

MARIZA MIOLA DOSCIATTI

**UM MÉTODO PARA A IDENTIFICAÇÃO DE
EMOÇÕES BÁSICAS EM TEXTOS EM
PORTUGUÊS DO BRASIL USANDO MÁQUINAS
DE VETORES DE SUPORTE EM SOLUÇÃO
MULTICLASSE**

CURITIBA

2015

MARIZA MIOLA DOSCIATTI

**UM MÉTODO PARA A IDENTIFICAÇÃO DE
EMOÇÕES BÁSICAS EM TEXTOS EM
PORTUGUÊS DO BRASIL USANDO MÁQUINAS
DE VETORES DE SUPORTE EM SOLUÇÃO
MULTICLASSE**

Tese de doutorado apresentado ao Programa de Pós-Graduação em Informática da Pontifícia Universidade Católica do Paraná, como requisito parcial para obtenção do título de Doutor em Informática.

Área de Concentração: *Ciência da Computação*

Orientador: Prof. Dr. Emerson Cabrera Paraiso

CURITIBA

2015

Dados da Catalogação na Publicação
Pontifícia Universidade Católica do Paraná
Sistema Integrado de Bibliotecas – SIBI/PUCPR
Biblioteca Central

D722m
2015

Dosciatti, Mariza Miola
Um método para a identificação de emoções básicas em textos em português do Brasil usando máquinas de vetores de suporte em solução multiclasse / Mariza Miola Dosciatti ; orientador, Emerson Cabrera Paraiso. – 2015.
223 f. : il. ; 30 cm

Tese (doutorado) – Pontifícia Universidade Católica do Paraná, Curitiba, 2015
Bibliografia: f. 168-186

1. Interação homem-máquina. 2. Emoções - Identificação. 3. Algoritmos. 4. Informática. I. Paraiso, Emerson Cabrera. II. Pontifícia Universidade Católica do Paraná. Programa de Pós-Graduação em Informática. III. Título.

CDD 20. ed. – 004



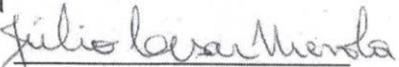
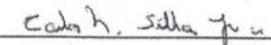
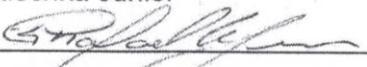
Pontifícia Universidade Católica do Paraná
Escola Politécnica
Programa de Pós-Graduação em Informática

**ATA DE DEFESA DE TESE DE DOUTORADO
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA**

ÁREA DE CONCENTRAÇÃO: CIÊNCIA DA COMPUTAÇÃO

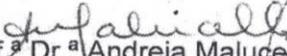
DEFESA DE TESE DE DOUTORADO Nº 036/2015

Aos 16 dias de Dezembro de 2015 realizou-se a sessão pública de Defesa da Tese de Doutorado intitulada **“Um Método para a Identificação de Emoções Básicas em Textos em Português do Brasil Usando Máquinas de Vetores de Suporte em Solução Multiclasse”** apresentada pela aluna **Mariza Miola Dosciatti** como requisito parcial para a obtenção do título de Doutor em Informática, perante uma Banca Examinadora composta pelos seguintes membros:

| | | |
|--|--|-----------------|
| Prof.Dr. Emerson Cabrera Paraiso PUCPR (Orientador) |  | <u>APROVADO</u> |
| | (assinatura) | (aprov/reprov.) |
| Prof. Dr. Júlio Cesar Nievola PUCPR |  | <u>APROVADO</u> |
| Prof. Dr. Fabrício Enembreck PUCPR |  | <u>APROVADO</u> |
| Prof. Dr. Carlos Nascimento Silla Junior UTFPR |  | <u>APROVADO</u> |
| Prof. Dr. Estevam Rafael Hruschka Junior UFSCAR |  | <u>Aprovado</u> |

Conforme as normas regimentais do PPGIa e da PUCPR, o trabalho apresentado foi considerado APROVADO

(aprovado/reprovado), segundo avaliação da maioria dos membros desta Banca Examinadora. Este resultado está condicionado ao cumprimento integral das solicitações da Banca Examinadora registradas no Livro de Defesas do programa.


Prof.ª Dr.ª Andreia Malucelli
Coordenadora do Programa de Pós-Graduação em Informática.



Dedico este trabalho à minha amada filha Lívia Dosciatti, que veio ao mundo no início deste trabalho de pesquisa, e ao meu querido esposo Eden Ricardo Dosciatti. Ambos foram a minha principal fonte de motivação para a conclusão deste trabalho.

“O poder nasce do querer. Sempre que o homem aplicar a veemência e perseverante energia de sua alma a um fim, vencerá os obstáculos e, se não atingir o alvo fará, pelo menos, coisas admiráveis.”

José de Alencar

Agradecimentos

Primeiramente agradeço a Deus, que me deu força para ir além dos meus limites e superar todos os obstáculos que surgiram durante a realização deste trabalho.

Agradeço aos meus familiares, que sofreram comigo nos momentos difíceis, meu esposo, minha filha, meus pais, meu irmão, minhas cunhadas e cunhados, meus tios e tias, minha avó e minhas amadas sobrinhas Júlia Dosciatti e Laura Dosciatti. Um agradecimento especial aos meus pais, Armerindo Miola e Loraide Miola, que sempre me apoiaram e me incentivaram nos estudos. Eles são os principais responsáveis por eu ter chegado até aqui. A eles o meu eterno agradecimento.

Ao meu orientador Emerson Cabrera Paraiso, pelos seus ensinamentos, pela sua paciência e principalmente por me motivar sempre. Agradeço imensamente por ele ter me orientado. É um exemplo de professor seguirei pelo resto da vida.

Aos meus colegas e amigos do PPGIa Alef Turatti, Aline Maria Malachini Miotto Amaral, André Luiz Brun, André Pinz Borges, Andreia Marini, Ayslan Trevizan Possebom, Carla Machado da Trindade, Daniel Sampaio, Denise Maria Veccino Sato, Edenilson José da Silva, Elias Cesar Araujo de Carvalho, Elieser Botelho Manhas Junior, Franciele Beal, Gregory Moro Puppi Wanderley, Irapurú Haruo Flórido, Jean-Paul Barddal, José Adilson Lopes da Silva, Leila Vriesmann, Luiz Henrique Franco Giovanini, Mauri Ferrandin, Osmar Betazzi Dordal, Patrícia Antonioli, Patricia Rucker de Bassi, Pedro Henrique Banali, Priscila Louise Santin, Ronan Assumpção Silva, Rodolfo Botto Garcia, Tânia Lúcia Monteiro, Viviane Dal Molin de Souza, Willian Augusto Dias dos Reis e tantos outros que cruzaram o meu caminho durante esta caminhada.

Aos professores do PPGIa, em especial aos professores Julio Cesar Nievola e Alessandro Lameiras Koerich (atualmente professor na Universidade de Quebec - Canadá), por esclarecerem as minhas dúvidas sempre que precisei.

Ao aluno de iniciação científica Lohann Paterno Coutinho Ferreira, pela sua importante colaboração neste trabalho de pesquisa.

Aos amigos e colegas de trabalho da UTFPR Pato Branco, em especial aos do DAINF, por permitir o meu afastamento das atividades profissionais para que eu pudesse me dedicar exclusivamente ao doutorado.

Às professoras de Linguística da UTFPR Pato Branco Denise Maria Bueno, Marcia Oberderfer Consoli e Joanita Hagedorn Vieira e os profissionais de Linguística da PUCPR Adir Jonatas dos Santos Junior e Emelle Ribeiro de Souza pela participação no processo de anotação dos textos.

À coordenadora do curso de Letras da PUCPR, professora Cristina Yukie Miyaki, pelo apoio à pesquisa e pelo suporte na parte de Linguística.

À Cheila Cristina Farias, secretária do PPGIa, pelos serviços prestados e pela amizade, aos funcionários do PPGIa Jhonatan Geremias e Anderson Bertling, pelo suporte técnico e aos recepcionistas do Bloco do PPGIa Sandoval Ribas Rupel, Sidnei Schuindt e Jurair Soares dos Santos, pelo pronto atendimento e principalmente pelo bom humor de sempre. À Marcia Assis também o meu sincero agradecimento.

Aos meus queridos amigos Omero Francisco Bertol e Vanessa Babinski, pelo carinho, pelo incentivo, por me ouvir, enfim, por tudo. Obrigada por vocês existirem!

Aos amigos Edenilson José da Silva, Carla Machado da Trindade, Andreia Marini, Franciele Beal, Irapuru Haruo Flórido e Viviane Dal Molin de Souza pelas sugestões, apoio, conversas e café.

À Silvana Padilha Rodrigues, por me auxiliar nos cuidados com a minha filha, enquanto eu me dedicava aos estudos.

E finalmente, agradeço a todas as pessoas as quais não citei aqui, mas que de alguma forma contribuíram para a realização deste trabalho.

Sumário

| | |
|--|-----------|
| Capítulo 1..... | 20 |
| Introdução..... | 20 |
| 1.1. Motivação..... | 21 |
| 1.2. Objetivos | 22 |
| 1.3. Contribuições Científicas e Tecnológicas | 23 |
| 1.4. Hipóteses de Trabalho..... | 23 |
| 1.5. Organização do Documento | 23 |
| Capítulo 2..... | 25 |
| Computação Afetiva..... | 25 |
| 2.1. As Emoções..... | 25 |
| 2.2. Computação Afetiva e Análise de Sentimentos | 33 |
| 2.2.1. Análise de Sentimentos em Textos | 36 |
| 2.2.2. Análise de Sentimentos em Fala | 39 |
| 2.2.3. Análise de Sentimentos em Imagens..... | 39 |
| 2.3. Considerações Finais..... | 40 |
| Capítulo 3..... | 42 |
| A Identificação de Emoções em Textos | 42 |
| 3.1. Principais Abordagens para a Identificação de Emoções em Textos | 42 |
| 3.2. Etapas de um Processo de Identificação de Emoções em Textos | 44 |
| 3.3. Corpus em Análise de Sentimentos..... | 45 |
| 3.4. Pré-processamento | 49 |
| 3.5. Seleção de Características e Representação Vetorial | 50 |
| 3.6. Algoritmos de Aprendizagem de Máquina para a Classificação de Emoções em Textos | 54 |
| 3.6.1. Máquina de Vetores de Suporte (<i>Support Vector Machine</i> - SVM) | 55 |
| 3.6.2. <i>Naive Bayes</i> (NB) | 60 |
| 3.6.3. <i>K-Nearest Neighbors</i> (KNN) | 61 |
| 3.6.4. Redes Neurais Artificiais (RNA) | 62 |
| 3.6.5. Máxima Entropia (ME) | 62 |
| 3.7. Avaliação de Algoritmos de Classificação..... | 63 |
| 3.8. Considerações Finais..... | 66 |
| Capítulo 4..... | 67 |
| Estado da Arte | 67 |

| | |
|--|------------|
| 4.1. Identificação de Emoções em Textos Escritos em Português Brasileiro | 68 |
| 4.2. Identificação de Emoções em Textos escritos em Outras Línguas | 73 |
| 4.3. Considerações Finais..... | 84 |
| Capítulo 5..... | 87 |
| Processo de Construção e Anotação de um Corpus | 87 |
| 5.1. Corpora em AS..... | 87 |
| 5.2. Construindo um Corpus de Notícias para a Análise de Sentimentos | 89 |
| 5.3. Avaliação da Concordância entre os Anotadores..... | 95 |
| 5.4. Considerações Finais..... | 97 |
| Capítulo 6..... | 99 |
| Um Método para a Identificação de Emoções em Textos | 99 |
| 6.1. Pressupostos do Método..... | 101 |
| 6.2. Visão Geral do Método | 101 |
| 6.3. Módulo de Treinamento | 102 |
| 6.3.1. Preparação dos Dados Textuais..... | 104 |
| 6.3.2. Seleção de Características | 104 |
| 6.3.3. Representação Vetorial dos Dados Textuais | 105 |
| 6.3.4. Treinamento dos Classificadores | 105 |
| 6.4. Módulo de Classificação | 110 |
| 6.5. Descrição de Diagramas do Método | 112 |
| 6.6. Considerações Finais..... | 120 |
| Capítulo 7..... | 121 |
| Procedimentos Metodológicos..... | 121 |
| 7.1. Implementação do Método..... | 121 |
| 7.2. Avaliação do Método | 133 |
| 7.3. Considerações Finais..... | 134 |
| Capítulo 8..... | 135 |
| Experimentos e Análise dos Resultados | 135 |
| 8.1. Experimentos com o Método usando um Corpus de Notícias | 135 |
| 8.1.1. Experimentos com o Método ao Classificar Textos com Seis Emoções Básicas e Neutro..... | 138 |
| 8.1.2. Experimentos com o Método ao Classificar Textos com as Seis Emoções Básicas | 143 |
| 8.1.3. Experimentos com o Método ao Classificar Textos com a Polaridade das Emoções e Neutro | 147 |
| 8.1.4. Experimentos com o Método ao Classificar a Polaridade das Emoções..... | 151 |
| 8.2. Experimento com o Método ao Usar um Corpus em Inglês | 153 |
| 8.3. Análise dos Resultados..... | 160 |

| | |
|---|------------|
| 8.4. Considerações Finais..... | 162 |
| Capítulo 9..... | 163 |
| Conclusão e Trabalhos Futuros | 163 |
| Referências..... | 167 |
| Apêndices | 186 |
| APÊNDICE 1 - Orientações aos Rotuladores | 186 |
| APÊNDICE 2 - Lista de <i>stopwords</i> da língua Portuguesa | 194 |
| APÊNDICE 3 - Lista de <i>stopwords</i> da língua Inglesa | 194 |
| APÊNDICE 4 - Pseudocódigo de Busca Automática de Limiar de Rejeição CHOW..... | 195 |
| APÊNDICE 5 - Outros Experimentos Realizados com o Método de Identificação de Emoções em Textos usando o Corpus de Notícias | 197 |
| Anexos | 219 |
| ANEXO 1 - Parecer consubstanciado do Comitê de Ética em Pesquisa da PUCPR | 219 |
| ANEXO 2 - Termo de Consentimento Livre e Esclarecido | 222 |

Lista de Figuras

| | |
|---|-----|
| Figura 2.1: Expressão facial das seis emoções básicas de Ekman. (a) <i>Raiva</i> ; (b) <i>Medo</i> ; (c) <i>Repugnância</i> ; (d) <i>Surpresa</i> ; (e) <i>Alegria</i> ; (f) <i>Tristeza</i> . Fonte: (EKMAN; FRIESEN, 1976)..... | 27 |
| Figura 2.2: Modelo circunplexo de afeto. Fonte: Extraído de (RUSSELL, 1980)..... | 29 |
| Figura 2.3: A estrutura bidimensional do afeto. Fonte: Extraído de (WATSON et al., 1999)..... | 30 |
| Figura 2.4: Modelo de emoções de Plutchik. Fonte: Extraído de (PLUTCHIK, 1980)..... | 31 |
| Figura 3.1: Abordagens para a AS em textos. Fonte: Adaptada de (MEDHAT; HASSAN; KORASHY, 2014)..... | 43 |
| Figura 3.2: Um processo de classificação de textos. Fonte: Adaptada de (SONG et al., 2014). | 44 |
| Figura 3.3: Identificação da margem e dos vetores de suporte. Fonte: Adaptada de (MANNING; RAGHAVAN; SCHÜTZE, 2008)..... | 56 |
| Figura 3.4: a) Dados não linearmente separáveis; b) Dados em uma dimensão linearmente separáveis. Fonte: Adaptada de (MÜLLER et al., 2001)..... | 56 |
| Figura 3.5: Superfície de decisão para quatro classificadores SVM com diferentes <i>kernels</i> . Fonte: Disponível em http://scikit-learn.org/stable | 57 |
| Figura 5.1: Interface do software utilizado para extrair notícias online..... | 91 |
| Figura 5.2: Interface do software de anotação de textos | 94 |
| Figura 6.1: Visão geral do método de identificação de emoções em textos..... | 102 |
| Figura 6.2: Módulo de treinamento do método..... | 103 |
| Figura 6.3: Módulo de classificação do método..... | 111 |
| Figura 6.4: Diagrama de classes do método de identificação de emoções em textos | 113 |
| Figura 6.5: Diagrama de sequência da etapa de treinamento do método de identificação de emoções em textos..... | 119 |
| Figura 7.1: Interface da ferramenta de AS | 122 |
| Figura 7.2: Exemplo de configuração de pré-processamento para os textos submetidos a um classificador multiclasse..... | 125 |
| Figura 7.3: Aba para configurar um classificador..... | 126 |
| Figura 7.4: Configurando um classificador..... | 127 |
| Figura 7.5: Configuração dos parâmetros de um classificador LibSVM | 127 |
| Figura 7.6: a) Configuração do classificador SVM_MULTICLASSE (primeira camada) e b) Configuração do classificador SVM_CRC (segunda camada)..... | 128 |
| Figura 7.7: Configuração de parâmetros de um CRCA | 129 |
| Figura 7.8: Opções do campo Modo de treinamento dos CRCs | 131 |

Figura 7.9: Outras opções de saída de dados disponíveis na ferramenta132

Lista de Tabelas

| | |
|---|----|
| Tabela 3.1: Frequência das características nas classes. Fonte: Extraído do corpus de notícias detalhado no Capítulo 5 | 48 |
| Tabela 3.2: Kernels SVM. Fonte: Adaptada de (HSU; CHANG; LIN, 2010) | 58 |
| Tabela 3.3: Exemplo de abordagem multiclasse utilizando a estratégia “Um-Contra-Todos”. Fonte: Adaptada de (LORENA, 2006). | 59 |
| Tabela 3.4: Exemplo de abordagem multiclasse utilizando a estratégia “Um-Contra-Um”. Fonte: Adaptada de (LORENA, 2006). | 59 |
| Tabela 3.5: Matriz de confusão para um problema binário. Fonte: (KOHAVI; PROVOST, 1998). | 64 |
| Tabela 3.6: Matriz de confusão para um problema multiclasse. | 65 |
| Tabela 4.1: Resultados obtidos com o LSA. Fonte: (MARTINAZZO, 2010) | 68 |
| Tabela 4.2: Acurácia dos modelos testados. Fonte: (NASCIMENTO et al., 2012). | 70 |
| Tabela 4.3: Desempenho das três abordagens. Fonte: (LIMA; DE CASTRO, 2012). | 71 |
| Tabela 4.4: Acurácia das duas abordagens ao avaliar comentários de <i>Twitter</i> e <i>Facebook</i> de três empresas. Fonte: (EVANGELISTA; PADILHA, 2014) | 72 |
| Tabela 4.5: Desempenho dos classificadores SVM e <i>Naive Bayes (NB)</i> . Fonte: (ALVES et al., 2014) | 73 |
| Tabela 4.6: Acurácia dos classificadores em relação a cada conjunto de características. Fonte: (PANG; LEE; VAITHYANATHAN, 2002) | 76 |
| Tabela 4.7: Acurácia dos classificadores em relação a cada conjunto de características. Fonte: (AMAN; SZPAKOWICZ, 2007) | 77 |
| Tabela 4.8: Desempenho médio das cinco abordagens ao avaliar os textos jornalísticos. Fonte: Adaptado de (STRAPPARAVA; MIHALCEA, 2008). | 78 |
| Tabela 4.9: Dois níveis de classificação no conjunto de dados de (AMAN; SZPAKOWICZ, 2007). Fonte: Adaptado de (GHAZI; INKPEN; SZPAKOWICZ, 2010) | 79 |
| Tabela 4.10: Três níveis de classificação no conjunto de dados de (AMAN; SZPAKOWICZ, 2007). Fonte: Adaptado de (GHAZI; INKPEN; SZPAKOWICZ, 2010) | 80 |
| Tabela 4.11: Dois níveis de classificação no conjunto de dados de (ALM; ROTH; SPROAT, 2005). Fonte: Adaptado de (GHAZI; INKPEN; SZPAKOWICZ, 2010) | 80 |
| Tabela 4.12: Resultados obtidos por avaliação do conjunto de teste. Fonte: Adaptado de (MOHAMMAD, 2012a) | 81 |
| Tabela 4.13: Resultados obtidos com Validação Cruzada com dez partes. Fonte: Adaptado de (MOHAMMAD, 2012a) | 82 |
| Tabela 4.14: Resultados obtidos com o corpus de conversas online | 82 |

| | |
|--|-----|
| Tabela 4.15: Melhor acurácia obtida em cada corpus. Fonte: Adaptada de (TURKMENOGLU; TANTUG, 2014) | 83 |
| Tabela 4.16: Principais trabalhos de AS desenvolvidos para o Português Brasileiro | 85 |
| Tabela 4.17: Principais trabalhos de AS desenvolvidos para outros idiomas | 85 |
| Tabela 5.1: Exemplos de anotação de textos..... | 93 |
| Tabela 5.2:Matriz de confusão da concordância entre anotadores para 2.000 textos | 95 |
| Tabela 5.3: Valores Kappa por emoção | 96 |
| Tabela 5.4: Textos anotados duas vezes pelo mesmo anotador | 97 |
| Tabela 5.5: Valores Kappa por emoção | 97 |
| Tabela 8.1: Configurações de pré-processamento cadastradas na ferramenta | 136 |
| Tabela 8.2: Informações dos CRCs apresentadas nos experimentos | 137 |
| Tabela 8.3: Desempenho do classificador SVM multiclasse ao usar pré-processamento com filtros . | 139 |
| Tabela 8.4: Desempenho do CRCA que rejeita todas as instâncias na primeira camada..... | 140 |
| Tabela 8.5: Desempenho dos CRCs ao classificar as instâncias rejeitadas..... | 140 |
| Tabela 8.6: CRCs que tiveram melhora em função da configuração do pré-processamento..... | 141 |
| Tabela 8.7: Desempenho do CRCA após modificação de pré-processamento dos CRCs | 141 |
| Tabela 8.8: Desempenho dos CRCs que obtiveram melhora ao usar outros algoritmos de classificação | 142 |
| Tabela 8.9: Desempenho final do CRCA..... | 142 |
| Tabela 8.10: Desempenho do classificador SVM multiclasse | 144 |
| Tabela 8.11: Desempenho do CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada | 145 |
| Tabela 8.12: Desempenho dos CRCs ao classificar as instâncias rejeitadas..... | 145 |
| Tabela 8.13: CRCs que tiveram melhora em função da configuração do pré-processamento..... | 145 |
| Tabela 8.14: CRCA com CRCs modificados em relação ao pré-processamento..... | 146 |
| Tabela 8.15: Desempenho dos CRCs que obtiveram melhora com outros algoritmos de classificação | 146 |
| Tabela 8.16: Desempenho final do CRCA..... | 147 |
| Tabela 8.17: Desempenho do classificador SVM multiclasse | 149 |
| Tabela 8.18: Desempenho do CRCA que rejeita todas as instâncias na primeira camada..... | 149 |
| Tabela 8.19: Desempenho dos CRCs ao classificar todas as instâncias rejeitadas | 149 |
| Tabela 8.20: Desempenho dos CRCs que obtiveram melhora ao usar outros algoritmos de classificação | 150 |
| Tabela 8.21: Desempenho final do CRCA..... | 150 |
| Tabela 8.22: Desempenho do classificador SVM ao ser avaliado com Validação Cruzada | 151 |

| | |
|---|-----|
| Tabela 8.23: Desempenho do classificador IBK ao ser avaliado com Validação Cruzada..... | 152 |
| Tabela 8.24: Desempenho do classificador <i>Naive Bayes</i> ao ser avaliado com Validação Cruzada..... | 152 |
| Tabela 8.25: Desempenho do classificador <i>J48</i> ao ser avaliado com Validação Cruzada | 152 |
| Tabela 8.26: Diferença estatística do SVM com os classificadores IBK, <i>Naive Bayes</i> e <i>J48</i> | 153 |
| Tabela 8.27: Desempenho do classificador SVM multiclasse avaliado com o conjunto de teste | 156 |
| Tabela 8.28: Desempenho do CRCA ao avaliar o conjunto de teste..... | 156 |
| Tabela 8.29: Desempenho dos CRCs | 157 |
| Tabela 8.30: CRCs que apresentaram melhorias em função da configuração do pré-processamento . | 157 |
| Tabela 8.31: Desempenho do CRCA após modificação de configuração de pré-processamento dos CRCs | 158 |
| Tabela 8.32: Desempenho final do CRCA..... | 158 |
| Tabela 8.33: Desempenho do classificador SVM multiclasse ao ser avaliado com o corpus de contos infantis | 160 |

Lista de Gráficos

| | |
|--|-----|
| Gráfico 3.1: Exemplo de desbalanceamento das classes em um corpus de notícias. Fonte: Extraído do corpus de notícias detalhado no Capítulo 5 | 47 |
| Gráfico 8.1: Distribuição dos textos do corpus de notícias | 135 |
| Gráfico 8.2: Distribuição dos textos no conjunto de treinamento | 138 |
| Gráfico 8.3: Distribuição dos textos no conjunto de teste | 138 |
| Gráfico 8.4: Distribuição dos textos no conjunto de treinamento | 143 |
| Gráfico 8.5: Distribuição dos textos no conjunto de teste | 143 |
| Gráfico 8.6: Distribuição dos textos no conjunto de treinamento | 148 |
| Gráfico 8.7: Distribuição dos textos no conjunto de teste | 148 |
| Gráfico 8.8: Distribuição dos textos no conjunto de treinamento | 151 |
| Gráfico 8.9: Distribuição dos textos do corpus de contos infantis | 154 |
| Gráfico 8.10: Distribuição dos textos no conjunto de treinamento | 155 |
| Gráfico 8.11: Distribuição dos textos no conjunto de teste | 155 |

Lista de Abreviaturas e Siglas

| | |
|------|---|
| AG | Algoritmo Genético |
| AM | Aprendizagem de Máquina |
| AS | Análise de Sentimentos |
| BPMN | <i>Business Process Modeling Notation</i> |
| CA | Correta Aceitação |
| CAAE | Certificado de Apresentação para Apreciação Ética |
| CR | Correta Rejeição |
| CRC | Classificador de Resolução de Confusão |
| CRCA | Classificador de Resolução de Confusão Agregado |
| EM | Emocional |
| ER | Estratégia de Rejeição |
| EWGA | <i>Entropy Weighted Genetic Algorithm</i> |
| FA | Falsa Aceitação |
| FAR | <i>False Acceptance Rate</i> |
| FF | <i>Feature Frequency</i> |
| FP | <i>Feature Presence</i> |
| FR | Falsa Rejeição |
| FRR | <i>False Rejection Rate</i> |
| GI | Ganho de Informação |
| GIn | <i>General Inquirer</i> |
| IHC | Interação Humano-Computador |
| IM | Informação Mútua |
| KNN | <i>K-Nearest Neighbors</i> |
| NB | <i>Naive Bayes</i> |
| NE | Não Emocional |
| NILP | Normalizador de Itens Lexicais em Português |
| PLN | Processamento de Linguagem Natural |
| RBF | <i>Radial Basis Function</i> |

| | |
|----------|--|
| ROC | <i>Receiver Operating Characteristic</i> |
| SVM | <i>Support Vector Machine</i> |
| TF-IDF | <i>Term Frequency - Inverse Document Frequency</i> |
| WNA | <i>WordNetAffect</i> |
| χ^2 | <i>CHI Square</i> |

Resumo

O estudo da interação entre humanos e computadores (Interação Humano-Computador) é uma área de pesquisa multidisciplinar, que tem registrado crescente atenção desde meados da década de 1980. Afirma-se que, para alcançar verdadeira e eficazmente essa interação, existe a necessidade de que o computador seja capaz de interagir com o usuário de forma natural, semelhante à maneira como ocorre na interação humano-humano. As emoções fazem parte da vida do ser humano e podem ser expressas e percebidas por meio de gestos e expressões, da fala e por meio da escrita. Identificar computacionalmente emoções em textos pode ser útil em diversas aplicações como, por exemplo, na síntese emocional (*text-to-speech*), no uso de avatares, na análise de opiniões de produtos e serviços, na detecção de *cyberbullyng* e de comportamentos depressivos em usuários de redes sociais. Existe uma área de pesquisa que busca inserir o tratamento das emoções no ambiente computacional: a Computação Afetiva. Entre as pesquisas realizadas em Computação Afetiva encontra-se a identificação automática de emoções em informação textual, conhecida como Análise de Sentimentos. As pesquisas em Análise de Sentimentos se iniciaram, e têm obtido um vasto crescimento, em decorrência da grande quantidade de informações que são disponibilizadas diariamente na internet. A maioria das pesquisas desenvolvidas em Análise de Sentimentos são feitas para textos da língua Inglesa. No Brasil, as pesquisas de Análise de Sentimentos ainda estão se estabelecendo. Com base nesse contexto, esta tese apresenta um método de identificação de emoções em textos, que permite identificar as emoções básicas em textos, além de identificar também textos neutros (sem emoção). Este método foi construído especialmente para textos escritos em Português Brasileiro. O método utiliza exclusivamente uma abordagem de Aprendizagem de Máquina supervisionada para classificar os textos e, dessa forma, é completamente independente de recursos léxicos de emoções como dicionários, ontologias e thesaurus. O método opera em camadas, sendo que na primeira camada usa um classificador SVM multiclasse e o conceito de rejeição para rejeitar os textos mais complexos de serem classificados. Os textos rejeitados são encaminhados para serem classificados pelos classificadores binários da segunda camada do método. O método foi avaliado por meio de um corpus de notícias, anotado especialmente para este propósito, visto a inexistência de corpora de emoções (anotados com categorias) para o Português Brasileiro. Ao ser avaliado com o corpus de notícias, o método obteve uma taxa de acerto de 65,5% ao identificar as seis emoções básicas, além de *neutro*, em textos. Ainda com o mesmo corpus, obteve 93% na taxa de acerto ao identificar a polaridade das emoções nos textos.

Palavras-chave: Análise de Sentimentos, SVM (*Support Vector Machine*), Classificação de Textos, Anotação de Corpus.

Abstract

The study of interaction between humans and computers (Human Computer Interaction) is an area of multidisciplinary research, which has recorded increasing attention since the mid 1980s. It is known that to achieve real and effective interaction, there is a need for the computer to interact with the user in a natural way, similar to the way in human-human interaction. Emotions are part of human life and can be expressed and perceived by gestures and expressions, speech and by means of writing. Identifying computational emotions in texts can be useful in several applications such as, for example, in emotional synthesis (text-to-speech), the use of avatars, in analyzing opinions of products and services, cyberbullying detection and depressive behavior in social network users. There is an area of research that seeks to insert the processing of emotions in the computing environment: the Affective Computing. Among the research in Affective Computing is the automatic identification of emotion in textual information, known as Sentiment Analysis. Most research done in Sentiment Analysis is made for English language texts. For Portuguese, Sentiment Analysis research is still being established. In this context, this thesis presents a method of identifying emotions in texts, which allows the identification of basic emotions in texts, and also identifies neutral texts (without emotion). This method was built for texts written in Brazilian Portuguese. The method uses a supervised machine learning approach to classify texts. Thus, it is completely independent of lexical resources of emotions as dictionaries, thesaurus and ontologies. The method works in layers, with the first layer using a multiclass SVM classifier and the concept of rejection to reject the most complex texts to be classified. Rejected texts are submitted for classification by binary classifiers of the second layer of the method. The method was evaluated using a news corpus. The method achieved a 65.5% accuracy rate in identifying the six basic emotions, as well as neutral, in texts. Using the same corpus, it obtained a 93% accuracy rate when identifying the polarity of emotions in texts.

Keywords: Sentiment analysis, SVM (Support Vector Machine), Text Classification, Corpus annotation.

Capítulo 1

Introdução

O estudo da interação entre humanos e computadores (Interação Humano-Computador) é uma área de pesquisa multidisciplinar, que tem registrado crescente atenção desde a década de 1980 (BOOTH, 1995), (MYERS, 1998). Entre os motivos de maior interesse estão a evolução tecnológica e a popularização dos computadores, que por muito tempo eram encontrados somente nos meios acadêmicos, militares e governamentais. Afirma-se que, para alcançar verdadeira e eficazmente essa interação, existe a necessidade de que o computador seja capaz de interagir com o usuário de forma natural, semelhante à maneira como ocorre na interação humano-humano (SEBE; LEW; HUANG, 2004).

As emoções fazem parte da vida do ser humano e podem ser expressas e percebidas por meio de gestos e expressões, da fala e por meio da escrita. Identificar computacionalmente emoções em textos pode ser útil em diversas aplicações como, por exemplo, na síntese emocional (*text-to-speech*), no uso de avatares, na análise de opiniões de produtos e serviços, na detecção de *cyberbullyng* e de comportamentos depressivos em usuários de redes sociais.

Existe uma área de pesquisa que busca inserir o tratamento das emoções no ambiente computacional: a Computação Afetiva (PICARD, 1995). Este campo de pesquisa busca fazer com que a emoção existente na comunicação entre pessoas, também esteja presente na relação entre homem e computador. Para a Computação Afetiva, o computador pode ser capaz de interagir com humanos identificando e simulando afeto por exemplo. Entre as pesquisas realizadas em Computação Afetiva encontra-se a identificação automática de emoções em informação textual, conhecida como Análise de Sentimentos (AS).

A AS é o campo de estudo que analisa opiniões, sentimentos, avaliações, atitudes e emoções das pessoas expressos em diferentes mídias, dentre elas os textos (LIU, 2015). Nesta

área, que ganhou impulso com a difusão da web, pesquisas vêm sendo desenvolvidas e grande parte delas visam criar métodos computacionais que sejam capazes de identificar fatores afetivos em textos. A maioria das pesquisas disponíveis atualmente são desenvolvidas para a língua Inglesa, focando principalmente a identificação da polaridade das emoções nos textos, ou seja, buscando identificar se os textos são positivos ou negativos. Dessa forma, métodos que sejam capazes de identificar emoções em textos escritos em Português do Brasil e que classifiquem emoções em categorias (*alegria, tristeza, raiva, etc.*) são uma contribuição relevante para a área.

1.1. Motivação

As emoções se encontram presentes em várias ocasiões e manifestações na vida do ser humano, como por exemplo, na tomada de decisão e nas interações sociais. As contribuições das pesquisas nessa área são significantes tanto teóricas quanto práticas e podem proporcionar avanços na interação homem-máquina e compreender melhor a influência que a tecnologia exerce no próprio desenvolvimento humano (PICARD, 1995), permitindo ao computador adaptar-se às pessoas e não o contrário.

O estudo da identificação das emoções em textos insere-se em um contexto multidisciplinar, saindo da Psicologia, passando pela Mineração de Textos e pelo Reconhecimento de Padrões e chegando até a Interação Humano-Computador. Trata-se de uma área de pesquisa que ganhou impulso recente com pesquisadores buscando a avaliação automática de opiniões deixadas por pessoas em sites de comércio eletrônico, área de pesquisa conhecida como *Opinion Mining*. As pesquisas realizadas atualmente são desenvolvidas para diversas línguas e culturas, dentre elas o Português do Brasil. A maior parte das pesquisas, entretanto, ainda são feitas para a língua Inglesa (STRAPPARAVA; MIHALCEA, 2008), (MOHAMMAD, 2012b) e (GHAZI; INKPEN; SZPAKOWICZ, 2014).

Neste trabalho é apresentado um método para a identificação automática das emoções presentes em textos escritos em Português do Brasil. As emoções a serem identificadas nos textos se referem às seis emoções básicas propostas por (EKMAN, 1992) sendo elas *alegria, tristeza, raiva, medo, repugnância e surpresa*. Os textos neutros (sem emoção) também são identificados pelo método. Para a avaliação do método proposto foi construído um corpus de textos de notícias jornalísticas e uma ferramenta que permite a realização de experimentos com diferentes configurações.

O método possui algumas características que o difere dos demais trabalhos já desenvolvidos na área de AS: 1) foi criado enfatizando especialmente a identificação de emoções em textos escritos em língua Portuguesa do Brasil, idioma carente em ferramentas de AS; 2) identifica as emoções presentes nos textos sem o uso de qualquer recurso léxico como dicionários, ontologias, etc., o que torna o método independente da construção ou manutenção desses recursos; 3) identifica categorias de emoções nos textos, neste caso as seis emoções básicas de (EKMAN, 1992) e também textos neutros (sem emoção), diferentemente da maioria dos trabalhos existentes na literatura, principalmente os voltados para o idioma Português como em (LIMA; DE CASTRO, 2012), (NASCIMENTO et al., 2012), (ALVES et al., 2014), (EVANGELISTA; PADILHA, 2014), que identificam a polaridade das emoções.

A tarefa de identificar emoções em textos por meio de um método computacional apresenta algumas dificuldades, tais como: a inexistência de um corpus em Português, anotado com as emoções básicas e disponível publicamente para ser usado nos testes e na avaliação do método; o fato dos dados textuais de emoções serem altamente desbalanceados e com sobreposição de classes; e também o fato de não se utilizar recursos léxicos para classificar os textos ou para extrair as características dos textos pode dificultar a obtenção de bons resultados na classificação, visto que na literatura, grande parte dos métodos que utilizam uma abordagem de Aprendizagem de Máquina combinada com uma abordagem léxica, costumam apresentar bons resultados.

Este trabalho de pesquisa também avalia a efetividade desse método, realizando experimentos por meio de uma ferramenta desenvolvida especialmente com este propósito, na qual as hipóteses de trabalho puderam ser testadas de forma controlada.

1.2. Objetivos

O objetivo geral deste trabalho de pesquisa é desenvolver um método que identifique automaticamente as seis emoções básicas de (EKMAN, 1992) e a categoria *neutro* em textos escritos em Português do Brasil usando o conceito de rejeição para criar um modelo de classificação em camadas que permita o uso de classificadores mais especializados para resolver as classes mais conflitantes.

O método construído opera em camadas. Na primeira camada, é composto de um classificador SVM multiclasse e utiliza a teoria da Rejeição. Na segunda camada, o método é composto de classificadores binários que são usados para classificar os textos rejeitados da

primeira camada. Os classificadores da segunda camada são treinados individualmente e novas características são extraídas para tornar esses classificadores mais específicos.

Os objetivos específicos desta pesquisa compreendem:

- Construir um corpus de textos para ser usado no treinamento e avaliação do método e desenvolver e aplicar uma metodologia para o processo de anotação humana dos textos;
- Desenvolver uma ferramenta que permita a realização de testes e avaliação do método proposto.

1.3. Contribuições Científicas e Tecnológicas

As contribuições desta pesquisa se enquadram nos eixos científicos e tecnológicos. No eixo científico, a principal contribuição deste trabalho se refere à disponibilização de um método capaz de identificar emoções em textos escritos em Português do Brasil, sem fazer uso de recursos léxicos. No eixo tecnológico, a contribuição deste trabalho se dá por meio da disponibilização de um corpus construído e anotado manualmente por uma equipe de anotadores e dos algoritmos desenvolvidos para o método. Também é disponibilizada uma ferramenta de AS que permite diversas combinações de configurações de pré-processamento e de classificação.

1.4. Hipóteses de Trabalho

Neste trabalho são identificadas duas hipóteses a serem validadas. A hipótese principal afirma que é possível identificar as seis emoções básicas de (EKMAN, 1992) e a classe *neutro* em textos escritos em Português do Brasil usando o conceito de rejeição para criar um modelo de classificação em camadas, que permite o uso de classificadores especializados para tratar as classes mais conflitantes. A hipótese secundária pretende confirmar que é possível a construção de um método de identificação de emoções que não utilize recursos léxicos e que obtenha resultados similares aos métodos que utilizam tais recursos.

1.5. Organização do Documento

O Capítulo 2 apresenta a fundamentação teórica relacionada com a Computação Afetiva. Este capítulo inicia conceituando emoções e apresentando os principais modelos de emoções que surgiram a partir dos diversos estudos realizados por pesquisadores de diferentes

áreas. Na sequência apresenta a definição de Computação Afetiva e de AS e mostra os conceitos relacionados à AS.

O Capítulo 3 apresenta as principais abordagens e conceitos relacionados à construção de um método de identificação de emoções em textos usando uma abordagem de Aprendizagem de Máquina supervisionada.

O Capítulo 4 apresenta o estado da arte. Este capítulo é dividido em duas sessões principais, sendo que a primeira apresenta os trabalhos de AS desenvolvidos especialmente para o Português Brasileiro. A segunda seção apresenta os principais trabalhos de AS que foram desenvolvidos para outras línguas e que estão relacionados, mesmo que indiretamente, com o método proposto.

O Capítulo 5 relata o processo de construção e anotação de um corpus de notícias jornalísticas extraídas da web.

O Capítulo 6 apresenta efetivamente o método de identificação de emoções em textos que está sendo proposto nesta pesquisa.

O Capítulo 7 cita as ferramentas e as tecnologias usadas na implementação do método e apresenta as funcionalidades da ferramenta de AS, que foi construída para testar e avaliar o método.

O Capítulo 8 apresenta os principais experimentos realizados com o método de identificação de emoções e faz uma análise dos resultados obtidos.

O Capítulo 9 apresenta as conclusões finais deste trabalho e também sugestões de trabalhos futuros.

Capítulo 2

Computação Afetiva

Neste capítulo, parte-se do estudo das emoções do ponto de vista das ciências cognitivas como a Psicologia, Filosofia e outras, chegando até os conceitos elementares da AS. O conceito de emoção ainda é complexo e tem sido discutido do ponto de vista de diferentes áreas. Essas discussões levaram à teorias que possibilitaram a construção de modelos estruturais de emoções. Recentemente, o estudo das emoções tem despertado o interesse dos pesquisadores da Ciência da Computação, que têm procurado usar esses modelos para identificar as emoções nos usuários de computadores. Dessa forma, a primeira seção deste capítulo apresenta o conceito de emoção e os principais modelos de emoções identificados na literatura.

A segunda seção define a Computação Afetiva, área de pesquisa mais ampla, preocupada em proporcionar aos computadores a capacidade de reconhecer e expressar emoções e outros fenômenos afetivos relacionados. A terceira e última seção se destina aos conceitos relacionados à AS, campo da Computação Afetiva destinado a análise de emoções, sentimentos e opiniões presentes principalmente em textos.'

2.1. As Emoções

As emoções têm sido objeto de estudo em diversas áreas do conhecimento tais como a Psicologia, a Neurociência, a Filosofia e a Inteligência Artificial. Entretanto, não existe um consenso sobre a definição de emoção devido à sua natureza subjetiva, à divergência dos pesquisadores quanto a sua origem, e pelo termo ser empregado para descrever uma ampla gama de estados cognitivos e fisiológicos (GAZZANIGA; HEATHERTON, 2005). Segundo (FEHR; RUSSELL, 1984), todas as pessoas sabem o que é emoção, até pedirem para defini-la. A emoção é muitas vezes utilizada para descrever não somente sentimentos (felicidade e

tristeza), mas também desejos de motivação biológicos (fome e sede). Assim, também pode ser definida como sendo os estados mentais fortemente influenciados pelos sentimentos gerados por alterações fisiológicas.

A noção precisa do que se conhece por emoção é algo ainda tão incompleto quanto o conhecimento acerca de sua importância (ROMAN, 2007). Várias são as definições, dependendo da área do conhecimento de onde surgem. Em termos psicológicos e comportamentais, as emoções podem ser vistas como respostas sistêmicas que ocorrem quando ações altamente motivadas são proteladas ou inibidas (LANG, 1995), ainda que estas ações não tenham ocorrido realmente (ROMAN, 2007). Assim, as emoções dizem respeito à execução de algo importante ao organismo (LANG, 1995).

O cientista Charles Darwin em (DARWIN, 1872) destacou o papel fundamental das emoções no processo de adaptação dos seres vivos. Segundo ele, a expressão facial indicando os estados emocionais é uma forma de comunicação eficiente e compreensível para as pessoas, independente da cultura, e essas características expressivas são adaptativas em todas as formas de vida.

Existe uma importante distinção a ser feita, e que por vezes é motivo de confusão: a diferença entre emoção e sentimento. Para isto, buscou-se primeiramente obter-se a definição de emoção e sentimento utilizando-se o dicionário brasileiro Aurélio (FERREIRA, 2010) e na sequência, a definição de pesquisadores que desenvolvem estudos sobre tais assuntos. De acordo com o dicionário, a emoção é uma perturbação, geralmente passageira, provocada por algum fato, por exemplo, uma boa ou má notícia, uma surpresa, um perigo. Já o sentimento é o ato ou efeito de sentir, por exemplo, dor, mágoa, pesar.

Segundo o neurocientista Damásio em (DAMASIO, 2003), as emoções são movimentos ou ações do corpo, "públicas" no sentido em que são visíveis para terceiros a olho nu. Já os sentimentos são "privados" do organismo em cujo cérebro ocorrem, invisíveis para o público, escondidos de todos menos daquele que "tem o sentimento". Os sentimentos podem surgir pelo simples pensar em um evento, e imaginar o que aconteceria se ele ocorresse.

Vale notar que as emoções na cognição possuem um papel muito mais visível, além de consciente, no dia a dia. Por exemplo, uma emoção como fascinação pode dar início ao aprendizado ou até mesmo acelerá-lo. Também o humor é muito usado em ambientes educacionais como forma de motivar a atenção, desenvolver sentimentos afetivos para com o con-

teúdo ensinado e promover uma experiência de aprendizado mais prazerosa (NIJHOLT, 2003).

Diferentes teorias científicas de emoção foram desenvolvidas ao longo dos anos de pesquisas em ciências cognitivas, cada uma tentando oferecer uma explicação para a diversidade de fenômenos de afeto. Essas teorias originaram três principais modelos de emoções: os modelos discretos, também chamados de categóricos; os modelos dimensionais; e os modelos baseados na teoria Appraisal.

Os modelos discretos tendem a agrupar as emoções em categorias e partem do princípio que as emoções são independentes. Segundo (LIBRALON, 2014), dentre os modelos discretos, o mais difundido é o modelo de emoções básicas, proposto pelo psicólogo Paul Ekman (EKMAN, 1992), que afirma a existência de seis emoções básicas: *alegria*, *tristeza*, *raiva*, *medo*, *repugnância* e *surpresa*. Uma das principais vantagens dos modelos discretos é a comprovação, por meio de experimentos psicofísicos, que a percepção das emoções pelos seres humanos é discreta, dessa forma, estes modelos permitem facilmente associar as emoções com expressões faciais que as representam (LIBRALON, 2014). As seis emoções básicas de (EKMAN, 1992) são representadas por seis expressões faciais universais, pois são compreensíveis pelas pessoas em diferentes localidades, independente da cultura. A expressão facial das seis emoções básicas é mostrada na Figura 2.1.



Figura 2.1: Expressão facial das seis emoções básicas de Ekman. (a) *Raiva*; (b) *Medo*; (c) *Repugnância*; (d) *Surpresa*; (e) *Alegria*; (f) *Tristeza*. Fonte: (EKMAN; FRIESEN, 1976)

Além do modelo de emoções de (EKMAN, 1992), conforme pode ser visto em (ORTONY; TURNER, 1990), existem diversos outros pesquisadores que tentaram categorizar as emoções. Até a década de 70 foram propostos alguns modelos categóricos, dentre eles: (MCDUGALL, 1926) composto pelas emoções *raiva*, *repugnância*, *alegria*, *medo* e *espanto*, (WATSON, 1930) composto pelas emoções *medo*, *amor* e *raiva*, (ARNOLD, 1960) composto pelas emoções *raiva*, *aversão*, *coragem*, *tristeza*, *desejo*, *desespero*, *medo*, *ódio*, *esperança*, *amor* e *tristeza*, (MOWRER, 1960) composto pelas emoções *dor* e *prazer*, (IZARD, 1971) composto pelas emoções *raiva*, *desprezo*, *repugnância*, *angústia*, *medo*, *culpa*, *interesse*, *alegria*, *vergonha* e *surpresa*.

Os esforços em categorizar as emoções também prosseguiram na década de 80 com os trabalhos de (PLUTCHIK, 1980) que categorizou as emoções em *confiança*, *raiva*, *expectativa*, *repugnância*, *alegria*, *medo*, *tristeza* e *surpresa*, (GRAY, 1982) com as emoções *raiva*, *terror*, *ansiedade* e *alegria*, (PANKSEPP, 1982) com *expectativa*, *medo*, *fúria* e *pânico*, (JAMES, 1884) com *medo*, *dor*, *amor* e *fúria*, (WEINER; GRAHAM, 1984) com *felicidade* e *tristeza*, (TOMKINS, 1984) com *raiva*, *interesse*, *desprezo*, *nojo*, *angústia*, *medo*, *alegria*, *vergonha* e *surpresa*, (OATLEY; JOHNSON-LAIRD, 1987) com *raiva*, *repugnância*, *ansiedade* e *felicidade* e (FRIJDA, 1986) com *desejo*, *felicidade*, *interesse*, *surpresa*, *espanto* e *tristeza*.

Em (DAMASIO, 1994) as emoções são classificadas em primárias e secundárias, sendo que as emoções primárias são consideradas inatas ou “reflexas” e são comuns a todos os seres humanos, independentemente de fatores sociais ou socioculturais. Deste grupo fazem parte as emoções básicas ou elementares, como: *alegria*, *tristeza*, *medo*, *repugnância*, *raiva* e *surpresa*. As emoções secundárias ou sociais são mais complexas que as primárias, dependem de fatores e variáveis socioculturais e podem variar amplamente e radicalmente entre culturas ou sociedades. São exemplos de emoções secundárias: *culpa*, *vergonha*, *gratidão*, *simpatia*, *compaixão*, *orgulho*, *inveja*, *desprezo*, *espanto*.

A conceituação de emoção como discreta e independente teve origem da pesquisa afetiva realizada com animais. Ao estimular seletivamente as vias neurais e observar o comportamento subsequente, ou inversamente, ao induzir comportamentos e medir a atividade neural dos animais, os pesquisadores construíram a taxonomia das emoções básicas (PANKSEPP, 1998). Porém, conforme descrito em (PANKSEPP, 1998) e (KAGAN, 2003), os comportamentos afetivos não são suficientes e necessários para caracterizar todos os estados emocio-

nais. A ansiedade, por exemplo, pode ser sentida sem qualquer alteração evidente no comportamento. Conforme observa (EKMAN, 1993), nem todas as emoções são acompanhadas de expressões faciais.

Outra teoria de emoções conduz aos modelos dimensionais de emoção, que visam descrever a relação existente entre as categorias de emoções diferenciando-as de acordo com duas características (modelos 2D) ou três características (modelos 3D). Dentre os modelos dimensionais em 2D, um dos mais difundidos é o modelo circumplexo de afeto, proposto pelo psicólogo James A. Russel (RUSSELL, 1980), no qual as emoções estão relacionadas entre si, dispostas em um círculo e representadas em duas dimensões: valência (sentimentos agradáveis versus desagradáveis) e ativação (desperto versus sonolento). Os defensores desse modelo de afeto sugerem que cada experiência afetiva é consequência de uma combinação linear dessas duas dimensões, que é então, interpretado como representando uma emoção particular (Figura 2.2). A emoção *medo*, por exemplo, é conceituada como um estado neurofisiológico envolvendo a combinação de valência negativa e maior ativação no sistema nervoso central. Em seu estudo, (RUSSELL, 1980) mostrou uma lista de 28 palavras que as pessoas usam para descrever sentimentos, humores e emoções.

