$	0,021187	$p(x/y,k)$	0,000000
3	(0,019578 - 0,022814)	$p(x y,k)$	0,023207	$p(x/y,k)$	0,017857
4	(0,022814 - 0,025325)	$p(x y,k)$	0,033971	$p(x/y,k)$	0,000000
5	(0,025325 - 0,027816)	$p(x y,k)$	0,031647	$p(x/y,k)$	0,040000
6	(0,027816 - 0,029958)	$p(x y,k)$	0,044777	$p(x/y,k)$	0,038462
7	(0,029958 - 0,032214)	$p(x y,k)$	0,059322	$p(x/y,k)$	0,102041
8	(0,032214 - 0,034456)	$p(x y,k)$	0,069915	$p(x/y,k)$	0,045455
9	(0,034456 - 0,036983)	$p(x y,k)$	0,080509	$p(x/y,k)$	0,018519
10	(0,036983 - 0,039548)	$p(x y,k)$	0,073996	$p(x/y,k)$	0,044444
11	(0,039548 - 0,042098)	$p(x y,k)$	0,110404	$p(x/y,k)$	0,140000
12	(0,042098 - 0,045143)	$p(x y,k)$	0,110170	$p(x/y,k)$	0,159091
13	(0,045143 - 0,048649)	$p(x y,k)$	0,114408	$p(x/y,k)$	0,085106
14	(0,048649 - 0,052854)	$p(x y,k)$	0,127119	$p(x/y,k)$	0,187500
15	(0,052854 - 0,057227)	$p(x y,k)$	0,144069	$p(x/y,k)$	0,244444
16	(0,057227 - 0,062706)	$p(x y,k)$	0,180085	$p(x/y,k)$	0,200000
17	(0,062706 - 0,069953)	$p(x y,k)$	0,220340	$p(x/y,k)$	0,277778
18	(0,069953 - 0,080629)	$p(x y,k)$	0,302969	$p(x/y,k)$	0,294118
19	(0,080629 - 0,098341)	$p(x y,k)$	0,324154	$p(x/y,k)$	0,512821
20	(0,098341 - 1,000000)	$p(x y,k)$	0,488467	$p(x/y,k)$	0,527273

APÊNDICE B

Tabela 9-24 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=4$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,012561)	$p(x y,k)$	0,004229	$p(x/y,k)$	0,000000
2	(0,012561 - 0,015410)	$p(x y,k)$	0,006342	$p(x/y,k)$	0,021739
3	(0,015410 - 0,017877)	$p(x y,k)$	0,008493	$p(x/y,k)$	0,016393
4	(0,017877 - 0,019972)	$p(x y,k)$	0,027543	$p(x/y,k)$	0,017241
5	(0,019972 - 0,021753)	$p(x y,k)$	0,016949	$p(x/y,k)$	0,026316
6	(0,021753 - 0,023256)	$p(x y,k)$	0,033756	$p(x/y,k)$	0,057143
7	(0,023256 - 0,024883)	$p(x y,k)$	0,038217	$p(x/y,k)$	0,038462
8	(0,024883 - 0,026599)	$p(x y,k)$	0,040340	$p(x/y,k)$	0,020000
9	(0,026599 - 0,028345)	$p(x y,k)$	0,050847	$p(x/y,k)$	0,050847
10	(0,028345 - 0,030178)	$p(x y,k)$	0,046511	$p(x/y,k)$	0,052632
11	(0,030178 - 0,032051)	$p(x y,k)$	0,063695	$p(x/y,k)$	0,046512
12	(0,032051 - 0,034091)	$p(x y,k)$	0,044211	$p(x/y,k)$	0,068182
13	(0,034091 - 0,036354)	$p(x y,k)$	0,059701	$p(x/y,k)$	0,000000
14	(0,036354 - 0,038855)	$p(x y,k)$	0,076273	$p(x/y,k)$	0,065217
15	(0,038855 - 0,041879)	$p(x y,k)$	0,093221	$p(x/y,k)$	0,097561
16	(0,041879 - 0,045718)	$p(x y,k)$	0,086866	$p(x/y,k)$	0,069767
17	(0,045718 - 0,050535)	$p(x y,k)$	0,129238	$p(x/y,k)$	0,081967
18	(0,050535 - 0,057143)	$p(x y,k)$	0,156781	$p(x/y,k)$	0,090909
19	(0,057143 - 0,069693)	$p(x y,k)$	0,194918	$p(x/y,k)$	0,122449
20	(0,069693 - 1,000000)	$p(x y,k)$	0,314465	$p(x/y,k)$	0,302326

Tabela 9-25 - Probabilidades $p(x/y,k)$ de validação versus $p(x/y,k)$ de teste para a posição $k=5$ do ranking em cada um dos 20 intervalos observados de f .

Ordem Intervalo	Intervalo	Validação		Teste	
		$p(x y,k)$		$p(x/y,k)$	
1	(0,000000 - 0,010737)	$p(x y,k)$	0,008457	$p(x/y,k)$	0,000000
2	(0,010737 - 0,013037)	$p(x y,k)$	0,002118	$p(x/y,k)$	0,000000
3	(0,013037 - 0,014770)	$p(x y,k)$	0,012712	$p(x/y,k)$	0,000000
4	(0,014770 - 0,016522)	$p(x y,k)$	0,004228	$p(x/y,k)$	0,000000
5	(0,016522 - 0,017941)	$p(x y,k)$	0,008493	$p(x/y,k)$	0,023256
6	(0,017941 - 0,019231)	$p(x y,k)$	0,029662	$p(x/y,k)$	0,020000
7	(0,019231 - 0,020573)	$p(x y,k)$	0,025370	$p(x/y,k)$	0,018868
8	(0,020573 - 0,021877)	$p(x y,k)$	0,021187	$p(x/y,k)$	0,000000
9	(0,021877 - 0,023211)	$p(x y,k)$	0,014862	$p(x/y,k)$	0,000000
10	(0,023211 - 0,024648)	$p(x y,k)$	0,033898	$p(x/y,k)$	0,000000
11	(0,024648 - 0,025945)	$p(x y,k)$	0,036017	$p(x/y,k)$	0,000000
12	(0,025945 - 0,027491)	$p(x y,k)$	0,050848	$p(x/y,k)$	0,071429
13	(0,027491 - 0,029170)	$p(x y,k)$	0,042373	$p(x/y,k)$	0,025641
14	(0,029170 - 0,031072)	$p(x y,k)$	0,042373	$p(x/y,k)$	0,022727
15	(0,031072 - 0,033122)	$p(x y,k)$	0,044398	$p(x/y,k)$	0,023810
16	(0,033122 - 0,035670)	$p(x y,k)$	0,048832	$p(x/y,k)$	0,044444
17	(0,035670 - 0,038920)	$p(x y,k)$	0,065679	$p(x/y,k)$	0,043478
18	(0,038920 - 0,043607)	$p(x y,k)$	0,091102	$p(x/y,k)$	0,063830
19	(0,043607 - 0,051114)	$p(x y,k)$	0,144069	$p(x/y,k)$	0,061224
20	(0,051114 - 1,000000)	$p(x y,k)$	0,213835	$p(x/y,k)$	0,127660