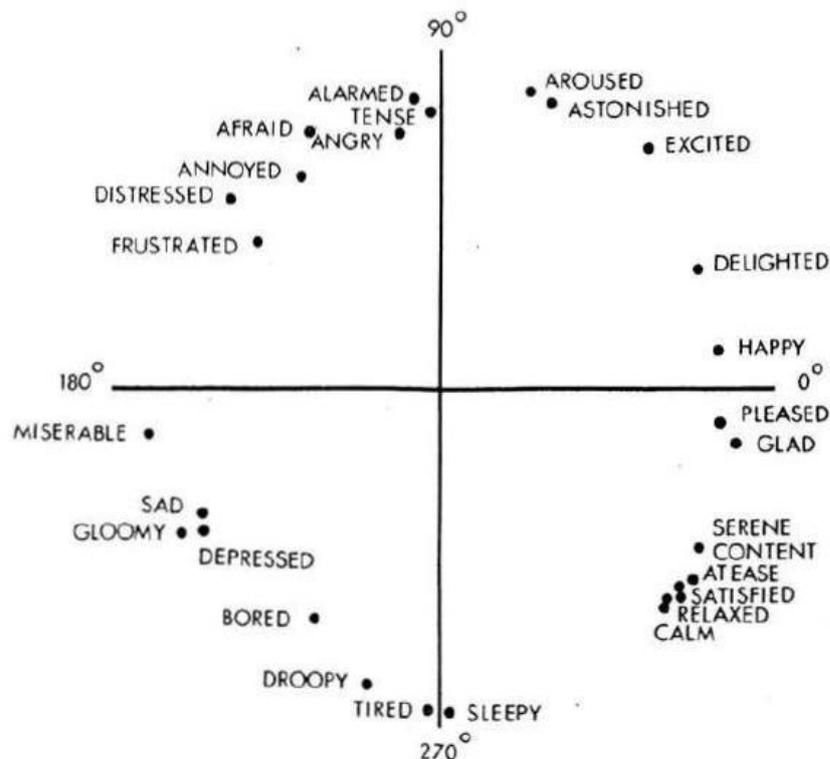


Figura 2.2: Modelo circumplexo de afeto. Fonte: Extraído de (RUSSELL, 1980)

O modelo de (RUSSELL, 1980) foi refinado por (WATSON et al., 1999) e é apresentado na Figura 2.3. A proximidade ou a distância entre as emoções representadas na circunferência pressupõem a semelhança ou a diferença entre as emoções. O modelo define que as emoções estão menos positivamente relacionadas quando estão afastadas, aproximadamente, 90 graus entre si. Aos 90 graus de afastamento, dois estados afetivos devem estar pouco ou nada relacionados. Por sua vez, aos 180 graus de afastamento, os estados afetivos devem estar negativamente relacionados.

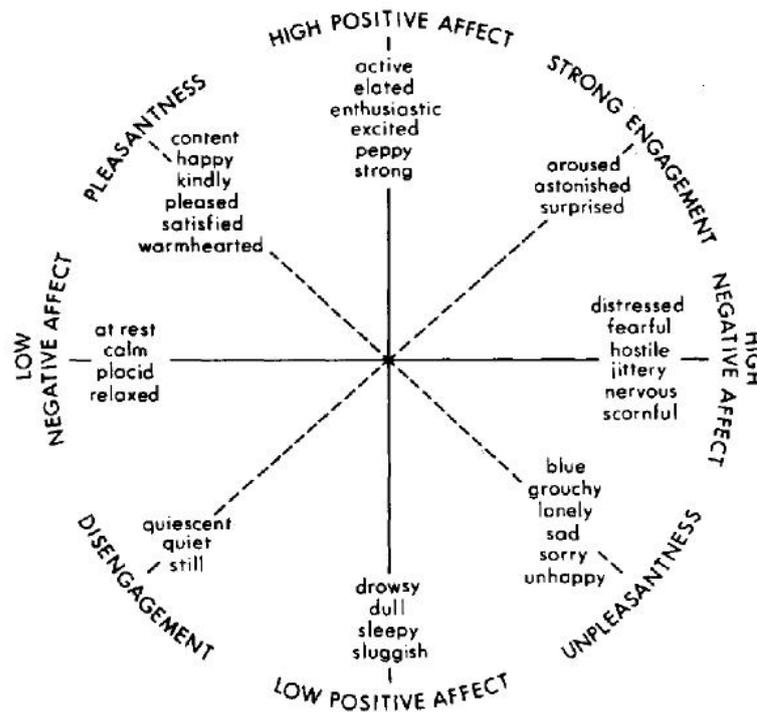


Figura 2.3: A estrutura bidimensional do afeto. Fonte: Extraído de (WATSON et al., 1999)

Nos modelos dimensionais em 3D, o modelo proposto pelo psicólogo Robert Plutchik (PLUTCHIK, 1980) se destaca. O modelo criado por Plutchik, mostrado na Figura 2.4, baseia-se em um contexto evolucionário (teoria de Darwin) e propõem oito emoções primárias sendo *alegria*, *tristeza*, *raiva*, *medo*, *repugnância*, *surpresa*, *expectativa* e *confiança*. Neste modelo tridimensional é possível verificar a combinação das emoções para gerar outras. A dimensão vertical do cone representa a intensidade, e o círculo representa o grau de similaridade entre as emoções. Os oito setores são projetados para indicar que há oito dimensões de emoções primárias. As emoções nos espaços em branco são a combinação de duas emoções primárias. Este modelo permite visualizar as relações existentes entre as emoções.

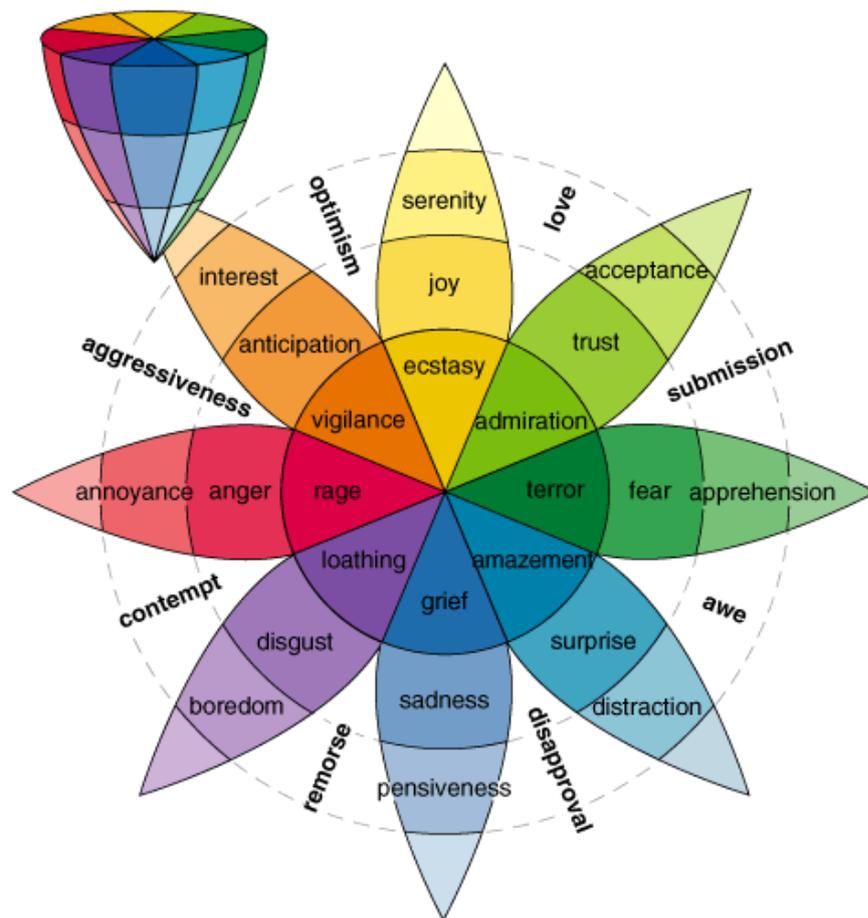


Figura 2.4: Modelo de emoções de Plutchik. Fonte: Extraído de (PLUTCHIK, 1980)

Um outro modelo tridimensional é o modelo PAD (iniciais de *Pleasure, Arousal, Dominance*) de emoções (MEHRABIAN, 1995). Neste modelo existem três dimensões: *satisfação, alerta e dominância*. A dimensão *satisfação* distingue estados afetivos positivos e negativos, por exemplo, *exaltação, conforto, segurança* versus *aborrecimento, ansiedade, raiva*. A dimensão *alerta* se refere ao estado de alerta e/ou de atividade física. Baixo alerta é exemplificado por *sono, sonolência, meditação* ou *descanso tranquilo* e alto alerta está relacionado com atividade mental intensa, como por exemplo, resolver um problema abstrato, ou praticar exercícios físicos. A dimensão de *dominância* se refere ao nível de controle sobre pessoas ou situações. Neste modelo, emoções específicas constituem pontos em um espaço tridimensional e podem ser definidas precisamente em termos de suas coordenadas nas três dimensões.

Os modelos de emoções baseados na teoria Appraisal consideram as emoções como resultado de avaliações subjetivas de um determinado evento ou situação que está acontecendo em um determinado momento (LAZARUS, 1991). Neste contexto, um dos modelos mais

conhecidos é o modelo OCC (ORTONY; CLORE; COLLINS, 1988) de emoções. Esta teoria supõe que as emoções são desenvolvidas como resultado das cognições e interpretações, sendo consideradas como reações com valência (*positivo*, *negativo* ou *neutro*) para eventos, agentes ou objetos. O modelo consiste em 22 emoções, sendo 11 positivas e 11 negativas. O conjunto de emoções é composto por: *satisfação - remorso*, *gratidão - raiva*, *orgulho - vergonha*, *admiração - censura*, *alegria - angústia*, *feliz por - ressentimento*, *soberba - pena*, *esperança - medo*, *satisfação - medo confirmado*, *confiança - desapontamento*, *amor - ódio*. Existem também outros modelos propostos na teoria Appraisal como os mostrados em (SMITH; LAZARUS, 1993), (ROSEMAN, 1996) e (SCHERER; SCHORR; JOHNSTONE, 2001).

Mesmo com a existência dos diversos modelos de emoções propostos pelos pesquisadores, ainda assim pode ser difícil para um ser humano identificar as emoções expressas por outro ser humano. Alguns autores como (ROLLS, 1998), (ORTONY, 2002), (DAVIDSON, 2003) e (ORTONY; NORMAN; REVELLE, 2004) afirmam que a dificuldade em identificar as emoções humanas se dá em função das diferenças individuais, das experiências vividas e dos fatores genéticos. Em (FELLOUS, 2004) o autor fala das dificuldades que os pesquisadores enfrentam ao tentar compreender as emoções e cita um exemplo: o *medo* de uma pessoa ao ver um urso pode ser muito diferente do *medo* experimentado por um guarda florestal que conhece os perigos que o urso representa e sabe como reagir caso seja atacado. Também o *medo* de uma pessoa pode ser diferente de outra que já teve aproximadamente a mesma quantidade de exposição aos ursos, mas que é mais propensa a comportamentos de risco. Este exemplo contextualiza o fato de que se duas ou mais pessoas forem submetidas a uma mesma situação elas podem reagir de forma bastante diferentes. Dessa forma, é bastante desafiador representar o comportamento emocional humano.

Recentemente, o estudo das emoções tem atraído também a atenção de pesquisadores da área da Ciência da Computação, especialmente em relação a interação entre homens e computadores (GROSSMAN; FRIEDER, 2004). Do ponto de vista computacional, a compreensão das emoções refere-se à capacidade de uma máquina não apenas detectar a informação emocional, mas também armazenar, processar, construir e manter um modelo emocional do usuário (LIBRALON, 2014). Entre as pesquisas realizadas neste sentido, encontra-se a identificação automática de emoções em textos, conhecida como AS. A AS é uma subárea da Computação Afetiva, ambas serão definidas na seção seguinte.

2.2. Computação Afetiva e Análise de Sentimentos

A Interação Humano-Computador (IHC) é uma área de pesquisa que visa melhorar a interface de relacionamento entre os usuários e os computadores (BOOTH, 1995). O uso cada vez mais intenso dos computadores nas formas de comunicação e na interação entre as pessoas tem levado a estudos em Computação Afetiva, subárea da Inteligência Artificial e área de interseção entre IHC e ciências cognitivas, para permitir que sistemas computacionais possam reconhecer e simular emoções. Uma referência nesta área é o trabalho da pesquisadora Rosalind Picard (PICARD, 1995), no qual a autora define que a habilidade de manipular emoções é essencial para que os computadores sejam capazes de uma interação mais natural e de maior qualidade com os seres humanos, aumentando assim a possibilidade de aplicações lúdicas, científicas e educativas. Segundo ela, o afeto é parte natural e social da comunicação humana e as pessoas naturalmente o usam quando interagem entre elas e assim também quando interagem com computadores. Se os computadores apresentarem qualidades afetivas e ainda, uma conformidade formal com o meio ambiente ou o corpo humano, a relação homem-máquina-ambiente tornar-se-á um processo mais natural.

Neste contexto, (PICARD, 1995) utiliza o termo Computação Afetiva para propor que se dê aos computadores as habilidades emocionais. Segundo a autora, para que os computadores se adaptem e interajam de forma natural com os seres humanos é necessário dotá-los da habilidade de reconhecer e expressar emoções. Os trabalhos desenvolvidos para realizar a análise automática de estados afetivos a partir de documentos escritos em linguagem natural, baseados em categorias de emoção, se enquadram em uma área bastante interessante da Computação Afetiva que se chama AS.

Segundo (BALAHUR; HERMIDA; MONTROYO, 2012), no domínio da Inteligência Artificial nas décadas de 1970 e 1980 já existiam trabalhos que buscavam construir sistemas para detectar automaticamente a emoção em textos. No entanto, foi a partir de (PICARD, 1995) que a pesquisa aumentou significativamente. A necessidade de se desenvolver sistemas que são capazes de detectar e responder ao afeto de uma forma automática tornou-se ainda mais evidente quando uma multiplicidade de ambientes de interação entre humanos e computadores emergiu, como os sites de *e-learning*, as aplicações de mídia social na web, os robôs inteligentes, dentre outros.

Liu (LIU, 2015), define a AS (ou *Sentiment Analysis*) como o campo de estudo que analisa opiniões, sentimentos, avaliações, atitudes e emoções das pessoas a favor das entida-

des e seus atributos expressos em texto escrito. Há também muitos nomes e tarefas diferentes, como por exemplo, *Opinion Mining*, *Opinion Analysis*, *Opinion Extraction*, *Sentiment Mining*, *Subjectivity Analysis*, *Affect Analysis*, *Emotion Analysis* e *Review Mining*, todos eles são agrupados sob o conceito da AS. Na indústria, o termo *Sentiment Analysis* é mais comumente utilizado, já nas pesquisas acadêmicas tanto *Sentiment Analysis* quanto *Opinion Mining* são frequentemente empregados. Independentemente disso, eles representam, basicamente, o mesmo campo de estudo. O termo *Sentiment Analysis* apareceu pela primeira vez em (NASUKAWA, 2003), e o termo *Opinion Mining* apareceu pela primeira vez em (DAVE et al., 2003).

Os termos afeto, sentimento, emoção e opinião são comumente referidos em AS e, dessa forma, vale a pena diferenciá-los. Em (MUNEZERO et al., 2014) os autores reúnem diversos conceitos: o termo afeto é o mais abstrato de ser verificado em linguagem, pois ele é considerado não consciente para o ser humano e é predecessor para sentimentos e emoções; já os sentimentos são fenômenos conscientes, centrados na pessoa, enquanto que as emoções são expressões sociais dos sentimentos influenciadas pela cultura; e as opiniões são interpretações pessoais de informações de determinada entidade que podem ou não conter sentimentos ou emoções.

Ainda segundo (MUNEZERO et al., 2014), em (PICARD, 1995), os termos emoção e afeto são utilizados indiferentemente. Isto é bastante compreensível, pois as emoções são, de fato, expressões de afeto. Dessa forma, as reações afetivas em relação a um objeto no mundo, como *bom*, *mau*, *feio* ou *bonito* são representações conscientes de afeto, que são expressos na linguagem por meio de sentimentos e emoções.

Em (LIU, 2015), o autor afirma que para a AS é necessário saber se as emoções e sentimentos das pessoas, tão discutidos e estudados pela Psicologia, podem ser expressos em linguagem natural e como eles podem ser reconhecidos. Segundo ele, a fala e a escrita são as principais formas que os seres humanos usam para se expressar. Além da gramática e das expressões léxicas, que são comuns à fala e à escrita, a emoção do falante também pode ser transmitida por meio de mecanismos como por exemplo entonação, expressão facial, movimentos corporais, sinais biofísicos, gestos e postura. Na escrita, pontuação especial, a capitalização de todas as letras de uma palavra, *emoticons*, alongamento de palavras, dentre outros fatores, são frequentemente utilizados para transmitir emoções, especialmente nos meios de comunicação social. Em relação às expressões gramaticais e lexicais, existe uma forma co-

mum das pessoas expressar emoções, como por exemplo: ao usar palavras emocionais (*amor, repugnância, tristeza*, dentre outras); ao descrever comportamentos relacionados com emoção como no exemplo "*Ele chorou quando viu a sua mãe*"; ao usar intensificadores como "*Este carro é muito bom*"; ao usar superlativos como "*Este carro é simplesmente o melhor*"; ou ao usar sarcasmo como em "*Um ótimo carro, ele quebrou no segundo dia*".

Do ponto de vista do Processamento de Linguagem Natural (PLN), a emoção pode ser expressa em linguagem textual e a investigação sobre a detecção de emoções em texto centrou-se na captura de palavras que contém emoção baseadas nos três modelos de emoções (vistos na Seção 2.1): modelos discretos, modelos dimensionais e modelos baseados na teoria Appraisal. Esses modelos são oriundos de diferentes teorias psicológicas de emoção e até a data atual, nenhum modelo geral de emoções foi acordado entre os pesquisadores, dessa forma, esses modelos são normalmente usados em métodos de identificação de emoções em textos (MUNEZERO et al., 2014). Em Linguística Computacional, as tentativas de detecção de emoções em textos são realizadas usando recursos lexicais, como por exemplo o *WordNetAffect* (STRAPPARAVA; VALITUTTI, 2004) e o *SentiWordNet* (ESULI; SEBASTIANI, 2006), que permitem identificar a presença de palavras de emoção nos textos.

Apesar da Linguística Computacional e da PLN terem uma longa história, eram raras as pesquisas realizadas sobre emoções, sentimentos e opiniões do usuário antes do ano de 2000. Desde então, o campo tornou-se uma área de pesquisa muito ativa. Existem várias razões para isto. Primeiro, porque esse campo tem um grande número de aplicações em muitos domínios. A indústria de AS também floresceu devido à proliferação de aplicações comerciais, o que fornece uma forte motivação para a pesquisa. Em segundo lugar, por oferecer muitos problemas de pesquisa desafiadores, que nunca haviam sido estudados antes. Em terceiro lugar, porque existe um vasto volume de dados opinativos na mídia social da web. Portanto, as pesquisas em AS não só tem um impacto importante sobre a PLN, mas também pode ter um impacto profundo em gestão, política e ciências sociais e econômicas, onde todos podem ser afetados pela opinião das pessoas (LIU, 2012).

Na AS, os métodos computacionais visam identificar as emoções, sentimentos e opiniões dos usuários expressos por meio da fala, de imagens, mas principalmente por meio de textos, visto que a maioria das informações disponibilizadas diariamente na web se encontram na forma textual.

2.2.1. Análise de Sentimentos em Textos

A AS em textos costuma ser uma tarefa bastante complexa visto que o próprio ser humano tem dificuldade em identificar emoções em textos. Este fato pode ser comprovado ao observar o grau de concordância obtido entre os anotadores em corpora consolidados, como é o caso do corpus de contos infantis desenvolvido por (ALM; ROTH; SPROAT, 2005), do corpus de blogs desenvolvido por (AMAN; SZPAKOWICZ, 2007) e do corpus de notícias desenvolvido por (STRAPPARAVA et al., 2007). Esses corpora são amplamente utilizados desde a sua criação até atualmente para testar e avaliar métodos de AS. O grau de concordância entre os anotadores humanos, nestes corpora entretanto, no melhor dos casos, pode chegar em torno de 0,75 (considerando um coeficiente como o Kappa, por exemplo). Isto mostra o quanto pode ser complexo para os métodos computacionais atingirem um bom desempenho ao identificar as emoções em textos.

Os principais desafios que dificultam a tarefa de AS em textos são:

- As emoções, sentimentos e opiniões expressos nos textos são comumente apresentados de forma subjetiva;
- os textos se apresentam em diferentes formatos e de forma não estruturada;
- a grande maioria dos textos são escritos em uma linguagem informal e muitos deles contém gírias, sarcasmo, ironia e *emoticons* (ícones de emoções usados na interação social);
- em alguns casos, os textos apresentam limitação de tamanho, caso por exemplo do *Twitter*, que limita o texto em 140 caracteres;
- normalmente os métodos desenvolvidos são sensíveis ao domínio e/ou ao idioma.

Em geral, a AS em textos pode ser aplicada em três níveis de granularidade: em nível de documento, em nível de sentença e em nível de aspecto ou entidade.

No nível de documento, a tarefa consiste em detectar o sentimento, opinião ou emoção predominante no documento como um todo. Conforme descrito em (LIU, 2015), este nível é conhecido como classificação de sentimento em nível de documento, um exemplo de análise realizada nesse nível pode ser visto no trabalho de (MORAES; VALIATI; GAVIÃO NETO, 2013).

No nível de sentença, o sentimento, a opinião ou a emoção é determinada considerando cada sentença do texto. (LIU, 2015) se refere a este nível de análise como classificação de

subjetividade, que distingue sentenças que expressam informação factual (sentenças objetivas) de sentenças que expressam ponto de vista subjetivo (sentenças subjetivas). Um exemplo de classificação de subjetividade em nível de sentença pode ser visto em (WIEBE; BRUCE; O'HARA, 1999).

No nível de aspecto ou de entidade, ao invés de se investigar a emoção analisando os textos em um nível de documento ou em um nível de sentença, determina-se um alvo de sentimento para o texto. Em (LIU, 2012) é apresentado o seguinte exemplo para o nível de aspecto, no texto "*A qualidade das chamadas do iPhone é boa, mas a vida útil da bateria é curta.*", são avaliados dois aspectos, a qualidade da chamada e a vida útil da bateria do *iPhone*. O sentimento sobre a qualidade das chamadas do *iPhone* é *positivo*, mas o sentimento da vida útil de sua da bateria é *negativo*. Neste exemplo, a qualidade da chamada e a vida útil da bateria do *iPhone* são os alvos de opinião. (LIU, 2015) chama este nível de análise de AS baseada em aspectos e cita como exemplo o trabalho (HU; LIU, 2004a).

A AS em textos pode ser realizada a partir de duas perspectivas: a partir do ponto de vista do autor, que expressa a emoção e o sentimento nas palavras do texto, e a partir do ponto de vista do leitor, que lê o texto e interpreta as emoções e sentimentos contidos nele. Por exemplo, no texto "*O preço da habitação caiu, isso é ruim para a economia.*", pode-se notar claramente que o autor se refere ao impacto negativo que o baixo preço da habitação está causando na economia. No entanto, este texto pode ser percebido em ambos os sentidos por leitores. Para os vendedores, este é, de fato negativo, mas para os compradores, isto poderia significar uma boa notícia (LIU, 2012).

Os autores (BALAHUR et al., 2010), ao realizarem AS em textos em um domínio de notícias jornalísticas, afirmam que do ponto de vista do autor e do leitor, os textos são puramente informativos e os fatos são interpretáveis pela emoção que transmitem. Os autores ainda acrescentam que a AS em textos pode ser realizada considerando-se um terceiro ponto de vista, o do texto estrito, que se refere ao sentimento expressamente declarado, e não o que está subentendido.

A subjetividade nos textos também é um tema bastante discutido na AS em textos. Segundo (LIU, 2012) uma sentença objetiva apresenta fatos sobre o mundo, enquanto uma sentença subjetiva manifesta alguns sentimentos, opiniões ou crenças pessoais. Uma sentença objetiva pode ser exemplificada como "*O iPhone é um produto da Apple.*", já a frase "*Eu gosto de iPhone.*" é uma sentença subjetiva.

Os autores (BALAHUR; MIHALCEA; MONTOYO, 2014) afirmam que enquanto a classificação de subjetividade visa rotular os textos como subjetivos ou objetivos, a classificação de sentimento acrescenta um nível adicional de granularidade, classificando o texto subjetivo como *positivo*, *negativo* ou *neutro*, que é depois refinado ainda mais pela análise de emoção, identificando a presença de categorias de emoções como *alegria*, *raiva*, *medo*, etc.

Em (LIU, 2012), o autor afirma que é comum haver confusão entre os pesquisadores ao equiparar subjetividade com sentimento, emoção ou opinião. Segundo ele, esses conceitos não são equivalentes, embora tenham um grande cruzamento. Uma frase subjetiva pode não expressar qualquer sentimento, por exemplo, "*Eu acho que ele foi para casa.*" é uma sentença subjetiva, mas não expressa sentimento. Os autores (ZHANG; LIU, 2011) afirmam que sentenças objetivas podem conter opiniões, sentimentos e emoções de forma implícita. Por exemplo, as sentenças "*O fone de ouvido quebrou em dois dias.*" e "*Eu trouxe o colchão há uma semana e um vale formou.*" indicam claramente alguns fatos que implicam em sentimentos negativos.

Nas primeiras pesquisas sobre classificação de subjetividade, o problema foi tratado de forma independente, ou seja, não com a finalidade de classificação de sentimento. Nas pesquisas mais recentes, alguns pesquisadores trataram a subjetividade como o primeiro passo da classificação de sentimento usando-a para remover textos objetivos, que são assumidos por não expressar ou transmitir qualquer sentimento, emoção ou opinião. Em (LIU, 2012), o autor sugere que é mais apropriado para a primeira etapa da classificação de sentimento separar cada sentença em afetiva ou não afetiva, independentemente se ela é subjetiva ou objetiva.

Os autores (PANG; LEE, 2008) afirmam que, em geral, sentimento e subjetividade são bastante sensíveis ao contexto e, que até uma mesma expressão textual pode indicar sentimento desigual em diferentes domínios. Por exemplo, a sentença "*Ir ler o livro.*" provavelmente indica sentimento positivo para resenhas de livros, mas sentimento negativo para críticas de filmes.

A tarefa de identificar sentimentos e emoções em textos é considerada um problema de classificação de textos usando categorias para representar as emoções. As abordagens mais utilizadas para resolver os problemas de AS em textos são apresentadas no Capítulo 3.

Além dos textos, a AS também poder ser realizada em outros tipos de corpora, como por exemplo em corpora de imagens ou de fala (áudio). As duas próximas seções fazem uma pequena descrição dessas modalidades.

2.2.2. Análise de Sentimentos em Fala

Dentre as diversas aplicações para a AS em fala, uma delas é adaptar a resposta do sistema em relação à emoção ou ao sentimento presente na voz do falante. O trabalho desenvolvido por (EL AYADI; KAMEL; KARRAY, 2011) faz um levantamento das principais contribuições científicas realizadas até o ano de 2011 para a AS em fala.

Identificar a emoção presente em fala pode ser útil para melhorar o desempenho de sistemas de reconhecimento de voz e sistemas que exigem uma interação mais natural entre o homem e a máquina tais como os tutoriais, onde a resposta do sistema para o usuário depende da emoção detectada; um sistema de bordo de automóvel, onde a informação do estado mental do motorista pode ser fornecida para que o sistema gere alguns aspectos de segurança. Também pode ser utilizado como uma ferramenta de diagnóstico para terapeutas e tem ampla utilização em aplicações destinadas a *call centers*.

A tarefa de reconhecimento de emoções em fala ainda é bastante desafiadora, principalmente por dois motivos principais. Em primeiro lugar, não é claro quais as características da fala são mais influentes para se distinguir as emoções. A variabilidade acústica introduzida pela existência de sentenças diferentes e estilos da fala e as taxas da fala são os principais obstáculos. Além disso, pode haver mais de uma emoção percebida no mesmo enunciado e cada emoção corresponde a uma porção diferente do enunciado falado. Outra questão complexa é a forma como uma certa emoção é expressa pelo falante, normalmente influenciável pela cultura e pelo ambiente em que ele vive (EL AYADI; KAMEL; KARRAY, 2011).

Existem diversos trabalhos desenvolvidos nesta área, dentre eles é possível citar alguns como (PIERRE-YVES, 2003), (FERNANDEZ, 2004), (SCHRODER, 2004), (VERVERIDIS; KOTROPOULOS, 2006), (GRAVES; MOHAMED; HINTON, 2013) e (AMER et al., 2014). Também a identificação de sentimentos e emoções em corpora de áudios de músicas tem sido frequentemente pesquisada, (LI; OGIHARA, 2003), (HU; DOWNIE; EHMANN, 2009), (KIM et al., 2010), (LI; OGIHARA; TZANETAKIS, 2011), (YANG; CHEN, 2012) e (WU et al., 2014) são alguns exemplos de estudos nesta área.

2.2.3. Análise de Sentimentos em Imagens

A necessidade de se desenvolver métodos que analisam sentimentos e emoções em imagens surgiu por dois motivos principais: primeiro, pelo fato de se ter disponíveis atualmente um grande número de repositórios digitais de imagens disponibilizados na internet, o

que cria uma necessidade de se desenvolver formas eficazes de recuperação de informações. Conforme descrito em (MACHAJDIK; HANBURY, 2010), a maioria dos sistemas comerciais usam indexação textual para recuperar imagens e existem muitas situações em que seria útil se as imagens fossem recuperadas com base em seu conteúdo emocional, como por exemplo, no caso de um editor de revista ao procurar fotos ilustrativas para um artigo sobre o tema depressão em que as imagens devem apresentar uma atmosfera triste. Nesse contexto, (SIERSDORFER et al., 2010) classifica os sentimentos de imagens do *Flickr Image Dataset*¹ em positivos ou negativos.

O outro motivo de se interpretar o sentimento ou emoção expressos em imagens surgiu devido à popularidade das redes sociais, onde as imagens se tornaram um veículo conveniente para a difusão de informações entre os usuários online. Trabalhos como (YOU; LUO, 2013) e (MA; LUO, 2013) exploram técnicas para reconhecer automaticamente o sentimento presente em expressões faciais de fotos sociais, como imagens de *tweets*, especialmente aquelas de políticos no contexto de eleições. Também trabalhos como (BORTH et al., 2013), (YUAN et al., 2013), (YOU et al., 2015) e (WANG et al., 2015) identificam emoções ou sentimentos em imagens.

2.3. Considerações Finais

Neste capítulo foram apresentados conceitos relacionados à Computação Afetiva e AS, e foi dado ênfase principalmente no estudo das emoções, que é o principal produto da Computação Afetiva. Inicialmente foi apresentado o conceito de emoções e, apesar de existirem muitas definições, diferentes pontos de vista e inúmeros estudos desenvolvidos sobre este assunto, os pesquisadores ainda têm uma grande dificuldade em conceituar emoções e definir um modelo geral de emoções.

Apesar da AS ter como foco a identificação de emoções, sentimentos e opiniões em textos, também têm sido aplicadas técnicas de AS em outros tipos de corpora, como por exemplo, fala e imagens.

A maioria dos pesquisadores tratam a Mineração de Opiniões como sinônimo de AS. Na prática, porém, ambas as tarefas podem ser diferentes. Um exemplo disso é o caso de identificar opiniões em favor de entidades, o que é bastante comum na Mineração de Opiniões e o

¹ <https://www.flickr.com/>

que pode ser bastante raro na AS, principalmente quando se trata de identificar categorias de emoções em domínios de textos que contenham diferentes entidades em cada texto.

Como o foco deste trabalho de pesquisa é desenvolver um método de AS em textos, o próximo capítulo segue apresentando as principais abordagens utilizadas na AS em textos e mostrando as principais técnicas e algoritmos que podem ser utilizados na construção de um método de identificação de emoções em textos.

Capítulo 3

A Identificação de Emoções em Textos

Identificar emoções em textos é um problema de classificação de textos. Neste capítulo são apresentadas as principais abordagens que podem ser usadas na construção de um método de identificação de emoções em textos.

3.1. Principais Abordagens para a Identificação de Emoções em Textos

As abordagens baseadas em Aprendizagem de Máquina (AM) e em léxico são as mais comumente utilizadas para resolver os problemas de AS em textos. A Figura 3.1 mostra as duas abordagens principais e como elas estão subdivididas.

É frequente encontrar na literatura trabalhos que utilizam as duas abordagens para identificar emoções em textos, como é o caso por exemplo do trabalho de (GHAZI; INKPEN; SZPAKOWICZ, 2014), que usa léxico e AM para identificar as seis emoções básicas e mais uma classe chamada "*Non-Emo*" em textos escritos em Inglês, e de (RANGEL; ROSSO, 2013), que usa um léxico para auxiliar na seleção de características e algoritmos de AM para identificar as seis emoções básicas em textos escritos em Espanhol. Os autores (ZHANG et al., 2011) também fazem uso de ambas abordagens para fazer AS em textos extraídos do *Twitter*.

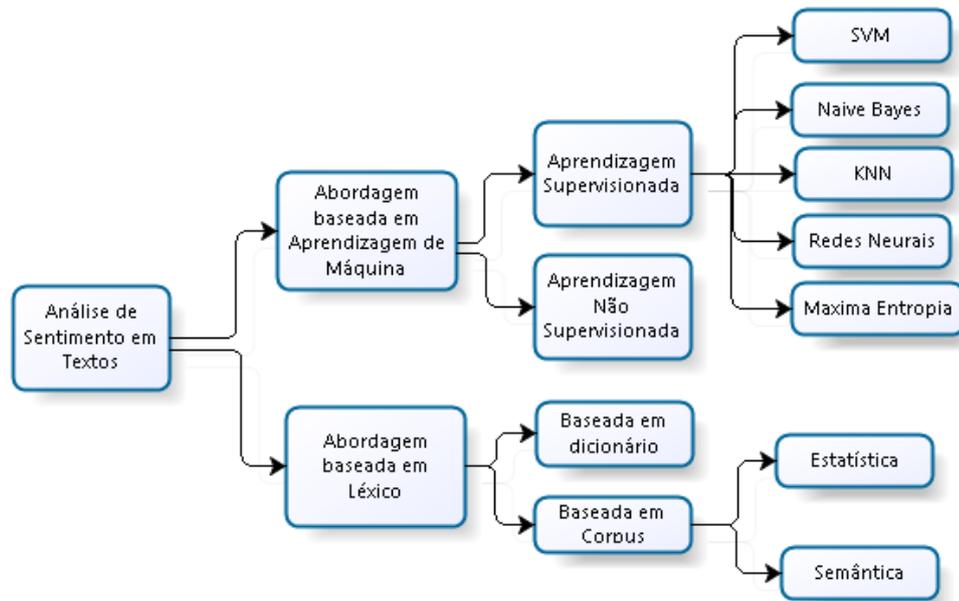


Figura 3.1: Abordagens para a AS em textos. Fonte: Adaptada de (MEDHAT; HASSAN; KORASHY, 2014)

A abordagem baseada em AM é dividida em AM supervisionada e AM não supervisionada. Os métodos supervisionados necessitam de um grande número de textos rotulados para realizar o treinamento. Os métodos não supervisionados são uma opção quando há dificuldade em se obter textos rotulados. Os principais algoritmos baseados em AM supervisionada que são mais comumente utilizados na classificação de emoções em textos são apresentados na Seção 3.6.

A abordagem baseada em léxico é dependente da disponibilidade de um léxico de termos emocionais. Esta abordagem é dividida em duas outras abordagens: baseada em dicionário e baseada em corpus. Na abordagem baseada em dicionário, inicialmente um pequeno conjunto de termos emocionais é recolhido manualmente onde cada termo possui a sua emoção associada. Este conjunto de palavras, chamado de sementes, é usado para efetuar pesquisas em dicionários como *WordNetAffect* (STRAPPARAVA; VALITUTTI, 2004) ou *SentiWordNet* (ESULI; SEBASTIANI, 2006) a fim de explorar as ligações semânticas como, por exemplo, sinônimos e antônimos, e os termos recém-descobertos são adicionados à lista de sementes. O processo iterativo é finalizado quando não são mais encontrados novos termos (LIU, 2012). A abordagem léxica baseada em dicionário foi usada em diversos trabalhos, dentre eles (HU; LIU, 2004b), (KIM; REY; HOVY, 2004), (DEVITT et al., 2007), (DING et al., 2008), (TABOADA et al., 2011) e (KIRITCHENKO; ZHU; MOHAMMAD, 2014).

Na abordagem baseada em corpus, também uma lista de termos emocionais sementes é utilizada para encontrar outros termos emocionais em um grande corpus de domínio. O objetivo é auxiliar na busca de termos emocionais com orientações específicas de contexto. Isto pode ser feito usando métodos estatísticos ou semânticos (LIU, 2012). A abordagem léxica baseada em corpus foi usada em trabalhos como (KAJI; KITSUREGAWA, 2006), (WIEBE; MIHALCEA, 2006), (KAJI; KITSUREGAWA, 2007), (DING et al., 2008) e (WU, 2010).

A partir da próxima seção, os conceitos serão direcionados à abordagem de AM supervisionada, sendo esta a abordagem utilizada no método de identificação de emoções desenvolvido neste trabalho de pesquisa.

3.2. Etapas de um Processo de Identificação de Emoções em Textos

Um processo tradicional de classificação de textos usando AM supervisionada (Figura 3.2) requer a obtenção de um conjunto de dados textuais, normalmente chamado de corpus, cujos textos devem ser previamente anotados por um especialista. Nos dados textuais são aplicadas técnicas de pré-processamento que têm como objetivo preparar os textos para um processamento posterior.

Após o pré-processamento, são aplicados ao conjunto de dados, métodos específicos para selecionar as melhores características. Na sequência, os dados são representados de forma que possam ser submetidos a um classificador, que irá gerar um modelo de classificação, o qual será usado posteriormente para a classificação de novos textos. O modelo de classificação gerado é normalmente avaliado por um conjunto de teste e/ou validação antes de ser usado para classificar novos textos não rotulados.

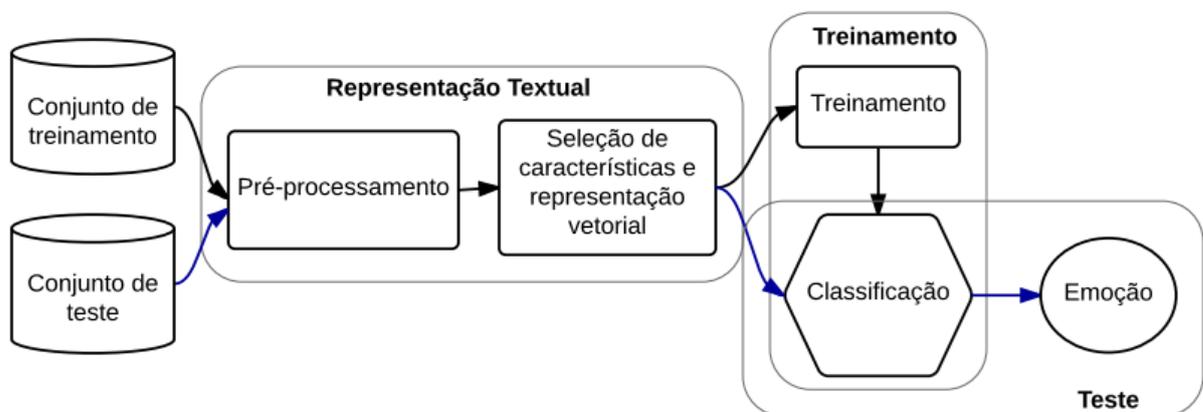


Figura 3.2: Um processo de classificação de textos. Fonte: Adaptada de (SONG et al., 2014).

Nas próximas seções são detalhados os processos ilustrados na Figura 3.2.

3.3. Corpus em Análise de Sentimentos

Segundo (SINCLAIR, 2004), um corpus é uma coletânea de textos em certo idioma que esteja em formato eletrônico. Especificamente, os textos que compõem um corpus são selecionados de acordo com critérios que surgem a partir das necessidades da pesquisa na qual o corpus será usado e que sejam capazes de representar uma língua ou uma parcela da língua. Atualmente, os corpora mais utilizados na AS são os compostos por comentários de produtos, notícias, e-mails e mídias sociais como blogs, *Twitter* e *Facebook*.

O foco em textos obtidos de comentários de produtos se justifica pelo interesse comercial nesta classe de aplicação. Esses dados apresentam um alvo definido e são disponibilizados em grande quantidade encontrada sobre um mesmo domínio. Os textos costumam apresentar com poucas gírias, ironias e ícones de emoções se comparado a outros tipos de mídias como os obtidos via *Twitter*, por exemplo, (BECKER; TUMITAN, 2013). Diversos trabalhos já foram desenvolvidos usando corpora de comentários de produtos, (TURNERY, 2002), (PANG; LEE; VAITHYANATHAN, 2002) e (HU; LIU, 2004b) são alguns desses trabalhos.

Os textos de notícias e de blogs também são utilizados em AS. Neste tipo de texto, o conteúdo de emoções costuma ser esparsos e o autor tende a não explicitar diretamente a sua emoção sobre o assunto (BECKER; TUMITAN, 2013). Trabalhos como (GODBOLE; SRINIVASIAH, 2007), (BAUTIN; VIJAYARENU; SKIENA, 2008), (BALAHUR et al., 2009) e (BALAHUR et al., 2010) fazem AS em corpora de notícias e/ou blogs.

Os textos extraídos de e-mails também têm interessado à comunidade que desenvolve pesquisa com AS. Existem diversas aplicações da AS em e-mails, uma delas é a identificação de mensagens significativas do ponto de vista emocional, para o usuário (HANGAL; LAM, 2011). Além disso, as empresas comerciais podem aplicar pesquisas baseadas em afeto para melhorar a satisfação do cliente em relação a produtos (MOHAMMAD, 2011). Alguns trabalhos que usaram corpora de e-mails em AS foram (LIU; LIEBERMAN; SELKER, 2003), (PESTIAN et al., 2008) e (MOHAMMAD; YANG, 2011).

A AS em dados do *Twitter* tem a informalidade como o principal desafio, porém o volume de dados é tão grande em relação a cada assunto que os erros de ortografia e de digitação podem não ser tão relevantes em um processo de classificação (BECKER; TUMITAN, 2013). O principal foco dos trabalhos desenvolvidos neste domínio é a capacida-

de de previsão. Trabalhos como (ASUR; HUBERMAN, 2010), (BOLLEN; MAO; ZENG, 2011) e inúmeros outros disponíveis na literatura usam corpora de tweets para fazer previsões.

Os dados extraídos do *Facebook* também costumam ser utilizados em pesquisas de AS, visto que o *Facebook* é um dos serviços de redes sociais que tem maior popularidade entre os usuários. No trabalho de (KAHN; VAYENA; MASTROIANNI, 2014) foram usados dados do *Facebook* para examinar as emoções dos usuários. Esse estudo foi polêmico porque ocorreu a manipulação dos *feeds* exibidos para 689.003 usuários do site. A pesquisa conseguiu comprovar que notícias negativas levam os usuários a postarem mensagens de status mais negativas e notícias positivas a estados positivos. Outros trabalhos de AS já usaram dados extraídos do *Facebook*, dentre eles (TROUSSAS et al., 2013) e (RANGEL; ROSSO, 2013).

Além desses tipos de textos, existem diversos outros que já foram usados em AS, dentre eles, pode-se citar os textos extraídos de conversas online (HOLZMAN; POTTENGER, 2003), os textos extraídos de contos infantis (ALM; ROTH; SPROAT, 2005), os textos extraídos de entrevistas (THOMAS; A.; P., 2014) e textos extraídos de poemas (BARROS; RODRIGUEZ; ORTIGOSA, 2013).

Após realizada a coleta dos textos para a construção de um determinado corpus, o próximo passo é submetê-los a um processo de anotação manual, em que avaliadores humanos fazem a leitura de cada texto e atribuem rótulos relacionados às emoções. Este processo exige uma metodologia rigorosa e os textos devem ser anotados de forma que as emoções atribuídas possam refletir a realidade. Os textos anotados são usados para testar e avaliar os métodos de AS.

Nos dados textuais, existem dois problemas que são mais recorrentes quando se trata de identificar emoções usando uma abordagem de AM supervisionada: o desbalanceamento e a sobreposição das classes. Segundo (DENIL; TRAPPENBERG, 2010), o problema do desbalanceamento dos dados ocorre quando os dados usados para treinar um classificador contêm significativamente mais representantes de uma classe em relação às outras. No Gráfico 3.1 é mostrado um exemplo de um corpus de notícias onde os dados multiclasse são desbalanceados. Os textos da classe minoritária (*raiva*) compõem menos de 5% da quantidade total dos dados e os textos da classe majoritária (*neutro*) compõem de 25% da quantidade total dos dados.

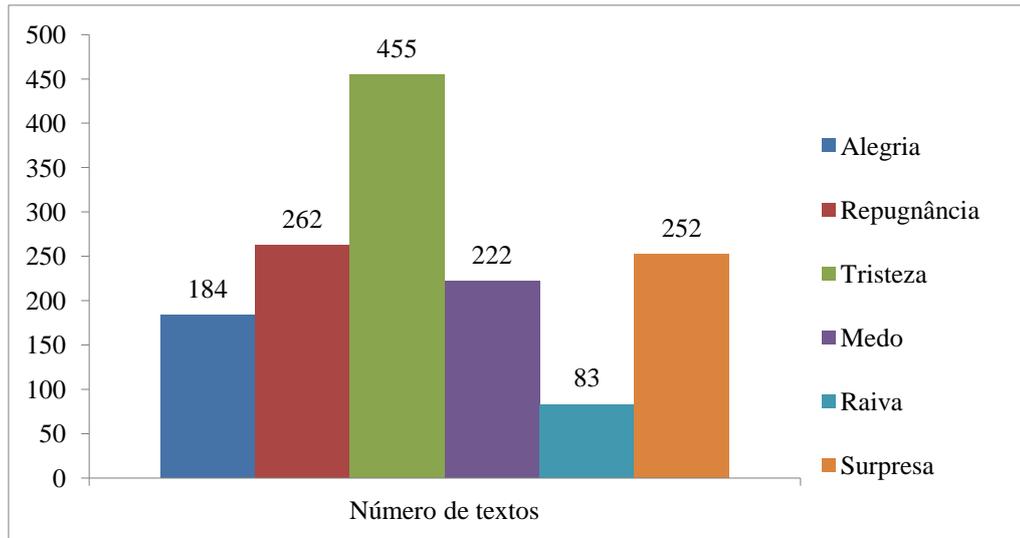


Gráfico 3.1: Exemplo de desbalanceamento das classes em um corpus de notícias. Fonte: Extraído do corpus de notícias detalhado no Capítulo 5

O problema do desbalanceamento das classes pode ser encontrado em diversos domínios. Um exemplo clássico é a detecção de fraudes em transações de cartão de crédito (STOLFO *et al.*, 1997), no qual o número de transações legítimas é muito maior que o número de transações fraudulentas.

Na literatura, as técnicas mais comumente utilizadas para tratar o problema do desbalanceamento dos dados são baseadas em *sobreamostragem*, *subamostragem* ou em ambas. A *sobreamostragem* aumenta o tamanho dos dados das classes minoritárias. Uma das formas de se realizar a *sobreamostragem* é repetir randomicamente os dados das classes minoritárias (CHAWLA; BOWYER, 2002). A *subamostragem* reduz o tamanho dos dados das classes majoritárias, removendo randomicamente os dados destas classes até que elas fiquem, aproximadamente, com o mesmo tamanho das classes minoritárias (KUBAT, M., MATWIN, 1997).

A combinação das técnicas em um mesmo conjunto de dados é feito realizando *sobreamostragem* dos dados das classes minoritárias e *subamostragem* nos dados das classes majoritárias (ESTABROOKS; JO; JAPKOWICZ, 2004). Essas técnicas têm desvantagens conhecidas. A *subamostragem* envolve a perda de informação por descartar dados potenciais úteis e a *sobreamostragem* aumenta o tamanho do conjunto de treinamento sem qualquer ganho de informação, replicando os dados e contribuindo para o acontecimento de um provável sobreajuste do modelo.

O problema do desequilíbrio das classes tem sido investigado há muito tempo por pesquisadores de AM e, apesar dos estudos desenvolvidos, a relação entre o desequilíbrio das classes e algoritmos de AM ainda não é totalmente clara. Apesar de haver uma diminuição no desempenho dos classificadores em muitos domínios desbalanceados, isto não significa que o desequilíbrio é o único responsável (PRATI; BATISTA; MONARD, 2004). O desbalanceamento dos dados, quando aliado à classes altamente sobrepostas, pode diminuir significativamente o desempenho de um classificador (SUN; WONG; KAMEL, 2009), (BATISTA; PRATI; MONARD, 2005).

A sobreposição das classes é causada devido à regiões ambíguas nos dados em que a probabilidade prévia de duas ou mais classes são aproximadamente iguais. A sobreposição das classes dificulta ou impossibilita a distinção entre duas ou mais classes (DENIL; TRAPPENBERG, 2010). Em (GARCIA; SANCHEZ; MOLLINEDA, 2007) foi realizado um estudo analisando o comportamento de seis algoritmos ao classificar dados desbalanceados e sobrepostos e foi concluído que a sobreposição é mais importante que o desbalanceamento dos dados para se obter um bom desempenho na classificação.

Na Tabela 3.1 é apresentado um exemplo onde é possível observar a frequência (número de ocorrências) de um conjunto de características em um conjunto de classes. Quando uma determinada característica ocorre demasiadamente em mais de uma classe, contribui para que haja sobreposição das classes durante o processo de treinamento de um classificador.

Tabela 3.1: Frequência das características nas classes. Fonte: Extraído do corpus de notícias detalhado no Capítulo 5

| Características | Frequência | <i>Neutro</i> | <i>Alegria</i> | <i>Repugnância</i> | <i>Tristeza</i> | <i>Medo</i> | <i>Raiva</i> | <i>Surpresa</i> |
|------------------------|-------------------|---------------|----------------|--------------------|-----------------|-------------|--------------|-----------------|
| ataque | 58 | 2 | 0 | 6 | 24 | 22 | 1 | 3 |
| acusar | 43 | 12 | 1 | 10 | 12 | 2 | 3 | 3 |
| matar | 67 | 0 | 1 | 3 | 37 | 12 | 12 | 2 |
| pessoa | 149 | 10 | 11 | 13 | 87 | 22 | 2 | 4 |
| policia | 57 | 2 | 1 | 19 | 16 | 11 | 2 | 6 |
| policia | 177 | 7 | 4 | 49 | 57 | 20 | 24 | 16 |
| suspeitar | 63 | 1 | 4 | 23 | 11 | 6 | 14 | 4 |
| vitimar | 93 | 2 | 1 | 11 | 50 | 13 | 11 | 5 |

Para reduzir a sobreposição (LAWRENCE et al., 1998) sugerem pré-processar os dados de maneira que resulte numa redução da sobreposição. Em (BATISTA; PRATI;

MONARD, 2005) os autores sugerem algumas estratégias de limpeza de dados que geralmente levam a uma melhoria de desempenho para conjuntos de dados altamente sobrepostos.

3.4. Pré-processamento

O pré-processamento desempenha um papel importante na AS, pois realiza a preparação do texto para a classificação (HADDI; LIU; SHI, 2013). Normalmente, o pré-processamento dos textos é composto pelos seguintes estágios: transformação do texto para letras minúsculas, remoção da acentuação, remoção dos caracteres especiais como sinais de pontuação, números, símbolos e hífen, remoção das *stopwords* e remoção de sufixos e/ou prefixos de palavras.

As *stopwords* são palavras que não possuem qualquer significado emocional ao texto, como por exemplo, as preposições, os artigos e as conjunções. Quando as *stopwords* são removidas podem melhorar o resultado da classificação. Outras classes de palavras auxiliares podem ser adicionadas à lista de *stopwords*, isso depende do domínio dos dados textuais.

A remoção de sufixos e/ou prefixos das palavras, também chamado de lematização é um processo de normalização morfológica e tem como objetivo reduzir as palavras às suas formas inflexionáveis e às suas derivações. Segundo (ARANHA, 2007), a lematização pode ser vista como inflexional, que considera apenas as remoções de flexões verbais, ou radical, que são removidas todas as formas de prefixos e sufixos dos termos. Conforme (CONRADO, 2009), os algoritmos de lematização realizam a eliminação de prefixos e sufixos das palavras ou a transformação de uma palavra para a sua forma infinitiva. Dessa forma, dois erros podem ocorrer durante um processo de lematização: o *overstemming*, que ocorre quando a parte removida da palavra não é um sufixo/prefixo e sim parte do radical, e *understemming*, que ocorre quando não se remove completamente o sufixo/prefixo. Por exemplo, a raiz da palavra "inteligência" é "intelig", porém, quando ocorre *overstemming*, o resultado pode ser "intel" e quando ocorre *understemming*, pode ser "inteligenc".

A maioria dos métodos de lematização são desenvolvidos para a língua Inglesa. Dentre os mais conhecidos na literatura, pode-se citar o algoritmo de Lovins (LOVINS, 1968), o algoritmo de Porter (PORTER, 1980) e o algoritmo de *Stemmer* (HARMAN, 1991). O algoritmo de Lovins (LOVINS, 1968) é executado em um único passo e remove apenas um sufixo por palavra, aquele que é mais longo. O algoritmo de Porter (PORTER, 1980) é formado por um conjunto de regras que se baseiam na remoção de sufixos e é executado em cinco passos

sendo que em cada passo realiza uma transformação no termo. O algoritmo de *Stemmer* (HARMAN, 1991) é o mais conservador, pois remove somente alguns finais de palavras como "ies", "es" e "s".

O algoritmo de Porter (PORTER, 1980) foi adaptado para o idioma Português Brasileiro e disponibilizado em Snowball². O algoritmo *PortugueseStemmer*, desenvolvido para o Português Brasileiro por (ORENGO; HUYCK, 2001), apesar de não ser baseado em (PORTER, 1980), também utiliza regras para a remoção dos sufixos, além disso, trata exceções por meio de um dicionário composto de 32.000 termos.

O Stembr (ALVARES et al., 2005) não usa regras para extrair o radical da palavra. Os prefixos e sufixos das palavras são removidos por meio do tratamento baseado em estudo estatístico da frequência das palavras contidas na web até 2005. Um outro lematizador proposto para o Português Brasileiro por (GONZALEZ et al., 2003), se chama NILP (Normalizador de Itens Lexicais em Português) e consiste em uma redução menos drástica dos sufixos das palavras. Por exemplo, as palavras "construções" e "construiremos" são transformadas, respectivamente, para "construção" e "construir".

Um estudo realizado por (VIERA; VIRGIL, 2007) faz uma comparação dos principais algoritmos de lematização para a língua Portuguesa Brasileira. Segundo este estudo, o algoritmo de (ORENGO; HUYCK, 2001), apresenta a melhor eficácia e gera menos erros de *overstemming* e *understemming*.

3.5. Seleção de Características e Representação Vetorial

Segundo (NICOLOSI, 2008), identificar corretamente as características relevantes dos textos é de importância vital para a tarefa de classificação de textos. Diversos métodos de seleção de características são propostos na literatura, os mais comumente utilizados são apresentados na sequência.

A Frequência de Documentos (*Document Frequency*) se refere ao número de documentos no qual um termo ocorre. Segundo (PEDERSEN; YANG, 1997), esse cálculo é realizado para cada termo do conjunto de treinamento. É removido do conjunto de características o termo cuja frequência nos documentos for inferior a um limiar pré-determinado. O pressupos-

² <http://snowball.tartarus.org>

to básico desse método é que termos raros não são informativos para a previsão da categoria ou não têm influência no desempenho global.

O Ganho de Informação (*Information Gain*) - GI (BAEZA-YATES; RIBEIRO-NETO, 2013) é um método usado para selecionar os termos mais representativos do conjunto de treinamento. O valor GI de um termo é definido nas equações 3.1 e 3.2. A Equação 3.1 mede o grau de entropia de cada termo em relação às classes. Na Equação 3.2 o conjunto de treinamento S pode ter c diferentes classes e p_i é a proporção dos dados em S que pertencem à classe i .

$$Entropia(S) = \sum_{i=1}^c (-p_i \log_2 p_i) \quad (3.1)$$

A Equação 3.2 define o valor de GI de um termo t do conjunto de treinamento S e v é o valor do termo.

$$GI(S, t) = Entropia(S) - \sum \frac{|S_v|}{|S|} Entropia(S_v) \quad (3.2)$$

Dado um conjunto de dados de treinamento, para cada termo é calculado o GI. São removidos do conjunto de características os termos que apresentarem um GI inferior a um limiar pré-determinado.

A Informação Mútua (*Mutual Information*) - IM é definida por meio das equações 3.3 e 3.4. A Equação 3.3 mede o grau de dependência de um termo em relação às classes e a Equação 3.4 determina a informação máxima do termo sobre todas as classes (BAEZA-YATES; RIBEIRO-NETO, 2013).

$$IM(k_i, C) = \sum_{p=1}^L \frac{n_p}{N_t} \log \left(\frac{\frac{n_{i,p}}{N_t}}{\frac{n_i}{N_t} \cdot \frac{n_p}{N_t}} \right) \quad (3.3)$$

k_i é o conjunto de termos, C é o conjunto de classes, L é o número de classes, n_p é o número total de documentos que são da c_p , N_t é o número total de documentos do conjunto de treinamento, $n_{i,p}$ são documentos contendo k_i e que são da classe c_p e n_i é o número total de documentos contendo k_i .

$$I_{\max}(k_i, C) = \max_{p=1}^L \left(\frac{\frac{n_{i,p}}{N_t}}{\frac{n_i}{N_t} \cdot \frac{n_p}{N_t}} \right) \quad (3.4)$$

Para cada termo é calculado o valor de IM e são removidos do conjunto de características os termos que apresentarem um valor de IM inferior a um limiar pré-estabelecido.

A estatística X^2 (*CHI Square*) mede a dependência entre um termo t e uma categoria c . Sendo A o número de vezes que t e c ocorrem simultaneamente, B o número de vezes que t ocorre em c , C é o número de vezes que c ocorre sem t , D é número de vezes que nem c e nem t ocorrem e N é o número total de documentos. O melhor termo é definido pela Equação 3.5 (SEBASTIANI, 2002) e (PEDERSEN; YANG, 1997).

$$X^2(t, c) = \frac{N(AD - CB)^2}{(A + C)(B + D)(A + B)(C + D)} \quad (3.5)$$

Se o valor de $X^2(t, c)$ for 0, eles são independentes. Sendo m o conjunto de categorias, a Equação 3.6 calcula o X^2 para cada categoria e a Equação 3.7 calcula o X^2 máximo de t entre todas as categorias.

$$X^2(t) = \sum_{i=1}^m P(c_i) X^2(t, c_i) \quad (3.6)$$

$$X^2max(t) = \max_{i=1}^m \{ X^2(t, c_i) \} \quad (3.7)$$

O *Gain Ratio* (SHARMA; DEY, 2012) é um método que permite aumentar o GI, uma vez que normaliza a contribuição de todas as características para decisão final na classificação de um documento. Um processo iterativo seleciona conjuntos menores de características e vai decrementando e utilizando a pontuação *Gain Ratio*. As iterações encerram-se quando um número predefinido de características permanece. O *Gain Ratio* é usado como uma medida de disparidade e alta pontuação *Gain Ratio* indica que as características selecionadas serão úteis para a classificação. O *Gain Ratio* foi introduzido em árvore de decisão (C4.5) por (QUINLAN, 1993). O valor da informação de divisão (Equação 3.8) é expresso pela informação prospectiva obtida dividindo o conjunto de treinamento D em v separações, correspondendo a v resultados na característica A . O *Gain Ratio* final é definido na Equação 3.9.

$$\text{SplitInfo}_A(D) = - \sum_{j=1}^v \frac{|D_j|}{|D|} \log_2 \frac{|D_j|}{|D|} \quad (3.8)$$

$$\text{Gain Ratio}(A) = \text{IG}(A)/\text{SplitInfo}(A) \quad (3.9)$$

Segundo (SHARMA; DEY, 2012), o uso de métodos de seleção de características pode contribuir para melhorar consideravelmente o desempenho da classificação em AS, porém para cada problema deve ser avaliado qual é o melhor método de seleção de características a ser utilizado.

Após selecionar as melhores características, os documentos são representados de forma vetorial. A maneira mais simples de representar os documentos em um processo de classificação de textos é a utilização do método *bag-of-words*, também chamado de Frequência de Características (*Feature Frequency*) por (PANG; LEE; VAITHYANATHAN, 2002). O método cria uma lista dos termos que aparecem no conjunto total de documentos e representa cada documento como um vetor composto pelo número de ocorrências de cada termo. Por exemplo, se o termo "excelente" apareceu duas vezes em um determinado documento, o peso associado a esse termo no vetor deste documento terá um valor 2.

Um outro método de representação de documentos, usado por (PANG; LEE; VAITHYANATHAN, 2002) e (O'KEEFE; KOPRINSKA, 2009), é a Presença de Características (*Feature Presence*). A Presença de Características é semelhante a Frequência de Características, exceto que ao invés de utilizar a frequência de uma característica como o seu valor, utiliza apenas o valor 1 para indicar que a palavra existe no documento e 0 para indicar que ela existe no conjunto total de documentos, mas não no documento em questão.

Um método de representação que adiciona pesos em termos com base em sua frequência foi proposto por (JONES, 1972) e usado por (SALTON; BUCKLEY, 1988) para fazer análise automática de textos. O método, chamado de TF-IDF (*Term Frequency - Inverse Document Frequency*) leva em conta que: 1) quanto mais frequentemente um termo ocorre em um documento, mais representativo ele é para o conteúdo e 2) quanto mais documentos o termo ocorre, menos discriminativo ele é (SEBASTIANI, 2002). Esse método atribui um peso $w_{t,d}$ para um termo t em um documento d , de acordo com a Equação 3.10. O valor $tf_{t,d}$ é o número de vezes que o termo t aparece no documento d , N é o número total de documentos que fazem parte do conjunto de dados e df_t (Equação 3.11) é o número de documentos que contém o termo t .

$$w_{t,d} = tf_{t,d} \cdot idf_t \quad (3.10)$$

$$idf_t = \log \frac{N}{df_t} \quad (3.11)$$

Na seção seguinte são apresentados os algoritmos de AM mais utilizados na construção de métodos de AS.

3.6. Algoritmos de Aprendizagem de Máquina para a Classificação de Emoções em Textos

Como já foi visto na Seção 3.1, a AM pode ser classificada em dois grupos principais, AM supervisionada e AM não supervisionada. Essas duas categorias de aprendizagem estão associadas com diferentes algoritmos de AM que representam como o método de aprendizagem funciona.

A AM supervisionada é composta por algoritmos que "aprendem" a partir de exemplos fornecidos previamente para produzir hipóteses gerais que permitem fazer previsões sobre novos exemplos (OMARY; MTENZI, 2010). Em geral, cada exemplo é descrito por um vetor de características e o rótulo da classe associada. O objetivo da AM supervisionada é construir um classificador que possa determinar corretamente a classe de novos exemplos não rotulados. Para rótulos de classe discretos, esse problema é conhecido como classificação, e para valores contínuos, como regressão (MONARD; BARANAUSKAS, 2003). Existem diversos algoritmos de AM supervisionada, dentre eles, os mais utilizados quando se trata de identificar emoções em textos são: *Support Vector Machines*, *Naive Bayes*, *K-Nearest Neighbour*, Redes Neurais e Máxima Entropia. Esses algoritmos são apresentados na seção seguinte.

A AM não supervisionada constrói modelos de dados sem o uso de exemplos rotulados. Isto significa que nenhum "supervisor" está disponível e a aprendizagem deve contar com a orientação obtida heurísticamente pelo sistema ao examinar diferentes amostras de dados (OMARY; MTENZI, 2010). Uma abordagem de AM não supervisionada foi usada para analisar emoções em (TURNEY, 2002), (GODBOLE; SRINIVASAIAH, 2007), (HU; LIU,

2004b), (ESULI; SEBASTIANI, 2006), (KAJI; KITSUREGAWA, 2007), (TABOADA et al., 2011) e (KIRITCHENKO; ZHU; MOHAMMAD, 2014).

Do ponto de vista da AM, o problema de classificar emoções em textos é relativamente complexo devido às características dos dados, que possuem alta dimensionalidade e são esparsos. Os dados com alta dimensionalidade implicam em restrições computacionais, enquanto os dados esparsos contribuem para que documentos sejam classificados com base em um pequeno número de características. Assim, encontrar um algoritmo que, ao mesmo tempo, seja eficiente e generalize bem é um desafio para este domínio de aplicação (SU; SHIRAB; MATWIN, 2011). Existem diversos algoritmos de AM supervisionada disponíveis na literatura. Na sequência são apresentados os que são mais utilizados na AS.

3.6.1. Máquina de Vetores de Suporte (*Support Vector Machine* - SVM)

A tarefa de classificação envolve um conjunto de dados de treinamento. Cada instância do conjunto de treinamento contém um "valor alvo" que se refere à classe ou rótulo. O objetivo do SVM é produzir um modelo, com base nos dados de treinamento, que prevê os valores alvos (classe) dos novos dados (HSU; CHANG; LIN, 2010).

A ideia principal dos classificadores baseados em SVM é a construção de um hiperplano ótimo de forma que ele possa separar diferentes classes de dados com a maior margem possível. Os hiperplanos SVM são determinados por um subconjunto relativamente pequeno de exemplos de treinamento, que são chamados de vetores de suporte (FELDMAN; SANGER, 2007). A Figura 3.3 ilustra um hiperplano ótimo para um conjunto de dados linearmente separáveis.

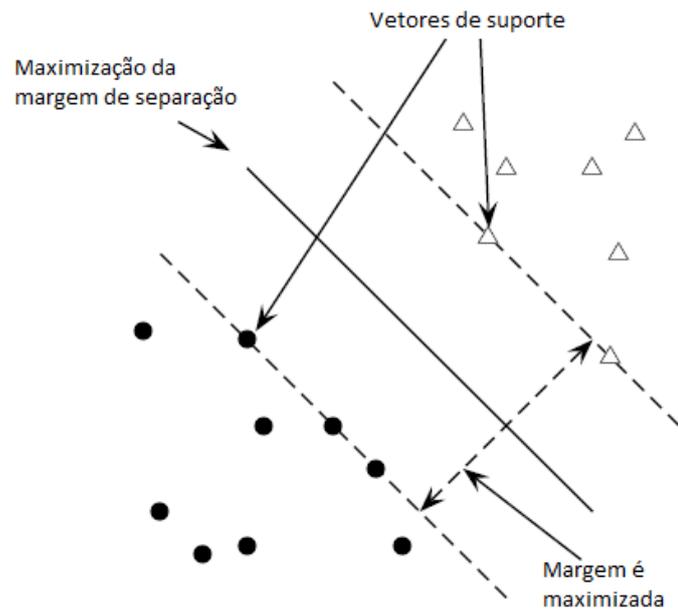


Figura 3.3: Identificação da margem e dos vetores de suporte. Fonte: Adaptada de (MANNING; RAGHAVAN; SCHÜTZE, 2008)

O SVM é eficaz na classificação de conjunto de dados que são linearmente separáveis. Porém há muitos casos em que não é possível dividir satisfatoriamente os dados de treinamento por um hiperplano, como é o caso dos dados exibidos na Figura 3.4a.

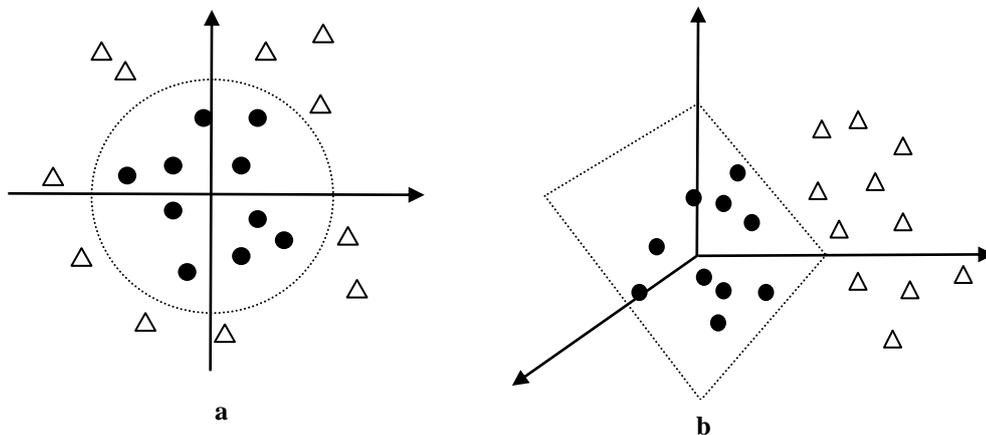


Figura 3.4: a) Dados não linearmente separáveis; b) Dados em uma dimensão linearmente separáveis. Fonte: Adaptada de (MÜLLER et al., 2001)

Dessa forma, o SVM mapeia o conjunto de treinamento de seu espaço original para um novo espaço de maior dimensão (Figura 3.4b) chamado de espaço de características (HEARST et al., 1998). O uso desse procedimento é motivado pelo teorema de Cover

(HAYKIN, 1999). Dado um conjunto de dados não linear no espaço de entrada, esse teorema indica que o espaço de entrada pode ser transformado em um espaço de características com alta probabilidade dos objetos serem linearmente separáveis. Logo, mapeiam-se inicialmente os objetos para um espaço de maior dimensão e aplica-se um SVM linear sobre esse espaço. É encontrado, então, o hiperplano com maior margem de separação, garantindo assim uma boa generalização (FACELI et al., 2011). Em (JOACHIMS, 1998), o SVM se mostrou ser altamente eficaz na categorização de textos, geralmente superando outros algoritmos de classificação.

Como o espaço de características pode ter uma dimensão muito alta (dependendo dos dados), a computação pode ser extremamente custosa ou inviável. Dessa forma, é necessário realizar cálculo de produtos escalares entre os objetos no espaço de características. Isso é obtido com o uso de funções *kernels*. Na Figura 3.5 é possível visualizar um exemplo que mostra a superfície de decisão para quatro classificadores SVM com diferentes *kernels*. A base de dados usada no exemplo é a *Iris Data Set*³ e foram usadas no exemplo apenas duas características: *sepal width* e *sepal length*.

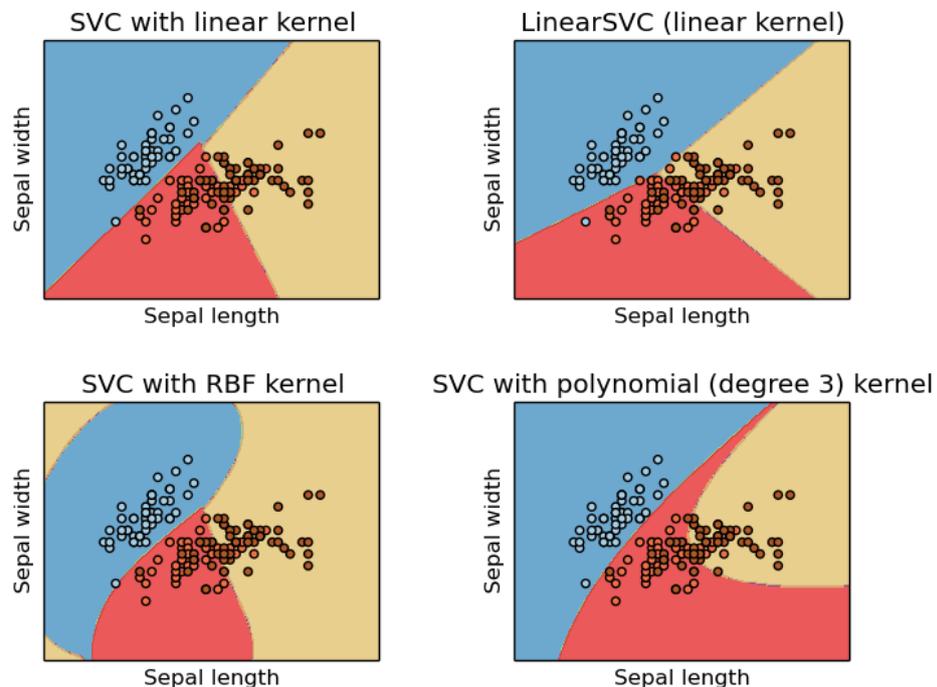


Figura 3.5: Superfície de decisão para quatro classificadores SVM com diferentes *kernels*.

Fonte: Disponível em <http://scikit-learn.org/stable>

³ <http://archive.ics.uci.edu/ml/datasets/Iris>

Os modelos não lineares têm limites de decisão mais flexíveis que os *kernels* lineares, com formas que dependem do tipo de *kernel* que é utilizado e dos seus parâmetros. Mesmo com a utilização de *kernels*, os dados reais normalmente possuem pontos que fogem do padrão esperado (*outliers*). Em geral, é possível fazer um ajuste perfeito, utilizando-se de *kernels* e outras parametrizações que façam o algoritmo se ajustar perfeitamente aos dados, porém esta possibilidade pode levar a ocorrência de sobreajuste (*overfitting*) nos dados, que significa que o modelo criado está tão bem ajustado aos dados, que não consegue generalizar bem para novos dados (GROOT, 2012). O modelo ideal, portanto, deve possuir um balanceamento entre estar bem ajustado com os dados de teste e estar bem generalizado para novos dados. No SVM, esse balanceamento é feito por meio do parâmetro C (*cost*), que controla o peso que um erro tem para o modelo, sendo que um C alto penaliza severamente cada erro, fazendo com que o modelo se ajuste mais aos dados para diminuir o erro (BOSER; GUYON; VAPNIK, 1992).

Segundo (HSU; CHANG; LIN, 2010), para o SVM existem quatro funções básicas de kernels: Linear, Polinomial, RBF (*Radial Basis Function*) e Sigmoidal. Os kernels podem ser vistos na Tabela 3.4 e γ , r e d são parâmetros kernel.

Tabela 3.2: Kernels SVM. Fonte: Adaptada de (HSU; CHANG; LIN, 2010)

| | |
|------------|--|
| Linear | x_i, x_j |
| Polinomial | $(\gamma x_i, x_j + r)^d, \gamma > 0$ |
| RBF | $\exp(-\gamma \ x_i, x_j\ ^2), \gamma > 0$ |
| Sigmoidal | $\tanh(\gamma x_i, x_j + r)$ |

O SVM foi projetado originalmente para a solução de problemas de classificação contendo apenas duas classes, entretanto, muitos problemas de classificação são multiclasse. Este fato não inviabiliza o uso do SVM e algumas técnicas são propostas para estendê-lo para essa finalidade. Uma estratégia para solucionar problemas que contenham mais de duas classes é combinar os classificadores gerados em subproblemas binários, sendo essa estratégia conhecida como decomposição (LORENA, 2006). Duas abordagens usuais para realizar a decomposição são chamadas de “*Um-Contra-Todos*” e “*Um-Contra-Um*”.

Na abordagem “*Um-Contra-Todos*” um problema com k classes é decomposto em k problemas binários. Por exemplo, para cada classe, um problema binário é criado e todas as

instâncias que pertencem à classe são consideradas exemplos positivos, enquanto que as instâncias restantes são consideradas exemplos negativos. Um classificador binário é construído para separar as duas classes. Na Tabela 3.5 é mostrado o exemplo de um problema com quatro classes decomposto por meio da abordagem “*Um-Contra-Todos*”.

Tabela 3.3: Exemplo de abordagem multiclasse utilizando a estratégia “*Um-Contra-Todos*”.

Fonte: Adaptada de (LORENA, 2006).

| Classes | Classificadores binários | | | |
|---------|--------------------------|----|----|----|
| | 1 | 2 | 3 | 4 |
| 1 | +1 | -1 | -1 | -1 |
| 2 | -1 | +1 | -1 | -1 |
| 3 | -1 | -1 | +1 | -1 |
| 4 | -1 | -1 | -1 | +1 |

A segunda abordagem, conhecida como “*Um-Contra-Um*”, constrói $k(k-1)/2$ classificadores binários onde cada classificador é usado para distinguir entre um par de classes. As instâncias que não pertencem a nenhuma das classes do classificador binário são ignoradas.

Tanto na abordagem “*Um-Contra-Todos*” quanto na abordagem “*Um-Contra-Um*”, uma determinada instância é classificada pela combinação das previsões feitas pelos classificadores binários. Um esquema de votação é geralmente empregado para combinar as previsões, onde a classe que recebe o maior número de votos é atribuída à instância. Na abordagem “*Um-Contra-Todos*”, se uma instância for classificada como negativa, então todas as classes, exceto a positiva, recebem um voto (TAN; STEINBACH; KUMAR, 2009). Na abordagem “*Um-Contra-Todos*” também é utilizada uma estratégia de votação onde para cada classificação binária é considerada uma votação e no final é designada a classe com o maior número de votos. Na Tabela 3.6 segue um exemplo de um problema com quatro classes decomposto por meio da abordagem “*Um-Contra-Um*”.

Tabela 3.4: Exemplo de abordagem multiclasse utilizando a estratégia “*Um-Contra-Um*”.

Fonte: Adaptada de (LORENA, 2006).

| Classes | Classificadores binários | | | | | |
|---------|--------------------------|----|----|----|----|----|
| | 1 | 2 | 3 | 4 | 5 | 6 |
| 1 | +1 | +1 | +1 | 0 | 0 | 0 |
| 2 | -1 | 0 | 0 | +1 | +1 | 0 |
| 3 | 0 | -1 | 0 | -1 | 0 | +1 |
| 4 | 0 | 0 | -1 | 0 | -1 | -1 |

Uma alternativa à estratégia de votação utilizada na abordagem “*Um-Contra-Um*” é transformar as saídas dos classificadores binários em estimativas de probabilidades e então atribuir a instância à classe que possui um valor mais alto de probabilidade estimada (TAN; STEINBACH; KUMAR, 2009).

Segundo (CHANG; LIN, 2011), o SVM prevê somente rótulos de classe sem fornecer informação probabilística, porém algumas implementações estendem o SVM para que ele possa estimar probabilidades, como pode ser visto em (WU; LIN; WENG, 2004).

Dadas k classes de dados, para cada exemplo x , o objetivo é estimar $p_i = P(y=i / x)$, onde $i = 1, \dots, k$ e y é o rótulo da classe.

Seguindo a abordagem de classificação multiclasse *Um-Contra-Um*, é necessário estimar a probabilidade dos pares de classes $r_{ij} \approx P(y=j / y=i \text{ ou } j, x)$ usando uma implementação de Platt em (PLATT, 1999) ou de (LIN; LIN; WENG, 2007).

3.6.2. Naive Bayes (NB)

O classificador *Naive Bayes* é bastante utilizado na classificação de textos devido a sua eficiência computacional e por ter um bom desempenho preditivo. Diversos autores (LEWIS, 1994), (MCCALLUM; NIGAM, 1998), (MLADENIĆ; GROBELNIK, 1999), (MLADENIĆ; GROBELNIK, 2003), (KIM et al., 2006), (SU; SHIRAB; MATWIN, 2011) aplicaram o *Naive Bayes* para a classificação de textos. O classificador *Naive Bayes* também é bastante utilizado na classificação de emoções em textos e foi usado para esse fim em trabalhos como (STRAPPARAVA; MIHALCEA, 2008), (SPASIC et al., 2012) (KANG; YOO; HAN, 2012), (NARAYANAN; ARORA; BHATIA, 2013).

O classificador *Naive Bayes* é chamado de ingênuo por assumir que as probabilidades são combinadas independentemente uma da outra, ou seja, a probabilidade de um termo no documento estar numa categoria específica não está relacionada com a probabilidade de outros termos estarem nesta categoria (SEGARAN, 2007).

Os classificadores bayesianos utilizam o Teorema de *Bayes* para realizar a tarefa de classificação de dados. Sendo X o conjunto de características e Y a variável da classe, pode-se capturar o seu relacionamento usando probabilisticamente $P(Y/X)$ (Equação 3.12).

$$P(Y | X) = \frac{P(X | Y) \cdot P(Y)}{P(X)} \quad (3.12)$$

Segundo (PANG; LEE; VAITHYANATHAN, 2002), na abordagem de classificação de textos, se deseja atribuir uma classe c para um documento d (equação 3.13).

$$P(c | d) = \frac{P(d | c) \cdot P(c)}{P(d)} \quad (3.13)$$

Sendo que $P(d)$ não desempenha nenhum papel na seleção de c e para estimar $P(d/c)$, assume-se que as probabilidades de cada característica são independentes da classe.

3.6.3. *K-Nearest Neighbors* (KNN)

A ideia deste algoritmo de classificação é encontrar todos os exemplos de treinamento que sejam relativamente semelhantes às características do exemplo de teste. Um classificador de vizinho mais próximo representa cada exemplo como um ponto de dado em um espaço d -dimensional, onde d é o número de características. Dado um exemplo de teste, é calculado a sua proximidade com o resto dos pontos de dados no conjunto de treinamento por meio de uma medida de proximidade. Os k vizinhos mais próximos de um determinado exemplo z se referem aos k pontos que estejam mais próximos de z (TAN; STEINBACH; KUMAR, 2009).

O algoritmo calcula a distância entre cada exemplo de teste $z=(x', y')$ e todos os seus exemplos de treinamento (x, y) para determinar a sua lista de vizinhos mais próximos. Esse cálculo pode ser custoso se o número de exemplos de treinamento for grande, dessa forma técnicas de indexação são utilizadas para reduzir a quantidade de cálculos necessários para encontrar os k vizinhos mais próximos de um exemplo (TAN; STEINBACH; KUMAR, 2009).

Segundo (JIANG et al., 2012), o KNN é um método simples para categorizar texto e já foi usado em diversos trabalhos, como por exemplo, (YANG; YANG, 1999), (HAN; KARYPIS; KUMAR, 2001), (GUO et al., 2005). Porém o algoritmo apresenta algumas desvantagens como a complexidade computacional e o seu desempenho é facilmente afetado por amostras de treinamento com ruídos. Alguns pesquisadores procuram formas de reduzir a complexidade do KNN, que pode ser normalmente dividido em três métodos: reduzir as dimensões do vetor do texto (DE VRIES et al., 2002), reduzir a quantidade de exemplos de treinamento (YUAN; YANG; YU, 2007) e acelerar o processo de encontrar os K vizinhos mais próximos (AGHBARI, 2005) e (WANG; WANG, 2007).

3.6.4. Redes Neurais Artificiais (RNA)

As redes neurais buscam implementar modelos matemáticos que se assemelhem às estruturas neurais biológicas. Dessa forma, apresentam capacidade de adaptar os seus parâmetros como resultado da interação com o meio externo, melhorando gradativamente o seu desempenho na solução de um determinado problema (FERNEDA, 2006).

Segundo (SEBASTIANI, 2002), uma rede neural para classificação de texto é uma rede de unidades, onde as unidades de entrada representam os termos, as unidades de saída representam a categoria ou as categorias de interesse, e os pesos nas extremidades de conexão são unidades que representam relações de dependência. Para classificar um documento de teste, os pesos do termo são carregados nas unidades de entrada; a ativação destas unidades é propagada para a frente por meio da rede, e o valor da unidade de saída de decisão determina a classificação. Uma forma típica do uso de redes neurais artificiais é a retropropagação, em que os pesos de um documento de treinamento são carregados nas unidades de entrada, e se um erro de classificação ocorre, o erro é propagado de volta, de modo a mudar os parâmetros da rede de forma a eliminar ou minimizar o erro.

As redes neurais artificiais foram usadas na categorização de textos em alguns trabalhos como (YIN; SAVIO, 1996), (RUIZ; SRINIVASAN, 1997), (RAMASUNDARAM; VICTOR, 2010), (JO, 2010) e na classificação de emoções em (SEOL; KIM; KIM, 2008), (UNLUTURK; OGUZ; ATAY, 2010), (HENDY; FARAG, 2013).

3.6.5. Máxima Entropia (ME)

Um classificador de máxima entropia é um modelo probabilístico que favorece a distribuição mais uniforme de classes que aderem a um conjunto específico de restrições que são determinadas com base nos dados de treinamento. Em (CUONG et al., 2006) é dado um exemplo no domínio da categorização de textos: Dado um documento d e três classes c_1, c_2, c_3 , se não é conhecido nada sobre o documento a partir dos dados de treinamento, pode-se dizer que a probabilidade de classificar o documento d em cada uma das classes é igual, ou seja, $1/3$. Mas se foi "aprendido" com os dados de treinamento que $2/3$ dos documentos que têm palavra "esportes" pertencem a classe c_1 e o documento d tem a palavra "esportes", é possível dizer que a probabilidade de classificação do documento d para a classe c_1 é $2/3$ e a probabilidade de classificar o documento d nas classes c_2 e c_3 é igual a $1/3$ cada. Os dados da amostra fornecem tais características e eles vão ser usados para determinar as restrições.

Classificadores de máxima entropia foram usados para classificar textos em trabalhos como (NIGAM; LAFFERTY; MCCALLUM, 1999), (ZHANG; YAO, 2003) e (ZHU et al., 2005), e para classificar emoções em (PANG; LEE; VAITHYANATHAN, 2002) e (LEE; BHD, 2011).

O Classificador de Stanford⁴ (MANNING; KLEIN, 2003) é uma ferramenta baseada em máxima entropia e foi desenvolvida para a classificação de textos. Também vem sendo bastante utilizada na AS.

3.7. Avaliação de Algoritmos de Classificação

Para se obter um desempenho preditivo mais confiável em um processo de classificação, normalmente são definidos conjuntos de treinamento, teste e validação. Os dados de treinamento são empregados na indução do modelo, os dados de validação no ajuste do modelo, enquanto os exemplos de teste simulam a apresentação de objetos novos ao classificador, os quais não foram vistos na sua indução. A avaliação por conjunto de teste e a Validação Cruzada são dois métodos de amostragem bastante utilizados (FACELI et al., 2011) em métodos de AS.

Na avaliação por conjunto de teste, normalmente o conjunto de dados é particionado aleatoriamente em 70% dos dados para o treinamento e 30% dos dados para o teste ou em 50% para o treinamento, 25% para a validação e 25% para o teste. O problema desse método é que esse tipo de divisão do conjunto de dados pode subestimar a taxa de acerto, uma vez que um classificador produzido sobre todos os objetos em geral apresentará uma taxa de acerto maior que a gerada a partir de uma parte deles (BARANAUSKAS; MONARD, 2000). Porém, segundo (MICHIE; SPIEGELHALTER; TAYLOR, 1994), para conjuntos de dados grandes isso não representa um problema. Outra crítica usual à avaliação por conjunto de teste é que o modelo pode ficar altamente dependente da composição dos conjuntos (TAN; STEINBACH; KUMAR, 2009).

No método de Validação Cruzada, o conjunto de exemplos é dividido em n subconjuntos de tamanho aproximadamente igual. Os objetos de $n-1$ partições são utilizados no treinamento do classificador, o qual é testado na partição restante. Esse processo é repetido n vezes, utilizando em cada ciclo uma partição diferente para o teste. O acerto total é obtido pela soma

⁴ <http://www-nlp.stanford.edu/software/classifier.shtml>

dos acertos nas n execuções. A desvantagem desse método é que, conforme o tamanho do conjunto de dados, pode ser computacionalmente custoso repetir o procedimento n vezes (TAN; STEINBACH; KUMAR, 2009).

A avaliação de um algoritmo de AM supervisionada é realizada pela análise do desempenho do classificador gerado pelo algoritmo durante a atribuição de rótulos aos novos exemplos, não apresentados previamente em seu treinamento (MONARD; BARANAUSKAS, 2003). Uma forma de verificar o desempenho de um classificador é o uso dos dados de uma matriz de confusão.

A matriz de confusão ilustra o número de classificações corretas e incorretas de cada classe. As linhas da matriz representam as classes verdadeiras e as colunas, as classes preditas pelo classificador. A diagonal principal representa os acertos do classificador, enquanto os outros elementos correspondem aos erros cometidos nas suas predições. Por meio da matriz de confusão, tem-se medidas quantitativas de quais classes o algoritmo de aprendizado tem maior dificuldade em acertar (FACELI et al., 2011). Para um problema binário, onde usualmente uma classe é chamada de positiva e a outra de negativa, tem-se a matriz de confusão ilustrada na Tabela 3.7.

Tabela 3.5: Matriz de confusão para um problema binário. Fonte: (KOHAVI; PROVOST, 1998).

| | | Classe predita | |
|-------------|----------|----------------|----------|
| | | Positiva | Negativa |
| Classe real | Positiva | VP | FN |
| | Negativa | FP | VN |

- *VP (Verdadeiro Positivo)* é o número de exemplos da classe positiva classificados corretamente.
- *VN (Verdadeiro Negativo)* é o número de exemplos da classe negativa classificados corretamente.
- *FP (Falso Positivo)* é o número de exemplos cuja classe verdadeira é negativa, mas que foram classificados incorretamente como sendo da classe positiva.
- *FN (Falso Negativo)* é o número de exemplos cuja classe verdadeira é positiva, mas que foram classificados incorretamente como sendo da classe negativa.

Para um problema multiclasse, as instâncias podem ser corretamente ou incorretamente classificadas em relação a qualquer uma das c classes. A Tabela 3.8 apresenta a matriz de

confusão para múltiplas classes. Nesse contexto, c representa a classe e a a amostra pertencente à classe.

Tabela 3.6: Matriz de confusão para um problema multiclasse.

| | Predição c_1 | Predição c_2 | Predição c_3 | ... | Predição c_n |
|--------------|----------------|----------------|----------------|-----|----------------|
| Classe c_1 | a_{11} | a_{12} | a_{13} | ... | a_{1n} |
| Classe c_2 | a_{21} | a_{22} | a_{23} | ... | a_{2n} |
| Classe c_3 | a_{31} | a_{32} | a_{33} | ... | a_{3n} |
| ⋮ | ⋮ | ⋮ | ⋮ | ⋮ | ⋮ |
| Classe c_n | a_{n1} | a_{n2} | a_{n3} | ... | a_{nn} |

A partir da matriz de confusão, uma série de medidas quantitativas de desempenho pode ser derivada, dentre elas:

- **Taxa de erro:** é o número de classificações incorretas, ou seja, é a soma de falsos positivos e falsos negativos dividido pelo número total de classificações (Equação 3.14).

$$\text{Taxa de Erro} = \frac{FP + FN}{VP + VN + FN + FP} \quad (3.14)$$

- **Taxa de acerto ou acurácia:** é o número de classificações corretas, ou seja, a soma dos verdadeiros positivos e verdadeiros negativos, dividido pelo número total de classificações (Equação 3.15).

$$\text{Acurácia} = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.15)$$

- **Precisão:** é o número de verdadeiros positivos dividido pela soma dos verdadeiros positivos e dos falsos positivos (Equação 3.16). Desta forma, VP pode ser $a_{11}, a_{22}, a_{33}, \dots, a_{nn}$ e FP pode ser $a_{21}, a_{31}, \dots, a_{n1}$.

$$\text{Precisão} = \frac{VP}{VP + FP} \quad (3.16)$$

- **Cobertura:** é o número de verdadeiros positivos, dividido pelos verdadeiros positivos e falsos negativos (Equação 3.17). Desta forma, VP pode ser $a_{11}, a_{22}, a_{33}, \dots, a_{nn}$ e FN pode ser $a_{12}, a_{13}, \dots, a_{1n}$.

$$\text{Cobertura} = \frac{VP}{VP + FN} \quad (3.17)$$

- **F1:** é a média harmônica das medidas de Precisão e de Cobertura (Equação 3.18):

$$F1 = \frac{2 \cdot \text{Precisão} \cdot \text{Cobertura}}{\text{Precisão} + \text{Cobertura}} \quad (3.18)$$

Quando se trata de um problema de classificação multiclasse, é importante observar as medidas de desempenho por classe e a classificação global que geralmente avaliada é por meio de média ponderada calculada em função do número de amostras de cada classe.

3.8. Considerações Finais

Neste capítulo foram apresentadas as principais abordagens utilizadas na classificação de emoções em textos. De tais abordagens, enfatizou-se a AM supervisionada, que é usada na construção do método proposto nesta pesquisa. Também foram pesquisados os principais conceitos, técnicas e algoritmos que podem ser aplicados na construção de um método de classificação de emoções em textos. Além dos algoritmos citados, recentemente, alguns pesquisadores têm feito uso de Aprendizagem Profunda (*Deep Learning*) como abordagem para métodos de Análise de Sentimento.

A Aprendizagem Profunda pode ser considerada um avanço da AM tradicional e atualmente vem despertando um grande interesse da comunidade científica que atua em PLN. Segundo (BENGIO; COURVILLE; VINCENT, 2013), as arquiteturas profundas são compostas de vários níveis de operações não lineares. Desta forma, a profundidade de uma arquitetura refere-se ao número de operações não lineares atribuídas a ela. Em uma Rede Neural, essas operações correspondem ao número de camadas.

Implementar arquiteturas profundas é uma tarefa de otimização difícil, mas alguns modelos de Aprendizagem Profunda vêm sendo utilizados com sucesso em muito domínios, incluindo as tarefas de classificação de textos. Alguns exemplos de uso de Aprendizagem Profunda em AS podem ser vistos nos trabalhos de (SOCHER et al., 2013)⁵, (TANG et al., 2014), (SEVERYN; MOSCHITTI, 2015), (BOWMAN; MANNING; POTTS, 2015).

⁵ <http://nlp.stanford.edu/sentiment/>

Capítulo 4

Estado da Arte

O objetivo principal deste capítulo é buscar na literatura trabalhos de AS desenvolvidos para textos em Português Brasileiro, que identifiquem categorias de emoções em textos e que não façam o uso de léxico de emoções para classificar ou para auxiliar no processo de classificação dos textos. Dessa forma, a primeira seção deste capítulo trata deste assunto.

A segunda seção é destinada à apresentação de trabalhos de AS em textos desenvolvidos para outros idiomas que estejam relacionados, mesmo que indiretamente, com o método de identificação de emoções que está sendo proposto neste trabalho.

A seleção dos trabalhos apresentados neste capítulo foi realizada por meio do acesso a diversos repositórios de pesquisa, dentre os quais estão: *SciencDirect*⁶, *IEEEexplore*⁷, *CiteSeer*⁸, *ACM Digital Library*⁹, *Google Scholar*¹⁰ e *ResearchGate*¹¹. Para dar início à busca foram utilizadas palavras-chave como: *basic emotions text*, *sentiment analysis texts*, *emotion annotation*, *sentiment classification*, *sentiment classification using machine learning*, *text classification for sentiment analysis*. Outros trabalhos foram obtidos por meio da análise de citações e referências contidas em artigos, teses, livros e relatórios técnicos.

⁶ sciencedirect.com

⁷ ieeexplore.ieee.org

⁸ citeseerx.ist.psu.edu

⁹ dl.acm.org

¹⁰ scholar.google.com.br

¹¹ researchgate.net

4.1. Identificação de Emoções em Textos Escritos em Português Brasileiro

A pesquisa em identificação de emoções em textos é um tema atual na área de AS, porém poucos são os trabalhos desenvolvidos especificamente para o idioma Português do Brasil. Nesse contexto, (MARTINAZZO, 2010) desenvolveu um método de identificação automática de emoções para textos curtos escritos em Língua Portuguesa do Brasil. Esse método foi baseado na teoria do LSA e obteve uma taxa de acerto de, aproximadamente, 70% ao identificar as seis emoções básicas de (EKMAN, 1992). O LSA é um método matemático/estatístico para identificação de relações entre palavras em textos e a partir dessas relações, visa estabelecer associações entre os termos encontrados (LANDAUER; FOLTZ; LAHAM, 1998).

No trabalho de (MARTINAZZO, 2010) foram usadas seis listas de palavras relacionadas com as emoções básicas, sendo essas listas baseadas na teoria apresentada por (STRAPPARAVA; MIHALCEA, 2008). Para a elaboração dos testes foi construído um corpus contendo 1.002 textos de notícias jornalísticas, extraídos do site *www.globo.com*. O corpus de notícias criado por (MARTINAZZO, 2010) foi manualmente anotado por um grupo de treze voluntários, todos pesquisadores e estudantes de pós-graduação, que analisaram os textos em um nível de documento indicando a emoção predominante. Cada notícia foi anotada por três avaliadores. O pré-processamento dos textos foi realizado convertendo todas as palavras para minúsculo, removendo os caracteres especiais (sinais de pontuação e números), removendo as *stopwords* e aplicando um lematizador. Após o pré-processamento dos textos, (MARTINAZZO, 2010) aplicou o método LSA e obteve os resultados mostrados na Tabela 4.1.

Tabela 4.1: Resultados obtidos com o LSA. Fonte: (MARTINAZZO, 2010)

| Emoções | Treinamento | | | Teste | | |
|-------------|-------------|----------|----------|--------|----------|----------|
| | Textos | Corretos | Acurácia | Textos | Corretos | Acurácia |
| Alegria | 239 | 159 | 67% | 116 | 69 | 59% |
| Repugnância | 189 | 146 | 77% | 78 | 60 | 77% |
| Medo | 30 | 22 | 73% | 20 | 16 | 80% |
| Raiva | 39 | 27 | 69% | 18 | 9 | 50% |
| Surpresa | 5 | 3 | 60% | 7 | 6 | 86% |
| Tristeza | 198 | 150 | 76% | 63 | 45 | 71% |

Os resultados apresentados na Tabela 4.1 alcançam uma acurácia média em torno de 70%, o que pode ser considerado um bom resultado visto que não existem outros métodos

para o Português Brasileiro que identificam categorias de emoções. O LSA foi utilizado para identificar as emoções em textos em Português em poucos trabalhos: (MARTINAZZO; PARAISO, 2010) e (MARTINAZZO; DOSCIATTI; PARAISO, 2011).

No trabalho de (VILELA, 2011) foi realizada a AS em notícias jornalísticas sobre o mercado financeiro. O trabalho não usa léxico de emoções e o objetivo foi classificar um conjunto de notícias em favoráveis ou não favoráveis em relação à Petrobras. Foi construído um corpus chamado *Petronews*, composto de 1.050 notícias sobre a Petrobras, extraídas de dois jornais: *Gazeta Mercantil* e *Valor Online*. Os textos foram anotados nas categorias *positivo* e *negativo* por três avaliadores. As notícias em que houveram dúvidas na anotação e não ficou claro a polaridade, foram descartadas. Para capturar o contexto foram usadas três técnicas de extração de características: n-gramas, anotação morfossintática e árvores de decisão.

Para selecionar as melhores características foram utilizadas quatro técnicas: árvores de decisão, Diferença Proporcional (*Proportional Difference*), o *Fisher Score* e *Entropy Weighted Genetic Algorithm* (EWGA). A Diferença Proporcional é uma medida usada para descobrir as características que ocorrem com mais frequência em textos positivos ou negativos; o *Fisher Score* usa funções probabilísticas para medir o quanto uma característica contribui para a classificação de um determinado exemplo; e EWGA, que envolve o uso de um algoritmo genético ponderado por entropia.

Para classificar as notícias foi utilizado um classificador SVM, avaliado com Validação Cruzada com dez partes, obtendo-se uma acurácia de 87,1%. O trabalho não forneceu outras métricas de desempenho além da acurácia.

Outro trabalho que não usa léxico e trata especificamente da identificação de emoções em textos escritos Língua Portuguesa Brasileira é o de (NASCIMENTO et al., 2012). Este trabalho visa avaliar a reação das pessoas em relação às notícias compartilhadas na mídia por meio da análise de publicações feitas no *Twitter*. As notícias escolhidas para este estudo estão inseridas nas categorias policiais, política e entretenimento. Para avaliar o desempenho do método, foi construído um corpus composto de 850 documentos, sendo 425 positivos e 425 negativos. Os textos foram anotados por três avaliadores.

O objetivo deste trabalho foi concluir, a partir das emoções expostas nos tweets, se a população achou um determinado fato *positivo* ou *negativo*. Dessa forma, o trabalho mostra um experimento de classificação supervisionada onde foram avaliados dois modelos estatísticos baseados em n-grama (unigrama e octagrama) e o classificador estatístico *Naive Bayes*.

De acordo com (JURAFSKY; MARTIN, 2000), os modelos estatísticos baseados em n-grama permitem prever a probabilidade de um grupo de palavras aparecerem em uma determinada sequência a partir das $n-1$ palavras do n-grama.

O modelo unigrama calcula a probabilidade de cada texto ser *positivo* ou *negativo* analisando cada palavra separadamente e o modelo octograma calcula a probabilidade de cada texto ser *positivo* ou *negativo* analisando sequências de oito palavras. Para apoiar o processo de classificação automática, foi utilizada uma biblioteca para processamento de texto chamada *LingPipe*¹². O trabalho não dá detalhes de como foi realizado o pré-processamento dos textos. Após fazer Validação Cruzada com dez partes, foram obtidos os resultados apresentados na Tabela 4.2.

Tabela 4.2: Acurácia dos modelos testados. Fonte: (NASCIMENTO et al., 2012).

| Categorias | Unigrama | Octograma | Naive Bayes |
|-------------------|-----------------|------------------|--------------------|
| Entretenimento | 74% | 74% | 75% |
| Policial | 76% | 77% | 81% |
| Política | 68% | 71% | 69% |
| Média | 73% | 74% | 75% |

Como pode ser observado na Tabela 4.2, embora seja mínima a diferença entre a acurácia dos classificadores, o classificador *Naive Bayes* obteve o melhor desempenho ao classificar a polaridade das emoções nos textos.

O trabalho de (LIMA; DE CASTRO, 2012) usa uma abordagem híbrida (léxico e AM) para identificar a polaridade das emoções em mensagens de *Twitter*. Para avaliar o desempenho do método proposto foram coletados, durante 24 horas, *tweets* que se referiam a um show de televisão Brasileira. As mensagens coletadas foram pré-processadas por meio de cinco passos: 1) tokenização; 2) remoção das *stopwords*; 3) lematização; 4) representação vetorial *bag-of-words*; e, 5) seleção de características.

Os autores propuseram uma solução usando três abordagens: baseada em *emoticons*, baseada em palavras emocionais e híbrida, composta por ambas abordagens. A abordagem baseada em *emoticons* usa uma lista de representações gráficas formadas por sinais de pontuação e letras representando as expressões faciais como um critério para classificar automati-

¹² <http://alias-i.com/lingpipe/>

camente as mensagens. A abordagem baseada em palavras emocionais usa as palavras "bom", "mau", "excelente" e "horrível" como critério para a classificação automática de emoções.

O método identifica automaticamente a polaridade das emoções no conjunto de treinamento por meio das abordagens e treina um classificador *Naive Bayes* com esse conjunto a fim de classificar o conjunto de testes. Os resultados das três abordagens podem ser vistos na Tabela 4.3.

Tabela 4.3: Desempenho das três abordagens. Fonte: (LIMA; DE CASTRO, 2012)

| Medida | <i>Emoticons</i> (550 tweets) | | Palavras (1.175 tweets) | | <i>Híbrido</i> (1.651 tweets) | |
|-----------------|----------------------------------|--------------------|----------------------------|--------------------|----------------------------------|--------------------|
| | Positivo (#381) | Negativo (#169) | Positivo (#915) | Negativo (#261) | Positivo (#1.236) | Negativo (#415) |
| Precisão | 0,99 | 0,25 | 0,97 | 0,61 | 0,96 | 0,39 |
| Cobertura | 0,99 | 0,25 | 0,97 | 0,39 | 0,96 | 0,61 |
| F1 | 0,99 | 0,25 | 0,97 | 0,48 | 0,96 | 0,48 |
| Acurácia | 89% | | 90% | | 92% | |

Os resultados mostrados na Tabela 4.3 mostram que a técnica proposta pelos autores (LIMA; DE CASTRO, 2012) obteve uma acurácia de 92% ao usar a abordagem híbrida para classificar os textos. Porém, ao analisar o F1 das classes é possível observar que o desbalançamento das classes favoreceu a classe *positivo* resultando em uma baixa identificação da classe *negativo*.

No trabalho de (EVANGELISTA; PADILHA, 2014), é apresentado o desenvolvimento de uma ferramenta para classificar comentários postados em redes sociais como *positivo*, *negativo* e *neutro*. A ferramenta faz uso do léxico *SentiWordNet* (ESULI; SEBASTIANI, 2006) e do algoritmo *Naive Bayes* para classificar os textos.

A ferramenta foi testada por meio do uso de um corpus que foi construído com avaliações de usuários do *e-bit*, do site Buscapé. O *e-bit* atua como um consultor de compras online. As avaliações no *e-bit* possuem basicamente três categorias: *elogio*, *reclamação* e *sugestão*. Para treinar o classificador *Naive Bayes* foram utilizadas as avaliações da categoria *elogio* como *positivo* e as avaliações da categoria *reclamação* como *negativo*. Foram coletadas automaticamente pela ferramenta 13.100 avaliações positivas e 3.824 avaliações negativas. Para a classe *neutro* foram coletados 613 tweets diretamente da linha do tempo de alguns usuários do *Twitter*. A acurácia obtida nos experimentos, realizados com as avaliações referentes à três empresas, pode ser visualizada na Tabela 4.4.

Tabela 4.4: Acurácia das duas abordagens ao avaliar comentários de *Twitter* e *Facebook* de três empresas. Fonte: (EVANGELISTA; PADILHA, 2014)

| Empresa | <i>Twitter</i> | | | <i>Facebook</i> | | |
|---------|----------------|--------------------|---------------------|-----------------|--------------------|---------------------|
| | # textos | <i>Naive Bayes</i> | <i>SentiWordNet</i> | # textos | <i>Naive Bayes</i> | <i>SentiWordNet</i> |
| X | 21 | 95% | 57% | 32 | 53% | 47% |
| Y | 13 | 76% | 53% | 17 | 47% | 52% |
| Z | 38 | 71% | 52% | 04 | 75% | 25% |

Com base nos resultados apresentados na Tabela 4.4 foi possível observar que a classificação com textos do *Twitter* obteve um melhor desempenho, principalmente ao usar o algoritmo *Naive Bayes*. Os autores justificam isso pelo fato dos comentários de *Twitter* apresentarem um maior número de críticas às empresas, funcionando como um serviço de atendimento ao consumidor, o que já não é frequente nos comentários de *Facebook*, onde as postagens normalmente possuem imagens e o texto sozinho acaba não fazendo muito sentido. O trabalho não forneceu outras medidas estatísticas para análise.

No trabalho de (ALVES et al., 2014) foi usada abordagem de AM para analisar a polaridade das emoções em tweets, escritos em Português Brasileiro, durante a Copa das Confederações realizada no Brasil em 2013. Foram usados dois algoritmos de classificação: o SVM e o *Naive Bayes*. O corpus foi construído com aproximadamente 300.000 tweets, mas apenas uma pequena porção desses textos foram anotados manualmente e usados nos experimentos do trabalho.

Um conjunto de 1.960 textos que continham *emoticons* foi anotado da seguinte forma: os 1.468 textos nos quais os *emoticons* eram relacionados com *alegria*, como por exemplo, "\:-)", ":)", "=)", ":D", foram associados com a categoria *positivo* e os 492 textos nos quais os *emoticons* eram relacionado com *tristeza*, como ":(", "=(", ";(", foram associados com a categoria *negativo*. Um conjunto de 1.110 textos foram anotados manualmente, sendo 326 anotados com a categoria *positivo*, 321 com a categoria *negativo* e 463 com a categoria *neutro*. Os resultados com os algoritmos SVM e *Naive Bayes* foram obtidos por meio de Validação Cruzada com dez partes e podem ser vistos na Tabela 4.5.

Tabela 4.5: Desempenho dos classificadores SVM e *Naive Bayes* (NB). Fonte: (ALVES et al., 2014)

| Conjunto de dados | Categoria | Precisão | | Cobertura | | F1 | | Acurácia | |
|---|-----------|----------|------|-----------|------|------|------|----------|-----|
| | | SVM | NB | SVM | NB | SVM | NB | SVM | NB |
| <i>Emoticons</i> | Positivo | 0,95 | 0,82 | 0,85 | 0,76 | 0,90 | 0,79 | 87% | 73% |
| | Negativo | 0,75 | 0,57 | 0,92 | 0,65 | 0,82 | 0,61 | | |
| Anotados manualmente | Positivo | 0,76 | 0,80 | 0,72 | 0,64 | 0,74 | 0,71 | 66% | 65% |
| | Negativo | 0,47 | 0,47 | 0,53 | 0,68 | 0,50 | 0,56 | | |
| <i>Emoticons</i> + Anotados manualmente | Positivo | 0,84 | 0,91 | 0,87 | 0,74 | 0,86 | 0,82 | 80% | 78% |
| | Negativo | 0,71 | 0,62 | 0,66 | 0,85 | 0,68 | 0,71 | | |

Os resultados obtidos mostrados na Tabela 4.5 indicam que o algoritmo SVM superou o algoritmo *Naive Bayes* em relação ao desempenho e que utilizar os textos que foram anotados com base nos *emoticons* juntamente com os dados que foram anotados manualmente contribuiu para se ter melhores resultados.

4.2. Identificação de Emoções em Textos escritos em Outras Línguas

Atualmente no Brasil existem alguns grupos de pesquisadores que desenvolvem trabalhos relacionados com a identificação das emoções em textos utilizando corpora em outros idiomas como o Português de Portugal ou o Inglês. A primeira parte desta seção faz um levantamento desses trabalhos e todos eles identificam a polaridade das emoções e, em alguns casos, também os textos neutros.

O trabalho de (SOUZA; VIEIRA, 2012) utiliza uma abordagem léxica para realizar AS em textos de *Twitter*. O objetivo do trabalho foi avaliar o impacto de diferentes modelos de negação e de diferentes léxicos além disso, verifica o impacto das técnicas de pré-processamento. Os autores construíram um corpus de 1.700 textos escritos em Português de Portugal, extraídos do *Twitter*, divididos em duas categorias balanceadas: *positivo* e *negativo*.

Nos trabalhos (CHAVES et al., 2012), (FREITAS; VIEIRA, 2013a) e (FREITAS; VIEIRA, 2013b), os autores utilizam textos de avaliações de clientes referentes a filmes e acomodações de hotéis, escritos em Português de Portugal, para avaliar um método que identifica a polaridade das emoções. Em (CHAVES et al., 2012), foram usados 180 comentários de clientes de hotéis de Lisboa. Cada comentário foi analisado em um nível de sentença de acordo com os conceitos de uma ontologia de domínio e uma lista de adjetivos com a correspon-

dente polaridade (*positivo*, *negativo* ou *neutro*) associada. Cada sentença foi anotada por um avaliador humano e posteriormente pelo método.

O trabalho de (FREITAS; VIEIRA, 2013a) tem como objetivo identificar a polaridade das emoções de acordo com as características descritas em uma ontologia de domínio. O trabalho é constituído por quatro etapas principais. Primeiramente, os textos são pré-processados aplicando um processo de tokenização¹³, separadores de sentenças, anotadores morfossintáticos e lematizadores. Na sequência são extraídas as características com base em uma ontologia de domínio (filmes e hotéis). Para identificar a polaridade das emoções é utilizado um léxico sentimento, o *OpLexicon* (SOUZA et al., 2011). Foram utilizados para o experimento 180 comentários de clientes sobre acomodações de hotéis e 150 comentários sobre filmes.

Em outro trabalho, (FREITAS; VIEIRA, 2013b) usam o corpus composto de 150 comentários de filmes para avaliar dois léxicos de sentimentos, o *OpLexicon* (SOUZA et al., 2011) e o *SentiLex* (SILVA; CARVALHO; SARMENTO, 2012) ao identificar a polaridade das emoções.

O trabalho de (BARBOSA et al., 2014) propõem uma abordagem de AS que permite gerar diversas classificações para um mesmo texto, atribuindo-lhe diferentes rótulos de acordo com os termos associados aos adjetivos. Esse trabalho tem como objetivo não desconsiderar as diversas emoções que podem existir dentro de um mesmo documento. A ferramenta desenvolvida tem seu funcionamento dividido em quatro etapas principais: encontrar todos os adjetivos do texto, encontrar todas as associações que esses adjetivos possuem com outros termos, encontrar a polaridade dos adjetivos e classificar os termos associados de acordo com a polaridade dos seus adjetivos. O léxico usado neste trabalho é o *SentiWordNet* (ESULI; SEBASTIANI, 2006). O método desenvolvido no trabalho foi avaliado com 2.000 textos escritos em Inglês, referentes a comentários de filmes, sendo 1.000 comentários positivos e 1.000 comentários negativos.

No trabalho de (CAVALCANTI et al., 2012) foi realizada a identificação da polaridade das emoções em citações científicas. Foi utilizada anotação morfossintática para extrair adjetivos, advérbios, verbos e substantivos e o *SentiWordNet* (ESULI; SEBASTIANI, 2006) para identificar o grau de polaridade para cada termo extraído da citação e graus de sentimento são calculados para classificar as citações de acordo com sentimento expresso no texto. Os

¹³ A tokenização tem como finalidade dividir um documento unidades textuais mínimas, mas que não percam o sentido semântico.

textos usados no trabalho se referem à citações da área médica, escritos em Inglês, classificados manualmente por dois anotadores e as categorias possíveis para cada texto é *positivo*, *negativo* ou *neutro*. Dos 140 textos, 24 foram anotados com sentimento *positivo*, 8 anotados com sentimento *negativo* e 108 sem sentimento (*neutro*).

No trabalho (GONÇALVES et al., 2013) e (ARAÚJO et al., 2014)¹⁴ foram utilizados dois conjunto de textos, escritos em Inglês, para realizar a uma análise comparativa de oito métodos de AS existentes na literatura. Os métodos avaliados foram: *Emoticons* (READ, 2005), *LIWC*¹⁵ (TAUSCZIK; PENNEBAKER, 2010), *SentiStrength* (THELWALL; BUCKLEY; PALTOGLOU, 2012), *SentiWordNet* (ESULI; SEBASTIANI, 2006), *SenticNet* (CAMBRIA et al., 2010), *SASA* (WANG et al., 2012), *Happiness Index* (DODDS; DANFORTH, 2009) e *PANAS-t* (GONÇALVES; BENEVENUTO; CHA, 2013). Os dois conjuntos possuem uma vasta quantidade de textos. O primeiro consiste de cerca de 1,8 milhões de tweets que referem a eventos como tragédias, lançamentos de produtos, política, saúde e esportes. O segundo conjunto é composto de 11.790 textos, cujos sentimentos foram anotados por humanos. Com base nestes dois conjuntos de dados, foi comparada a acurácia dos métodos ao identificar a polaridade das emoções nos textos.

No trabalho (MALHEIROS, 2014) foi usado um conjunto de textos em Inglês (GO; BHAYANI; HUANG, 2009) para avaliar o desempenho de uma ferramenta que identifica a polaridade das emoções em textos de *Twitter* usando uma abordagem léxica e de AM. O conjunto de textos, composto por 800.000 tweets positivos e 800.000 tweets negativos, foram destinados ao treinamento e um conjunto de teste, composto de 177 tweets negativos e 182 tweets positivos, foi coletado e anotado manualmente.

Na segunda parte desta seção, foram selecionados alguns trabalhos relacionados, mesmo que indiretamente, com o método que está sendo proposto nesta pesquisa. Para a seleção destes trabalhos levou-se em consideração duas características principais: 1) identificação de categorias de emoção em textos e, 2) identificação de emoções utilizando uma abordagem de classificação supervisionada.

O trabalho de (PANG; LEE; VAITHYANATHAN, 2002) foi um dos primeiros trabalhos na literatura a utilizar uma abordagem de AM supervisionada para classificar emoções

¹⁴ <http://blackbird.dcc.ufmg.br:1210/>

¹⁵ <http://www.liwc.net/>

em textos. Os autores aplicaram os algoritmos *Naive Bayes*, Máxima Entropia e SVM para determinar se comentários de filmes apresentavam uma polaridade positiva ou negativa.

Para o experimento realizado neste trabalho foram selecionados 700 textos positivos e 700 textos negativos, escritos em idioma Inglês. No pré-processamento dos textos foi extraída a informação textual do documento HTML original e tratada a pontuação como itens lexicais separados. Nenhum lematizador ou lista de *stopwords* foi utilizada. Todos os classificadores foram avaliados com Validação Cruzada com três partes. Na Tabela 4.6 é possível ver a acurácia dos classificadores obtida com diferentes conjuntos de características extraídas por meio de: unigramas, unigramas mais frequentes, bigramas, unigramas + bigramas, adjetivos, unigramas + anotação formossintática, bigramas + anotação da posição no texto. Para o classificador de Máxima Entropia, apenas a presença ou ausência de uma característica é relevante. Foi investigado se a informação de frequência pode influenciar na acurácia dos classificadores *Naive Bayes* e SVM.

Tabela 4.6: Acurácia dos classificadores em relação a cada conjunto de características. Fonte: (PANG; LEE; VAITHYANATHAN, 2002)

| Características | Frequência ou presença | NB | ME | SVM |
|--|------------------------|--------------|--------------|--------------|
| Unigramas | Frequência | 78,7% | --- | 72,8% |
| Unigramas | Presença | 81,0% | 80,4% | 82,9% |
| Unigramas + bigramas | Presença | 80,6% | 80,8% | 82,7% |
| Bigramas | Presença | 77,3% | 77,4% | 77,1% |
| Unigramas + POS | Presença | 81,5% | 80,4% | 81,9% |
| Adjetivos | Presença | 77,0% | 77,7% | 75,1% |
| Bigramas + posição da palavra no texto | Presença | 81,0% | 81,0% | 81,6% |
| Unigramas mais frequentes | Presença | 80,3% | 81,0% | 81,4% |

Observando os resultados mostrados na Tabela 4.6, é possível perceber que, embora o SVM obteve o melhor desempenho, a diferença não foi significativa se comparada com o melhor desempenho dos outros classificadores. Com relação ao conjunto de características, o conjunto extraído por unigrama com informação de presença se mostrou mais eficaz. O trabalho não informou outras medidas estatísticas para análises mais detalhadas.

O trabalho de (AMAN; SZPAKOWICZ, 2007) usa AM supervisionada para classificar emoções em sentenças de blogs escritas em Inglês. Neste trabalho, foi desenvolvido um corpus com 5.205 sentenças que foram anotadas com as categorias *alegria*, *repugnância*, *raiva*, *medo*, *tristeza* e *surpresa*, porém, no experimento realizado no trabalho, o foco estava apenas em reconhecer sentenças como emocionais e não emocionais, independente de sua ca-

tegoria de emoção. No experimento foram excluídas todas as sentenças nas quais não houve consenso entre os anotadores, em seguida foi atribuída EM (*Emocional*) para as sentenças que continham emoção e NE (*Não Emocional*) para as sentenças que não continham emoção. O conjunto de textos anotados resultou em 1.466 sentença EM e 2.800 sentenças NE.

Para selecionar as características, foram usados dois recursos léxicos: o *General Inquirer* (GIn) (STONE et al., 1966) e o *WordNetAffect* (WNA) (STRAPPARAVA; VALITUTTI, 2004). O GIn consiste de palavras extraídas de vários dicionários e agrupadas em diversas categorias semânticas. Esse recurso permite enumerar diferentes sentidos de um termo e fornece várias *tags* indicando as diferentes categorias semânticas a que ele pertence. O WNA atribui uma variedade de rótulos de afeto para uma determinada categoria de emoção. Neste trabalho foram usadas seis listas correspondendo às seis emoções básicas de (EKMAN, 1992).

Para classificar os textos em EM e NE foram utilizados os algoritmos *Naive Bayes* e SVM, sendo realizada Validação Cruzada com dez partes. Os resultados apresentados na Tabela 4.7 mostram o desempenho dos classificadores com cada conjunto de características, GIn somente, WNA somente, combinando GIn com WNA e com todas as características (incluindo as não lexicais).

Tabela 4.7: Acurácia dos classificadores em relação a cada conjunto de características. Fonte: (AMAN; SZPAKOWICZ, 2007)

| Características | <i>Naive Bayes</i> | SVM |
|------------------------|---------------------------|--------------|
| GIn | 71,4% | 71,3% |
| WNA | 70,2% | 70,6% |
| GIn+ WNA | 71,7% | 73,9% |
| Todas | 72,1% | 73,9% |

Conforme apresentado na Tabela 4.7, o melhor resultado foi obtido com a combinação de todas as características e a utilização de características não lexicais não afetou o resultados do SVM e ainda aumentou a acurácia do *Naive Bayes*. Um fato interessante neste trabalho é que os autores justificaram inicialmente o uso de textos de blogs por esperar que estes fossem dados textuais ricos em emoção. Contudo, foi verificado por meio do processo de anotação, que mais da metade dos textos coletados não apresentaram nenhuma emoção. Não houve diferença significativa entre a acurácia obtida pelos classificadores. O trabalho não informou outras medidas estatísticas para permitir uma análise mais detalhada.

No trabalho de (STRAPPARAVA; MIHALCEA, 2008), os autores elaboraram dois corpora, um composto por 1.250 manchetes de notícias jornalísticas e outro composto de 8.761 posts de blogs, ambos escritos em Inglês. O objetivo do trabalho foi identificar as seis emoções básicas de (EKMAN, 1992) nos textos em um nível de documento.

O trabalho usou uma abordagem léxica e de AM para analisar as emoções nos textos. Foi realizada uma avaliação comparativa de cinco abordagens de AS: *WordNetAffect Presence*, que consiste em um sistema de referência para definir as emoções baseando-se apenas na presença ou ausência das palavras no dicionário léxico *WordNetAffect* (STRAPPARAVA; VALITUTTI, 2004); *LSA Single Word*, que calcula a similaridade LSA entre o texto e cada emoção; *LSA Emotion Synset*, que além da palavra que denomina uma emoção, seus sinônimos armazenados no dicionário também são usados; *LSA All Emotion Words*, que incrementa o conjunto a cada iteração adicionando a ele todos os sinônimos encontrados no dicionário para uma determinada emoção; e por último o sistema *Naive Bayes Trained on Blogs*, que usa um classificador *Naive Bayes* treinado com dados de *blogs* anotados com as seis emoções. Cada sistema foi avaliado por meio de um conjunto de 1.000 manchetes de notícias. O desempenho de cada sistema pode ser visto na Tabela 4.8.

Tabela 4.8: Desempenho médio das cinco abordagens ao avaliar os textos jornalísticos. Fonte:

Adaptado de (STRAPPARAVA; MIHALCEA, 2008).

| Método | Precisão | Cobertura | F1 |
|------------------------------|-----------------|------------------|-----------|
| <i>WN-Affect Presence</i> | 0,38 | 0,01 | 0,04 |
| <i>LSA Single Word</i> | 0,09 | 0,66 | 0,16 |
| <i>LSA Emotion Synset</i> | 0,09 | 0,77 | 0,13 |
| <i>LSA All Emotion Words</i> | 0,09 | 0,90 | 0,17 |
| <i>NB Trained on Blogs</i> | 0,12 | 0,18 | 0,13 |

Como pode ser verificado nos resultados mostrados na Tabela 4.8, o método *LSA All Emotion Words* obteve os melhores resultados para Cobertura e F1. O melhor resultado com base na Precisão foi obtido com o método *WN-Affect Presence*. Esse foi um dos primeiros trabalhos de AS da literatura que identifica as seis emoções de (EKMAN, 1992) em textos.

O trabalho de (GHAZI; INKPEN; SZPAKOWICZ, 2010) usa uma abordagem de AM para construir um método de classificação de emoções que considera níveis de classificação, sendo que as categorias são parcialmente ordenadas, usualmente da mais genérica para mais específica. Os autores usaram dois conjuntos de dados textuais para avaliar o método desenvolvido neste trabalho. O primeiro conjunto é composto 2.090 sentenças de blogs e faz parte

do corpus desenvolvido por (AMAN; SZPAKOWICZ, 2007) e o segundo, é composto de 1.207 sentenças de contos infantis e faz parte do corpus desenvolvido por (ALM; ROTH; SPROAT, 2005).

Na Tabela 4.9 são mostrados os resultados obtidos com a classificação em níveis e com a classificação plana para o conjunto de dados de blogs. No primeiro nível, a classificação determina se uma instância é *Emocional* ou *Não Emocional*. No segundo nível considera todas as instâncias que foram classificadas como *Emocional* no primeiro nível e as classifica em uma das seis emoções básicas *alegria, tristeza, raiva, medo, repugnância e surpresa*.

Tabela 4.9: Dois níveis de classificação no conjunto de dados de (AMAN; SZPAKOWICZ, 2007). Fonte: Adaptado de (GHAZI; INKPEN; SZPAKOWICZ, 2010)

| Nível | Categoria | Dois níveis de classificação | | | Classificação plana | | |
|-----------------|---------------|------------------------------|-----------|------|---------------------|-----------|------|
| | | Precisão | Cobertura | F1 | Precisão | Cobertura | F1 |
| 1º nível | Emocional | 0,88 | 0,85 | 0,86 | --- | --- | --- |
| | Não Emocional | 0,88 | 0,81 | 0,84 | 0,54 | 0,87 | 0,67 |
| 2º nível | Alegria | 0,59 | 0,95 | 0,71 | 0,74 | 0,60 | 0,66 |
| | Tristeza | 0,77 | 0,49 | 0,60 | 0,69 | 0,42 | 0,52 |
| | Medo | 0,91 | 0,49 | 0,63 | 0,82 | 0,49 | 0,62 |
| | Surpresa | 0,75 | 0,32 | 0,45 | 0,64 | 0,27 | 0,38 |
| | Repugnância | 0,66 | 0,35 | 0,45 | 0,68 | 0,31 | 0,43 |
| | Raiva | 0,72 | 0,33 | 0,46 | 0,67 | 0,26 | 0,38 |
| Acurácia | | 68,3% | | | 61,7% | | |

Na Tabela 4.10, a classificação de sete classes é realizada em três níveis. O primeiro nível define se a instância é *Emocional* ou *Não Emocional*. No segundo nível, as instâncias definidas como *Emocional* no primeiro nível são classificadas em sua polaridade. No terceiro nível, supõem-se que as instâncias da classe *alegria* têm polaridade positiva e *tristeza, raiva, repugnância, medo e surpresa* têm polaridade negativa. Dessa forma, as instâncias negativas do segundo nível são classificadas em cinco classes de emoção no terceiro nível.

Tabela 4.10: Três níveis de classificação no conjunto de dados de (AMAN; SZPAKOWICZ, 2007). Fonte: Adaptado de (GHAZI; INKPEN; SZPAKOWICZ, 2010)

| Nível | Categoria | Três níveis de classificação | | |
|-----------------|---------------|------------------------------|-----------|------|
| | | Precisão | Cobertura | F1 |
| 1º nível | Emocional | 0,88 | 0,85 | 0,86 |
| | Não Emocional | 0,88 | 0,81 | 0,84 |
| 2º nível | Positivo | 0,89 | 0,65 | 0,75 |
| | Negativo | 0,79 | 0,94 | 0,86 |
| 3º nível | Tristeza | 0,63 | 0,54 | 0,59 |
| | Medo | 0,88 | 0,52 | 0,65 |
| | Surpresa | 0,79 | 0,37 | 0,50 |
| | Repugnância | 0,42 | 0,38 | 0,40 |
| | Raiva | 0,38 | 0,71 | 0,49 |
| Acurácia | | 65,5% | | |

Os resultados mostrados na Tabela 4.11 foram obtidos no experimento executado com o conjunto de dados de contos infantis de (ALM; ROTH; SPROAT, 2005). Neste experimento, baseou-se no pressuposto de que a classe *alegria* é positiva e as quatro classes restantes são negativas. No primeiro nível, é determinado se uma instância possui uma polaridade positiva ou negativa. No segundo nível são consideradas todas as instâncias que foram classificadas como negativa e são então classificadas em uma das quatro classes negativa: *tristeza*, *medo*, *surpresa* e *raiva*.

Tabela 4.11: Dois níveis de classificação no conjunto de dados de (ALM; ROTH; SPROAT, 2005). Fonte: Adaptado de (GHAZI; INKPEN; SZPAKOWICZ, 2010)

| Nível | Categoria | Dois níveis de classificação | | | Classificação plana | | |
|-----------------|-----------|------------------------------|-----------|------|---------------------|-----------|------|
| | | Precisão | Cobertura | F1 | Precisão | Cobertura | F1 |
| 1º nível | Negativo | 0,81 | 0,93 | 0,87 | --- | --- | --- |
| | Positivo | 0,84 | 0,64 | 0,72 | 0,56 | 0,86 | 0,68 |
| 2º nível | Tristeza | 0,65 | 0,68 | 0,66 | 0,67 | 0,53 | 0,59 |
| | Medo | 0,59 | 0,40 | 0,47 | 0,59 | 0,38 | 0,46 |
| | Surpresa | 0,45 | 0,21 | 0,29 | 0,35 | 0,10 | 0,16 |
| | Raiva | 0,49 | 0,73 | 0,59 | 0,54 | 0,43 | 0,48 |
| Acurácia | | 59,1% | | | 57,4% | | |

Os resultados obtidos nos dois experimentos com classificação plana deste trabalho mostram que em ambos os casos a Precisão da abordagem de dois níveis é significativamente melhor do que a Precisão da classificação plana. Um resultado interessante observado nas informações da Tabela 4.9 é a Precisão da classe *Não Emocional*, ela aumenta enquanto a Cobertura diminui. Isso ocorre também em outras experiências e acontece com as classes que costumavam dominar na classificação plana, mas que já não dominam mais na classificação

em níveis. Os classificadores tendem a dar prioridade a uma classe dominante, de modo que mais instâncias são classificadas nesta classe, dessa forma a classificação alcança uma baixa Precisão e uma alta Cobertura. Os experimentos apresentados no trabalho de (GHAZI; INKPEN; SZPAKOWICZ, 2010) mostram que a classificação em níveis tende a produzir maior valor de Precisão e de F1 do que a classificação plana.

No trabalho de (MOHAMMAD, 2012a), o autor investiga o uso de um léxico de emoção usado na extração das características para melhorar o desempenho de método supervisionado, que usa características N-gramas. Foram usados neste trabalho um corpus composto por 1.250 notícias, que desenvolvido por (STRAPPARAVA; MIHALCEA, 2008) e anotado com as seis emoções básicas de (EKMAN, 1992) e o léxico *WordNetAffect* (STRAPPARAVA; VALITUTTI, 2004). Foram criados no Weka¹⁶ (HALL et al., 2009) classificadores binários para cada uma das seis emoções, por exemplo, o classificador *medo - não medo* determina se um texto expressa *medo* ou não.

Os resultados mostrados nas tabelas 4.12 e 4.13 foram obtidos com o classificador SVM. Na Tabela 4.13 são mostrados os resultados obtidos por meio de Validação Cruzada com dez partes usando um conjunto de 1.000 textos e na Tabela 4.12 são mostrados os resultados obtidos por avaliação do conjunto de teste, sendo que os classificadores foram treinados com 1.000 textos e avaliados com 250 textos.

Tabela 4.12: Resultados obtidos por avaliação do conjunto de teste. Fonte: Adaptado de (MOHAMMAD, 2012a)

| Características | Classificador | Precisão | Cobertura | F1 |
|------------------------------|----------------------|-----------------|------------------|-----------|
| Léxico, unigramas e bigramas | Raiva | 0,42 | 0,35 | 0,38 |
| | Repugnância | 0,47 | 0,15 | 0,23 |
| | Medo | 0,59 | 0,80 | 0,68 |
| | Alegria | 0,51 | 0,67 | 0,58 |
| | Tristeza | 0,66 | 0,68 | 0,68 |
| | Surpresa | 0,21 | 0,33 | 0,25 |
| | Todos | 0,51 | 0,54 | 0,52 |
| Léxico | Todos | 0,35 | 0,68 | 0,46 |
| Unigramas e bigramas | Todos | 0,43 | 0,50 | 0,46 |

¹⁶ <http://www.cs.waikato.ac.nz/ml/weka/>

Tabela 4.13: Resultados obtidos com Validação Cruzada com dez partes. Fonte: Adaptado de (MOHAMMAD, 2012a)

| Características | Classificador | Precisão | Cobertura | F1 |
|------------------------------|---------------|----------|-----------|------|
| Léxico, unigramas e bigramas | Todos | 0,44 | 0,62 | 0,52 |
| Léxico | Todos | 0,24 | 0,95 | 0,38 |
| Unigramas e bigramas | Todos | 0,42 | 0,50 | 0,49 |

Esses resultados indicam que o uso de léxico e de N-gramas (neste caso, unigramas e bigramas) juntos podem contribuir para se obter um melhor desempenho ao classificar os textos com classificadores SVM binários.

No trabalho de (BROOKS et al., 2013), os autores usaram AM supervisionada para identificar afeto em textos em Inglês referentes à conversas online coletadas em ambientes colaborativos. O corpus é composto por cerca de 485.000 mensagens de conversas online, coletadas durante um período de quatro anos. Esses textos são resultantes da comunicação online entre 32 pesquisadores de astrofísica, que participam de uma organização internacional de pesquisa. A taxonomia de emoções usada neste trabalho é composta por treze categorias: *interesse, divertimento, consideração, concordância, aborrecimento, confusão, aceitação, apreensão, frustração, solidariedade, surpresa, expectativa, e serenidade*. Algumas destas categorias foram baseadas no modelo de emoções de (PLUTCHIK, 1980).

Uma parte do corpus de conversas online, cerca de 27.344 mensagens, foram anotadas por até cinco anotadores. Além do uso do tradicional *bag-of-words*, a seleção de características foi realizada com o uso de marcadores gramaticais incluindo pronomes, ortografia incomum como "haha", "hmmm", *emoticons*, sinais de pontuação e meta-informação sobre as mensagens de bate-papo como duração conversa, tamanho, etc.

Na Tabela 4.14 é possível visualizar os resultados obtidos com os classificadores *Naive Bayes*, SVM e C4.5 usando o conjunto de dados de conversas online. Pelo fato das categorias não serem mutuamente exclusivas, os autores decidiram criar classificadores binários separados, dessa forma, os resultados apresentados na Tabela 4.14 se referem a média de todos resultados obtidos com Validação Cruzada com quatro partes em cada uma das categorias.

Tabela 4.14: Resultados obtidos com o corpus de conversas online

| Classificador | Precisão | Cobertura | F1 |
|--------------------|-------------|-------------|-------------|
| <i>Naive Bayes</i> | 0,64 | 0,69 | 0,65 |
| SVM | 0,77 | 0,75 | 0,76 |
| C4.5 | 0,72 | 0,68 | 0,70 |

Como é possível observar na Tabela 4.14, os melhores resultados foram obtidos usando o classificador SVM. É importante destacar que esses resultados foram alcançados usando *subamostragem*, uma técnica balanceamento de dados que reduz aleatoriamente exemplos da classe majoritária.

No trabalho de (TURKMENOGLU; TANTUG, 2014), os autores desenvolveram dois métodos de AS para o idioma Turco, um baseado em léxico e outro baseado em AM supervisionada, para identificar a polaridade das emoções em dois corpora diferentes, textos de *Twitter* e textos de comentários de filmes. O corpus de tweets é composto de 5.900 tweets, extraídos de seis páginas de marcas populares e anotados manualmente com as categorias *positivo*, *negativo* e *neutro*, contendo um número médio de 14 palavras em cada documento. O corpus de comentários de filmes é composto por 20.244 textos, com uma média de 39 palavras por documento. Os textos foram extraídos de um site popular que permite aos usuários emitir comentários sobre os filmes e selecionar uma classificação de uma a cinco estrelas. Dessa forma, todos os comentários que possuem uma classificação superior a quatro estrelas são considerados como positivos e os que possuem uma classificação inferior a 2,5 são negativos, e os textos pertencentes à escala restante são descartados.

Como não existe nenhum léxico de palavras afetivas para o idioma Turco, os autores traduziram um léxico básico do Inglês, composto por 2.547 palavras, para o idioma Turco. Além disso, tiveram que realizar um árduo trabalho linguístico no pré-processamento para lidar com as características da língua Turca no método baseado em léxico. Este trabalho também abordou o tratamento da negação das palavras do texto e a identificação de segmentos de textos com significado.

Na abordagem de AM foram utilizados unigramas e bigramas com um ranqueamento dos pesos TF-IDF para selecionar as melhores características. Nos experimentos foram usados os classificadores SVM, *Naive Bayes* e J48, que foram avaliados por meio de Validação Cruzada com dez partes. Na Tabela 4.15 são apresentados os melhores resultados obtidos com os experimentos mostrados no trabalho.

Tabela 4.15: Melhor acurácia obtida em cada corpus. Fonte: Adaptada de (TURKMENOGLU; TANTUG, 2014)

| <i>Twitter</i> | | | | <i>Filmes</i> | | | |
|----------------|-------|-------|--------|---------------|--------------|-------|--------|
| SVM | NB | J48 | Léxico | SVM | NB | J48 | Léxico |
| 85,0% | 84,3% | 81,0% | 75,2% | 89,5% | 89,5% | 83,0% | 79,0% |

Nos resultados mostrados na Tabela 4.15 foi possível observar que, embora a diferença de acurácia entre os classificadores não seja tão significativa, o SVM obteve a maior taxa de acerto no geral. Também foi possível observar que a abordagem de AM superou a abordagem léxica. O trabalho não fornece outras métricas de desempenho por classe, o que permitiria uma análise mais completa.

4.3. Considerações Finais

Neste capítulo foram apresentados trabalhos relacionados com a pesquisa que está sendo proposta. Na primeira seção, buscou-se por trabalhos de AS produzidos para identificar categorias de emoções em textos escritos em Português Brasileiro e que não façam o uso de léxico de emoções para classificar ou para auxiliar no processo de classificação dos textos. Entretanto, a maioria dos trabalhos encontrados na literatura são voltados para a identificação da polaridade das emoções nos textos, e são raros os que identificam categorias de emoções. Além disso, a maioria dos trabalhos usam léxico de emoções para classificar os textos ou para extrair as características.

Ainda na primeira seção, o único trabalho encontrado para o Português Brasileiro que identifica categorias de emoções em textos é o trabalho de (MARTINAZZO, 2010). Esse trabalho tem limitações: 1) o fato de usar um léxico de palavras de emoção o torna dependente deste recurso; e 2) apresentou resultados inferiores ao ser testado com um novo corpus de notícias, o que leva a supor que pode sofrer grandes variações de desempenho mesmo ao ser avaliado com textos de um domínio idêntico.

Na segunda seção, buscou-se por trabalhos de AS desenvolvidos para identificar categorias de emoções em textos escritos em outros idiomas. Além disso, procurou-se principalmente por aqueles que fazem uso de uma abordagem de AM supervisionada em sua solução. Entretanto, ainda são poucos os trabalhos desenvolvidos para identificar categorias de emoções e dessa forma, acrescentou-se alguns trabalhos que identificam a polaridade das emoções e textos neutros, visto que o método proposto também poderá ser usado para esse objetivo.

Na segunda seção também foram adicionados os trabalhos de AS desenvolvidos no Brasil e que usam corpora de outros idiomas para testar os seus métodos. Isso ocorre em função de serem raros os corpora anotados para o Português Brasileiro que estão disponíveis para o uso em pesquisas.

Na Tabela 4.16 são apresentadas as principais características dos trabalhos mostrados na primeira seção deste capítulo, que foram desenvolvidos para analisar textos escritos em Português Brasileiro.

Tabela 4.16: Principais trabalhos de AS desenvolvidos para o Português Brasileiro

| Trabalho | Corpus | Categorias | Classes balanceadas | Abordagem | Acurácia | F1 |
|------------------------------|--|---|---------------------|--------------|-----------------------------|------------------------------------|
| (MARTINAZZO, 2010) | 1.002 notícias jornalísticas | <i>Alegria, tristeza, raiva, medo, repugnância e surpresa</i> | Não | Léxico e LSA | 70% | Não apresenta |
| (VILELA, 2011) | 1.050 notícias financeiras | <i>Positivo e negativo</i> | Não | AM | 87,1% | Não apresenta |
| (NASCIMENTO et al., 2012) | 850 tweets relacionados à notícias | <i>Positivo e negativo</i> | Sim | AM | 75% | Não apresenta |
| (LIMA; DE CASTRO, 2012) | 3.376 tweets | <i>Positivo e negativo</i> | Não | Léxico e AM | 92% | Positivo = 0,96 Negativo = 0,48 |
| (EVANGELISTA; PADILHA, 2014) | 72 tweets e 53 comentários do Facebook | <i>Positivo, negativo e neutro</i> | Não | AM | 81% Twitter 58% Facebook | Não apresenta |
| | | | | Léxico | 54% Twitter 41% Facebook | Não apresenta |
| (ALVES et al., 2014) | 3.070 tweets | <i>Positivo e negativo</i> | Não | AM | 87% | Positivo = 0,90 Negativo = 0,82 |

Na Tabela 4.17 são apresentadas as principais características dos trabalhos da segunda seção, que foram desenvolvidos para analisar textos escritos em outros idiomas.

Tabela 4.17: Principais trabalhos de AS desenvolvidos para outros idiomas

| Trabalho | Idioma | Corpus | Categorias | Classes balanceadas | Abordagem | Nível | Acurácia | F1 |
|----------------------------------|--------|-----------------------------|----------------------------------|---------------------|-------------|----------|----------|---------------|
| (PANG; LEE; VAITHYANATHAN, 2002) | Inglês | 1.400 comentários de filmes | <i>Positivo e negativo</i> | Sim | AM | Sentença | 82,9% | Não apresenta |
| (AMAN; SZPAKOWICZ, 2002) | Inglês | 4.266 comentários de blogs | <i>Emocional e Não Emocional</i> | Não | AM e léxico | Sentença | 73,9% | Não apresenta |

| | | | | | | | | |
|--|--------|--|---|-----|----------------|----------------|------------------------|-----------------------|
| 2007) | | | | | | | | |
| (STRAPP ARAVA; MIHALCE A, 2008) | Inglês | 1.250 notí- cias e 8.761 posts | <i>Alegria, tristeza, raiva, medo, repugnância e surpresa</i> | Não | AM e léxico | Documen- to | Não apre- sentou | 0,17 |
| (GHAZI; INKPEN; SZPAKO WICZ, 2010) | Inglês | 2.090 co- mentários de blogs e 1.207 contos | <i>Neutro, tristeza, raiva, medo, repugnância e surpresa</i> | Não | AM | Sentença | 68,3% | 0,55 |
| (MOHAM MAD, 2012a) | Inglês | 1.000 notí- cias | <i>Alegria, tristeza, raiva, medo, repugnância e surpresa</i> | Não | AM e léxico | Documen- to | Não apre- sentou | 0,52 |
| (BROOKS et al., 2013) | Inglês | 27.344 con- versas onli- ne | <i>Interesse, diver- timento, conside- ração, concor- dância, aborre- cimento, confu- são, aceitação, apreensão, frus- tração, solidari- idade, surpresa, expectativa, e serenidade</i> | Sim | AM | Sentença | 75% | 0,76 |
| (TURKME NOGLU; TANTUG, 2014) | Turco | 5.900 tweets e 20.244 comentários de filmes | <i>Positivo, negati- vo e neutro</i> | Não | AM e léxico | Documen- to | 89,5% | Não apresen- ta |

Assim como a grande maioria das pesquisas desenvolvidas no mundo, também no Brasil a maior parte das pesquisas em AS são produzidas visando identificar a polaridade das emoções nos textos. Dessa forma, existe uma carência de métodos que possam, além de identificar a polaridade das emoções e textos neutros, também identificar categorias de emoções, como por exemplo, *tristeza, raiva, medo, alegria*, dentre outras.

Um fator que dificulta a criação de novos métodos para o Português Brasileiro é não se ter disponíveis corpora anotados com categorias de emoções que tenham passado por um rigoroso processo de anotação.

Analisando-se os trabalhos apresentados na segunda seção, foi possível verificar que em outros idiomas também são raros os trabalhos que identificam categorias de emoções em textos e que são isentos do uso de uma abordagem léxica. Além disso, percebeu-se que a análise em nível de sentença costuma ser a usual nos trabalhos pesquisados. Isso se deve ao fato de ser mais simples o processo de anotação humana neste nível de análise.

Capítulo 5

Processo de Construção e Anotação de um Corpus

O método proposto nesta pesquisa visa identificar as emoções básicas de (EKMAN, 1992) em textos, além dos textos neutros. Portanto, se faz necessário o uso de um corpus anotado para avaliar o método.

Atualmente para o Português Brasileiro, não se encontra disponível para uso em pesquisa nenhum corpus anotado com categorias de emoções. Deste modo, este capítulo relata o processo de construção e anotação de um corpus usado para avaliar o método de identificação de emoções em textos.

Os textos escolhidos para compor o corpus são textos de notícias, escritos em Português Brasileiro, extraídos de jornais online. O corpus é composto por textos curtos (título e linha fina de notícias). Optou-se por utilizar este comprimento de textos pois, em geral, os trabalhos na área de AS são construídos e avaliados para análise de textos como *tweets*, *posts*, avaliações de produtos, etc.

5.1. Corpora em AS

A literatura não é farta quanto a artigos que apresentem resultados obtidos quando da construção de um corpus para a AS. Antes da construção do corpus, buscou-se na literatura trabalhos que apresentassem os seguintes elementos: 1) a existência de corpora para AS na língua Portuguesa do Brasil; 2) a metodologia de construção e anotação de corpora utilizados em métodos de AS; 3) o grau de concordância entre os anotadores nos corpora de AS.

Alguns trabalhos envolvendo a construção de corpora em Português para a AS foram identificados na literatura. O trabalho de (FREITAS et al., 2014) se refere a construção de um corpus composto por resenhas de livros publicadas na internet e anotado manualmente em

relação à polaridade. O Reli (Resenha de livros), como é chamado o corpus, tem como objetivo identificar opiniões sobre entidades nos textos. As 1.600 resenhas totalizando 12.000 sentenças foram anotadas, considerando aspectos linguísticos como as categorias morfossintáticas e a informação semântica. Os textos foram anotados por três anotadores e o estudo do grau de concordância entre os anotadores foi realizado com 400 sentenças. Usando-se a métrica *Agr*, a mesma que foi usada em (WIEBE, 2005), a concordância na atribuição de polaridade alcançou quase 100% e a concordância na identificação de expressões que continham opiniões ficou em 80%.

No trabalho de (NASCIMENTO et al., 2012) foi construído e anotado um corpus de tweets que se referem a comentários de notícias. As notícias (três no total) foram selecionadas por terem ampla repercussão na imprensa na época da coleta dos textos. Os documentos de tweets foram anotados manualmente por três pesquisadores envolvidos no trabalho, que atribuíram a cada texto uma das duas categorias: *positivo* ou *negativo*. Ao final do processo, foi criado um corpus composto de 850 documentos, divididos em 50% positivos e 50% negativos.

No trabalho de (ALVES et al., 2014), foi construído um corpus com 17.000 tweets que foram colhidos durante a Copa das Confederações de futebol, em 2013. Dos 17.000 textos, 1.500 foram anotados por dez voluntários, que puderam atribuir a cada texto uma entre as três categorias possíveis: *positivo*, *negativo* ou *neutro*. A categoria final atribuída ao texto foi escolhida por meio de voto majoritário.

Alguns pesquisadores publicaram artigos apresentando os resultados do processo de construção e anotação dos corpora em outras línguas e mostraram o grau de concordância obtido entre os avaliadores por meio do índice Kappa (COHEN, 1960), que é um coeficiente que leva em conta a proporção de concordância que ocorre devido ao acaso. O Kappa tem como valor máximo 1, que representa alta concordância entre os avaliadores e 0, que indica que não houve nenhuma concordância.

Os textos de um corpus composto de 5.205 posts de blogs, escritos em Inglês, desenvolvido por (AMAN; SZPAKOWICZ, 2007) e usado em diversos trabalhos de AS, dentre eles (GHAZI; INKPEN; SZPAKOWICZ, 2014), foram anotados em um nível de sentença por quatro anotadores. Cada anotador atribuiu a cada texto uma das seis emoções básicas ou uma categoria chamada *Emoções Mistas*. Também classificaram o texto como *Emocional* ou *Não Emocional* e avaliaram a intensidade das emoções atribuindo uma das categorias *alta*, *média*

ou *baixa*. O valor Kappa obtido entre os anotadores foi de 0,76 para os textos das categorias *Emocional* e *Não emocional*, de 0,65 (valor médio) para os textos das categorias *alegria*, *tristeza*, *raiva*, *medo*, *repugnância* e *surpresa*, e de 0,52 (valor médio) para as intensidades *alta*, *média* ou *baixa*.

Em (STRAPPARAVA; MIHALCEA, 2008), um corpus composto por 1.250 textos de notícias, escritos em Inglês, foi anotado em um nível de documento por cinco anotadores sendo que em cada texto o anotador escolheu uma entre as seis emoções básicas de (EKMAN, 1992). O valor Kappa obtido entre os anotadores foi de 0,53.

No trabalho de (HABERNAL; PTÁČEK; STEINBERGER, 2014) um corpus com 10.000 comentários extraídos do *Facebook*, escritos em idioma Tcheco, foi anotado em um nível de documento por dois anotadores atribuindo-se uma entre três categorias possíveis: *positivo*, *negativo* ou *neutro*. O valor Kappa obtido entre os anotadores neste corpus foi de 0,66.

Em (ALM; ROTH; SPROAT, 2005), um corpus com 1.580 textos extraídos de 185 contos infantis, escritos em Inglês, foi anotado em um nível de sentença por dois anotadores. Cada texto foi anotado com: *raiva*, *repugnância*, *medo*, *alegria*, *tristeza*, *surpresa positiva* ou *surpresa negativa*. O grau de concordância Kappa entre os anotadores neste corpus ficou entre 0,24 e 0,51.

Analisando o grau de concordância obtido nos trabalhos, percebe-se que corpora com seis ou mais classes tiveram um baixo grau de concordância se considerar o limite de aceitabilidade defendido por (KRIPPENDORFF, 1980), que considera aceitável um corpus anotado com um valor Kappa superior a 0,67. Para o Português Brasileiro não foi encontrado nenhum corpus que tenha sido anotado com as seis emoções básicas de (EKMAN, 1992) e que estivesse disponível para ser utilizado em pesquisas de AS.

5.2. Construindo um Corpus de Notícias para a Análise de Sentimentos

A maioria dos textos usados para validar os métodos de AS costumam ser informais, com autores expressando livremente as suas emoções. Os textos extraídos de notícias, por sua vez, possuem algumas características que os diferem dos textos comumente usados: são escritos usando uma estrutura formal, e as emoções não são explicitamente encontradas e, quando o são, normalmente apresentam-se contraditórias, como as identificadas no exemplo “*Mãe e*

bebê caem em rio do Recife e dupla consegue resgatar criança” que pode ser interpretado como sendo um texto que transmite um fato alegre e triste ao mesmo tempo.

Alguns pesquisadores da área de AS se interessaram em trabalhar com corpora de notícias. Gomes e colegas (GOMES; NETO; HENRIQUES, 2013) utilizaram um corpus de notícias para monitorar o estado da economia. Em (BALAHUR; STEINBERGER, 2009), os autores ressaltam a importância de se aplicar a AS em textos de notícias. Também destacam os três diferentes tipos de pontos de vista que devem ser levados em conta no momento da anotação quando se trata de textos de notícias: o ponto de vista do autor, do leitor e do texto. Do ponto de vista do autor e do leitor, os fatos transmitidos são interpretáveis pela emoção que emitem, porém algumas dessas emoções não são universais em seu significado e são determinadas por influências sociais e culturais. Os autores citam o exemplo do texto “*The results of the match between Juventus Torino and Real Madrid last night are 3-0*” (“O resultado do jogo entre Juventus de Torino e Real Madrid ontem à noite foi 3-0”), que poderia ser interpretado como algo alegre para um jornal italiano ou uma notícia triste para um jornal espanhol.

Os textos de notícias que compõem o corpus apresentado neste trabalho de pesquisa têm, em média, 23 palavras em cada e foram extraídos automaticamente do site *www.globo.com* mediante uma ferramenta chamada *FeedReader*¹⁷. A Figura 5.1 mostra a interface do software *FeedReader*.

¹⁷ <http://feedreader.com/>

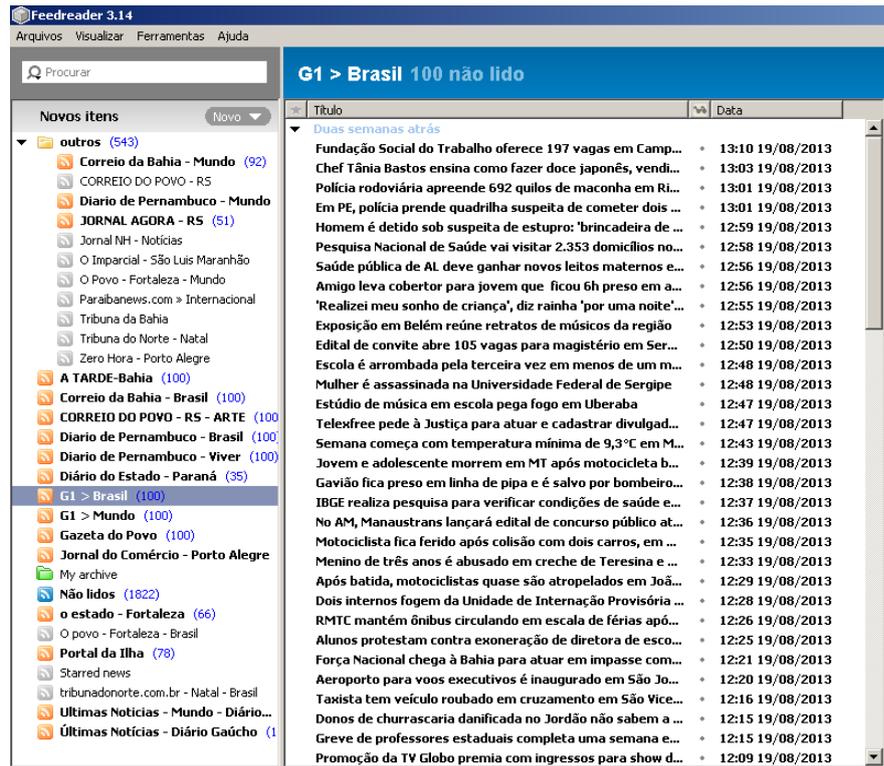


Figura 5.1: Interface do software utilizado para extrair notícias online

Os textos do corpus de notícias pertencem a diferentes categorias, tais como: mundial, política, polícia e economia. O corpus contém 2.000 textos anotados e distribuídos da seguinte forma: 184 (9%) anotados como *alegria*, 262 (13%) como *repugnância*, 222 (11%) como *medo*, 83 (4%) como *raiva*, 252 (13%) como *surpresa*, 455 (23%) como *tristeza* e 542 (27%) como textos neutros.

Uma primeira conclusão importante a se destacar no corpus de notícias é o alto grau de desbalanceamento entre as emoções (classes). Há uma grande dificuldade em encontrar textos jornalísticos com a emoção predominante *raiva*.

Anterior ao processo de anotação dos textos, a pesquisa proposta neste trabalho foi encaminhada para o Comitê de Ética em Pesquisa da PUCPR, a qual recebeu um Certificado de Apresentação para Apreciação Ética (CAAE) sob o número 247648813.7.0000.0020 (parecer no Anexo 1). Todos os voluntários envolvidos na pesquisa preencheram e assinaram o Termo de Consentimento Livre e Esclarecido que está no Anexo 2.

O processo de anotação dos textos iniciou-se com cinco anotadores voluntários. Estabeleceu-se como regra que todos os textos do corpus fossem anotados por dois anotadores diferentes e, em caso de discordância, o texto deveria passar pela análise de um terceiro ano-

tador. Uma das principais dificuldades do processo de anotação como um todo foi encontrar voluntários aptos e que executassem a atividade com comprometimento. O perfil esperado dos voluntários era de profissionais com experiência em Linguística ou Linguística Computacional e que não estivessem envolvidos no projeto do método de AS.

Na primeira etapa do processo de anotação, que consistia em anotar 2.000 textos, participaram cinco anotadores voluntários, todos profissionais com experiência mínima de 15 anos em Linguística (professores no ensino superior). Cada anotador teve dois meses para que esta etapa fosse concluída. Ao final deste prazo apenas 1.540 textos foram anotados duas vezes e 460 textos tiveram que ser submetidos à análise de um novo anotador.

A atividade de anotação consistiu em ler o texto e identificar a emoção (ou ausência dela) presente no mesmo. Os anotadores foram orientados a avaliar os textos considerando a interpretação do ponto de vista do autor. Os rótulos possíveis nos textos eram: *alegria*, *tristeza*, *raiva*, *medo*, *repugnância*, *surpresa* e *neutro*. A cada texto foi atribuído um único rótulo, ou seja, aquele que representa a emoção predominante do texto. O anotador também atribuiu um rótulo de intensidade (ou neutralidade) da emoção no texto. Esta intensidade pôde ser escolhida entre *alta*, *média* ou *baixa*. O anotador tinha a possibilidade de escolher uma emoção secundária, para indicar um segundo rótulo e uma segunda intensidade. Apesar de não ser obrigatória, esta opção foi fornecida a fim de facilitar o processo de anotação de textos que possuem duas emoções na mesma proporção.

Apesar da atividade de anotação ser uma tarefa completamente subjetiva, é preciso encontrar uma forma de padronizá-la. Assim, foi elaborado um documento com orientações aos anotadores (apresentado no Apêndice 1). Este documento contém informações a respeito dos textos, como: tipo (domínio), categorias (emoções), instruções de como usar o sistema web de anotação, além de uma lista de 40 textos já anotados pela equipe do projeto. Estes textos, usados como modelo, foram escolhidos por serem difíceis de serem analisados. A maioria deles continha várias emoções por texto ou emoções contraditórias.

Os anotadores foram incentivados a identificar primeiramente a emoção predominante em cada sentença do texto; em seguida identificar a emoção que obteve o maior número de ocorrências no texto como um todo e, por fim, determinar esta emoção como sendo a predominante do texto. Em muitos textos, porém, ocorreu um empate no número de emoções encontradas nas sentenças e nessas situações, optou-se pela escolha intuitiva da emoção, anali-

sando o documento em sua totalidade. Na Tabela 5.1 podem ser visualizados dois dos 40 textos que foram fornecidos previamente aos anotadores a título de ilustração do processo.

Tabela 5.1: Exemplos de anotação de textos

| Texto | Emoções em cada sentença | Emoção predominante | Intensidade |
|---|--|---------------------|-------------|
| Mãe e bebê caem em rio do Recife e dupla consegue resgatar criança. Mulher ainda está desaparecida e bombeiros trabalham nas buscas. No momento do acidente, chovia muito e nível do Rio Tejiipió havia subido. | <i>Sentença 1:</i> tristeza e alegria <i>Sentença 2:</i> tristeza <i>Sentença 3:</i> repugnância | tristeza | alta |
| Estudante queimada em sessão de bronzamento recebe alta, em Goiás. Mãe comemora recuperação: 'Ela está bem emocionalmente, animada'. Treze mulheres se queimaram ao passar óleo de coco com canela, em Jataí. | <i>Sentença 1:</i> tristeza e alegria <i>Sentença 2:</i> alegria <i>Sentença 3:</i> tristeza | alegria | baixa |

Para gerenciar o processo de anotação e registrar os dados anotados, implementou-se um sistema web de anotação¹⁸. A Figura 5.2 apresenta a interface principal do sistema de anotação de textos. Ao lado esquerdo de cada texto há um botão *expandir*, que ao ser acionado, permite ao anotador escolher as opções de anotação.

¹⁸ <http://www.ppgia.pucpr.br/~paraiso/mineracaodeemocoes/pesquisa>

EmoçõesBR @ Rotulação

Show entries Search:

| # | Texto | Rótulo |
|---|---|--------|
| 1 | Britânica pega 14 semanas de prisão por matar gato no micro-ondas. Mulher de 23 anos sofre de problemas psicológicos. Ela admitiu ato após gato ter comido um peixe. | |
| Emoção primária: <input type="button" value="Alegria"/> <input type="button" value="Desgosto"/> <input type="button" value="Medo"/> <input type="button" value="Raiva"/> <input type="button" value="Surpresa"/> <input type="button" value="Tristeza"/> <input type="button" value="Neutro"/> | | |
| Intensidade primária: <input type="button" value="Baixa"/> <input type="button" value="Media"/> <input type="button" value="Alta"/> | | |
| Emoção secundária: (Opcional) <input type="button" value="Alegria"/> <input type="button" value="Desgosto"/> <input type="button" value="Medo"/> <input type="button" value="Raiva"/> <input type="button" value="Surpresa"/> <input type="button" value="Tristeza"/> <input type="button" value="Neutro"/> | | |
| Intensidade secundária: (Opcional) <input type="button" value="Baixa"/> <input type="button" value="Media"/> <input type="button" value="Alta"/> | | |
| 2 | Câmera flagra ladrão dentro de loja de roupas em MG: Perfumaria, que fica ao lado, também foi invadida. Ele está sendo procurado pela polícia. | |
| 3 | Indústria 'empurra' novas drogas, sem garantir que são melhores que antigas: Interesses comerciais acabam muitas vezes atrapalhando tratamentos. Opinião é de psiquiatra americano, em artigo no jornal "New York Times". | |
| 4 | Primeiro centro de pesquisa brasileiro da Boeing é inaugurado em São José. Objetivo é desenvolver projetos em parceria com setor aeroespacial. Empresa é a maior do mundo no setor, Brasil é o 6º país a receber centro. | |
| 5 | Arqueólogos encontram vestígios com mais de 1.200 anos em MG: Pesquisadores localizaram amostras de vegetais em Montes Claros. Com projeto, cientistas querem aproximar comunidade das descobertas. | |
| 6 | Energia do impacto sobre Felipe Massa foi 30% da letal, estima engenheiro: Perito em acidentes automotivos ressalva que adotou premissas. Detalhes que só a perícia vão revelar indicarão números exatos. | |
| 7 | Homem rouba 2 bolsas e é espancado por 10 pessoas em Araraquara, SP. Suspeito de 36 anos está em estado grave e respira com aparelhos. Esse foi o 2º caso de espancamento registrado na cidade em 9 dias. | |
| 8 | Corpo de coreano morto em obra do metrô deixa a capital baiana. Segundo consulado, corpo de Kim Jong Pyo segue para a Coreia na sexta. Vítima morreu após choque próximo à Estação Acesso Norte. | |
| 9 | Quarto jacaré é encontrado na Região Metropolitana do Recife, esta semana. mal da espécie papo amarelo tem 1,5 metro e foi levado ao Ibama. | |
| 10 | Novo radar vai detectar voos em baixa altitude na fronteira amazônica: Equipamento pode identificar rotas de até 40 alvos simultaneamente. Aviões serão localizados se voarem abaixo de 300 metros de altura. | |

Showing 1 to 10 of 10 entries Previous Next

Figura 5.2: Interface do software de anotação de textos

Cada anotador cadastrado no sistema de anotação recebeu um login e senha para acessá-lo. O administrador configura o número de textos que os anotadores receberão ao acessarem o sistema. Por exemplo, se o sistema foi configurado para mostrar 25 textos a cada vez, o anotador deverá avaliar todo o conjunto de 25 textos e submeter os dados para então receber mais um novo conjunto de 25 textos.

Na segunda etapa do processo de anotação foi necessário que um novo anotador decidisse o rótulo dos textos que não obtiveram concordância na primeira etapa do processo. Nos casos em que os textos haviam recebido um segundo rótulo e/ou grau de intensidade em uma ou em ambas as anotações, o anotador analisava essas informações antes de escolher o rótulo final. Nos textos que não continham esta informação, o anotador era obrigado a escolher intuitivamente um entre os dois rótulos possíveis.

5.3. Avaliação da Concordância entre os Anotadores

O percentual de casos em que dois anotadores concordam em relação à classificação de um conjunto de textos com um dado número de categorias é a forma mais simples de se atribuir confiabilidade a um processo de anotação de textos realizado em um determinado corpus. Porém, este método não considera a proporção dessa concordância que é devido ao acaso. O coeficiente Kappa leva em conta no cálculo a proporção de concordância que ocorre devido ao acaso e por esse motivo é bastante utilizado para medir a concordância entre anotadores em corpora de sistemas de AS.

Em Linguística Computacional, o limite de aceitabilidade do grau de concordância de um corpus anotado pode variar de pesquisador para pesquisador. (KRIPPENDORFF, 1980), defende que só pode ser considerado aceitável um corpus anotado com um valor Kappa superior a 0,67. Em (ARTSTEIN; POESIO, 2005) verificou-se que apenas valores acima de 0,8 sugerem uma anotação de qualidade. Entretanto, (EUGENIO; GLASS, 2004) sugerem que os pesquisadores devem apresentar detalhadamente a metodologia que foi seguida na coleta e anotação dos textos, como por exemplo, número de anotadores, se os textos foram anotados independentemente, se a anotação se baseou em um manual de anotação, dentre outros detalhes.

Neste trabalho, o coeficiente Kappa foi usado para avaliar o grau de concordância entre os anotadores. Para tal, alguns experimentos foram realizados durante o processo de anotação. No primeiro experimento, o objetivo foi verificar o grau de concordância geral entre as duas anotações realizadas em cada um dos 2.000 textos de notícias, além do grau de concordância entre as duas anotações em relação a cada categoria (emoção). A Tabela 5.2 apresenta a matriz de confusão da concordância para os 2.000 textos anotados. A Tabela 5.3 apresenta os valores de concordância obtidos por emoção.

Tabela 5.2: Matriz de confusão da concordância entre anotadores para 2.000 textos

| Categoria | | Anotação 1 | | | | | | |
|------------|-------------|------------|-------------|---------|------|-------|----------|----------|
| | | Neutro | Repugnância | Alegria | Medo | Raiva | Surpresa | Tristeza |
| Anotação 2 | Neutro | 294 | 34 | 51 | 12 | 8 | 64 | 43 |
| | Repugnância | 32 | 66 | 4 | 21 | 13 | 37 | 55 |
| | Alegria | 34 | 1 | 97 | 3 | 0 | 43 | 7 |
| | Medo | 4 | 28 | 1 | 73 | 4 | 27 | 78 |
| | Raiva | 2 | 13 | 1 | 8 | 15 | 5 | 24 |
| | Surpresa | 55 | 18 | 31 | 10 | 8 | 150 | 35 |
| | Tristeza | 23 | 38 | 5 | 50 | 29 | 47 | 299 |

Na Tabela 5.2 os valores destacados na diagonal representam o número de textos que tiveram concordância. O valor Kappa obtido para o acordo geral das categorias entre os seis anotadores foi 0,38, um valor baixo considerando as metas de anotação comumente usadas em Linguística Computacional (KRIPPENDORFF, 1980) e (ARTSTEIN; POESIO, 2008).

Analisando os valores de Kappa apresentados na Tabela 5.3 e o número de textos que tiveram concordância/discordância em cada categoria apresentada na Tabela 5.2, pode-se verificar que as maiores discordâncias ocorreram entre as categorias *medo*, *repugnância*, *tristeza* e *raiva* e entre as categorias *neutro*, *alegria* e *surpresa*. Isto faz bastante sentido visto que um texto cuja emoção predominante é *tristeza*, por exemplo, pode conter palavras que remetem o anotador a interpretar a emoção do autor como *raiva*, *medo* ou *repugnância*. O texto "*Francesa admite que matou afogados dois bebês encontrados congelados. A mulher, que mantinha o corpo de dois bebês congelados em sua casa no centro da França, declarou à polícia ter matado os dois recém-nascidos afogados*" é um exemplo disso, pois na primeira anotação o texto foi anotado com a emoção *raiva* e na segunda anotação, com *tristeza*. Esta situação também ocorre frequentemente ao analisar os textos das categorias *neutro*, *alegria* e *surpresa*. O texto "*Jornalista Merval Pereira recebe prêmio da Universidade de Columbia: Colunista do jornal O Globo receberá medalha e um prêmio de US\$ 5 mil. Premiação acontecerá em Nova York no dia 14 de outubro*" foi analisado como *alegria* na primeira anotação e como *neutro* na segunda anotação.

Tabela 5.3: Valores Kappa por emoção

| Categoria | Neutro | Repugnância | Alegria | Medo | Raiva | Surpresa | Tristeza |
|------------------|--------|-------------|---------|------|-------|----------|----------|
| kappa | 0,50 | 0,23 | 0,47 | 0,31 | 0,18 | 0,33 | 0,43 |

No segundo experimento o objetivo foi verificar se havia diferença entre as duas anotações quando um mesmo texto é analisado por um mesmo anotador em datas diferentes. Percebeu-se que o grau de subjetividade e o alto número de textos a serem anotados por anotador estavam gerando diferenças de “comportamento” nos anotadores. O sistema de anotação foi configurado para que o anotador anotasse 25 textos por sessão. O anotador poderia realizar várias sessões em sequência. Como o intervalo entre sessões poderia ser curto (segundos) ou longo (semanas), os anotadores não perceberam que anotaram duas vezes alguns textos.

O sistema de anotação foi configurado para que, aleatoriamente, em torno de 20% do total de textos do corpus fossem anotados duas vezes por um mesmo avaliador. Dessa forma,

438 textos foram anotados duas vezes pelo mesmo avaliador na primeira etapa do processo de anotação. Estes textos foram analisados neste segundo experimento. A Tabela 5.4 apresenta a matriz de confusão da concordância entre as duas anotações realizadas pelo mesmo anotador. A Tabela 5.5 apresenta os valores de concordância Kappa obtidos por emoção.

Tabela 5.4: Textos anotados duas vezes pelo mesmo anotador

| | | Anotação 1 | | | | | | |
|------------|-------------|------------|-------------|---------|------|-------|----------|----------|
| | | Neutro | Repugnância | Alegria | Medo | Raiva | Surpresa | Tristeza |
| Anotação 2 | Neutro | 75 | 4 | 2 | 1 | 1 | 7 | 8 |
| | Repugnância | 4 | 14 | 0 | 4 | 3 | 1 | 8 |
| | Alegria | 2 | 0 | 28 | 0 | 0 | 4 | 1 |
| | Medo | 0 | 5 | 0 | 36 | 2 | 2 | 24 |
| | Raiva | 1 | 2 | 0 | 1 | 7 | 0 | 2 |
| | Surpresa | 14 | 4 | 4 | 2 | 3 | 33 | 8 |
| | Tristeza | 5 | 5 | 2 | 11 | 4 | 9 | 85 |

Tabela 5.5: Valores Kappa por emoção

| Categoria | Neutro | Repugnância | Alegria | Medo | Raiva | Surpresa | Tristeza |
|-----------|--------|-------------|---------|------|-------|----------|----------|
| kappa | 0,68 | 0,36 | 0,77 | 0,51 | 0,40 | 0,46 | 0,52 |

O grau Kappa de concordância obtido neste experimento foi de 0,55 e, dessa forma pode-se concluir que mesmo quando um texto é anotado duas vezes pelo mesmo anotador, ainda assim o grau de discordância é bastante alto.

Outros experimentos foram realizados com o corpus de notícias levando-se em conta a anotação e são apresentados no Capítulo 8, pois fazem uso do método de identificação de emoções em textos.

5.4. Considerações Finais

Neste capítulo foi apresentado o processo de anotação do corpus de notícias. Experimentos foram realizados para entender o baixo grau de concordância entre os anotadores. Com base na análise dos resultados foi possível chegar a algumas conclusões. Inicialmente é importante destacar que textos jornalísticos não têm uma grande variabilidade de emoções expressas, em função da forma de escrita utilizada por seus autores (jornalistas).

Pode-se concluir ainda que analisar emoções em um nível de documento contribui para se obter um baixo grau de concordância devido ao grande número de documentos que contêm mais de uma emoção presente. Finalmente, o fato de nos interessar a identificação de seis

diferentes emoções também colabora para que o grau de concordância entre os anotadores seja reduzido.

Capítulo 6

Um Método para a Identificação de Emoções em Textos

Neste capítulo é apresentado o método de identificação de emoções em textos proposto nesta pesquisa. O método foi construído com o objetivo principal de identificar categorias de emoções, neste caso, as seis emoções básicas de (EKMAN, 1992) e a classe *neutro*, em textos escritos em Português do Brasil.

Ao elaborar o método, optou-se por identificar categorias de emoções em textos. Dentre os modelos categóricos de emoções existentes na literatura, adotou-se o modelo de emoções de (EKMAN, 1992), também chamado de emoções básicas, por se tratar de um conjunto de emoções compreensíveis, do ponto de vista das expressões faciais, por pessoas de diferentes culturas.

Como é possível visualizar no Capítulo 4, alguns autores como (STRAPPARAVA; MIHALCEA, 2008), (GHAZI; INKPEN; SZPAKOWICZ, 2010) já identificaram as emoções básicas de (EKMAN, 1992) em textos. Porém, sabe-se que ainda existem muitas discussões a respeito dos modelos categóricos de emoções, principalmente sobre o fato de aplicá-los em textos, visto que os experimentos que evidenciaram a taxonomia das emoções, no caso do modelo de (EKMAN, 1992), se referem à observação da interpretação das emoções por meio das expressões faciais de pessoas de diferentes culturas.

No entanto, ao usar este modelo de emoções no método desenvolvido neste trabalho, acredita-se que as emoções de (EKMAN, 1992) possam ser fortemente influenciadas pela cultura e pela sociedade em que o autor do texto se encontra. Desta forma, o próximo passo a ser realizado na pesquisa (trabalho futuro) é verificar, por meio do método proposto, se as dife-

renças culturais no Brasil influenciam na forma como as pessoas expressam as emoções de (EKMAN, 1992) em textos.

Diante dos diversos estudos de AS já existentes na literatura, percebe-se que há uma carência de métodos que identificam categorias de emoções em textos. Esses métodos são escassos em todos os idiomas e praticamente inexistentes para o idioma Português Brasileiro. Identificar categorias de emoções em textos escritos em Português Brasileiro contribuirá para ampliar o leque de aplicações dos métodos de AS, que até o presente momento se resumem em identificar a polaridade das emoções e, em alguns casos, também os textos neutros.

O método desenvolvido visa identificar as emoções nos textos considerando o ponto de vista do autor, uma vez que a ideia é que o método possa ser aplicado em domínios onde há um interesse em identificar as emoções de quem escreve o texto, como por exemplo, ao identificar as emoções em textos de usuários de redes sociais, em textos de alunos em ambientes virtuais de aprendizagem, em textos de pacientes com distúrbios psiquiátricos, dentre outros domínios de textos. No entanto, isso é independente no método, ou seja, pois depende de como os textos de treinamento foram anotados.

Determinar categorias de emoções em textos pode ser considerado um problema de classificação multiclasse, onde D é um conjunto de documentos e d é um documento sendo que $d \in D$; k é o número de classes e E é conjunto de rótulos das classes $E = \{emo_1, emo_2, \dots, emo_k\}$, onde emo_1 denota o caso especial de neutralidade ou ausência de emoção. O objetivo é determinar uma função $f: d \rightarrow emo_i$, sendo que esta função mapeia um documento d em um dos elementos de E .

O método de identificação de emoções apresentado neste trabalho não usa nenhum léxico de termos emocionais para extrair as características e para classificar os textos. Sabe-se que o uso de léxicos tornam o método dependente destes recursos e o objetivo deste método é que ele seja o mais independente possível de recursos externos. Além disso, para o Português Brasileiro, ainda não existe um léxico de termos emocionais consolidado, que possa ser aplicado para as seis emoções básicas de (EKMAN, 1992).

Também a opção de se traduzir os léxicos já existentes da língua Inglesa para o Português Brasileiro pode ser um processo complexo devido às especificidades da língua Portuguesa, embora já exista uma tradução e adaptação do *Affective Norms for English Words* (ANEW) para o Português Brasileiro (ANEW-Br) (KRISTENSEN et al., 2011). Apesar desta tradução e adaptação ter sido realizada para um conjunto de 1.046 palavras em Português, ela

não se aplica às emoções básicas de (EKMAN, 1992) por definir a emoção das palavras por meio de uma escala de avaliação de valência e de alerta (BRADLEY; LANG, 1999).

O método descrito neste capítulo usa classificadores SVM para classificar as emoções nos textos, embora outros algoritmos de classificação também possam ser utilizados. Na literatura existem alguns argumentos teóricos que justificam o uso do SVM para classificar dados textuais. Esses argumentos acabam se confirmando ao se observar os resultados obtidos com o algoritmo na maioria dos trabalhos de AS disponíveis na literatura.

Segundo (JOACHIMS, 1998), uma particularidade dos dados textuais é que a maioria das características são relevantes, o que conduz a uma alta dimensionalidade dos dados na representação vetorial. O SVM consegue combinar muitas características e lidar bem com o problema da dimensionalidade. O SVM também é adequado para tratar problemas com dados esparsos como é o caso, por exemplo, dos dados textuais nos quais um vetor correspondente a um documento que pode conter poucas entradas diferentes de zero. Além disso, o SVM é capaz de linearizar os dados, mesmo que para isso tenha que contar com o auxílio de *kernels* (RBF, polinomial, linear, etc.).

6.1. Pressupostos do Método

O método de identificação de emoções em textos tem os seguintes pressupostos: 1) o método deverá identificar automaticamente emoções em textos escritos em Português do Brasil; 2) o método deverá identificar nos textos as seis emoções básicas de (EKMAN, 1992) sendo elas *alegria*, *tristeza*, *raiva*, *medo*, *repugnância* e *surpresa*, além da classe *neutro*; 3) o método está preparado para identificar emoções em textos não estruturados; 4) o método não fará uso de recursos linguísticos como dicionários léxicos de termos emocionais ou ontologias de domínios; 5) o método foi desenvolvido para analisar textos curtos, semelhantes aos extraídos de redes sociais. Ao aumentar o tamanho dos textos, aumenta-se também o número de emoções presentes no texto e, conseqüentemente, diminui-se a precisão do método ao identificar a emoção predominante.

6.2. Visão Geral do Método

O método de identificação de emoções foi desenvolvido utilizando uma abordagem de AM supervisionada para classificar os textos em uma das sete classes nominais (*alegria*, *tristeza*, *raiva*, *medo*, *repugnância*, *surpresa* e *neutro*). A Figura 6.1 fornece uma visão geral do

funcionamento do método. Neste trabalho é utilizado o *Business Process Model and Notation* (BPMN) (CAMPOS, 2013) como linguagem para a especificação do controle de fluxo de tarefas dos processos.

O método de identificação de emoções em textos opera em camadas. Na primeira camada, pré-processa os dados e rejeita os textos nos quais o classificador não tem "certeza" suficiente sobre a classe correta. Os textos rejeitados na primeira camada poderão ser classificados posteriormente pelos classificadores da segunda camada, que são classificadores binários.

Os Classificadores de Resolução de Confusão (CRCs), como são chamados os classificadores da segunda camada, são treinados e novas características são extraídas para tornar esses classificadores específicos para tratar as instâncias mais "confusas".

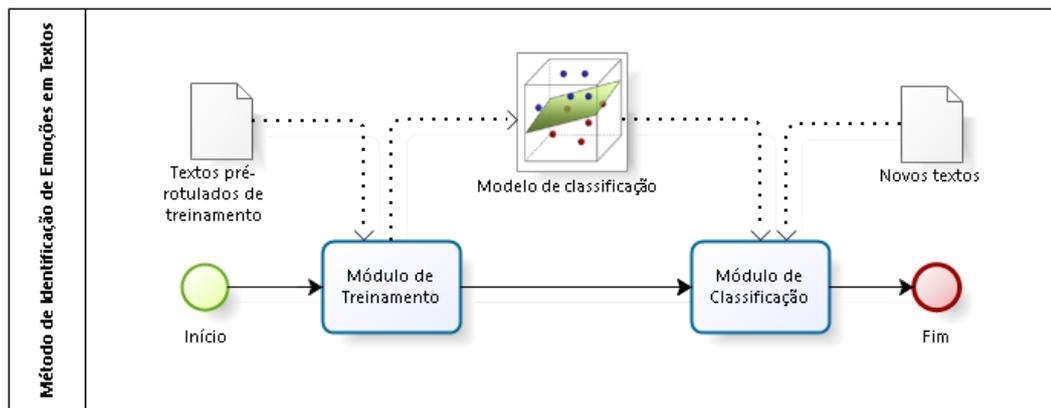


Figura 6.1: Visão geral do método de identificação de emoções em textos

O método é composto por um módulo de treinamento que necessita de um conjunto de dados de treinamento para gerar um modelo de classificação. Este modelo é utilizado no módulo de classificação para classificar novos textos. Ambos os módulos são detalhados na sequência.

6.3. Módulo de Treinamento

O módulo de treinamento visa treinar o método de identificação de emoções para atuar em um determinado domínio de textos. Este módulo é composto por quatro etapas principais: a preparação dos dados textuais, a seleção das características, a representação vetorial e o treinamento dos classificadores (Figura 6.2).

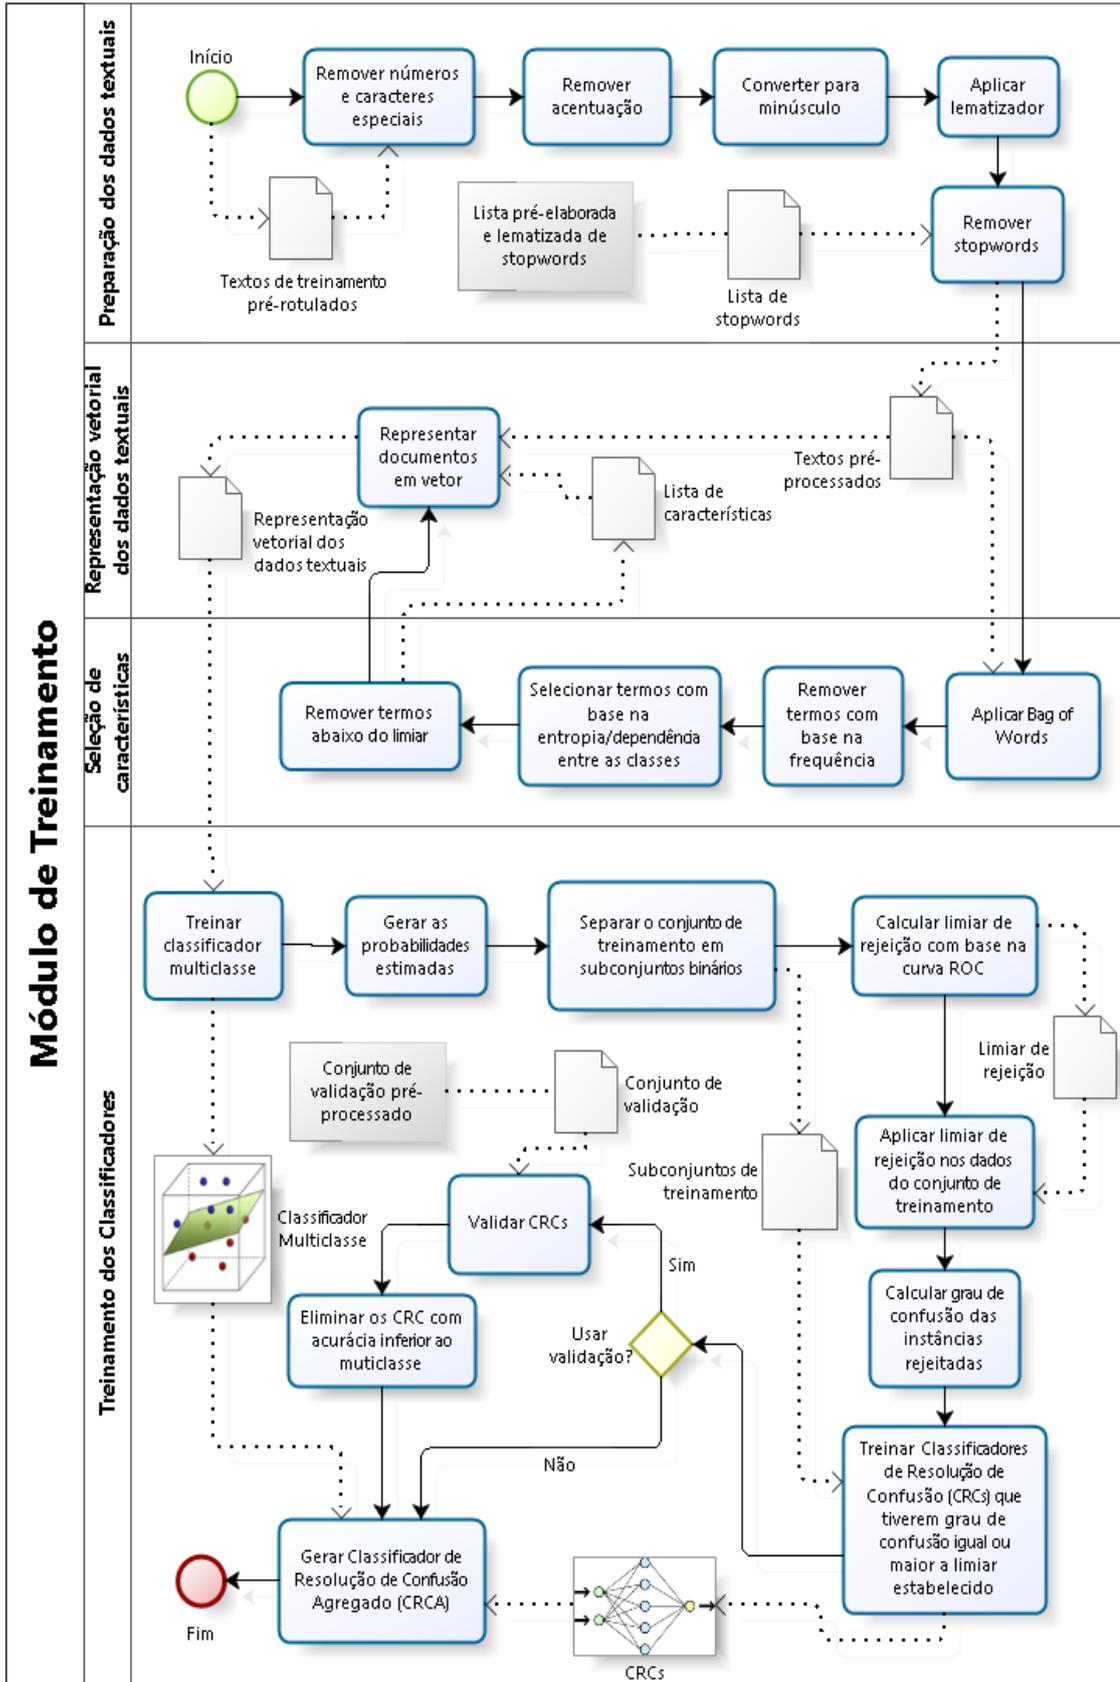


Figura 6.2: Módulo de treinamento do método

6.3.1. Preparação dos Dados Textuais

Como pode ser visualizado na Figura 6.2, os textos de treinamento submetidos ao método passam primeiramente pela etapa de preparação dos dados. Esta etapa é composta pelas seguintes atividades: remoção dos números e caracteres especiais (sinais de pontuação, símbolos e hífens), remoção dos acentos, transformação dos textos para letras minúsculas, aplicação de um lematizador e remoção das *stopwords*. O lematizador visa reduzir a dimensionalidade dos dados removendo sufixos e/ou prefixos de forma a reduzir um termo ao seu radical.

A última etapa da preparação dos dados se refere a remoção de termos com base em uma lista pré-definida de *stopwords*. O método usa uma lista de *stopwords* composta por conjunções, preposições e artigos da língua Portuguesa (Apêndice 2).

6.3.2. Seleção de Características

A etapa de seleção de características do método é realizada da seguinte forma: os dados gerados pela etapa de preparação são submetidos a um processo *bag-of-words* (RADOVANOVIĆ; IVANOVIĆ, 2008), em que é gerada uma lista sem repetição dos termos que ocorrem nos documentos. A partir desta lista de termos são aplicadas técnicas destinadas a reduzir a dimensionalidade dos dados e a extrair as melhores características do conjunto de dados.

Na sequência é aplicada uma técnica baseada na frequência dos termos para reduzir a dimensionalidade dos dados. Desta forma, são excluídos todos os termos que possuem um número de ocorrências global inferior a um limiar pré-estabelecido. Esta técnica leva em consideração a hipótese de que termos muito raros são irrelevantes para a classificação do documento.

Em seguida são aplicadas técnicas para extrair as melhores características do conjunto de treinamento. A técnica de GI, conforme apresentada no Capítulo 3 (equações 3.1 e 3.2), verifica o grau de entropia e o ganho de informação dos termos em relação às classes e a técnica de IM, como apresentada no Capítulo 3 (equações 3.3 e 3.4), mede o grau de dependência dos termos em relação às classes. Após a aplicação dessas técnicas nos termos do conjunto de treinamento, o método faz um ranqueamento dos termos com base no seu valor em ordem decrescente e são excluídos todos aqueles que possuem um valor inferior ao limiar.

Os limiares de GI e/ou IM podem ser obtidos automaticamente de acordo com o número de casos de instâncias ambíguas que são geradas durante o pré-processamento. Esses

limiares são estabelecidos de forma que o número de instâncias ambíguas geradas durante o pré-processamento seja igual a zero. Neste contexto, uma instância é dita ambígua quando há outra instância exatamente igual em relação à sua representação vetorial, mas com classe diferente. O limiar de GI e/ou IM é obtido automaticamente por meio de uma busca binária, que visa encontrar um limiar que não gere nenhuma instância ambígua.

6.3.3. Representação Vetorial dos Dados Textuais

No método de identificação de emoções, os dados textuais são representados em vetor usando uma representação TF-IDF (SALTON; BUCKLEY, 1988) conforme as equações 3.10 e 3.11, apresentadas no Capítulo 3.

O TF-IDF é usado no método com o seguinte princípio: 1) quanto maior a frequência de um termo em um documento, mais representativo ele é para o conteúdo, e 2) quanto mais documentos contiverem um termo, menos discriminante ele é para o conteúdo. Dessa forma, o TF-IDF atribui pesos para os termos que ocorrem nos documentos.

6.3.4. Treinamento dos Classificadores

Na etapa de treinamento dos classificadores, os documentos devidamente pré-processados e representados em vetor são submetidos ao treinamento de um classificador SVM multiclasse. Por meio de Validação Cruzada são obtidas as probabilidades estimadas. As probabilidades estimadas têm diversas funções no método, uma delas é possibilitar a aplicação de uma Estratégia de Rejeição (ER).

Com o objetivo de incrementar o processo de classificação, o conceito de rejeição admite que um sistema de classificação aplique uma decisão global de aceitar ou recusar uma instância se o classificador não estiver certo o suficiente para classificá-la. Conhecidas as probabilidades estimadas fornecidas pelo classificador, uma ER pode ser aplicada. A decisão de aceitar ou rejeitar uma instância é controlada por um limiar. Quando uma instância possui probabilidade estimada maior ou igual ao limiar, esta instância é classificada, enquanto que as instâncias com valores inferiores ao limiar são rejeitadas. A finalidade, ao se aplicar uma ER em um determinado problema, é encontrar um valor ótimo para o limiar de rejeição de forma a rejeitar todos os exemplos incorretamente classificados e aceitar todos os exemplos corretamente classificados pelo classificador (MARINI; KOERICH, 2008).

Algumas das ERs mais utilizadas e descritas na literatura são: rejeição com um único limiar (CHOW, 1970), rejeição com múltiplos limiares (FUMERA; ROLI; GIACINTO, 2000) e rejeição utilizando a diferença entre os dois maiores valores de confiança obtidos na saída do classificador (PITRELLI; PERRONE, 2002).

Na ER com um único limiar, apenas um limiar de rejeição T é estabelecido para todas as classes (CHOW, 1970). Dessa forma, uma instância x é associada a uma classe c_k caso respeite a Equação 6.1 e a instância é rejeitada caso respeite a Equação 6.2.

$$\max_{k=1,\dots,n} P(c_k | x) \geq T \quad (6.1)$$

$$\max_{k=1,\dots,n} P(c_k | x) < T \quad (6.2)$$

Sendo $T \in [0,1]$.

Na ER com múltiplos limiares (FUMERA; ROLI; GIACINTO, 2000), é proposto o uso de um limiar para cada classe do problema. Para esta estratégia, uma instância x é associada a uma classe c_k caso respeite a Equação 6.3 e rejeitada caso respeite a Equação 6.4.

$$\max_{k=1,\dots,n} P(c_k | x) \geq T_i \quad (6.3)$$

$$\max_{k=1,\dots,n} P(c_k | x) < T_i \quad (6.4)$$

Sendo $T \in [0,1]$.

Na ER que utiliza a diferença entre os dois maiores valores de confiança, o limiar é obtido calculando-se a diferença entre as duas maiores probabilidades estimadas obtidas na saída do classificador (PITRELLI; PERRONE, 2002).

Essas três ERs fazem parte do método. Ao serem aplicadas, o método calcula, com base nas probabilidades estimadas dos dados de treinamento, os dois erros que podem ocorrer: a *False Acceptance Rate* (FAR) e a *False Rejection Rate* (FRR). A FAR é a taxa de erro calculada pela Equação 6.5 e representa as instâncias incorretas que foram aceitas erroneamente pelo classificador e FRR é a taxa de erro calculada pela Equação 6.6 e representa as instâncias corretas que foram rejeitadas erroneamente pelo classificador.

$$FAR = \frac{FA}{FA + CR} \quad (6.5)$$

$$FRR = \frac{FR}{FR + CA} \quad (6.6)$$

Sendo:

- Correta Aceitação (CA): Instâncias classificadas corretamente são aceitas pelo classificador;
- Correta Rejeição (CR): Instâncias classificadas incorretamente são rejeitadas pelo classificador;
- Falsa Aceitação (FA): Instâncias classificadas incorretamente são aceitas pelo classificador;
- Falsa Rejeição (FR): Instâncias classificadas corretamente são rejeitadas pelo classificador.

Uma forma de se obter um limiar de rejeição mais adequado é checar todos os possíveis limiares entre 0 e 1, avaliando FRR e FAR e plotando os resultados em uma curva ROC (*Receiver Operating Characteristic*). Uma curva ROC mais próxima da origem indica uma medida de confiança alta, permitindo uma taxa mais baixa de ambos os tipos de erros em simultâneo. O limiar que representa a menor taxa de FRR e FAR é aplicado nas instâncias de treinamento. As instâncias cuja maior probabilidade estimada for menor que o limiar de rejeição, serão rejeitadas. Um pseudocódigo que exemplifica a busca automática do limiar ao usar uma ER (CHOW, 1970) é mostrado no Apêndice 4.

Tanto as instâncias rejeitadas como as não rejeitadas do conjunto de treinamento são usadas no método para treinar os CRCs. Os CRCs são classificadores destinados a tratar as maiores confusões detectadas durante o treinamento do classificador multiclasse e são criados dinamicamente pelo método.

Para criar os CRCs, primeiramente o método separa o conjunto dos dados de treinamento em subconjuntos. O conjunto de treinamento é composto por instâncias de k classes, então o método separa as instâncias em k subconjuntos. Na sequência, o método faz todas as combinações binárias possíveis para esses subconjuntos. Exemplificando: dado um conjunto de treinamento composto por instâncias de sete classes, existem 21 combinações possíveis de classificadores binários. Para cada CRC é extraído um novo conjunto de características baseado nos dados do seu respectivo conjunto de treinamento. A ideia básica do método é que os CRCs possam ser usados para classificar as instâncias rejeitadas pelo classificador multiclasse que possuam um alto grau de confusão.

Ao avaliar o classificador SVM multiclasse durante o treinamento é possível avaliar o nível de confiança das saídas. Um exemplo disso pode ser verificado na Tabela 6.1. Neste exemplo, para um conjunto de dados de treinamento, composto por 1.600 instâncias e sete

classes, avaliado por meio de Validação Cruzada com dez partes, foi possível verificar que em torno de 75% das instâncias, a classe correta se encontra entre a primeira e a segunda maior probabilidade estimada, e que isto se reflete ao avaliar o modelo de classificação com um conjunto de dados de teste composto por 200 textos.

Tabela 6.1: Medidas de confiança de um classificador SVM multiclasse

| | Avaliação do classificador multiclasse | |
|---------------------------------|---|---------------------------------|
| | Durante o Treinamento (1.600 textos) | Durante o Teste (200 textos) |
| 1ª maior probabilidade estimada | 60,3% | 58% |
| 2ª maior probabilidade estimada | 16,5% | 16,0% |
| 3ª maior probabilidade estimada | 9,2% | 6,5% |
| 4ª maior probabilidade estimada | 6,2% | 5,0% |
| 5ª maior probabilidade estimada | 3,6% | 5,0% |
| 6ª maior probabilidade estimada | 3,1% | 6,5% |
| 7ª probabilidade estimada | 1,2% | 3,0% |

Sabendo-se disso, estabeleceu-se um critério para conduzir as instâncias rejeitadas aos CRCs. Esse critério foi determinado por meio da análise das probabilidades estimadas das instâncias rejeitadas do conjunto de treinamento. Primeiro, separa-se as instâncias rejeitadas em subconjuntos binários conforme as classes da primeira e da segunda maior probabilidade estimada, e em seguida, considerando que para cada subconjunto tem-se:

A = quantidade de instâncias cuja a maior probabilidade estimada é a classe correta.

B = quantidade de instâncias cuja a segunda maior probabilidade estimada é a classe correta.

C = quantidade de instâncias cuja classe correta não é nem a primeira nem a segunda maior probabilidade estimada.

Calcula-se o grau de confusão entre as classes por meio da Equação 6.7.

$$\text{Grau de Confusão} = \frac{B}{(A + B)} \quad (6.7)$$

Se o grau de confusão obtido em um determinado subconjunto binário de instâncias rejeitadas do conjunto de treinamento é maior ou igual a um limiar de confusão determinado no método, então o CRC correspondente a este subconjunto binário será utilizado para classificar os novos textos, cuja classe da primeira ou da segunda maior probabilidade estimada

pertençam às respectivas classes do CRC. Exemplificando o processo que ocorre no método durante a seleção dos CRCs: um determinado conjunto de treinamento composto por 1.600 textos tem, após ser aplicada uma dada ER, um conjunto de 766 instâncias rejeitadas. Dessas instâncias, 123 pertencem ao subconjunto binário REPUGNÂNCIA x NEUTRO. Isto significa que a primeira ou a segunda maior probabilidade dessas instâncias se refere ou a classe *repugnância* ou a classe *neutro*. Constatou-se que: em 59 destas instâncias, a classe correta se encontra na primeira maior probabilidade, em 24 delas, a classe correta se encontra na segunda maior probabilidade e em 40 delas, a classe correta se encontra em uma das demais probabilidades estimadas. Assim, o grau de confusão calculado conforme a Equação 6.7 obtém um valor de 0,29, o que significa que em 29% das instâncias desse subconjunto binário, a classe correta se encontra na segunda maior probabilidade estimada.

Considerando o grau de confusão obtido pelo subconjunto no exemplo anterior e o limiar de rejeição predefinido com um valor de 20%, o método selecionará o CRC REPUGNÂNCIA x NEUTRO para classificar as instâncias rejeitadas, cuja primeira e segunda maior probabilidade estimada se referem à classe *repugnância* ou *neutro*. Dessa forma, todos os CRCs que apresentarem um grau de confusão igual ou superior a 20% estarão disponíveis para classificar as novas instâncias que serão rejeitadas. O uso dos CRCs no método nos faz acreditar que é mais fácil resolver as instâncias mais "confusas" com um classificador binário, especializado para tratar essas "confusões", do que com um classificador multiclasse.

O método possui um módulo extra que permite verificar se o desempenho dos CRCs é superior ao desempenho do classificador SVM multiclasse. Este módulo necessita de um conjunto de dados anotados chamado de conjunto de validação.

Ao aplicar uma ER no método, parte-se do princípio que as instâncias rejeitadas na primeira camada do método têm um melhor desempenho ao serem classificadas com os CRCs do que ao serem classificadas com o classificador SVM multiclasse. Dessa forma, o módulo de validação dos CRCs tem a função de verificar se as instâncias rejeitadas do conjunto de validação são melhor classificadas pelos CRCs (como é o esperado) do que pelo classificador SVM multiclasse.

O módulo funciona da seguinte forma: os dados do conjunto de validação são submetidos ao módulo de classificação do método (Figura 6.3 a seguir). Até este ponto, o processo que ocorre com os dados do conjunto de validação é o mesmo que ocorre com qualquer conjunto de dados que é submetido ao módulo de classificação do método. A diferença ocorre na

sequência. As mesmas instâncias rejeitadas do conjunto de validação, que foram submetidas aos CRCs, são submetidas ao classificador SVM multiclasse e são calculadas as métricas de desempenho. O método compara o desempenho obtido pelos CRCs com o desempenho obtido pelo classificador SVM multiclasse. Se um determinado CRC apresentar um desempenho inferior ao desempenho obtido com o classificador SVM multiclasse, este CRC é ignorado e os dados serão classificados pelo classificador SVM multiclasse.

Ao final da etapa de treinamento, o método gera um Classificador de Resolução de Confusão Agregado (CRCA), que é composto por um classificador SVM multiclasse e por um conjunto de CRCs que foram selecionados pelo limiar de confusão e podem ter passado por um processo de validação. Dessa forma, o CRCA vai ser responsável por classificar as instâncias rejeitadas e as não rejeitadas de um novo conjunto de dados. As instâncias não rejeitadas e as instâncias rejeitadas, cujo grau de confusão for inferior ao limiar de confusão, serão classificadas pelo classificador SVM multiclasse e as instâncias rejeitadas, cujo grau de confusão for igual ou superior ao limiar de confusão estabelecido, serão classificadas pelos CRCs.

6.4. Módulo de Classificação

O módulo de classificação visa classificar os novos textos que são submetidos ao método. Ele é composto por três etapas: a preparação dos dados textuais, a representação vetorial e a classificação dos textos. A Figura 6.3 ilustra o fluxo das tarefas executadas neste módulo.

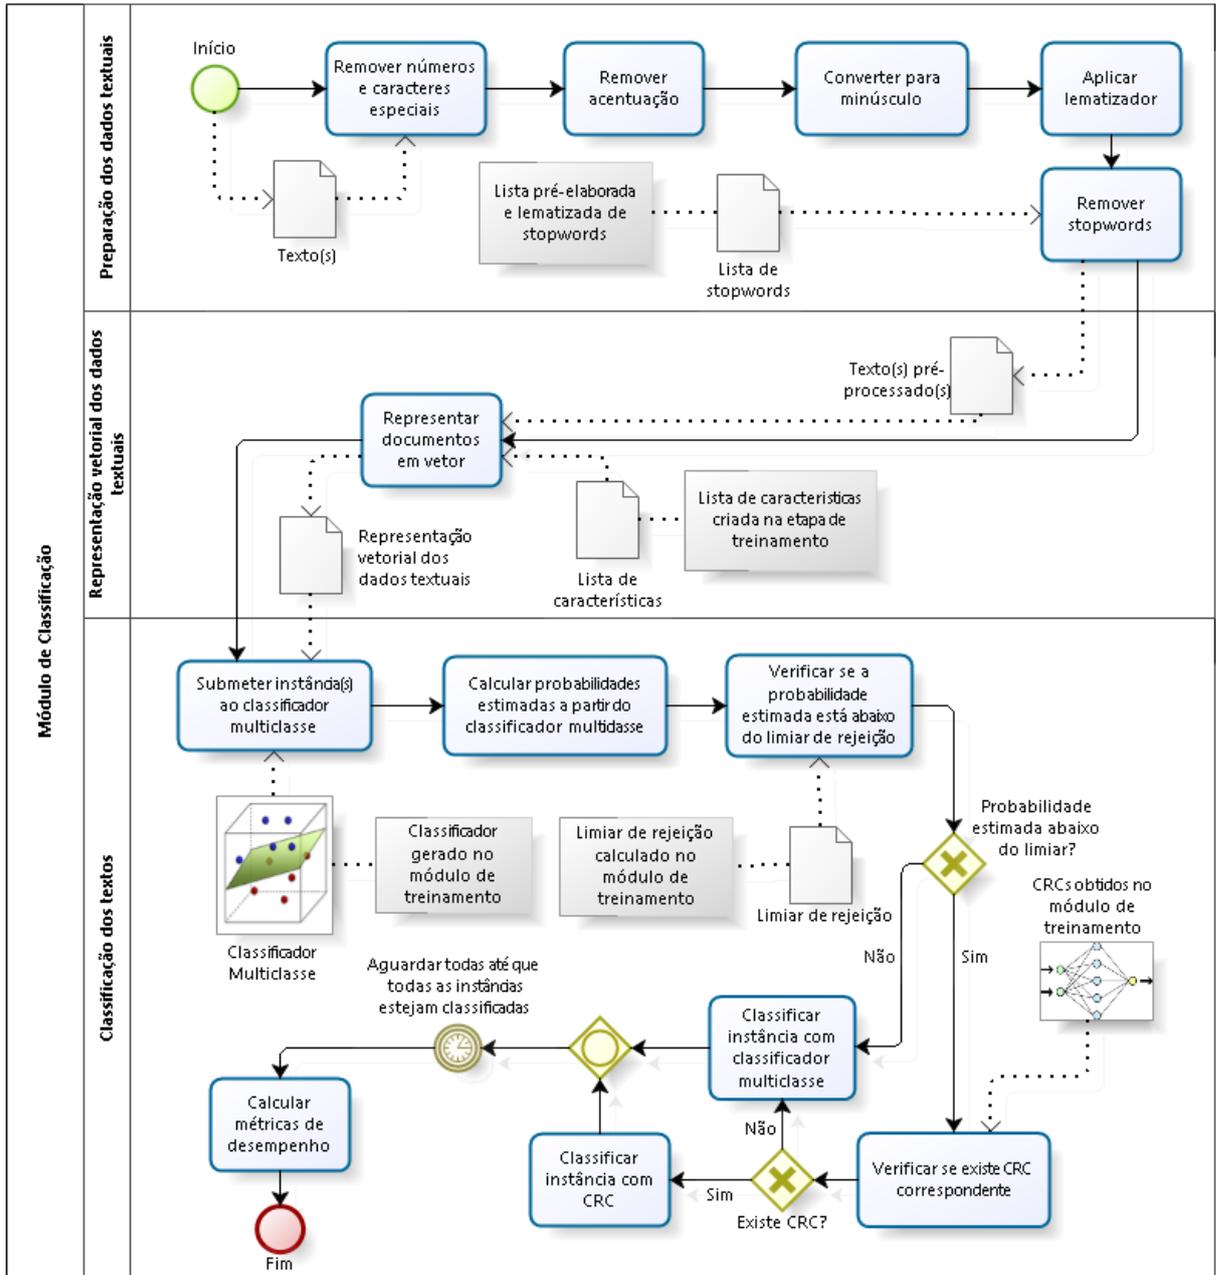


Figura 6.3: Módulo de classificação do método

Conforme a Figura 6.3, no módulo de classificação um novo texto ou um novo conjunto de textos é submetido ao pré-processamento onde é feita a preparação dos dados e a representação vetorial dos dados pré-processados usando a lista de características obtida no módulo de treinamento. Cada texto, devidamente pré-processado e representado em vetor, é submetido ao classificador SVM multiclasse (que foi gerado no módulo treinamento) para que sejam geradas as probabilidades estimadas.

Para cada instância é verificada a probabilidade estimada. Se a probabilidade estimada estiver abaixo do limiar de rejeição, significa que a instância é rejeitada e, dessa forma, é verificado se existe um CRC correspondente a ela, ou seja, se existe um CRC cujas classes sejam equivalentes a primeira e a segunda maior probabilidade da instância. Se existir, a instância será classificada por este CRC, caso contrário, será classificada pelo classificador SVM multiclasse. Se a probabilidade estimada da instância estiver acima do limiar de rejeição, significa que esta é uma instância não rejeitada e portanto, será classificada pelo classificador SVM multiclasse.

Após a instância ou as instâncias serem classificadas, são calculadas as métricas de desempenho. As métricas de desempenho utilizadas no método são apresentadas na segunda seção do Capítulo 7.

6.5. Descrição de Diagramas do Método

Nesta seção são apresentados o diagrama de classes e o diagrama de sequência do método. No diagrama de classes, mostrado na Figura 6.4, são apresentadas as classes com seus atributos e módulos implementados. As classes em cor azul pertencem ao pacote *Fabricas*, e as demais classes, pertencem ao pacote *Base*. As classes são descritas na sequência.

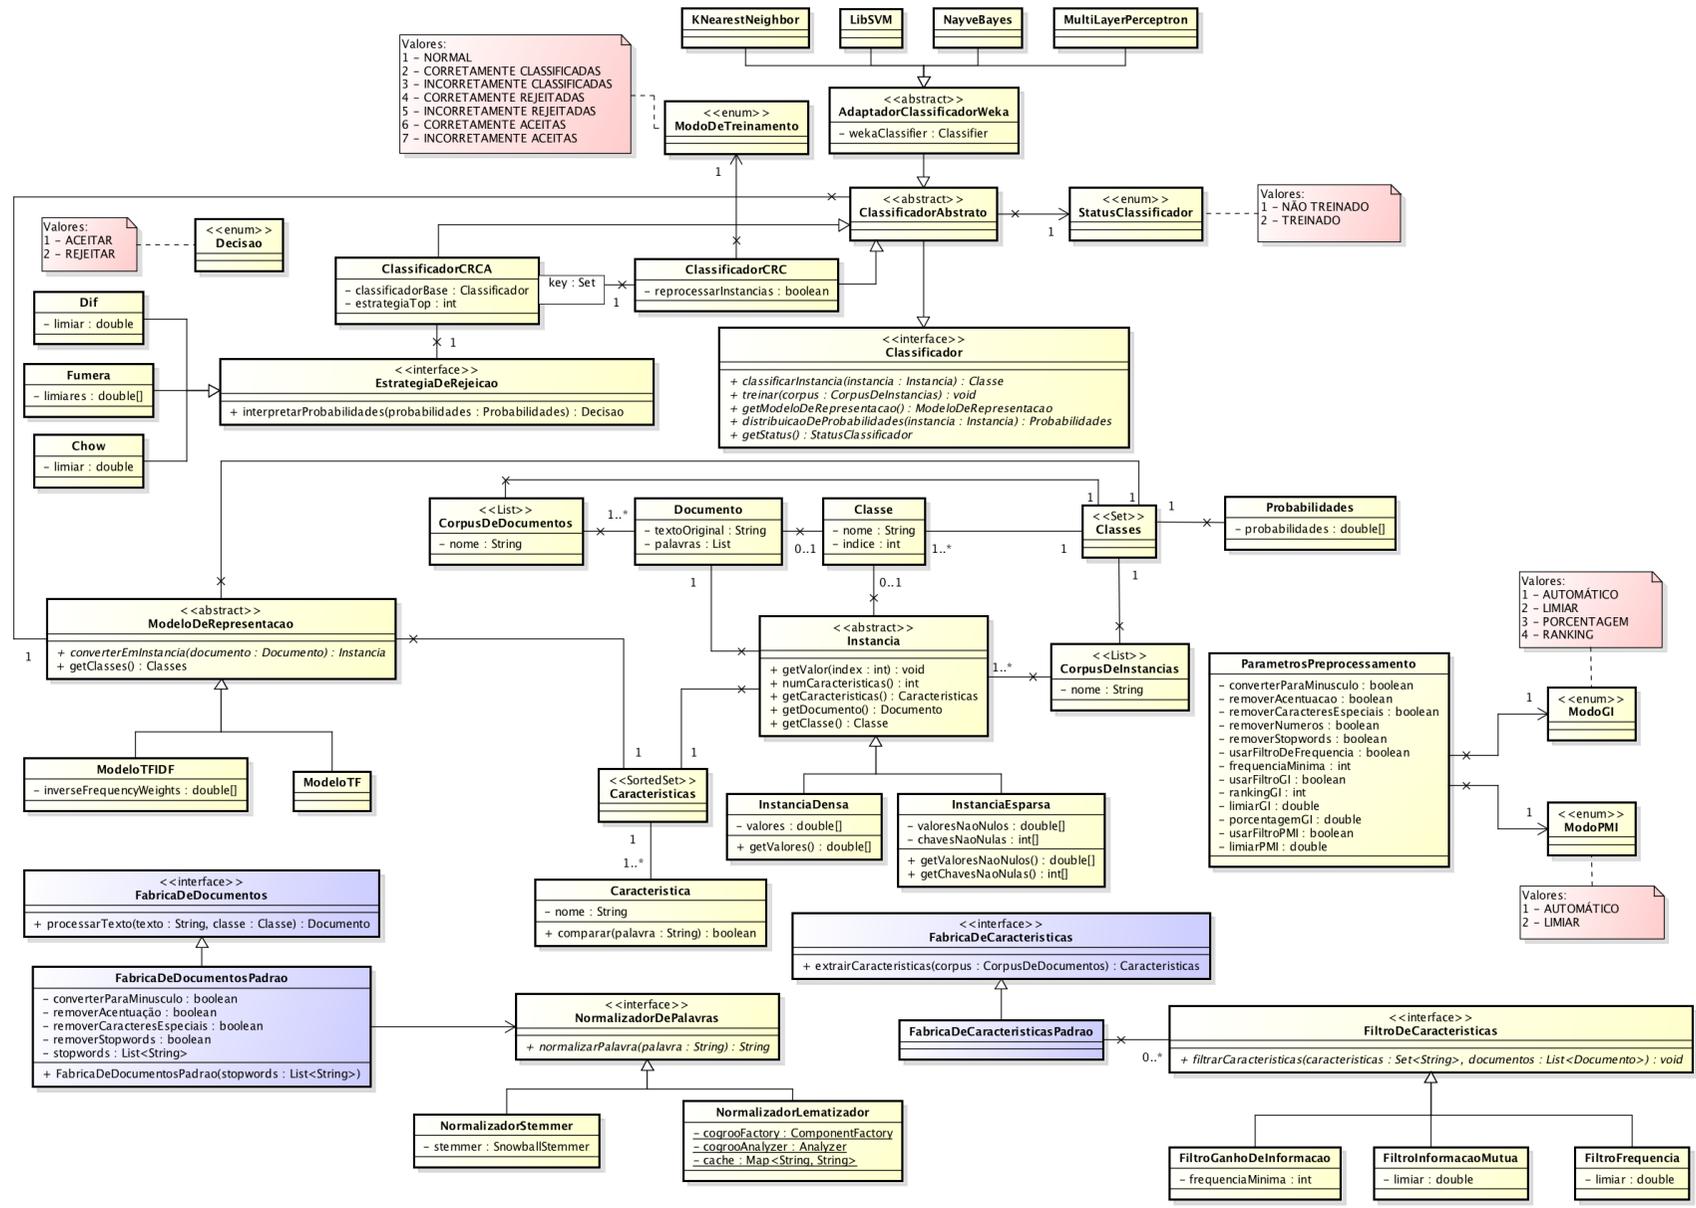


Figura 6.4: Diagrama de classes do método de identificação de emoções em textos

Documento

É a classe que representa o texto pré-processado. Ela possui dois atributos, o *textoOriginal* e *palavras*. O atributo *textoOriginal* representa o texto da forma como ele foi escrito originalmente e será utilizado no processamento do classificador CRC. O atributo *palavras* armazena em forma de lista as palavras pré-processadas do *textoOriginal*.

CorpusDeDocumento

Armazena uma lista de documentos que pertencem às categorias de emoção de um corpus. O atributo *nome* se refere ao nome do corpus e *documentos* se refere aos documentos que pertencem ao corpus.

Classe

Armazena a categoria de emoção que pode ser atribuída a um documento ou instância. O atributo *Nome* armazena o nome da categoria e o atributo *indice* armazena um índice único para a categoria.

Classes

É um SET que armazena as categorias de emoção que podem ser atribuídas a um documento ou instância.

Probabilidades

Armazena o grau de confiança para cada classe calculado a partir de uma instância, o grau de confiança é calculado para todas classes do SET *Classes*.

Instancia

Interface que representa uma instância. Todos os valores são armazenadas internamente como números de ponto flutuante nas implementações *InstanciaDensa* e *IntanciaEsparsa*. Armazena a lista de características, o documento que originou a instância e a categoria da instância.

InstanciaEsparsa

É um tipo de implementação que armazena apenas valores não nulos. Possui a vantagem de utilizar menos memória. Por exemplo, se em um vetor com 2.000 características apenas dez forem diferentes de zero, é armazenado somente os valores diferentes de zero e seus respectivos índices.

InstanciaDensa

É um tipo de implementação que armazena todos os valores, nulos e não nulos. No exemplo citado anteriormente, armazenaria o valor das 2.000 características.

CorpusDeInstancias

Armazena uma lista de instâncias que pertencem às mesmas categorias de emoção e também às mesmas características.

Característica

Armazena uma característica extraída com base nos documentos do *CorpusDeDocumentos*. Uma característica é obtida por uma busca a termos discriminantes das classes nos documentos.

Características

É um SortedSet, ou seja, um conjunto de características ordenadas e sem repetição.

ModeloDeRepresentacao

Interface que é responsável por transformar um *Documento* em representação vetorial (*Instância*). Possui duas implementações: *ModeloTFIDF* e *ModeloTF*.

ModeloTF

Representa os termos considerando o número de vezes que um determinado termo aparece em um determinado documento.

ModeloTFIDF

Representa os termos considerando que: 1) quanto mais frequentemente um termo ocorre em um documento mais representativo ele é para o conteúdo e 2) quanto mais documentos o termo ocorre menos discriminativo ele é (Equação 3.11 do Capítulo 3).

Classificador

Interface genérica que representa um algoritmo classificador por Aprendizagem de Máquina. *treinar* realiza o treinamento do *Classificador* com um *CorpusDeInstancias*; *getModeloDeRepresentação* retorna o modelo de representação que está sendo utilizado; *distribuiçãoDeProbabilidades* retorna o grau de confiança das classes para a instância; *getStatus*: retorna se o *Classificador* está treinado ou não.

ClassificadorAbstrato

Sobrescreve o método *distribuicaoDeProbabilidades* para que, caso não seja implementado nas classes filhas, retorne 1 para a classe identificada e 0 para as demais. Também possui outras propriedades comuns a todos os classificadores como *statusDoClassificador* e *modeloDeRepresentacao*.

ClassificadorWekaAdapter

É uma classe que aplica o *Adapter Design Pattern* (SHALLOWAY; TROTT, 2004). Tem a função de adaptar os classificadores do Weka para a interface *Classificador*.

EstrategiaDeRejeicao

Permite que um classificador aceite ou recuse uma instância se o mesmo não estiver certo o suficiente para classificá-la. Conhecidas as *Probabilidades*, a decisão de aceitar ou rejeitar uma instância é controlada por um limiar. Quando uma instância possui um grau de confiança maior ou igual ao limiar, esta instância é classificada, enquanto que as instâncias com valores inferiores ao limiar são rejeitadas.

FabricaDeDocumentos

Interface que aplica o *Abstract Factory Pattern* (ERICH GAMMA et al., 1994).

FabricaDeDocumentosPadrao

É a implementação da interface *FabricaDeDocumentos*, essa classe é responsável por pré-processar um texto e transformá-lo em um *Documento*.

NormalizadorDePalavras

Interface responsável por normalizar os termos.

NormalizadorStemmer

Implementa a interface *NormalizadorDePalavras* e é responsável remover os sufixos dos termos.

NormalizadorStemmer

Implementa a interface *NormalizadorDePalavras* e além de remover os sufixos dos termos, também trata as exceções ao utilizar um dicionário de termos.

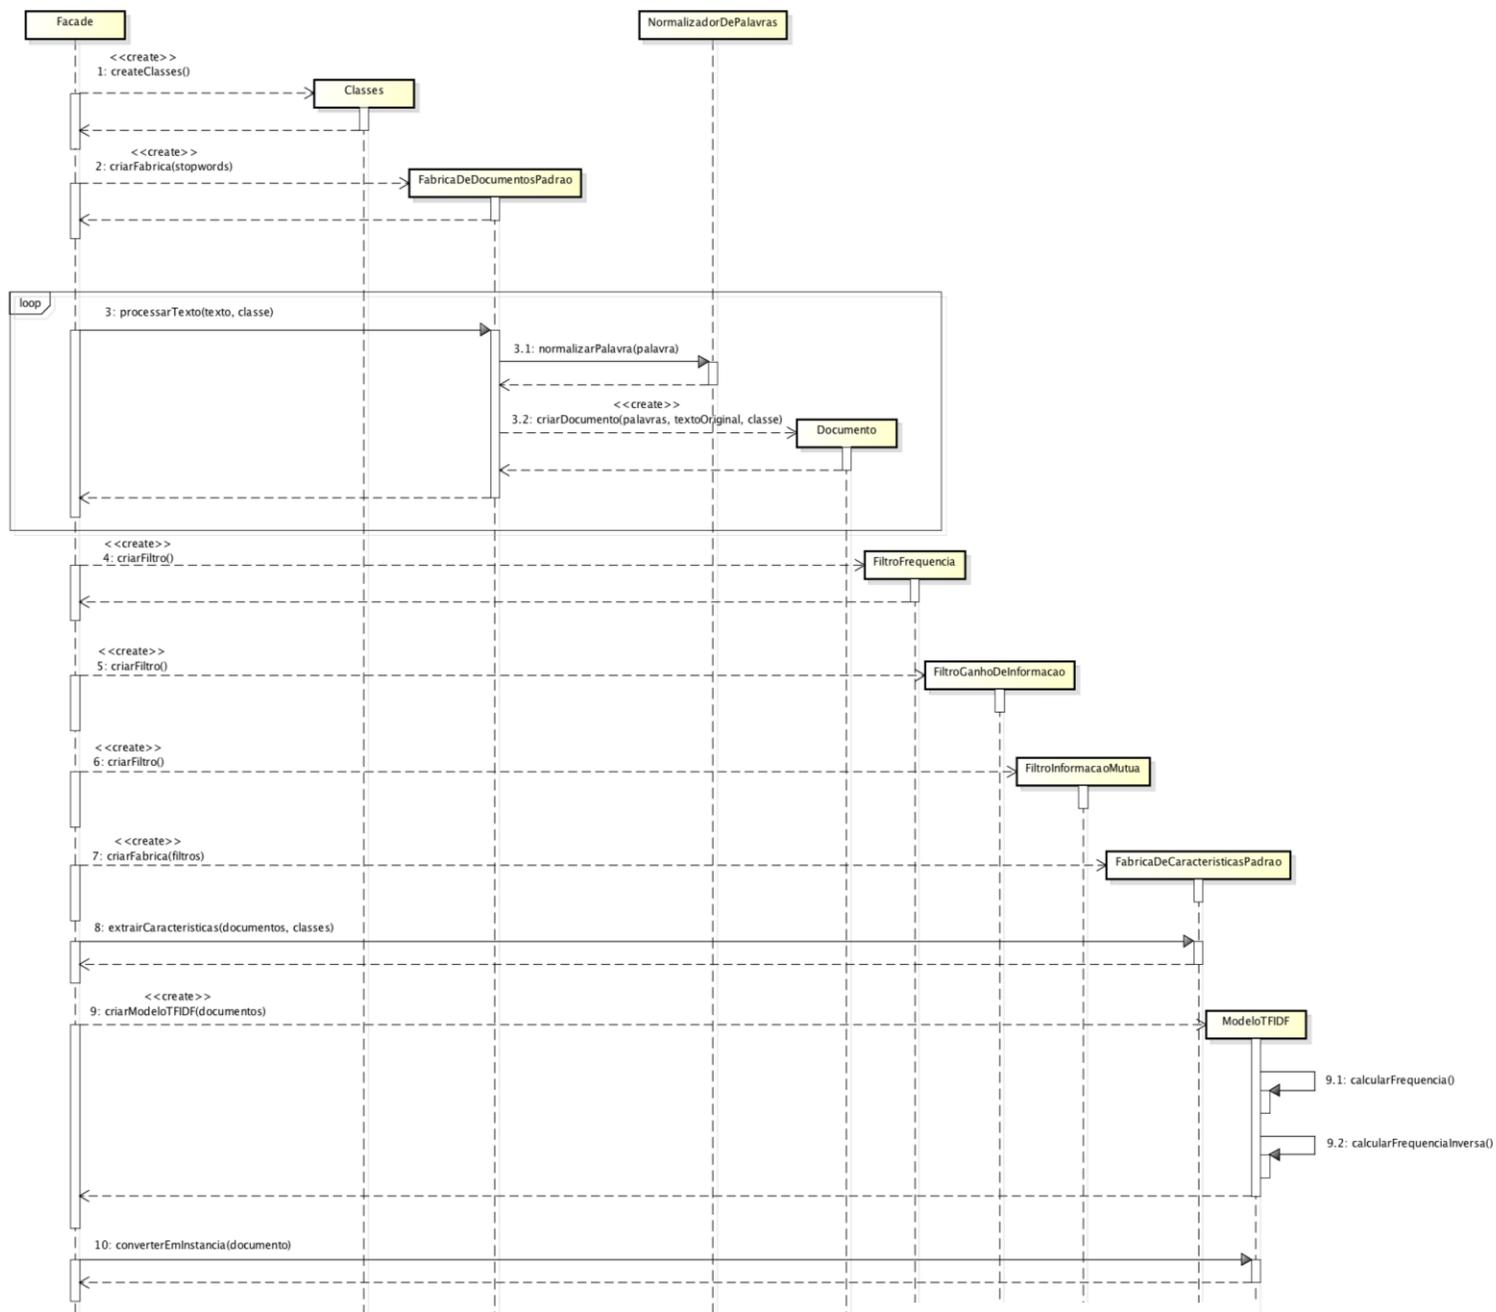
FabricaDeCaracteristicas

Interface responsável por extrair as *Caracteristicas* de um *CorpusDeDocumento*.

FabricaDeCaracteristicasPadrao

Implementação da interface *FabricaDeCaracteristicas*. Utiliza um conjunto de *FiltroDeCaracteristicas* para filtrar e extrair os termos relevantes dos documentos.

Na Figura 6.5 é apresentado o diagrama de sequência da etapa de treinamento do método. Ele mostra o resumo das tarefas executadas pelo método de identificação de emoções durante o processo de treinamento do(s) classificador(es).



(Continua na página seguinte)

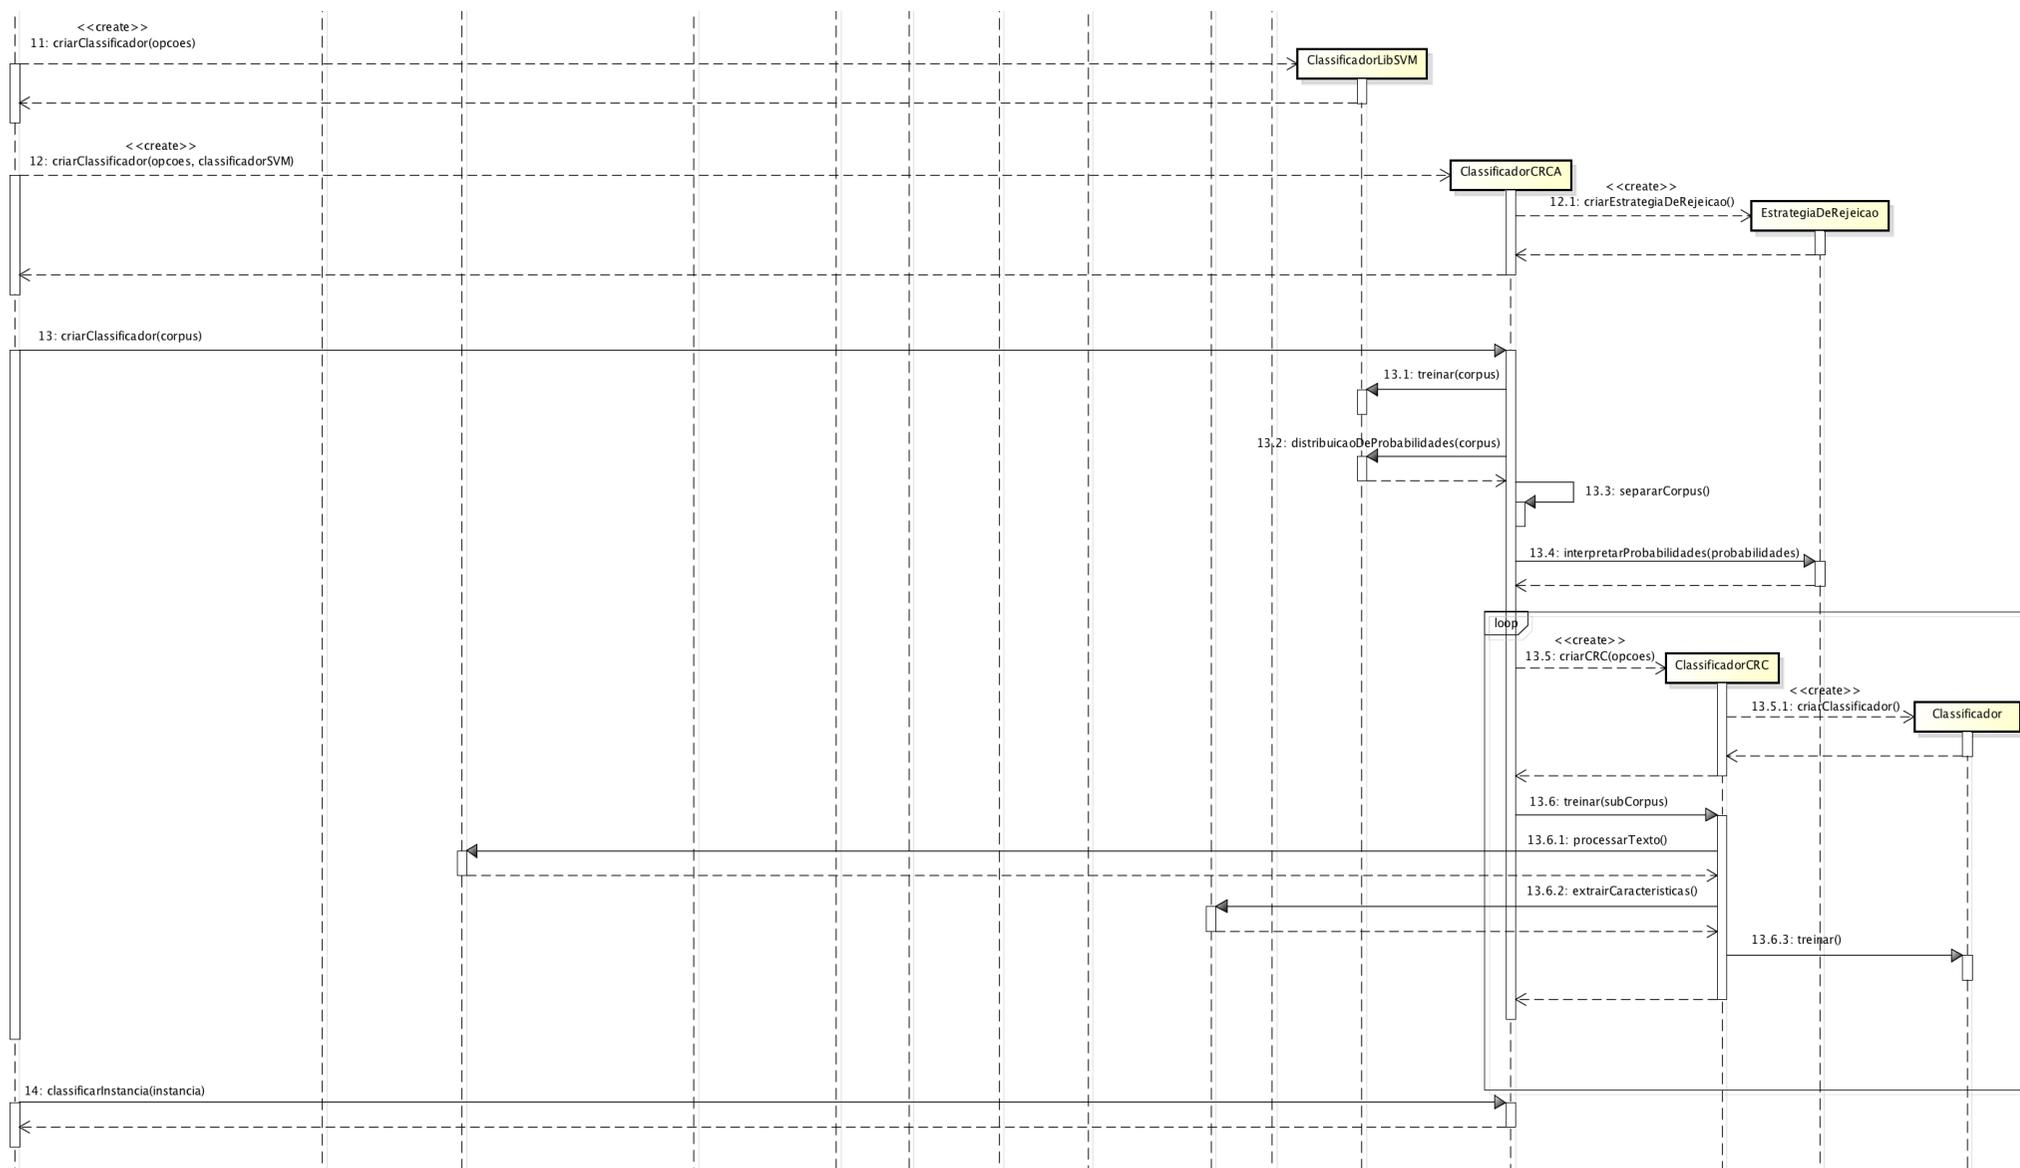


Figura 6.5: Diagrama de sequência da etapa de treinamento do método de identificação de emoções em textos

6.6. Considerações Finais

Neste capítulo foi apresentado um método de identificação de emoções para textos escritos em Português do Brasil. O método permite identificar categorias de emoções em textos por meio de um classificador SVM multiclasse e por meio de classificadores binários especializados para tratar as instâncias mais confusas. A opção de rejeição foi usada no método como uma forma de permitir que essas instâncias pudessem ser classificadas em uma segunda camada do método por classificadores mais especializados. Até este momento, ainda são raros os trabalhos de AS que usaram ERs. Na literatura, encontrou-se o trabalho de (YANG et al., 2012), que usa uma ER para identificar as emoções em um corpus de fala.

O método apresentado neste capítulo possui algumas limitações: 1) necessita de um corpus com textos rotulados em domínio específico para treinar os classificadores; 2) exige o ajuste de alguns parâmetros, como é o caso, por exemplo, do limiar de confusão. Espera-se, no entanto, que em pesquisas futuras todos os parâmetros possam ser completamente automatizados.

O próximo capítulo apresenta os detalhes de implementação, a descrição completa da ferramenta construída para testar e avaliar o método e também as métricas utilizadas para medir o desempenho do método.

Capítulo 7

Procedimentos Metodológicos

Neste capítulo são detalhados os procedimentos aplicados na construção e avaliação do método de identificação de emoções em textos. O capítulo está dividido em duas seções principais: a Seção 7.1, que cita as tecnologias utilizadas na implementação do método e apresenta detalhadamente a ferramenta de AS que foi construída para testar e avaliar o método; e a Seção 7.2, que apresenta as métricas utilizadas para avaliar o método.

7.1. Implementação do Método

O método apresentado no Capítulo 6 foi implementado em linguagem Java, utilizando a plataforma de desenvolvimento IntelliJ IDEA¹⁹ e o algoritmo SVM²⁰, implementado por (CHANG; LIN, 2011) e incorporado ao Weka (HALL et al., 2009) por (EL-MANZALAWY; HONAVAR, 2005). Para utilizar o LibSVM do Weka, as bibliotecas foram importadas para o projeto do método de identificação de emoções. O Weka Developer em versão 3.7.11 foi usado para representar os arquivos de textos em objetos computacionais.

Além dessas ferramentas foram utilizados também o *Snowball Stemmer*²¹ que disponibiliza uma versão implementada do algoritmo de (PORTER, 1980) em Português, e o Cogroo 4.0²², que disponibiliza uma versão implementada do algoritmo *PortugueseStemmer* (ORENGO; HUYCK, 2001). Ambas as ferramentas foram usadas no pré-processamento do método para lematizar os termos dos textos.

¹⁹ <https://www.jetbrains.com/idea/>

²⁰ <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>

²¹ <http://snowball.tartarus.org/algorithms/portuguese/stemmer.html>

²² <http://cogroo.sourceforge.net/>

Para que o método pudesse ser testado e avaliado, foi construída uma ferramenta de AS com uma interface de funcionamento semelhante ao ambiente Weka, que permite inúmeras combinações de funções e possibilita a realização de uma diversidade de testes. A Figura 7.1 mostra a interface da ferramenta. A tela de pré-processamento é o ponto inicial da ferramenta.

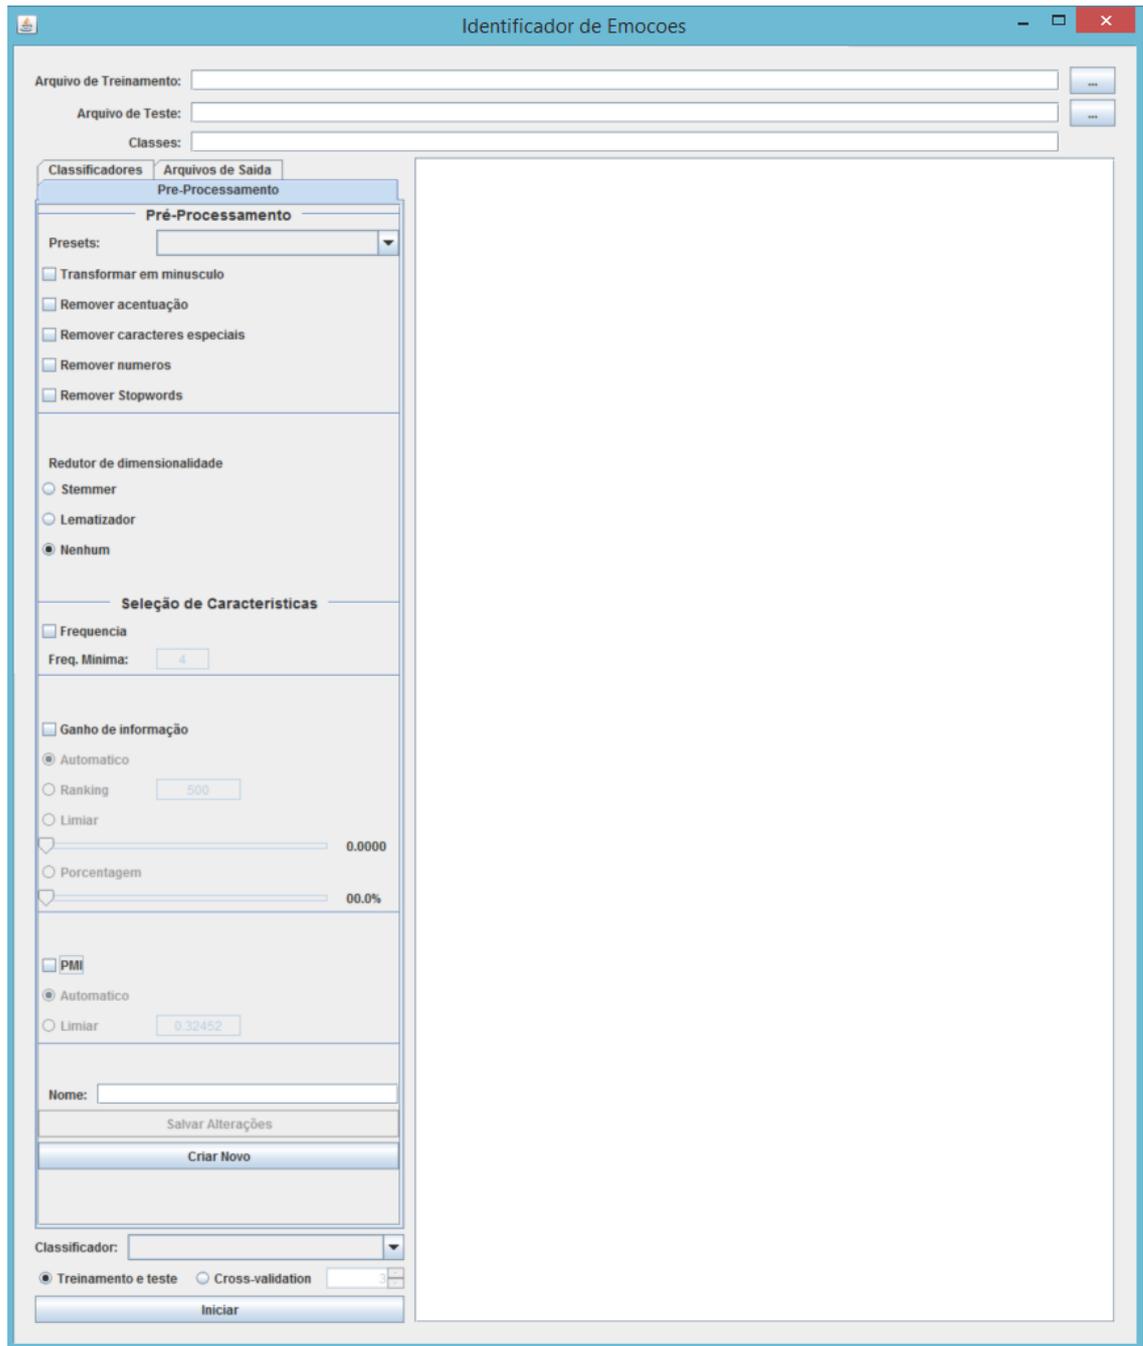


Figura 7.1: Interface da ferramenta de AS

Para fazer uma avaliação do método por um conjunto de teste, a ferramenta requer um arquivo de treinamento e um arquivo de teste, ambos em formato .TXT. Para fazer a Validação Cruzada, apenas o arquivo de treinamento é necessário. No campo *Classes* é necessário informar, por extenso, o nome das classes presentes no conjunto de textos.

Na interface mostrada na Figura 7.1, existem três abas: *Classificadores*, *Arquivos de Saída* e *Pré-processamento*. Será detalhado primeiramente o *Pré-processamento* e as demais abas na sequência.

A primeira parte das opções de pré-processamento se refere a preparação dos textos e permite ativar ou não as seguintes funções: 1) remover números, 2) remover os caracteres especiais como símbolos, sinais de pontuação e hífens, 3) remover a acentuação, 4) transformar os textos para minúsculo, e, 5) remover as *stopwords*.

A segunda parte do pré-processamento se refere a redução da dimensionalidade. Dessa forma é possível escolher se a lematização será feita pelo algoritmo de (PORTER, 1980), que na ferramenta é chamado de *Stemmer* ou se será feita pelo algoritmo de (ORENGO; HUYCK, 2001), que na ferramenta é chamado simplesmente de *Lematizador*. Também é possível ignorar ambos os recursos ativando a opção *Nenhum*.

A primeira opção é o uso do algoritmo *Stemmer Snowball*²³ (PORTER, 1980), no idioma Português, que remove sufixos por meio de regras com o objetivo de gerar uma única característica para palavras originárias da mesma raiz. Por exemplo, se o texto contiver as palavras “mata”, “matou”, “mataram”, “matei”, após a aplicação do *Stemmer Snowball*, essas palavras serão reduzidas para o radical “mat”, dessa forma diminuindo consideravelmente o número de características semelhantes.

A segunda opção para lematização de termos na ferramenta é o uso do algoritmo *PortugueseStemmer* (ORENGO; HUYCK, 2001), que também remove sufixos por meio de regras e trata as exceções por meio de um dicionário composto de 32.000 termos escritos em Português Brasileiro.

A escolha desses lematizadores se deu pelo fato deles removerem apenas os sufixos das palavras, o que pode ser considerado menos rigoroso do que remover os prefixos também. Além disso, o algoritmo de (PORTER, 1980) é bastante utilizado na literatura, o que de certa forma, justifica a sua escolha nesta ferramenta. Já o algoritmo de (ORENGO; HUYCK, 2001) foi adotado por, segundo a teoria, gerar menos erros de *overstemming* e *understemming*.

²³ <http://snowball.tartarus.org>

A terceira parte do pré-processamento se refere a seleção de características e permite a aplicação dos filtros de frequência, de GI e de IM. No filtro de frequência, é informado um limiar de frequência mínima, que representa o número de vezes que um termo deverá ser repetido no conjunto total de documentos para que seja considerado como uma característica.

O filtro de GI, ao ser ativado, necessita que seja indicado como será feita a seleção dos termos por GI. Se a opção *Automática* for ativada, a ferramenta buscará um limiar de GI automaticamente, por meio de uma busca binária, a fim de obter um limiar que não gere nenhuma instância ambígua. Caso existam instâncias ambíguas no conjunto de dados, é necessário que outra forma de seleção de termos seja escolhida: a opção *Ranking* permite que um número determinado de termos GI sejam selecionados; a opção *Limiar* permite estabelecer um limiar de seleção de termos GI manualmente; e a *Porcentagem* permite definir um percentual de termos GI que serão selecionados.

No filtro de IM, o limiar pode ser obtido automaticamente, assim como o filtro de GI com base na busca binária, a fim de encontrar um limiar que não gere nenhuma instância ambígua, ou pode ser definido manualmente.

Ao final das configurações de pré-processamento, existe um campo *Nome* no qual é informado um nome para o conjunto de configurações de pré-processamento e na sequência deve ser selecionado o campo *Criar Novo* para criar a configuração do pré-processamento. Ao fazer qualquer alteração na configuração, basta somente clicar em *Salvar Alterações*.

É importante salientar que todas essas configurações de pré-processamento funcionam independentemente e dessa forma permitem inúmeras combinações possíveis. Como exemplo, são selecionadas algumas configurações de pré-processamento na Figura 7.2 para pré-processar os textos que serão submetidos ao classificador multiclasse mostrado na sequência.

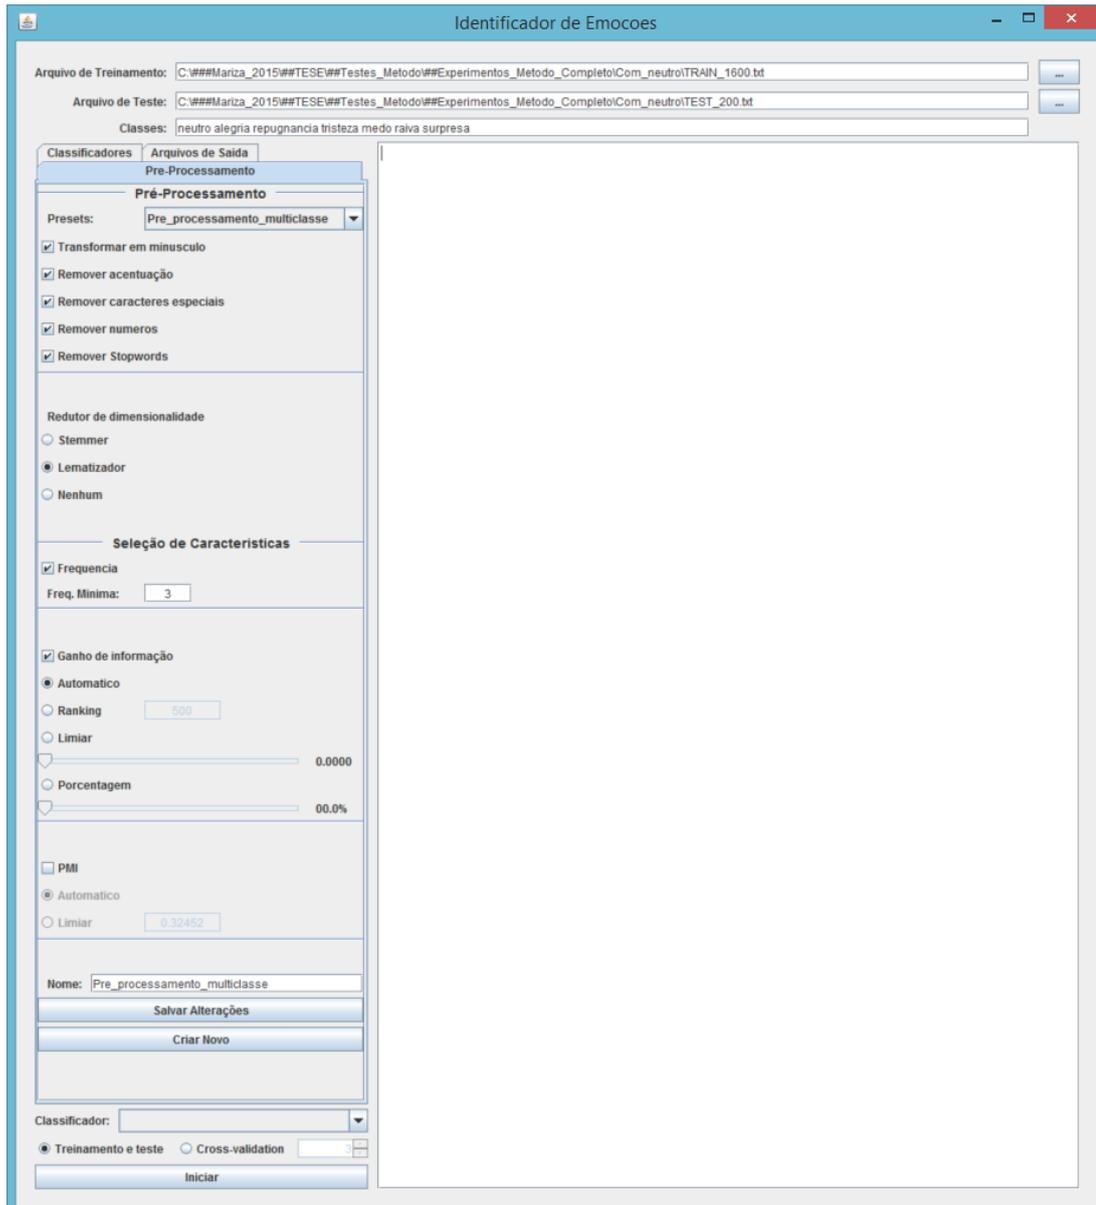


Figura 7.2: Exemplo de configuração de pré-processamento para os textos submetidos a um classificador multiclasse

Na aba *Classificadores*, é possível usar diferentes algoritmos de classificação (Figura 7.3), dentre eles o LibSVM, o IBK, o *Naive Bayes* e o J48 estão implementados na ferramenta e podem ser configurados individualmente. O CRCA se refere a um tipo especial de classificador que permite agrupar vários outros classificadores.

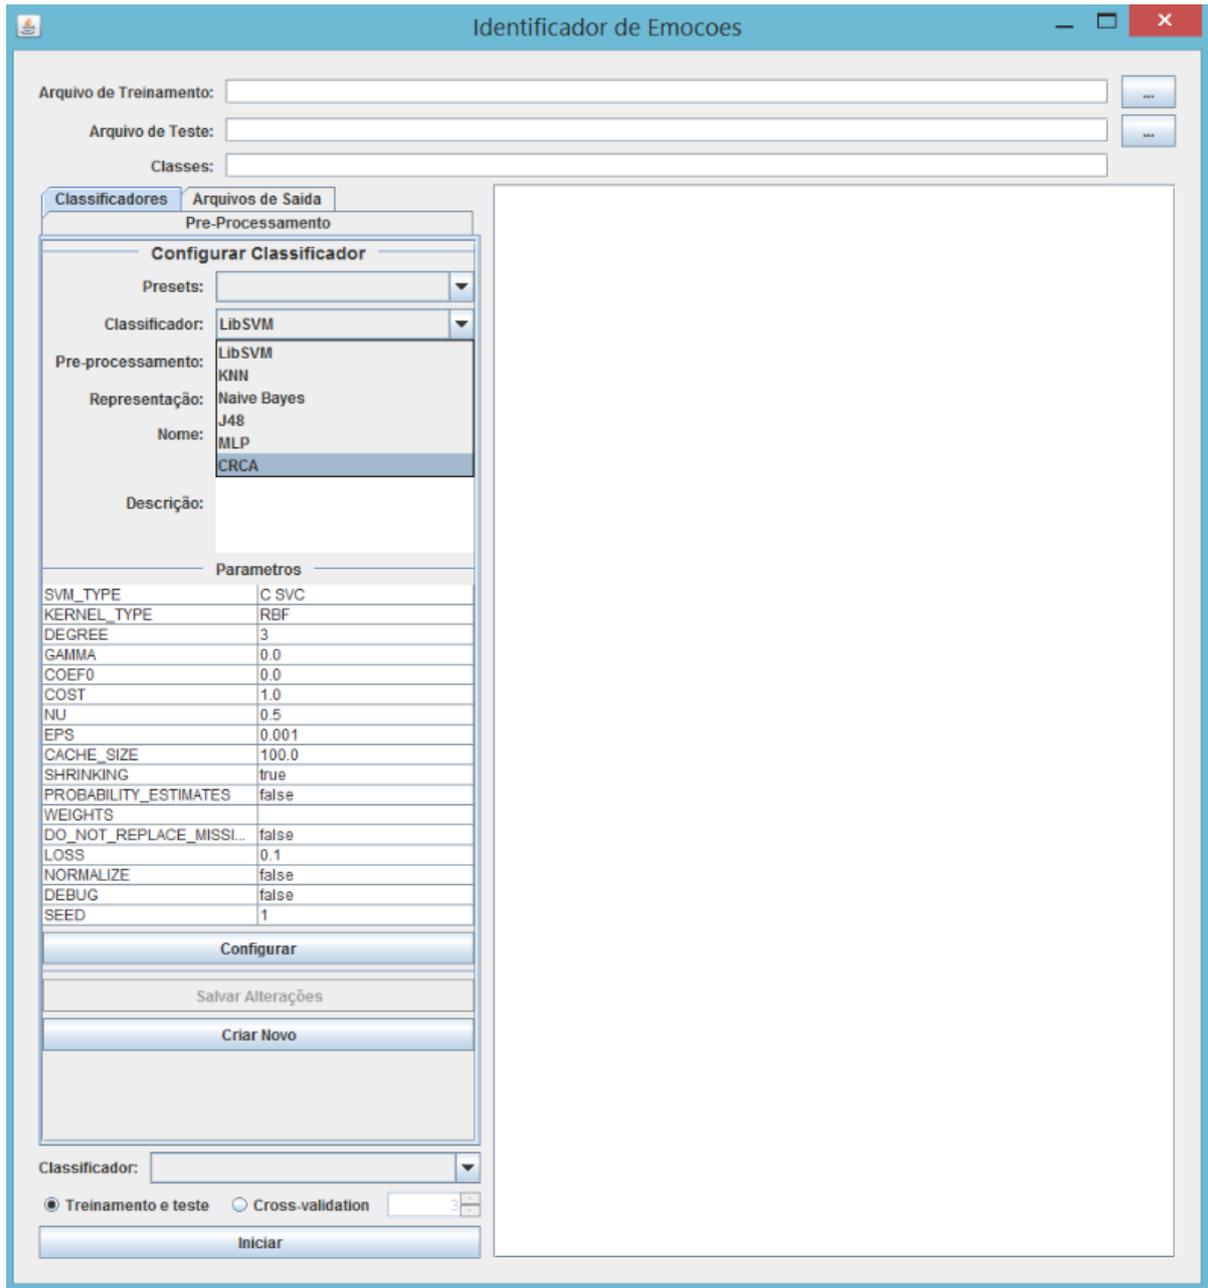


Figura 7.3: Aba para configurar um classificador

Na Figura 7.4 é possível visualizar mais detalhes sobre a configuração de um classificador. Ao escolher um algoritmo de classificação, é necessário escolher uma configuração de pré-processamento e uma configuração de representação vetorial, que pode ser TF-IDF ou simplesmente TF. O campo *Descrição* permite descrever brevemente o classificador, os parâmetros do classificador devem ser selecionados por meio do botão *Configurar*.

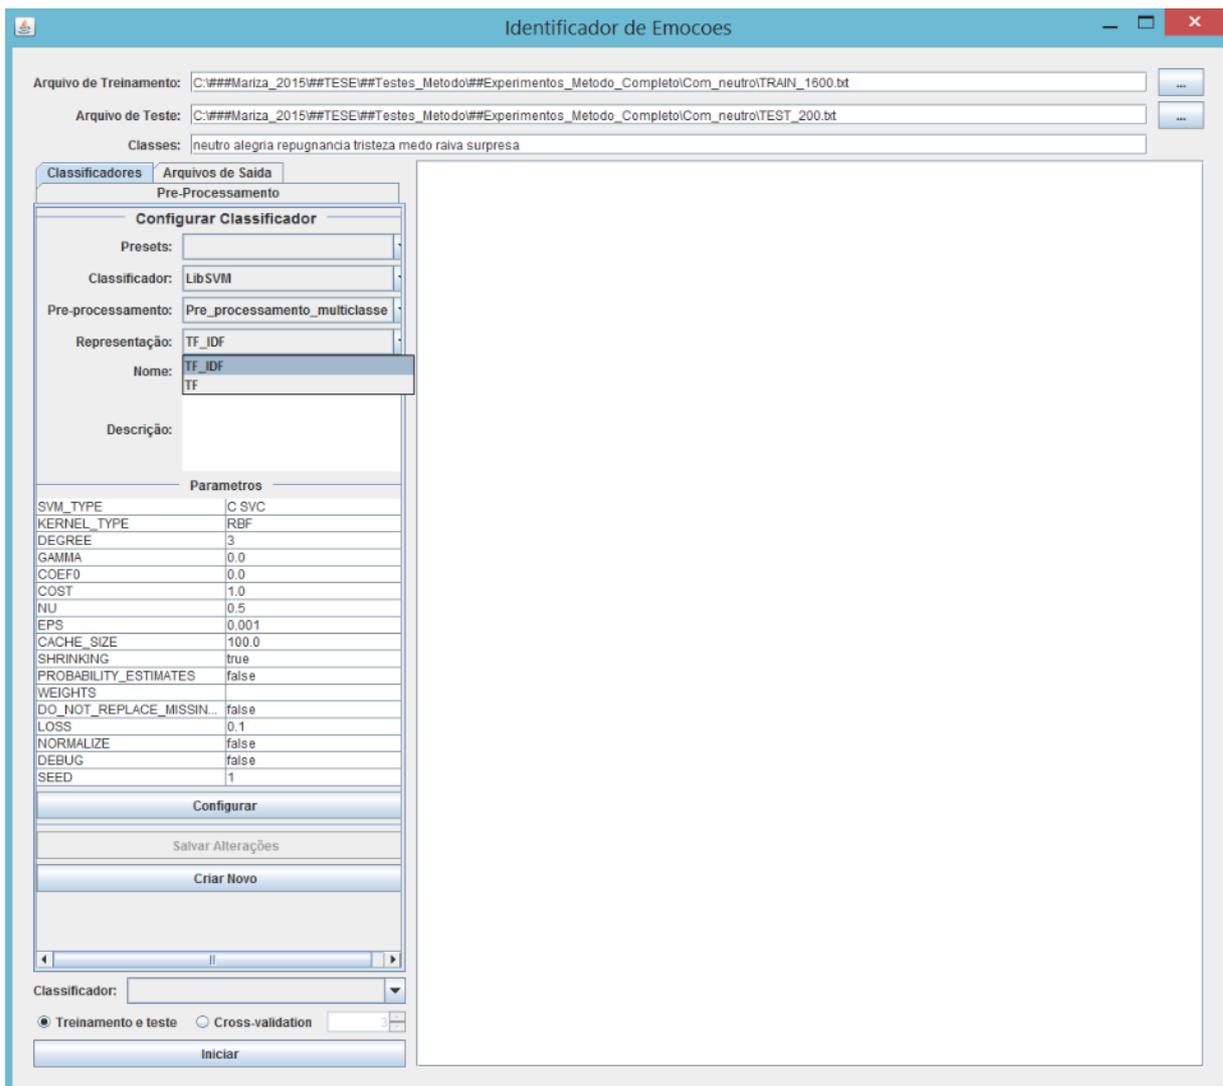


Figura 7.4: Configurando um classificador

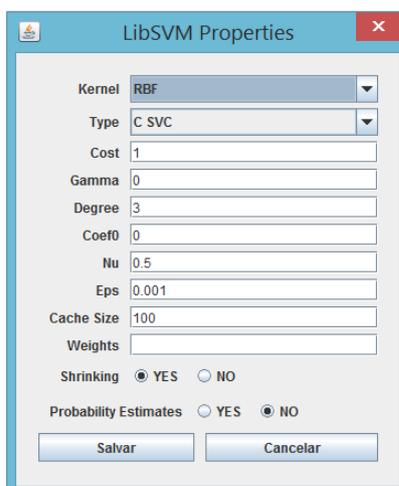


Figura 7.5: Configuração dos parâmetros de um classificador LibSVM

Cada algoritmo de classificação tem um conjunto específico de parâmetros. No caso do algoritmo LibSVM, os parâmetros são apresentados conforme a Figura 7.5. O classificador CRCA foi desenvolvido na ferramenta para possibilitar que o método de identificação de emoções em textos opere em camadas. Para exemplificar o funcionamento do CRCA, serão criados dois classificadores LibSVM, um que atuará na primeira camada da classificação e o outro na segunda camada. O classificador da primeira camada será chamado de SVM_MULTICLASSE (Figura 7.6a) e o classificador da segunda camada será chamado de SVM_CRC (Figura 7.6b).

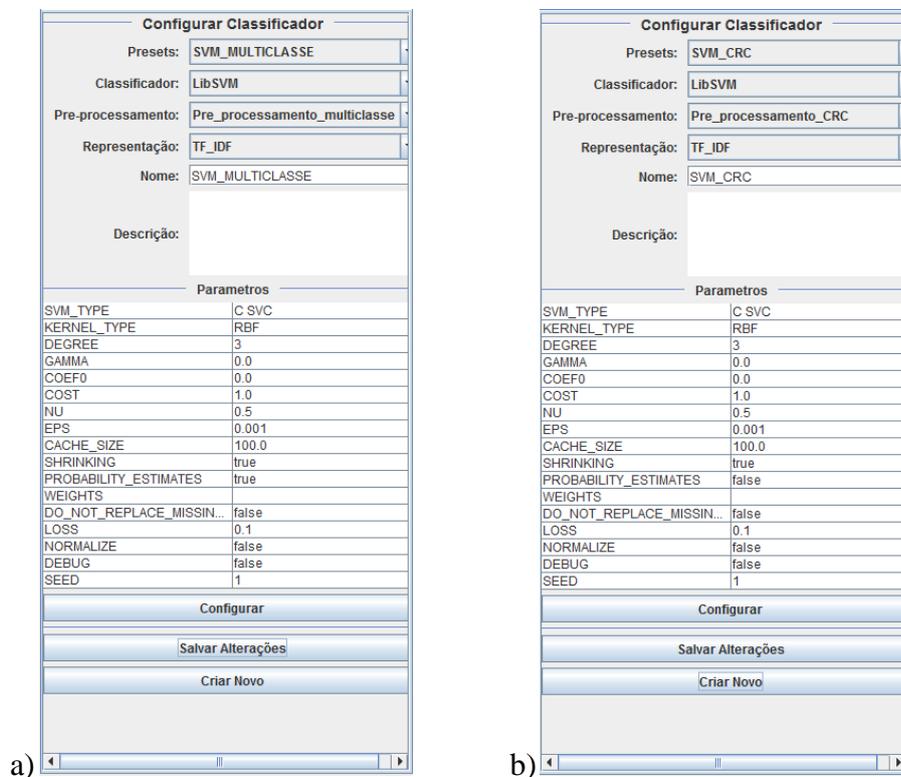


Figura 7.6: a) Configuração do classificador SVM_MULTICLASSE (primeira camada) e b) Configuração do classificador SVM_CRC (segunda camada)

Na Figura 7.7 é mostrada a configuração de parâmetros de um CRCA. O *Modo CRC* é a forma como os CRCs (classificadores da segunda camada) são criados, que pode ser *Manual*, que significa que todos os CRCs possíveis (conforme valor da *Estratégia TOP*) serão criados e utilizados para classificar as instâncias rejeitadas, ou por meio do *Grau de Confusão*, onde somente os CRCs com grau de confusão igual ou superior a um limiar estabelecido serão criados e utilizados para classificar as instâncias rejeitadas.

O campo *Estratégia TOP* se refere às n classes que haverá nos CRCs da segunda camada. Por exemplo: dado um conjunto de treinamento composto por textos com sete classes, se a *Estratégia TOP* do CRCA for configurada com o valor 2, os CRCs serão binários e dessa forma poderão ser criados até 21 CRCs no total, o que representa todas as combinações possíveis de classificadores binários para sete classes. Se a *Estratégia TOP* for configurada com valor 3, os CRCs serão ternários e dessa forma poderão ser criados até 35 CRCs no total. E assim sucessivamente para n classes.

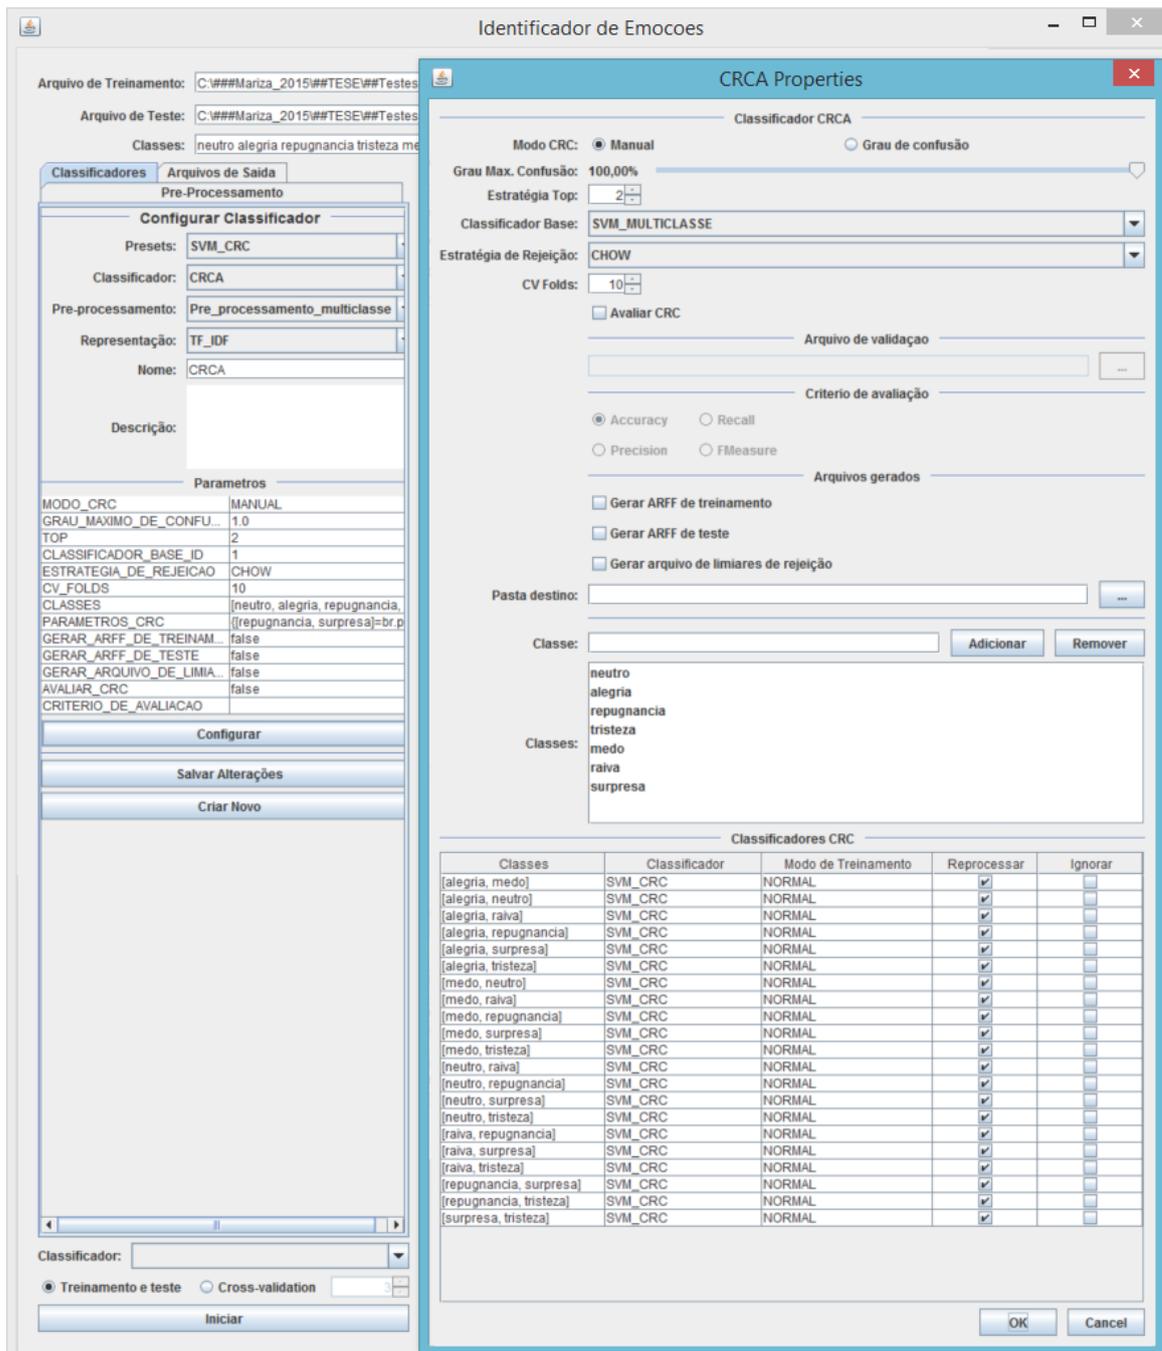


Figura 7.7: Configuração de parâmetros de um CRCA

Ainda se tratando da Figura 7.7, o campo *Classificador Base* se refere à configuração do classificador da primeira camada (neste caso, o classificador SVM_MULTICLASSE da Figura 7.6a). O campo *Estratégia de Rejeição* permite escolher uma ER a ser aplicada nos dados. São cinco opções neste campo: *Chow*, *Fumera*, *Dif*, *Rejeitar todas* e *Aceitar todas*. As três primeiras opções dizem respeito às ER apresentadas no Capítulo 6, que determinam um limiar de rejeição como critério para rejeitar ou aceitar as instâncias. A opção *Rejeitar todas* não usa limiar de rejeição e rejeita todas as instâncias na primeira camada. A opção *Aceitar todas* faz com que todas as instâncias sejam classificadas diretamente pelo classificador da primeira camada.

O campo *CV Folds* se refere ao número de subconjuntos que deverá ser dividido o conjunto dos dados de treinamento para ser avaliado por meio de Validação Cruzada e gerar as probabilidades estimadas.

O campo *Avaliar CRC* foi criado para verificar o desempenho dos CRCs em relação ao classificador multiclasse. Ao ativar este campo, deve ser escolhido um critério para avaliar o CRC. Por exemplo: se for escolhida a *Accuracy* como critério de avaliação, a ferramenta permite verificar se a acurácia de um CRC, obtida com um determinado conjunto de instâncias rejeitadas foi superior ou igual a acurácia obtida com o classificador SVM multiclasse ao avaliar o mesmo conjunto de instâncias rejeitadas. Se isto se confirmar, o CRC é mantido e os dados são classificados por ele, caso contrário, o CRC é ignorado e os dados são classificados pelo classificador SVM multiclasse.

Os campos *Gerar ARFF de treinamento* e *Gerar ARFF de teste* permitem imprimir os conjuntos de dados de treinamento e de teste usados nos classificadores CRCs em um formato .ARFF. A opção *Gerar arquivo de limiares de rejeição* gera um arquivo no formato .TXT com todos os limiares de rejeição possíveis para o conjunto de treinamento. Para cada limiar é informado CA, CR, FA, FR, FAR, FRR e também a distância obtida na curva ROC ao se avaliar FAR e FRR.

O campo *Classe* serve para adicionar as classes para as quais deverão ser gerados os CRCs. Ao se incluir as classes, a ferramenta gera automaticamente todos os CRCs possíveis. Embora no exemplo da Figura 7.7 todos os CRCs estão configurados igualmente, cada CRC pode ter uma configuração específica, que inclui o uso de uma configuração de classificação (algoritmo de classificação), de pré-processamento e de representação vetorial, como a mostrada na Figura 7.6b.

O campo *Reprocessar*, permite gerar um novo conjunto de características com base nos dados do conjunto de treinamento do CRC. O campo *Ignorar* foi incluído na ferramenta para o caso de se ignorar manualmente um CRC.

O campo *Modo de treinamento* de um CRC se refere a quais instâncias devem ser consideradas para treinar o CRC. A ferramenta disponibiliza sete opções, conforme mostrado na Figura 7.8, sendo elas: 1) *Normal*, que é a configuração padrão e significa que o CRC será treinado com todas as instâncias das respectivas classes do CRC que existem no conjunto de treinamento, por exemplo: o CRC ALEGRIA x TRISTEZA, ao usar o modo de treinamento *Normal*, será treinado com todas as instâncias das classes *alegria* e *tristeza* do conjunto de treinamento; 2) *Corretamente classificadas*, permite que o CRC seja treinado com as instâncias que foram corretamente classificadas na avaliação do conjunto de treinamento; 3) *Incorretamente classificadas*, permite que o CRC seja treinado com as instâncias que foram incorretamente classificadas na avaliação do conjunto de treinamento; 4) *Corretamente rejeitadas*, permite que o CRC seja treinado com as instâncias que foram corretamente rejeitadas no conjunto de treinamento; 5) *Incorretamente rejeitadas*, permite que o CRC seja treinado com as instâncias que foram incorretamente rejeitadas no conjunto de treinamento; 6) *Corretamente aceitas*, permite que o CRC seja treinado com as instâncias que foram corretamente aceitas no conjunto de treinamento; 7) *Incorretamente aceitas*, permite que o CRC seja treinado com as instâncias que foram incorretamente aceitas no conjunto de treinamento.

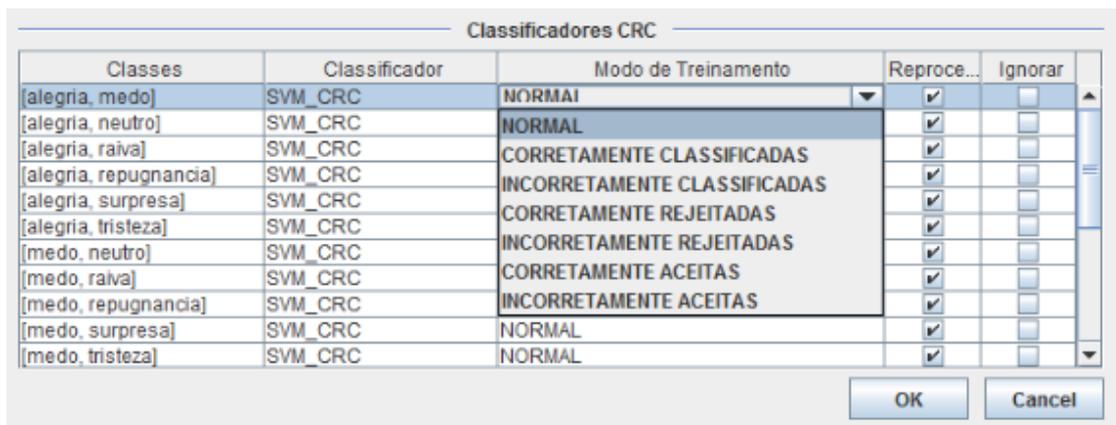


Figura 7.8: Opções do campo *Modo de treinamento* dos CRCs

Após realizada a configuração de um classificador, é possível avaliá-lo, por meio de um conjunto de teste ou por meio de Validação Cruzada. Essas duas opções podem ser visualizadas no canto inferior esquerdo da tela, mostrada na Figura 7.7.

A aba *Arquivos de Saída*, mostrada na Figura 7.9, apresenta outras opções de saída de dados que é disponibilizada pela ferramenta. Na *Pasta base* deve ser fornecido o caminho de uma pasta na qual deverão ser salvos os arquivos gerados. O campo *ARFF de treinamento* ativado permite gerar um arquivo em formato .ARFF dos dados do conjunto de treinamento pré-processados e representados em vetor. O campo seguinte, chamado *ARFF de teste*, tem a mesma função que o anterior, porém diz respeito ao conjunto de teste ou de validação.

The screenshot shows the 'Identificador de Emocoes' application window. The 'Arquivos de Saída' tab is active, displaying the following configuration options:

- Arquivo de Treinamento:** C:\###Mariza_2015\##TESE\##Testes_Metodo\##Experimentos_Metodo_Completo\Com_neutro\TRAIN_1600.bt
- Arquivo de Teste:** C:\###Mariza_2015\##TESE\##Testes_Metodo\##Experimentos_Metodo_Completo\Com_neutro\TEST_200.bt
- Classes:** neutro alegria repugnancia tristeza medo raiva surpresa
- Pre-Processamento:**
 - Pasta base:** [Empty field with browse button]
 - ARFF de treinamento**: Nome: [Empty field]
 - ARFF de teste**: Nome: [Empty field]
 - Prob. Estimadas de Teste**: Nome: [Empty field]
 - Prob. Estimadas de Treinamento**: Nome: [Empty field], folds: 3
 - Arquivo de rotulção**: Nome: [Empty field]
 - Arquivo de Características**: Nome: [Empty field]
- Classificador:** [Dropdown menu]
- Treinamento e teste** **Cross-validation** (folds: 3)
- Iniciar** button

Figura 7.9: Outras opções de saída de dados disponíveis na ferramenta

O campo *Prob. Estimada de Teste* gera um arquivo com extensão .TXT dos dados do conjunto de teste contendo o texto original, o texto pré-processado e as probabilidades estimadas. O campo *Prob. Estimada de Treinamento* gera um arquivo com extensão .TXT dos dados do conjunto de treinamento que contém o texto original, o texto pré-processado, a classe real, a classe resultante da classificação, as probabilidades estimadas e as classes ordenadas por ordem decrescente de probabilidade estimada. É necessário informar o número de divisões do conjunto de dados para a Validação Cruzada no campo *folds*.

O campo *Arquivo de rotação* permite gerar um arquivo com extensão .TXT dos dados que estão sendo avaliados pelo classificador contendo o texto original, o texto pré-processado, a classe real e a classe classificada. O campo *Arquivo de Características* permite gerar um arquivo com extensão .TXT contendo para cada característica a frequência que ela ocorre no conjunto de treinamento, o limiar de GI e/ou de IM, a frequência GI e/ou de IM em cada classe.

7.2. Avaliação do Método

Para testar e avaliar o método descrito no Capítulo 6 foram utilizados os textos do corpus de notícias descrito no Capítulo 5, divididos em 80% para treinar o método, 10% para testar o método e 10% para validar os CRCs do método.

Para avaliar o desempenho do método foi utilizada a matriz de confusão (apresentada na Tabela 3.8 do Capítulo 3), e as métricas Acurácia, *Precisão*, *Cobertura* e *F1*, cujas fórmulas procedentes do Capítulo 3 serão reapresentadas nesta seção.

$$Acurácia = \frac{VP + VN}{VP + VN + FP + FN} \quad (3.15)$$

$$Precisão = \frac{VP}{VP + FP} \quad (3.16)$$

$$Cobertura = \frac{VP}{VP + FN} \quad (3.17)$$

$$F1 = \frac{2 \cdot Precisão \cdot Cobertura}{Precisão + Cobertura} \quad (3.18)$$

Para avaliar se existe diferença estatística significativa de desempenho entre os classificadores do método nos experimentos que serão apresentados nos capítulos seguintes, foi utilizado um teste de hipóteses, o Teste Z, para comparar duas proporções amostrais (BECKER, 2015).

7.3. Considerações Finais

Neste capítulo foram citadas as tecnologias utilizadas na implementação do método de identificação de emoções em textos e a ferramenta de AS, que foi construída especialmente para possibilitar que o método pudesse ser testado e avaliado em diferentes configurações. Também foram apresentadas as métricas utilizadas para avaliar o desempenho do método.

No Capítulo 8 são apresentados os principais experimentos que foram realizados com o método de identificação de emoções.

Capítulo 8

Experimentos e Análise dos Resultados

Este capítulo visa apresentar os principais experimentos que foram realizados com o método. Ele é composto por três seções principais: a Seção 8.1 apresenta experimentos realizados com o método de identificação de emoções usando os textos do corpus de notícias (apresentado no Capítulo 5). A Seção 8.2 apresenta experimentos realizados com o método usando um corpus de contos infantis, com textos escritos em Inglês, que faz parte de um dos trabalhos descrito no estado da arte (Capítulo 4). A Seção 8.3 faz uma análise geral dos resultados obtidos pelo método.

8.1. Experimentos com o Método usando um Corpus de Notícias

Os experimentos realizados com o método e apresentados nesta primeira seção foram realizados usando o corpus de notícias que foi descrito no Capítulo 5. O Gráfico 8.1 mostra a distribuição dos textos do corpus de notícias entre as classes.

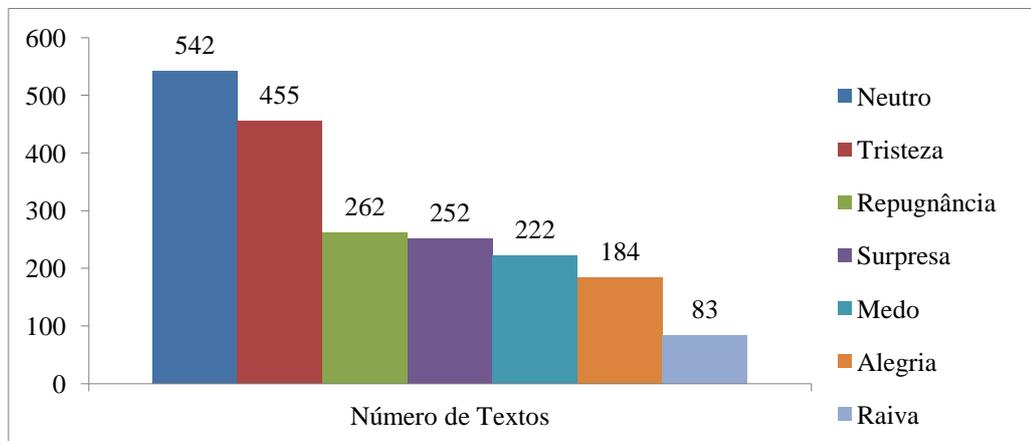


Gráfico 8.1: Distribuição dos textos do corpus de notícias

Nesta seção são apresentados os principais experimentos realizados com o método ao classificar textos com as seis emoções básicas: *alegria, tristeza, raiva, medo, repugnância e surpresa*, além da classe *neutro*.

No âmbito do relato dos experimentos desta seção, ao se mencionar o uso do *Lematizador*, está se referindo ao processo de lematização realizado com o algoritmo de (ORENGO; HUYCK, 2001) e ao se mencionar o uso do *stemmer*, está se referindo ao processo de lematização realizado pelo algoritmo de (PORTER, 1980).

Ainda no contexto dos experimentos deste capítulo, ao se mencionar que foi realizada uma preparação completa dos dados, é considerado que as seguintes etapas de pré-processamento foram executadas nos dados textuais:

- 1) Textos transformados para minúsculo;
- 2) Removida a acentuação dos textos;
- 3) Removidos os caracteres especiais dos textos;
- 4) Removidos os números;
- 5) Removidas as *stopwords*;
- 6) Representação vetorial TF-IDF.

Além disso, foi determinado empiricamente um conjunto de configurações de pré-processamento, apresentadas na Tabela 8.1. Essas configurações são referidas nos experimentos pelo *Nome da Configuração*. Por exemplo, quando se aplica a configuração de pré-processamento nomeada *Config_Pre_1*, significa que a preparação dos dados é completa, ou seja, são executadas todas as seis etapas citadas anteriormente, que é aplicado um lematizador, um filtro de frequência de termos com limiar igual a três, um filtro com limiar automático baseado no Ganho de Informação e não é utilizado nenhum filtro de termos com base na Informação Mútua.

Tabela 8.1: Configurações de pré-processamento cadastradas na ferramenta

| Nome da Configuração | Preparação dos Dados | Dimensionalidade | Frequência | GI | IM |
|-----------------------------|-----------------------------|-------------------------|-------------------|-----------|-----------|
| <i>Config_Pre_1</i> | Completa | Lematizador | 3 | Sim | Não |
| <i>Config_Pre_2</i> | Completa | Lematizador | 3 | Sim | Sim |
| <i>Config_Pre_3</i> | Completa | Lematizador | 3 | Não | Sim |
| <i>Config_Pre_4</i> | Completa | Lematizador | 4 | Sim | Não |
| <i>Config_Pre_5</i> | Completa | Lematizador | 4 | Sim | Sim |
| <i>Config_Pre_6</i> | Completa | Lematizador | 4 | Não | Sim |
| <i>Config_Pre_7</i> | Completa | Stemmer | 3 | Sim | Não |
| <i>Config_Pre_8</i> | Completa | Stemmer | 3 | Sim | Sim |
| <i>Config_Pre_9</i> | Completa | Stemmer | 3 | Não | Sim |

| | | | | | |
|----------------------|---------------------------|-------------|---|-----|-----|
| <i>Config_Pre_10</i> | Completa | Stemmer | 4 | Sim | Não |
| <i>Config_Pre_11</i> | Completa | Stemmer | 4 | Sim | Sim |
| <i>Config_Pre_12</i> | Completa | Stemmer | 4 | Não | Sim |
| <i>Config_Pre_13</i> | Completa | Nenhum | 0 | Não | Não |
| <i>Config_Pre_14</i> | Completa | Nenhum | 3 | Sim | Sim |
| <i>Config_Pre_15</i> | Completa | Nenhum | 4 | Sim | Sim |
| <i>Config_Pre_16</i> | Completa, menos a Etapa 3 | Lematizador | 3 | Sim | Sim |
| <i>Config_Pre_17</i> | Completa, menos a Etapa 3 | Lematizador | 3 | Sim | Não |
| <i>Config_Pre_18</i> | Completa, menos a Etapa 3 | Lematizador | 3 | Não | Sim |
| <i>Config_Pre_19</i> | Completa, menos a Etapa 3 | Lematizador | 4 | Sim | Sim |
| <i>Config_Pre_20</i> | Completa, menos a Etapa 3 | Lematizador | 4 | Não | Sim |
| <i>Config_Pre_21</i> | Completa, menos a Etapa 3 | Stemmer | 3 | Sim | Sim |
| <i>Config_Pre_22</i> | Completa, menos a Etapa 3 | Stemmer | 3 | Sim | Não |
| <i>Config_Pre_23</i> | Completa, menos a Etapa 3 | Stemmer | 3 | Não | Sim |
| <i>Config_Pre_24</i> | Completa, menos a Etapa 3 | Stemmer | 4 | Sim | Sim |
| <i>Config_Pre_25</i> | Completa, menos a Etapa 3 | Stemmer | 4 | Não | Sim |

Outras convenções dos experimentos desta seção são: 1) todos os experimentos que fizeram uso de uma lista de *stopwords*, utilizaram a lista de *stopwords* em Português Brasileiro apresentada no Apêndice 2; 2) todos os CRCs usados nos experimentos foram treinados com todos os textos de suas respectivas classes do conjunto de treinamento.

Tabela 8.2: Informações dos CRCs apresentadas nos experimentos

| Informação | Descrição da informação |
|-----------------------------|--|
| CRC | Indica o nome do CRC |
| % de confusão | Indica o grau de confusão do CRC obtido com base nas probabilidades estimadas |
| Características | É o número de características obtidas durante o treinamento do CRC |
| Instâncias de treinamento | É o número de instâncias usadas no treinamento do CRC |
| Instâncias encaminhadas | É o número de instâncias rejeitadas que foram encaminhadas para o CRC |
| Tem capacidade de acertar | Se refere ao número de instâncias que pertencem às classes do CRC |
| Acertou | É o número de instâncias que o CRC classificou como corretas |
| Encaminhadas incorretamente | É o número de instâncias que foram encaminhadas ao CRC, mas que não pertencem às classes do CRC |
| Acertou (%) | É o percentual de instâncias que o CRC classificou como corretas (acurácia) |
| Capacidade máxima (%) | É o percentual de instâncias que o CRC pode classificar (considerando somente as instâncias que pertencem às classes do CRC) |

8.1.1. Experimentos com o Método ao Classificar Textos com Seis Emoções Básicas e Neutro

Nesta seção, os experimentos utilizaram 1.600 textos para o treinamento do e 200 textos para a avaliação do método. A distribuição dos dados desses conjuntos nas classes podem ser vista, respectivamente, nos gráficos 8.2 e 8.3.

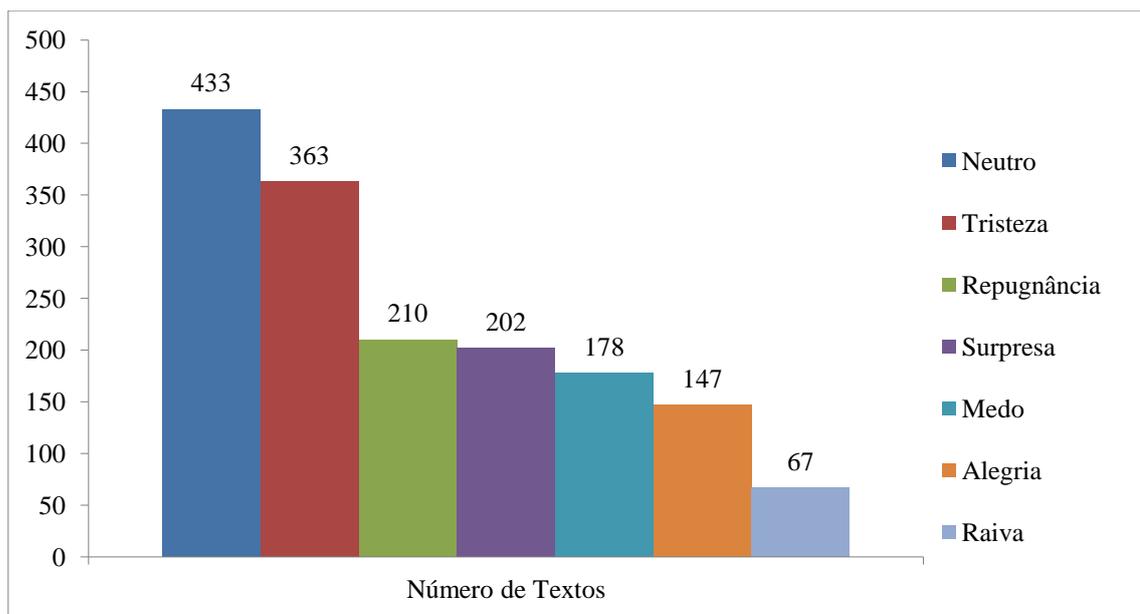


Gráfico 8.2: Distribuição dos textos no conjunto de treinamento

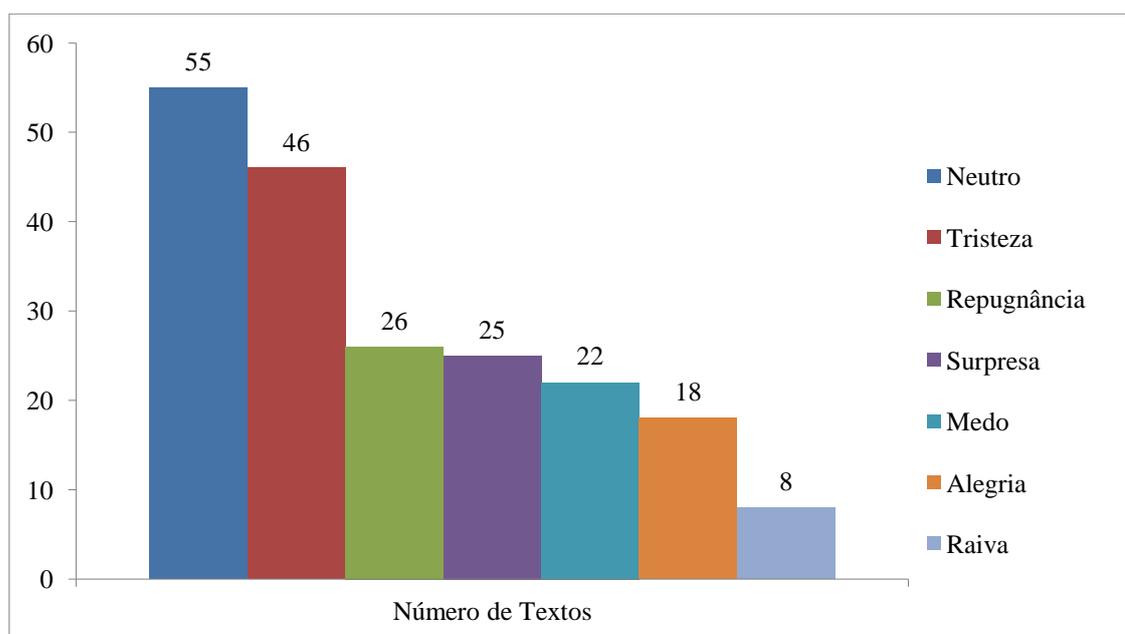


Gráfico 8.3: Distribuição dos textos no conjunto de teste

O primeiro experimento desta seção visa avaliar o método classificando os dados textuais usando apenas o classificador da primeira camada, ou seja, o classificador multiclasse, que é treinado com o conjunto de treinamento e avaliado com o conjunto de teste.

Para este e todos os demais experimentos realizados neste capítulo, o classificador da primeira camada é um classificador SVM configurado com *kernel* RBF padrão ($cost=1$, $gamma=0$) e probabilidades estimadas=*true* (que significa são geradas probabilidades estimadas de todas as classes para cada instância).

Os dados de treinamento foram pré-processados usando a configuração *Config_Pre_1* da Tabela 8.1. O desempenho obtido com o classificador SVM multiclasse pode ser visualizado na Tabela 8.3.

Tabela 8.3: Desempenho do classificador SVM multiclasse ao usar pré-processamento com filtros

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|------------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,66 | 0,73 | 0,69 | 40 | 6 | 3 | 5 | 0 | 0 | 1 |
| Alegria (A) | 0,32 | 0,33 | 0,32 | 6 | 6 | 1 | 2 | 1 | 1 | 1 |
| Repugnância (Re) | 0,57 | 0,50 | 0,53 | 5 | 2 | 13 | 2 | 2 | 0 | 2 |
| Tristeza (T) | 0,63 | 0,76 | 0,69 | 2 | 2 | 2 | 35 | 3 | 0 | 2 |
| Medo (M) | 0,53 | 0,41 | 0,46 | 3 | 0 | 1 | 6 | 9 | 1 | 2 |
| Raiva (R) | 0,50 | 0,25 | 0,33 | 2 | 0 | 1 | 2 | 0 | 2 | 1 |
| Surpresa (S) | 0,55 | 0,44 | 0,49 | 3 | 3 | 2 | 4 | 2 | 0 | 11 |
| Média | 0,57 | 0,58 | 0,57 | Características = 805 | | | | | | |
| Acurácia | 58,0% | | | | | | | | | |

O segundo experimento desta seção visa avaliar o CRCA que rejeita todas as instâncias na primeira camada e as classifica na segunda camada. Neste experimento, o classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e o CRCA é avaliado com o conjunto de teste. Os dados de treinamento do corpus de notícias foram pré-processados usando a configuração *Config_Pre_1* da Tabela 8.1.

Os CRCs usados na segunda camada são classificadores SVM binários, configurados com *kernel* RBF padrão ($cost=1$, $gamma=0$), probabilidades estimadas=*false* e os dados são pré-processados usando a configuração *Config_Pre_6* da Tabela 8.1. Além disso, cada CRC obtém um novo conjunto de características.

O desempenho do CRCA que rejeita todas as instâncias na primeira camada e classifica todas as instâncias na segunda camada pode ser visualizado na Tabela 8.4 e o desempenho individual dos CRCs pode ser visto na Tabela 8.5.

Tabela 8.4: Desempenho do CRCA que rejeita todas as instâncias na primeira camada

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>FI</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,61 | 0,86 | 0,71 | 47 | 0 | 2 | 4 | 0 | 0 | 2 |
| Alegria (A) | 0,38 | 0,17 | 0,23 | 11 | 3 | 1 | 3 | 0 | 0 | 0 |
| Repugnância (Re) | 0,56 | 0,39 | 0,46 | 7 | 2 | 10 | 4 | 2 | 0 | 1 |
| Tristeza (T) | 0,62 | 0,83 | 0,71 | 3 | 1 | 1 | 38 | 2 | 0 | 1 |
| Medo (M) | 0,56 | 0,41 | 0,47 | 4 | 1 | 1 | 6 | 9 | 0 | 1 |
| Raiva (R) | 0,00 | 0,00 | 0,00 | 1 | 0 | 3 | 3 | 0 | 0 | 1 |
| Surpresa (S) | 0,70 | 0,56 | 0,62 | 4 | 1 | 0 | 3 | 3 | 0 | 14 |
| Média | 0,57 | 0,61 | 0,57 | Características: 805 | | | | | | |
| Acurácia | 60,5% | | | | | | | | | |

Tabela 8.5: Desempenho dos CRCs ao classificar as instâncias rejeitadas

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|-----------------|---------------------------|-------------------------|---------------------------|------------|-----------------------------|-------------|-----------------------|
| AxRe | 221 | 357 | 5 | 4 | 3 | 1 | 60,0 | 80,0 |
| AxM | 161 | 325 | 4 | 3 | 3 | 1 | 75,0 | 75,0 |
| AxN | 352 | 580 | 38 | 30 | 22 | 8 | 57,9 | 78,9 |
| AxR | 151 | 214 | 0 | 0 | 0 | 0 | 0,00 | 0,00 |
| AxS | 253 | 349 | 16 | 12 | 11 | 4 | 68,8 | 75,0 |
| AxT | 293 | 510 | 4 | 2 | 2 | 2 | 50,0 | 50,0 |
| RexM | 193 | 388 | 5 | 3 | 2 | 2 | 40,0 | 60,0 |
| RexN | 366 | 643 | 26 | 20 | 16 | 6 | 61,5 | 76,9 |
| RexR | 248 | 277 | 1 | 0 | 0 | 1 | 0,00 | 0,00 |
| RexS | 235 | 412 | 10 | 6 | 6 | 4 | 60,0 | 60,0 |
| RexT | 300 | 573 | 14 | 11 | 10 | 3 | 71,4 | 78,6 |
| MxN | 233 | 611 | 3 | 3 | 3 | 0 | 100,0 | 100,0 |
| MxR | 78 | 245 | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| MxS | 278 | 380 | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| MxT | 292 | 541 | 31 | 25 | 21 | 6 | 67,7 | 80,6 |
| NxR | 259 | 500 | 1 | 0 | 0 | 1 | 0,00 | 0,00 |
| NxS | 389 | 635 | 6 | 4 | 4 | 2 | 66,7 | 66,7 |
| NxT | 363 | 796 | 13 | 7 | 5 | 6 | 38,5 | 53,8 |
| RxT | 172 | 430 | 14 | 12 | 9 | 2 | 64,3 | 85,7 |
| RxS | 151 | 269 | 0 | 0 | 0 | 0 | 0,00 | 0,00 |
| SxT | 296 | 565 | 7 | 4 | 2 | 3 | 28,6 | 57,1 |
| TOTAL | | | 200 | 148 | 121 | 52 | | |

A primeira ação para melhorar o desempenho dos CRCs foi obter a melhor configuração de pré-processamento da Tabela 8.1 para cada um dos CRCs. Os CRCs que apresentaram melhora no desempenho são apresentados na Tabela 8.6.

Tabela 8.6: CRCs que tiveram melhora em função da configuração do pré-processamento

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxRe | 221 | 357 | 5 | 4 | 4 | 1 | 80,0 | 80,0 |
| AxS | 253 | 349 | 16 | 12 | 12 | 4 | 75,0 | 75,0 |
| RexM | 193 | 388 | 5 | 3 | 3 | 2 | 60,0 | 60,0 |
| MxT | 292 | 541 | 31 | 25 | 23 | 6 | 74,2 | 80,6 |
| NxT | 363 | 796 | 13 | 7 | 6 | 6 | 46,2 | 53,8 |

Os CRCs AxRe (configurado com *Config_Pre_4*), AxS (configurado com *Config_Pre_24*) e RexM (configurado com *Config_Pre_4*) atingiram a sua capacidade máxima. Os CRCs MxT e NxT, ambos configurados com *Config_Pre_20*, obtiveram uma melhora parcial da sua capacidade. Para os CRCs que não obtiveram melhorias no desempenho foi mantida a configuração de pré-processamento *Config_Pre_6*. O desempenho do CRCA, com os CRCs da Tabela 8.6 modificados, pode ser visualizado na Tabela 8.7.

Tabela 8.7: Desempenho do CRCA após modificação de pré-processamento dos CRCs

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,62 | 0,87 | 0,72 | 48 | 0 | 2 | 3 | 0 | 0 | 2 |
| Alegria (A) | 0,60 | 0,17 | 0,26 | 11 | 3 | 1 | 3 | 0 | 0 | 0 |
| Repugnância (Re) | 0,60 | 0,46 | 0,52 | 7 | 1 | 12 | 4 | 1 | 0 | 1 |
| Tristeza (T) | 0,63 | 0,85 | 0,72 | 3 | 0 | 1 | 39 | 1 | 0 | 2 |
| Medo (M) | 0,77 | 0,46 | 0,57 | 4 | 1 | 1 | 5 | 10 | 0 | 1 |
| Raiva (R) | 0,00 | 0,00 | 0,00 | 1 | 0 | 3 | 3 | 0 | 0 | 1 |
| Surpresa (S) | 0,68 | 0,60 | 0,64 | 4 | 0 | 0 | 5 | 1 | 0 | 15 |
| Média | 0,62 | 0,64 | 0,60 | Características: 805 | | | | | | |
| Acurácia | 63,5% | | | | | | | | | |

Na sequência, os CRCs foram submetidos aos algoritmos de classificação *Naive Bayes*, J48 e IBK. Os CRCs que obtiveram melhora no desempenho são mostrados na Tabela 8.8.

Tabela 8.8: Desempenho dos CRCs que obtiveram melhora ao usar outros algoritmos de classificação

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| RexN | 366 | 643 | 26 | 20 | 17 | 6 | 65,4 | 76,9 |
| RxT | 172 | 430 | 14 | 12 | 11 | 2 | 78,6 | 85,7 |
| SxT | 296 | 565 | 7 | 4 | 3 | 3 | 42,9 | 57,1 |

Os CRCs RexN e RxT obtiveram melhora no desempenho ao usar o algoritmo *Naive Bayes* e o CRC SxT ao usar o algoritmo J48, entretanto, nenhum desses CRCs atingiu a sua capacidade máxima. O desempenho do CRCA, com os CRCs da Tabela 8.8 modificados, pode ser visualizado na Tabela 8.9.

Tabela 8.9: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,64 | 0,85 | 0,73 | 47 | 0 | 3 | 3 | 0 | 0 | 2 |
| Alegria (A) | 0,60 | 0,17 | 0,26 | 10 | 3 | 2 | 3 | 0 | 0 | 0 |
| Repugnância (Re) | 0,56 | 0,54 | 0,55 | 5 | 1 | 14 | 4 | 1 | 0 | 1 |
| Tristeza (T) | 0,67 | 0,85 | 0,75 | 3 | 0 | 1 | 39 | 1 | 0 | 2 |
| Medo (M) | 0,77 | 0,45 | 0,57 | 3 | 1 | 2 | 4 | 10 | 1 | 1 |
| Raiva (R) | 0,67 | 0,25 | 0,36 | 1 | 0 | 3 | 1 | 0 | 2 | 1 |
| Surpresa (S) | 0,70 | 0,64 | 0,67 | 4 | 0 | 0 | 4 | 1 | 0 | 16 |
| Média | 0,65 | 0,66 | 0,63 | Características: 805 | | | | | | |
| Acurácia | 65,5% | | | | | | | | | |

O Teste Z (Diferença de Proporções) foi aplicado, em um nível de significância de 5%, para comparar o desempenho do método ao classificar o conjunto de teste: 1) usando apenas o classificador SVM multiclasse para classificar os dados na primeira camada do método, que obteve acurácia de 58%; e 2) usando o CRCA, que rejeita todas as instâncias na primeira camada e as classifica na segunda camada pelos CRCs, que obteve acurácia de 65,5%.

Estatisticamente para ser significativa, esta diferença deveria ser de no mínimo de 8 pontos percentuais, o que é bem próximo da taxa alcançada. O teste estatístico apresentou um p-valor igual a 0,12.

Embora o método desenvolvido neste trabalho de pesquisa tenha sido desenvolvido para identificar as seis emoções básicas e os textos neutros, também foram realizados outros

experimentos, que serão descritos na sequência. Estes experimentos visam avaliar o método usando parte dos dados do corpus de notícias.

8.1.2. Experimentos com o Método ao Classificar Textos com as Seis Emoções Básicas

Nesta seção, foram utilizados nos experimentos 1.167 textos para o treinamento e 145 textos para avaliação do método. A distribuição dos dados desses conjuntos nas classes podem ser vista, respectivamente, nos gráficos 8.4 e 8.5.

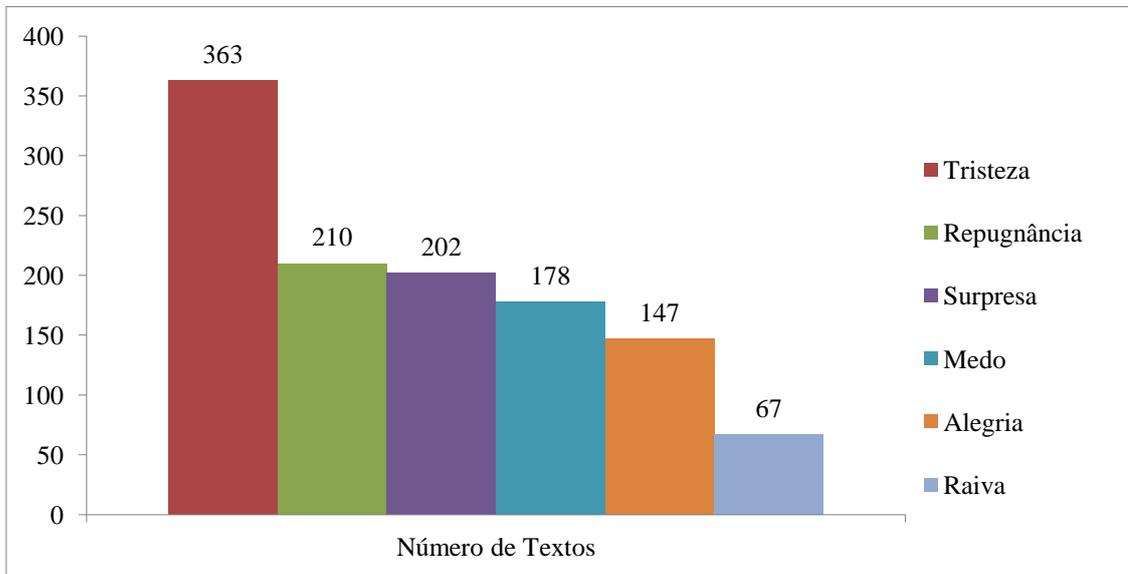


Gráfico 8.4: Distribuição dos textos no conjunto de treinamento

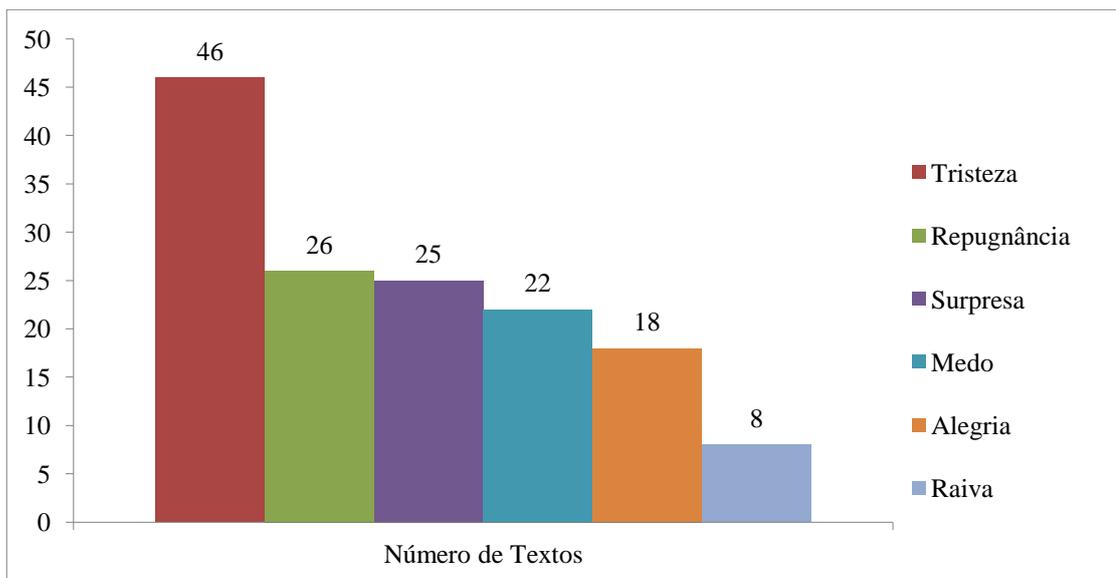


Gráfico 8.5: Distribuição dos textos no conjunto de teste

O primeiro experimento desta seção visa avaliar o método classificando os dados textuais usando apenas o classificador da primeira camada, que foi treinado com o conjunto de treinamento e avaliado com o conjunto de teste.

Os dados de treinamento foram pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1. O desempenho obtido com o classificador SVM multiclasse, pode ser visualizado na Tabela 8.10.

Tabela 8.10: Desempenho do classificador SVM multiclasse

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Alegria (A) | 0,33 | 0,44 | 0,38 | 8 | 1 | 2 | 2 | 1 | 4 |
| Repugnância (Re) | 0,61 | 0,54 | 0,57 | 4 | 14 | 5 | 3 | 0 | 0 |
| Tristeza (T) | 0,67 | 0,67 | 0,67 | 4 | 3 | 31 | 5 | 1 | 2 |
| Medo (M) | 0,46 | 0,50 | 0,48 | 2 | 2 | 4 | 11 | 1 | 2 |
| Raiva (R) | 0,33 | 0,25 | 0,29 | 0 | 2 | 2 | 1 | 2 | 1 |
| Surpresa (S) | 0,59 | 0,52 | 0,55 | 6 | 1 | 2 | 2 | 1 | 13 |
| Média | 0,55 | 0,55 | 0,55 | Características = 545 | | | | | |
| Acurácia | 54,5% | | | | | | | | |

O segundo experimento desta seção avaliar o CRCA que rejeita todas as instâncias na primeira camada e as classifica na segunda camada. Porém, utiliza na segunda camada apenas os CRCs que apresentaram um grau de confusão igual ou superior a 20% durante o treinamento. Os dados de treinamento foram pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1.

Os CRCs usados na segunda camada são classificadores SVM binários configurados com *kernel* RBF padrão (*cost*=1, *gamma*=0), probabilidades estimadas=*false* e os dados são pré-processados usando a configuração *Config_Pre_9* da Tabela 8.1. Para cada CRC é gerado um novo conjunto de características.

O desempenho do CRCA, que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada, pode ser visto na Tabela 8.11 e o desempenho individual dos CRCs pode ser visto na Tabela 8.12.

Tabela 8.11: Desempenho do CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|--------------|-------------|-------------|-----------------------|----|----|---|---|----|
| | Precisão | Cobertura | F1 | A | Re | T | R | M | S |
| Alegria (A) | 0,75 | 0,50 | 0,60 | 9 | 2 | 3 | 0 | 1 | 3 |
| Repugnância (Re) | 0,70 | 0,62 | 0,65 | 0 | 16 | 5 | 0 | 4 | 1 |
| Tristeza (T) | 0,62 | 0,78 | 0,69 | 2 | 1 | 36 | 2 | 2 | 3 |
| Raiva (R) | 0,40 | 0,25 | 0,31 | 0 | 2 | 3 | 2 | 0 | 1 |
| Medo (M) | 0,47 | 0,41 | 0,44 | 0 | 2 | 7 | 1 | 9 | 3 |
| Surpresa (S) | 0,61 | 0,68 | 0,64 | 1 | 0 | 4 | 0 | 3 | 17 |
| Média | 0,61 | 0,61 | 0,61 | Características = 545 | | | | | |
| Acurácia | 61,4% | | | | | | | | |

Tabela 8.12: Desempenho dos CRCs ao classificar as instâncias rejeitadas

| CRC | Limiar de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|--------------------|-----------------|---------------------------|-------------------------|---------------------------|-----------|-----------------------------|-------------|-----------------------|
| AxRe | 21,2 | 314 | 357 | 15 | 12 | 12 | 3 | 80,0 | 80,0 |
| AxS | 28,0 | 282 | 349 | 19 | 15 | 13 | 4 | 68,4 | 78,9 |
| AxT | 26,3 | 430 | 510 | 4 | 0 | 0 | 4 | 0,00 | 0,00 |
| AxM | 28,6 | 193 | 325 | 1 | 0 | 0 | 1 | 0,00 | 0,00 |
| RexM | 29,4 | 255 | 388 | 9 | 6 | 5 | 3 | 55,6 | 66,7 |
| RexT | 27,2 | 313 | 573 | 15 | 11 | 9 | 4 | 60,0 | 73,3 |
| MxS | 35,7 | 314 | 380 | 5 | 5 | 4 | 0 | 80,0 | 100,0 |
| MxT | 22,2 | 302 | 541 | 37 | 29 | 23 | 8 | 62,2 | 78,4 |
| RxT | 23,7 | 168 | 430 | 12 | 10 | 8 | 2 | 66,7 | 83,3 |
| RxS | 33,3 | 269 | 269 | 4 | 2 | 1 | 2 | 25,0 | 50,0 |
| SxT | 36,8 | 404 | 565 | 7 | 5 | 3 | 2 | 42,9 | 71,4 |
| Total | | | 128 | 95 | 78 | 33 | | | |

A primeira ação para melhorar os CRCs foi obter a melhor configuração de pré-processamento da Tabela 8.1 para cada um dos CRCs. Os CRCs que apresentaram melhora no desempenho são apresentados na Tabela 8.13.

Tabela 8.13: CRCs que tiveram melhora em função da configuração do pré-processamento

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxS | 282 | 349 | 19 | 15 | 14 | 4 | 73,7 | 78,9 |
| RexS | 291 | 412 | 12 | 9 | 7 | 3 | 58,3 | 75,0 |
| RexT | 313 | 573 | 15 | 11 | 10 | 4 | 66,7 | 73,3 |

| | | | | | | | | |
|-----|-----|-----|----|----|----|---|-------|-------|
| MxS | 314 | 380 | 5 | 5 | 5 | 0 | 100,0 | 100,0 |
| MxT | 302 | 541 | 37 | 29 | 25 | 8 | 67,5 | 78,4 |
| RxS | 269 | 269 | 4 | 2 | 2 | 2 | 50,0 | 50,0 |

Os CRCs MxS (configurado com *Config_Pre_14*) e RxS (configurado com *Config_Pre_23*) atingiram a sua capacidade máxima. Os CRCs AxS (configurado com *Config_Pre_25*), RexS (configurado com *Config_Pre_2*), RexT (configurado com *Config_Pre_11*) e MxT (configurado com *Config_Pre_14*) atingiram melhora parcial da sua capacidade. Para os CRCs que não obtiveram melhora no desempenho, foi mantida a configuração *Config_Pre_9*. O desempenho do CRCA, com os CRCs modificados da Tabela 8.13, pode ser visualizado na Tabela 8.14.

Tabela 8.14: CRCA com CRCs modificados em relação ao pré-processamento

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>R</i> | <i>M</i> | <i>S</i> |
| Alegria (A) | 0,75 | 0,50 | 0,60 | 9 | 2 | 4 | 0 | 0 | 3 |
| Repugnância (Re) | 0,74 | 0,65 | 0,69 | 0 | 17 | 6 | 0 | 2 | 1 |
| Tristeza (T) | 0,61 | 0,83 | 0,70 | 2 | 1 | 38 | 2 | 0 | 3 |
| Raiva (R) | 0,50 | 0,38 | 0,43 | 0 | 2 | 2 | 3 | 1 | 0 |
| Medo (M) | 0,64 | 0,41 | 0,50 | 1 | 1 | 8 | 1 | 9 | 2 |
| Surpresa (S) | 0,68 | 0,76 | 0,72 | 0 | 0 | 4 | 0 | 2 | 19 |
| Média | 0,66 | 0,66 | 0,65 | Características = 545 | | | | | |
| Acurácia | 65,5% | | | | | | | | |

A segunda ação para melhorar os CRCs foi submeter os CRCs aos algoritmos de classificação *Naive Bayes*, J48 e IBK. Os CRCs que obtiveram melhora no desempenho são mostrados na Tabela 8.15.

Tabela 8.15: Desempenho dos CRCs que obtiveram melhora com outros algoritmos de classificação

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|-----|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxR | 306 | 214 | 2 | 2 | 2 | 0 | 100,0 | 100,0 |
| RxT | 168 | 430 | 12 | 10 | 9 | 2 | 75,0 | 83,3 |

Os CRCs RexN e RxT obtiveram melhora no desempenho ao usar o algoritmo *Naive Bayes*. O resultado final do CRCA pode ser visualizado na Tabela 8.16.

Tabela 8.16: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>R</i> | <i>M</i> | <i>S</i> |
| Alegria (A) | 0,75 | 0,50 | 0,60 | 9 | 2 | 4 | 0 | 0 | 3 |
| Repugnância (Re) | 0,74 | 0,65 | 0,69 | 0 | 17 | 6 | 0 | 2 | 1 |
| Tristeza (T) | 0,62 | 0,83 | 0,71 | 2 | 1 | 38 | 2 | 0 | 3 |
| Raiva (R) | 0,57 | 0,50 | 0,53 | 0 | 2 | 1 | 4 | 1 | 0 |
| Medo (M) | 0,64 | 0,41 | 0,50 | 1 | 1 | 8 | 1 | 9 | 2 |
| Surpresa (S) | 0,68 | 0,76 | 0,72 | 0 | 0 | 4 | 0 | 2 | 19 |
| Média | 0,67 | 0,66 | 0,65 | Características = 545 | | | | | |
| Acurácia | 66,2% | | | | | | | | |

O Teste Z (Diferença de Proporções) foi aplicado, em um nível de significância de 5%, para comparar o desempenho do método ao classificar os dados do conjunto de teste: 1) usando apenas o classificador SVM multiclasse da primeira camada, que obteve acurácia de 54,5%; e 2) usando o CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada, que obteve acurácia de 66,2%.

O teste estatístico apresentou um p-valor igual a 0,04, o que permite afirmar que existe diferença significativa entre os dois classificadores. Dessa forma, o método que classifica em duas camadas apresentou melhor desempenho que o método que classifica em uma única camada as seis emoções básicas dos textos.

8.1.3. Experimentos com o Método ao Classificar Textos com a Polaridade das Emoções e Neutro

Nos experimentos desta seção, os textos do corpus de notícias foram manipulados. Os textos da classe *alegria* foram renomeados para *positivo* e os textos das classes *tristeza*, *repugnância*, *medo* e *raiva* foram renomeados para *negativo*. Os textos da classe *surpresa* não foram utilizados nestes experimentos por se tratarem de textos que podem conter uma polaridade *positiva* ou *negativa* e assim exigiria um novo processo de anotação. Os textos da classe *neutro* foram usados normalmente.

Foram utilizados 1.573 textos para treinamento e 175 textos para avaliação do método. A distribuição dos dados dos conjuntos nas classes podem ser vista, respectivamente, nos gráficos 8.6 e 8.7.

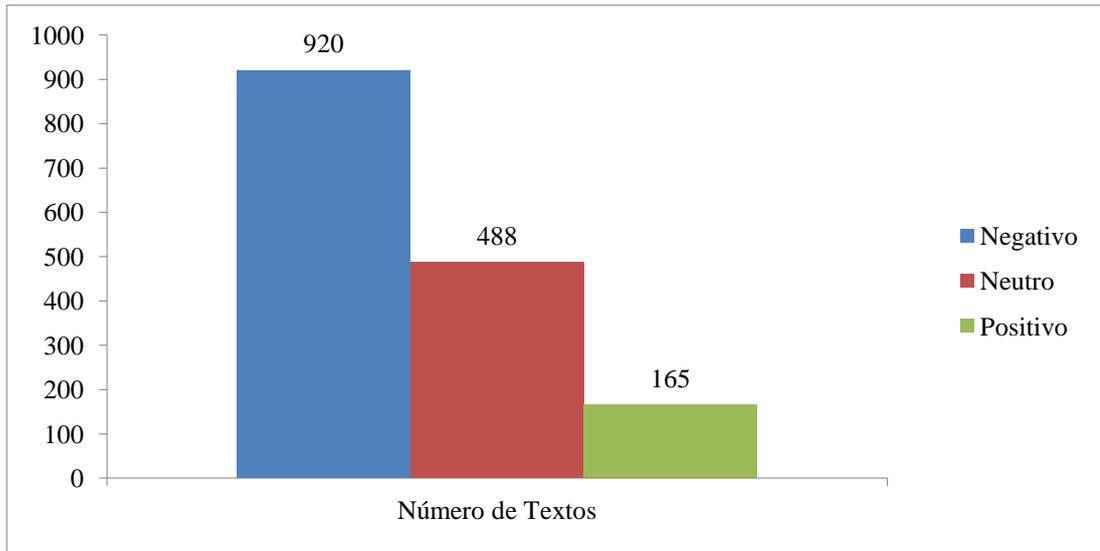


Gráfico 8.6: Distribuição dos textos no conjunto de treinamento

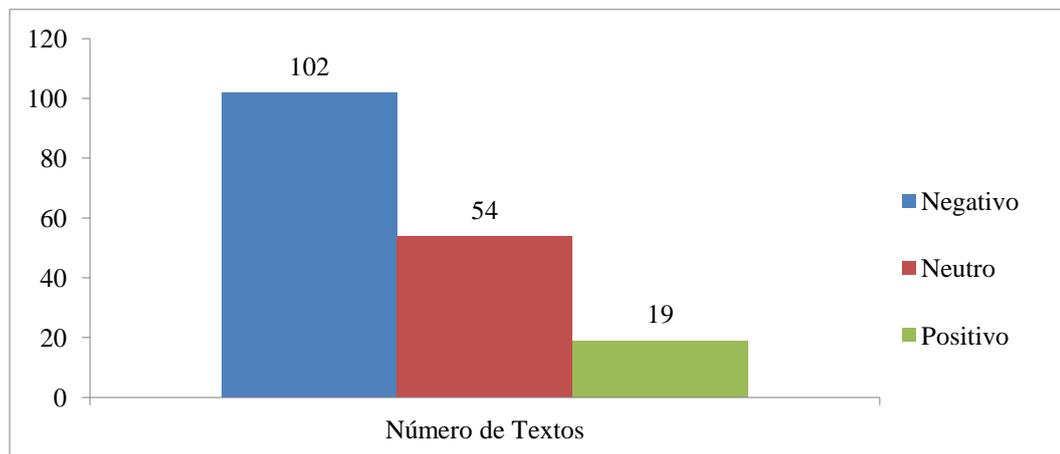


Gráfico 8.7: Distribuição dos textos no conjunto de teste

O primeiro experimento desta seção visa avaliar o método classificando os dados textuais usando apenas o classificador multiclasse, que foi treinado com o conjunto de treinamento e avaliado com o conjunto de teste.

Os dados de treinamento foram pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1. O desempenho obtido com o classificador SVM multiclasse, pode ser visualizado na Tabela 8.17.

Tabela 8.17: Desempenho do classificador SVM multiclasse

| Classe | SVM | | | Matriz de Confusão | | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Neutro</i> | <i>Positivo</i> | <i>Negativo</i> |
| Neutro | 0,68 | 0,78 | 0,72 | 42 | 1 | 11 |
| Positivo | 0,20 | 0,05 | 0,08 | 9 | 1 | 9 |
| Negativo | 0,82 | 0,86 | 0,84 | 11 | 3 | 88 |
| Média | 0,71 | 0,75 | 0,72 | Características = 966 | | |
| Acurácia | 75,0% | | | | | |

O segundo experimento visa avaliar o CRCA que rejeita todas as instâncias na primeira camada e as classifica com os CRCs na segunda camada. Os dados de treinamento foram pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1.

Os CRCs usados na segunda camada são classificadores SVM binários configurados com *kernel* RBF padrão (*cost*=1, *gamma*=0), probabilidades estimadas=*false* e os dados são pré-processados usando a configuração *Config_Pre_24* da Tabela 8.1. Para cada CRC é obtido um novo conjunto de características.

O desempenho do CRCA que rejeita todas as instâncias na primeira camada e as classifica na segunda camada pode ser visualizado na Tabela 8.57 e o desempenho individual dos CRCs pode ser visto na Tabela 8.18.

Tabela 8.18: Desempenho do CRCA que rejeita todas as instâncias na primeira camada

| Classe | SVM | | | Matriz de Confusão | | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Neutro</i> | <i>Positivo</i> | <i>Negativo</i> |
| Neutro | 0,74 | 0,63 | 0,68 | 34 | 0 | 20 |
| Positivo | 1,0 | 0,05 | 0,10 | 7 | 1 | 11 |
| Negativo | 0,76 | 0,95 | 0,84 | 5 | 0 | 97 |
| Média | 0,78 | 0,75 | 0,71 | Características = 966 | | |
| Acurácia | 75,4% | | | | | |

Tabela 8.19: Desempenho dos CRCs ao classificar todas as instâncias rejeitadas

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acer-tou | Encami-nhadas incorretamente | Acer-tou (%) | Capaci-dade Má-xima (%) |
|--------------|---------------|-----------------|---------------------------|-------------------------|---------------------------|------------|------------------------------|--------------|-------------------------|
| PosXNeu | 6,3 | 407 | 653 | 25 | 22 | 19 | 3 | 76,0 | 88,0 |
| NegXNeu | 20,0 | 772 | 1408 | 89 | 79 | 59 | 10 | 66,3 | 88,8 |
| NegXPos | 5,7 | 660 | 1085 | 61 | 59 | 54 | 2 | 88,5 | 96,7 |
| TOTAL | | | | 175 | 160 | 132 | 15 | | |

O passo seguinte é melhorar o desempenho individual dos CRCs visando atingir a sua capacidade máxima e consequentemente aumentar a acurácia e o F1 do CRCA. As ações de melhorias dos CRCs foram as mesmas utilizadas nos experimentos anteriores. Porém, neste experimento, os únicos CRCs que obtiveram melhorias foram os CRCs NegXNeu e PosX-Neu, usando o algoritmo *Naive Bayes*. Os CRCs que apresentaram melhora no desempenho são apresentados na Tabela 8.20 e o resultado final do CRCA pode ser visto na Tabela 8.21.

Tabela 8.20: Desempenho dos CRCs que obtiveram melhora ao usar outros algoritmos de classificação

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Aceitou | Encaminhadas incorretamente | Aceitou (%) | Capacidade Máxima (%) |
|---------|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| NegXNeu | 772 | 1408 | 89 | 79 | 63 | 10 | 70,8 | 88,8 |
| NegXPos | 660 | 1085 | 61 | 59 | 55 | 2 | 90,2 | 96,7 |

Tabela 8.21: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Neutro</i> | <i>Positivo</i> | <i>Negativo</i> |
| Neutro | 0,70 | 0,83 | 0,76 | 45 | 1 | 8 |
| Positivo | 0,50 | 0,11 | 0,17 | 8 | 2 | 9 |
| Negativo | 0,84 | 0,88 | 0,86 | 11 | 1 | 90 |
| Média | 0,76 | 0,78 | 0,76 | Características = 966 | | |
| Acurácia | 78,3% | | | | | |

Foi aplicado o Teste Z (Diferença de Proporções), em um nível de significância de 5%, para comparar o desempenho do método ao classificar os dados do conjunto de teste: 1) usando apenas o classificador SVM multiclasse da primeira camada, que obteve acurácia de 75%; e 2) usando o CRCA que rejeita todas as instâncias, que obteve acurácia de 78,3%.

O teste estatístico apresentou um p-valor igual a 0,46 e, dessa forma, não se pode afirmar que existe uma diferença significativa entre os dois classificadores que justifique a escolha de um ou de outro ao identificar emoções a polaridade das emoções e a classe neutro em textos.

Observou-se nos experimentos desta seção que nenhum dos CRCs conseguiu atingir a sua capacidade máxima. O fato dos textos serem altamente desbalanceados em relação às

classes contribuiu para tal situação, tendo em vista que o desbalanceamento se intensificou ainda mais nos classificadores binários.

8.1.4. Experimentos com o Método ao Classificar a Polaridade das Emoções

Nesta seção foram utilizados nos experimentos 1.206 textos para treinamento e avaliação do método. A distribuição do conjunto de dados pode ser visto no gráfico 8.8.

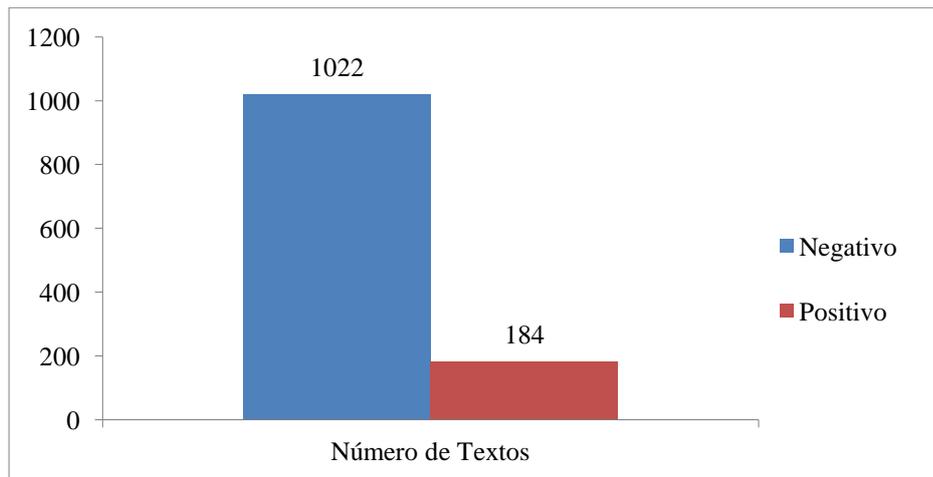


Gráfico 8.8: Distribuição dos textos no conjunto de treinamento

O primeiro experimento desta seção avalia um classificador SVM por meio de Validação Cruzada com dez partes. O resultado pode ser visualizado na Tabela 8.22.

Tabela 8.22: Desempenho do classificador SVM ao ser avaliado com Validação Cruzada

| Classe | SVM | | | Matriz de Confusão | |
|-----------------|-----------------|------------------|-------------|------------------------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Positivo</i> | <i>Negativo</i> |
| Positivo | 0,80 | 0,72 | 0,76 | 133 | 51 |
| Negativo | 0,95 | 0,97 | 0,96 | 34 | 988 |
| Média | 0,93 | 0,93 | 0,93 | Características = 974 | |
| Acurácia | 93,0% | | | | |

Os dados textuais foram submetidos a outros algoritmos de classificação. Desta forma, com o algoritmo IBK foi possível obter o resultado da tabelas 8.23.

Tabela 8.23: Desempenho do classificador IBK ao ser avaliado com Validação Cruzada

| Classe | IBK | | | Matriz de Confusão | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Positivo</i> | <i>Negativo</i> |
| Positivo | 0,20 | 0,91 | 0,32 | 167 | 17 |
| Negativo | 0,95 | 0,33 | 0,49 | 680 | 342 |
| Média | 0,84 | 0,42 | 0,47 | Características = 974 | |
| Acurácia | 42,2% | | | | |

Com o algoritmo *Naive Bayes*, o resultado pode ser visualizado na tabela 8.24.

Tabela 8.24: Desempenho do classificador *Naive Bayes* ao ser avaliado com Validação Cruzada

| Classe | Naive Bayes | | | Matriz de Confusão | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Positivo</i> | <i>Negativo</i> |
| Positivo | 0,37 | 0,57 | 0,45 | 104 | 80 |
| Negativo | 0,91 | 0,83 | 0,87 | 177 | 845 |
| Média | 0,83 | 0,79 | 0,80 | Características = 974 | |
| Acurácia | 78,7% | | | | |

Com o algoritmo *J48*, o resultado pode ser visualizado na tabela 8.25.

Tabela 8.25: Desempenho do classificador *J48* ao ser avaliado com Validação Cruzada

| Classe | J48 | | | Matriz de Confusão | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Positivo</i> | <i>Negativo</i> |
| Positivo | 0,00 | 0,00 | 0,00 | 0 | 184 |
| Negativo | 0,85 | 1,00 | 0,92 | 0 | 1022 |
| Média | 0,72 | 0,85 | 0,78 | Características = 974 | |
| Acurácia | 84,7% | | | | |

Para verificar se existe diferença significativa ao usar o método com um classificador SVM ou com os outros algoritmos de classificação para identificar a polaridade das emoções em textos, foi aplicado o Teste Z (Diferença de Proporções), em um nível de significância de 5%. Na Tabela 8.26, é possível verificar o p-valor obtido pelo teste estatístico ao comparar a acurácia do SVM com a acurácia dos algoritmos de classificação IBK, *Naive Bayes* e J48.

Tabela 8.26: Diferença estatística do SVM com os classificadores IBK, *Naive Bayes* e J48

| Classificador | Avaliado com Validação Cruzada | P-valor | Diferença significativa com o SVM |
|---------------|--------------------------------|---------------|-----------------------------------|
| SVM | 93,0% | --- | --- |
| IBK | 42,2% | 0,0 | Sim |
| Naive Bayes | 78,7% | 0,0 | Sim |
| J48 | 84,7% | 0,00000000009 | Sim |

Observou-se na Tabela 8.26 que a acurácia do SVM foi superior à acurácia dos demais classificadores e o resultado do teste estatístico comprovou que existe diferença significativa entre o SVM e os classificadores IBK, *Naive Bayes* e J48. Assim, é possível afirmar que, entre os classificadores analisados, o SVM apresenta um melhor desempenho ao classificar os textos com a polaridade das emoções.

8.2. Experimento com o Método ao Usar um Corpus em Inglês

Nesta seção, foi realizado um experimento com um corpus em Inglês, usado no trabalho de (GHAZI; INKPEN; SZPAKOWICZ, 2010) que foi citado no estado da arte (Capítulo 4). O corpus se refere a textos de contos infantis que foi desenvolvido por (ALM, 2008) e é composto por 176 contos. O corpus foi anotado com as emoções básicas de (EKMAN, 1992) por dois anotadores.

O corpus usado no trabalho de (GHAZI; INKPEN; SZPAKOWICZ, 2010) e nos experimentos desta seção é composto por textos que tiveram total concordância pelos dois anotadores durante o processo de anotação. As 1.207 sentenças foram anotadas com cinco emoções, sendo elas: *happy*, *sad*, *angry-disgusted*, *fearful* e *surprised*. O corpus foi originalmente anotado com as emoções básicas de (EKMAN, 1992) porém, na versão usada pelos autores (GHAZI; INKPEN; SZPAKOWICZ, 2010), as classes *angry* e *disgusted* foram unidas na classe *angry-disgusted*. No Gráfico 8.9 é possível visualizar a distribuição dos textos do corpus nas classes.

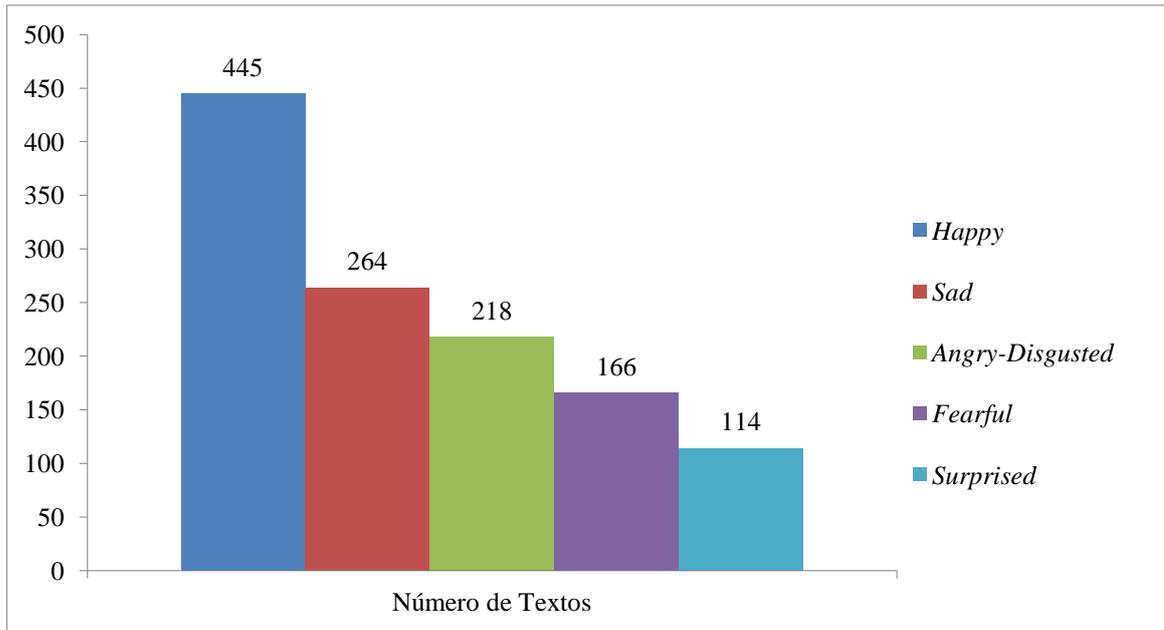


Gráfico 8.9: Distribuição dos textos do corpus de contos infantis

Nesta seção, foram utilizados nos experimentos 1.080 textos para o treinamento e 127 textos para avaliação do método. Além disso, as *stopwords* utilizadas nos experimentos foram extraídas de <http://snowball.tartarus.org/algorithms/english/stop.txt>, e são apresentadas no Apêndice 3.

Nos experimentos foram desconsideradas todas as opções de pré-processamento da Tabela 8.1 que usam *Lematizador* na opção *Dimensionalidade*. Isto ocorreu porque os textos do atual corpus são escritos em Inglês e a configuração *Lematizador* se refere ao uso do algoritmo de (ORENGO; HUYCK, 2001) para lematizar termos em Português, já a opção *Stemmer*, neste experimento, foi adaptada para usar o algoritmo de (PORTER, 1980) em textos escritos em Inglês. A distribuição dos dados de treinamento e de teste pode ser vista, respectivamente, nos gráficos 8.10 e 8.11.

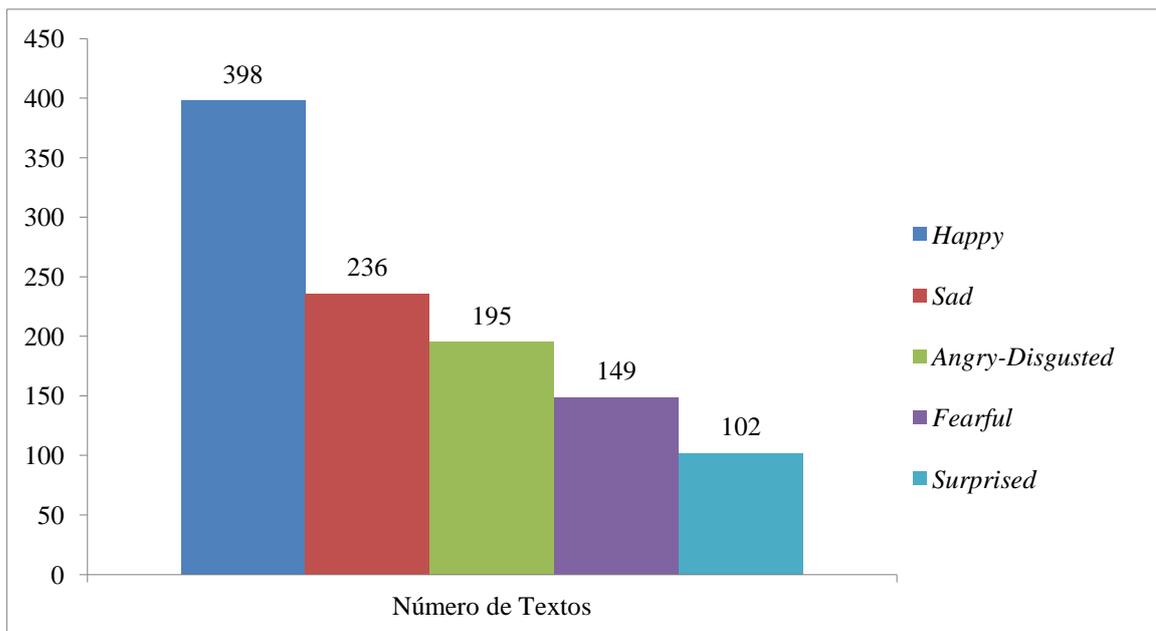


Gráfico 8.10: Distribuição dos textos no conjunto de treinamento

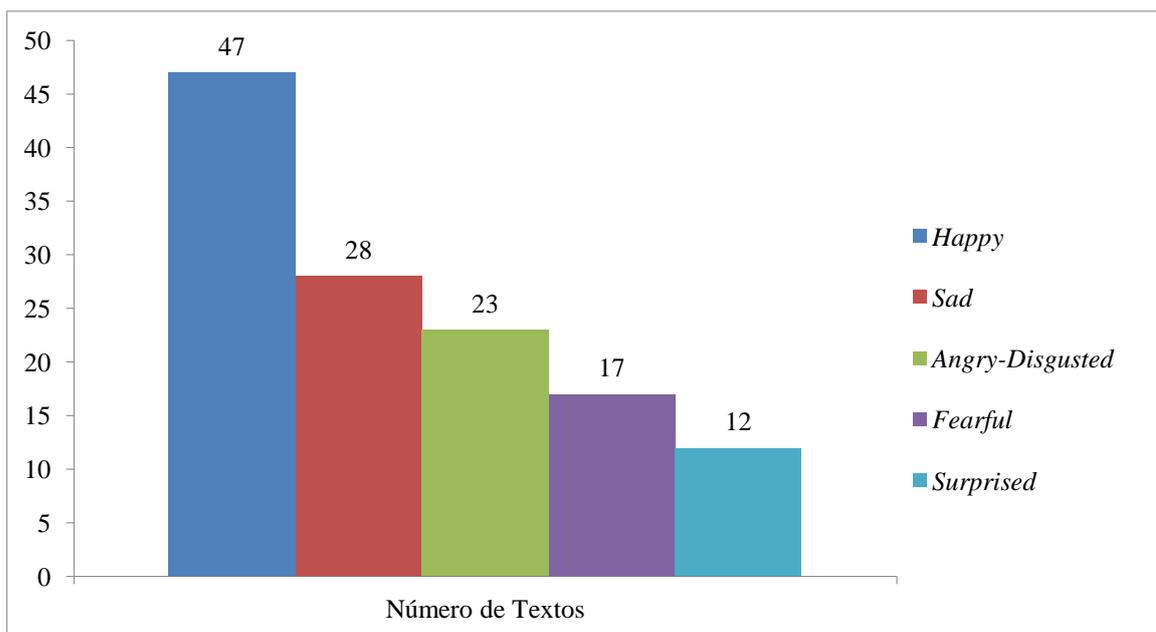


Gráfico 8.11: Distribuição dos textos no conjunto de teste

O primeiro experimento desta seção visa avaliar o método classificando os dados textuais usando apenas o classificador da primeira camada, o qual foi treinado com o conjunto de treinamento e avaliado com o conjunto de teste.

Os dados de treinamento e de teste foram pré-processados com a configuração *Config_Pre_7* da Tabela 8.1, porém, neste caso, o GI foi selecionado manualmente devido a ocor-

rência de instâncias ambíguas no conjunto de dados e assim, foi configurado para considerar 93% dos termos com o maior valor de GI.

O desempenho do método ao usar o classificador SVM multiclasse para classificar os dados do conjunto de teste pode ser visualizado na Tabela 8.27.

Tabela 8.27: Desempenho do classificador SVM multiclasse avaliado com o conjunto de teste

| Classe | SVM | | | Matriz de Confusão | | | | |
|-----------------------------|-----------------|------------------|-----------|------------------------------|----------|-----------|----------|-----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>H</i> | <i>S</i> | <i>AD</i> | <i>F</i> | <i>Su</i> |
| <i>Happy (H)</i> | 0,71 | 0,75 | 0,73 | 35 | 4 | 3 | 2 | 3 |
| <i>Sad (S)</i> | 0,71 | 0,61 | 0,65 | 5 | 17 | 5 | 1 | 0 |
| <i>Angry-Disgusted (AD)</i> | 0,55 | 0,78 | 0,64 | 3 | 1 | 18 | 1 | 0 |
| <i>Fearful (F)</i> | 0,77 | 0,77 | 0,77 | 2 | 0 | 2 | 13 | 0 |
| <i>Surprised (Su)</i> | 0,25 | 0,08 | 0,13 | 4 | 2 | 5 | 0 | 1 |
| Média | 0,65 | 0,66 | 0,65 | Características = 563 | | | | |
| Acurácia | 66,1% | | | | | | | |

O segundo experimento visa avaliar o método usando um CRCA para classificar os dados do conjunto de teste. Assim, na primeira camada, o método é composto de um classificador SVM multiclasse e na segunda camada é configurado para criar CRCs binários e a usar a ER CHOW, a qual obteve, automaticamente, um limiar de rejeição = 0,59. O limiar de confusão = 20% foi usado selecionar os CRCs a serem criados para classificar os dados na segunda camada.

Os dados de treinamento e de teste foram pré-processados com configuração igual a definida no experimento anterior. Os CRCs são classificadores SVM binários configurados com *kernel* RBF padrão (*cost*=1, *gamma*=0), probabilidades estimadas=*false*. Para cada CRC é obtido um novo conjunto de características.

O desempenho do CRCA pode ser observado na Tabela 8.28 e os resultados obtidos com os CRCs são mostrados na Tabela 8.29.

Tabela 8.28: Desempenho do CRCA ao avaliar o conjunto de teste

| Classe | SVM | | | Matriz de Confusão | | | | |
|-----------------------------|-----------------|------------------|-----------|------------------------------|----------|-----------|----------|-----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>H</i> | <i>S</i> | <i>AD</i> | <i>F</i> | <i>Su</i> |
| <i>Happy (H)</i> | 0,67 | 0,85 | 0,75 | 40 | 1 | 5 | 1 | 0 |
| <i>Sad (S)</i> | 0,93 | 0,50 | 0,65 | 8 | 14 | 5 | 1 | 0 |
| <i>Angry-Disgusted (AD)</i> | 0,53 | 0,78 | 0,63 | 4 | 0 | 18 | 1 | 0 |
| <i>Fearful (F)</i> | 0,77 | 0,77 | 0,77 | 2 | 0 | 2 | 13 | 0 |
| <i>Surprised (Su)</i> | 1,00 | 0,08 | 0,15 | 6 | 20 | 4 | 1 | 1 |
| Média | 0,75 | 0,68 | 0,65 | Características = 563 | | | | |
| Acurácia | 67,7% | | | | | | | |

Tabela 8.29: Desempenho dos CRCs

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acer-tou | Encami-nhadas incorre-tamente | Acer-tou (%) | Capaci-dade Máxima (%) |
|--------------|---------------|-----------------|---------------------------|-------------------------|---------------------------|-----------|-------------------------------|--------------|------------------------|
| HxS | 35,0 | 341 | 634 | 10 | 7 | 4 | 3 | 40,0 | 70,0 |
| HxAD | 37,4 | 313 | 593 | 11 | 6 | 4 | 5 | 36,4 | 54,5 |
| HxF | 28,6 | 306 | 547 | 6 | 5 | 4 | 1 | 66,7 | 83,3 |
| HxSu | 40,0 | 312 | 500 | 3 | 2 | 2 | 1 | 66,7 | 66,7 |
| ADxS | 29,6 | 21 | 431 | 6 | 6 | 3 | 0 | 50,0 | 100,0 |
| FxS | 35,0 | 199 | 385 | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| SuxS | 33,3 | 185 | 338 | 0 | 0 | 0 | 0 | 0,00 | 0,00 |
| ADxF | 32,2 | 139 | 344 | 6 | 4 | 1 | 2 | 16,7 | 66,7 |
| ADxSu | 41,0 | 106 | 297 | 4 | 2 | 1 | 2 | 25,0 | 50,0 |
| FxSu | 33,3 | 117 | 251 | 2 | 1 | 1 | 1 | 50,0 | 50,0 |
| TOTAL | | | | 49 | 34 | 21 | 15 | | |

A primeira ação para melhorar os CRCs foi obter para cada um deles a melhor configuração de pré-processamento. Os CRCs nos quais a configuração de pré-processamento impactou na melhora do desempenho são apresentados na Tabela 8.30.

Tabela 8.30: CRCs que apresentaram melhorias em função da configuração do pré-processamento

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acer-tou | Encami-nhadas incorre-tamente | Acer-tou (%) | Capaci-dade Máxima (%) |
|------|---------------|-----------------|---------------------------|-------------------------|---------------------------|----------|-------------------------------|--------------|------------------------|
| HxS | 35,0 | 341 | 634 | 10 | 7 | 5 | 3 | 50,0 | 70,0 |
| HxAD | 37,4 | 313 | 593 | 11 | 6 | 5 | 5 | 45,5 | 54,5 |
| HxF | 28,6 | 306 | 547 | 6 | 5 | 5 | 1 | 83,3 | 83,3 |
| ADxS | 29,6 | 213 | 431 | 6 | 6 | 5 | 0 | 83,3 | 100,0 |
| ADxF | 32,2 | 139 | 344 | 6 | 4 | 2 | 2 | 33,3 | 66,7 |

O CRC HxS foi configurado com *Config_Pre_10* (GI = 93%) e os CRCs HxAD, HxF, ADxS e ADxF foram configurados com *Config_Pre_24* (GI = 93% e IM = 0.002229). Os demais CRCs não obtiveram melhora no desempenho e manteve-se a configuração *Config_Pre_7* (GI = 93%). O desempenho do CRCA, com os CRCs da Tabela 8.73 modificados, pode ser visualizado na Tabela 8.31.

Tabela 8.31: Desempenho do CRCA após modificação de configuração de pré-processamento dos CRCs

| Classe | SVM | | | Matriz de Confusão | | | | |
|-----------------------------|-----------------|------------------|-----------|------------------------------|----------|-----------|----------|-----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>H</i> | <i>S</i> | <i>AD</i> | <i>F</i> | <i>Su</i> |
| <i>Happy (H)</i> | 0,68 | 0,87 | 0,77 | 41 | 1 | 3 | 2 | 0 |
| <i>Sad (S)</i> | 0,94 | 0,61 | 0,74 | 7 | 17 | 3 | 1 | 0 |
| <i>Angry-Disgusted (AD)</i> | 0,64 | 0,78 | 0,71 | 4 | 0 | 18 | 1 | 0 |
| <i>Fearful (F)</i> | 0,75 | 0,88 | 0,81 | 1 | 0 | 1 | 15 | 0 |
| <i>Surprised (Su)</i> | 1,00 | 0,08 | 0,15 | 7 | 0 | 3 | 1 | 1 |
| Média | 0,77 | 0,72 | 0,70 | Características = 563 | | | | |
| Acurácia | 72,4% | | | | | | | |

A segunda ação para melhorar os CRCs foi submetê-los aos outros algoritmos de classificação como *Naive Bayes*, J48 e KNN. O único CRC que apresentou melhora no desempenho foi o CRC ADxF, que usou o algoritmo *Naive Bayes*. O desempenho final do CRCA pode ser visualizado na Tabela 8.32.

Tabela 8.32: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | | | |
|-----------------------------|-----------------|------------------|-----------|------------------------------|----------|-----------|----------|-----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>H</i> | <i>S</i> | <i>AD</i> | <i>F</i> | <i>Su</i> |
| <i>Happy (H)</i> | 0,68 | 0,87 | 0,77 | 41 | 1 | 4 | 1 | 0 |
| <i>Sad (S)</i> | 0,94 | 0,61 | 0,74 | 7 | 17 | 3 | 1 | 0 |
| <i>Angry-Disgusted (AD)</i> | 0,66 | 0,83 | 0,73 | 4 | 0 | 19 | 0 | 0 |
| <i>Fearful (F)</i> | 0,84 | 0,94 | 0,89 | 1 | 0 | 0 | 16 | 0 |
| <i>Surprised (Su)</i> | 1,00 | 0,08 | 0,15 | 7 | 0 | 3 | 1 | 1 |
| Média | 0,79 | 0,74 | 0,71 | Características = 563 | | | | |
| Acurácia | 74,0% | | | | | | | |

O Teste Z (Diferença de Proporções) foi aplicado, em um nível de significância de 5%, para comparar o desempenho do método ao classificar os dados do conjunto de teste: 1) usando apenas o classificador SVM multiclasse para classificar os dados na primeira camada do método, que obteve acurácia de 66,1%; e 2) usando o CRCA com limiar de rejeição e limiar de confusão para classificar os dados na primeira e na segunda camada do método, que obteve acurácia de 74,0%.

Embora o CRCA obteve um melhor desempenho em relação a acurácia se comparado ao classificador SVM multiclasse, o resultado do teste apresentou um p-valor igual a 0,17. Dessa forma, do ponto de vista estatístico, não se pode afirmar que existe uma diferença signi-

ficativa entre os dois classificadores que justifique a escolha de um ou de outro para classificar textos com as emoções *happy, sad, angry-disgusted, fearful e surprised*.

Os autores (GHAZI; INKPEN; SZPAKOWICZ, 2010) obtiveram uma acurácia de 56,6% na classificação plana e 59,1% na classificação em níveis. O método desenvolvido neste trabalho obteve 66,1% na primeira camada e 74,0% ao usar duas camadas. Embora os resultados de (GHAZI; INKPEN; SZPAKOWICZ, 2010) foram obtidos por Validação Cruzada (com 1.207 textos) e os do método por avaliação do conjunto de teste (treinado com 1.080 textos e avaliado com 127 textos), foi possível verificar a diferença de desempenho entre os métodos por meio de teste estatístico que avalia a diferença de proporções.

Primeiramente, o Teste Z foi aplicado em um nível de significância de 5%, para verificar se a acurácia de 66,1%, obtida pelo método na primeira camada é superior a acurácia de 56,6%, obtida por (GHAZI; INKPEN; SZPAKOWICZ, 2010) na classificação plana. O teste estatístico apresentou um p-valor de 0,03, que permite afirmar que a acurácia obtida pelo método em questão é maior que a acurácia obtida por (GHAZI; INKPEN; SZPAKOWICZ, 2010).

Em seguida, o Teste Z foi aplicado em um nível de significância de 5%, para comparar se a acurácia de 74%, obtida ao usar a primeira e a segunda camada do método é superior a acurácia de 59,1%, obtida por (GHAZI; INKPEN; SZPAKOWICZ, 2010) na classificação em níveis. O teste estatístico apresentou um p-valor de 0,001, o que permite afirmar que a acurácia obtida pelo método em questão é maior que a acurácia obtida por (GHAZI; INKPEN; SZPAKOWICZ, 2010).

É importante ressaltar ainda que (GHAZI; INKPEN; SZPAKOWICZ, 2010) utiliza uma abordagem léxica na extração das características e o método desenvolvido neste trabalho é isento da utilização de tais recursos.

Embora os testes estatísticos confirmam que são significativas as diferenças de desempenho entre o método desenvolvido neste trabalho e o método de (GHAZI; INKPEN; SZPAKOWICZ, 2010), na sequência é realizado um breve experimento com o objetivo de proporcionar uma comparação mais direta entre ambos os métodos.

Neste experimento, os dados do corpus de contos infantis são submetidos ao método, que é avaliado por meio de Validação Cruzada com dez partes. Assim, o conjunto de 1.207 textos foi submetido ao classificador SVM multiclasse. Os dados foram pré-processados u-

sando a configuração *Config_Pre_7* (GI = 80%) da Tabela 8.1. O desempenho do classificador SVM multiclasse pode ser visualizado na Tabela 8.33.

Tabela 8.33: Desempenho do classificador SVM multiclasse ao ser avaliado com o corpus de contos infantis

| Classe | SVM | | | Matriz de Confusão | | | | |
|-----------------------------|-----------------|------------------|-----------|------------------------------|----------|-----------|----------|-----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>H</i> | <i>S</i> | <i>AD</i> | <i>F</i> | <i>Su</i> |
| <i>Happy (H)</i> | 0,77 | 0,81 | 0,79 | 361 | 26 | 38 | 11 | 9 |
| <i>Sad (S)</i> | 0,78 | 0,73 | 0,75 | 38 | 192 | 27 | 4 | 3 |
| <i>Angry-Disgusted (AD)</i> | 0,51 | 0,74 | 0,60 | 38 | 13 | 162 | 2 | 3 |
| <i>Fearful (F)</i> | 0,80 | 0,57 | 0,67 | 17 | 12 | 41 | 95 | 1 |
| <i>Surprised (Su)</i> | 0,70 | 0,33 | 0,45 | 16 | 4 | 51 | 5 | 38 |
| Média | 0,72 | 0,70 | 0,70 | Características = 333 | | | | |
| Acurácia | 70,3% | | | | | | | |

O Teste Z (Diferença de Proporções), foi aplicado em um nível de significância de 5%, para verificar se a acurácia de 70,3%, obtida pelo método com Validação Cruzada com dez partes, é maior que a acurácia de 56,6%, obtida com Validação Cruzada com dez partes pelo método de (GHAZI; INKPEN; SZPAKOWICZ, 2010).

O teste estatístico resultou em um p-valor igual a 0,000000000001, o que significa que é possível afirmar que o método de identificação de emoções, desenvolvido neste trabalho de pesquisa, apresenta um melhor desempenho ao classificar textos de emoções em Inglês se comparado ao desempenho obtido por (GHAZI; INKPEN; SZPAKOWICZ, 2010) ao classificar o mesmo corpus de textos.

8.3. Análise dos Resultados

Nos experimentos da Seção 8.1, o método de identificação de emoções foi avaliado com o corpus de notícias, escrito em Português Brasileiro, construído especialmente para esta finalidade, ou seja, avaliar o método.

Embora o objetivo principal do método de identificação de emoções é identificar as seis emoções básicas e a classe *neutro*, os experimentos da Seção 8.1 também mostraram o desempenho do método em outras situações, tais como: identificar somente as seis emoções básicas, identificar a polaridade das emoções e o *neutro* e identificar a polaridade das emoções.

A primeira e a segunda parte da Seção 8.1 mostrou os experimentos realizados com o método ao identificar textos com as seis emoções básicas e o *neutro* e textos somente com as seis emoções básicas. Com os experimentos, foi possível observar que, em termos de acurácia, o uso da classificação em camadas contribuiu para melhorar significativamente o desempenho do método ao identificar as emoções nos textos.

Nos experimentos realizados com o método ao identificar a polaridade das emoções e *neutro* nos textos, o uso da classificação em camadas não proporcionou uma diferença significativa. Neste caso, o desbalanceamento das classes é bastante evidente no conjunto de dados, o que contribuiu para tal situação.

Nos experimentos realizados com o método ao identificar a polaridade das emoções nos textos foi possível comprovar estatisticamente que acurácia obtida ao usar o SVM para identificar a polaridade das emoções nos textos é maior do que a acurácia obtida no método ao usar outros algoritmos de classificação, neste caso, o IBK, o *Naive Bayes* e o J48. Esse fato permite verificar que as particularidades do SVM ao ser usado para a classificação de textos, observadas na teoria de (JOACHIMS, 1998), se confirmam na prática.

Nos experimentos da Seção 8.2 foi possível avaliar o método com textos escritos em Inglês. Observou-se que, apesar do método ter sido desenvolvido enfatizando o idioma Português brasileiro, obteve resultados superiores ao ser comparado com o método desenvolvido por (GHAZI; INKPEN; SZPAKOWICZ, 2010) ao classificar textos em Inglês. É importante considerar que até este momento o método não foi comparado com outros métodos para o Inglês, pois existe uma certa dificuldade em se encontrar corpora disponíveis, que tenham sido anotados com as seis emoções básicas.

Embora até o presente momento, o desempenho do método desenvolvido neste trabalho não pôde ser comparado diretamente com outros métodos para o Português Brasileiro, considera-se que de um modo geral ele alcançou resultados satisfatórios, visto que; 1) foi avaliado com um corpus naturalmente desbalanceado, e além disso, o corpus de notícias possui classes que apresentam um baixo número de instâncias, é o caso por exemplo, da classe "raiva", que tem apenas 4,2% das instâncias do corpus, o que implica numa baixa representatividade de características discriminantes para esta classe; 2) utiliza um corpus de notícias, sendo que textos de notícias normalmente apresentam uma maior complexidade de anotação e, conseqüentemente, de classificação, visto que o conteúdo de emoções costuma ser esparsa e o autor tende a não explicitar diretamente a sua emoção. Ao contrário de outros textos, como os

do *Twitter*, por exemplo, em que o autor expressa mais livremente as suas emoções; 3) não usou nenhum recurso léxico de emoções para classificar os textos ou para extrair as características.

8.4. Considerações Finais

Neste capítulo foram apresentados os principais experimentos realizados com o método de identificação de emoções. O desbalanceamento dos dados é um fator característico em corpora de emoções. Isto pôde ser percebido com os corpora utilizados nos trabalhos descritos no estado da arte e também com os corpora utilizados nos experimentos deste trabalho de pesquisa.

No Apêndice 5, são apresentados outros experimentos interessantes que foram realizados com o método de identificação de emoções usando o corpus de notícias.

Capítulo 9

Conclusão e Trabalhos Futuros

As pesquisas sobre emoções e computadores têm crescido amplamente nos últimos anos, impulsionadas principalmente pelos avanços da tecnologia. As tecnologias eficazes e de baixo custo permitem que os computadores pessoais possam fazer avaliações sobre o estado emocional do usuário em tempo real.

Embora na atualidade muitas pesquisas estão sendo produzidas sobre este tema, mais especificamente na AS a grande maioria delas se referem a identificação da polaridade das emoções em textos e normalmente são produzidas para o idioma Inglês, o que contribui para que se tenha disponível neste idioma muitos recursos já consolidados, como por exemplo, métodos, corpora e léxicos.

Não tão rápidas e avançadas como para a identificação de polaridade das emoções, as pesquisas de AS que tratam de identificar categorias de emoções em textos e que se baseiam em modelos estruturais de emoções, como o de (EKMAN, 1992) por exemplo, vêm sendo desenvolvidas para a língua Inglesa e ainda são raras para outras línguas. Para o Português Brasileiro, as pesquisas em AS ainda estão se estabelecendo para a identificação de polaridade das emoções e alguns recursos estão surgindo, como por exemplo, a elaboração de um léxico para o Português (FREITAS, 2013) e alguns corpora como (FREITAS et al., 2014) e (LÓPEZ et al., 2015). Entretanto, quando se refere a identificação de categorias de emoções em textos, as pesquisas e os recursos são completamente escassos para este idioma.

Com base neste contexto é que o método descrito neste trabalho de pesquisa foi proposto e elaborado. O método foi desenvolvido para identificar categorias de emoções em textos escritos em Português Brasileiro, em especial as categorias de emoções de (EKMAN, 1992) e a categoria *neutro*. O método usa exclusivamente uma abordagem de AM supervisio-

nada para classificar os textos. Desta forma, o método é totalmente livre de léxicos de termos emocionais, o que o torna independentes desses recursos.

Ao ser avaliado com os textos do corpus de notícias, ao identificar as categorias de emoções e *neutro*, o método atingiu uma acurácia de 65,5% e, embora não tenha sido possível compará-lo diretamente com outros métodos pelo fato do corpus ser em Português, os resultados se mantiveram semelhantes aos obtidos com métodos de outros idiomas quando avaliados com as mesmas categorias usando outros corpora. É o caso, por exemplo, do trabalho de (GHAZI; INKPEN; SZPAKOWICZ, 2010), no qual os autores avaliaram um método usando um corpus em Inglês composto de 2.090 textos de blogs e obtiveram uma acurácia de 65,5% em uma classificação plana e 68,3% em uma classificação em níveis. Estatisticamente, não existe diferença significativa entre ambos os resultados, o que permite afirmar que o método de identificação de emoções, desenvolvido neste trabalho de pesquisa, obteve um desempenho semelhante.

Ao ser avaliado com um corpus em Inglês, o método obteve uma acurácia de 70,3%. Esta acurácia foi significativamente superior à acurácia de 56,6% obtida por (GHAZI; INKPEN; SZPAKOWICZ, 2010) ao avaliar um mesmo conjunto de textos, um corpus de contos infantis composto de 1.207 textos. Além disso, é importante salientar que o método de (GHAZI; INKPEN; SZPAKOWICZ, 2010) utiliza léxicos para selecionar as características.

O método atingiu uma acurácia de 93% ao identificar a polaridade das emoções nos textos usando o corpus de notícias. Se comparado indiretamente com os outros métodos desenvolvidos para o Português Brasileiro, este resultado acaba sendo semelhante aos melhores resultados já obtidos com os outros métodos ao usar recursos léxicos, como pode ser visto na Tabela 4.16 (Capítulo 4) do estado da arte.

Além de disponibilizar um método de identificação de emoções em textos, as atividades executadas durante a realização da pesquisa permitiram disponibilizar também: 1) um corpus de textos de notícias, escrito em Português Brasileiro, composto de 2.000 textos e anotado com as seis emoções básicas e o *neutro*, 2) um sistema de anotação de textos; 3) uma ferramenta computacional para a AS, que permite inúmeras combinações possíveis de configurações de pré-processamento e de classificação; 4) uma abordagem de balanceamento de dados. Todos esses recursos estão disponíveis e poderão ser utilizados em outras pesquisas de AS.

A pesquisa desenvolvida neste trabalho também resultou em contribuições científicas que se traduzem em artigos publicados em conferências na área da Ciência da Computação, são eles:

- DOSCIATTI, M. M.; MARTINAZZO, B.; PARAISO, E. C. *Identifying Emotions in Short Texts for Brazilian Portuguese*. In: IV International Workshop on Web and Text Intelligence (WTI), Curitiba, 2012, Curitiba, Brazil, p. 1-10
- DOSCIATTI, M. M.; FERREIRA, L. P. C.; PARAISO, E. C. *Identificando Emoções em Textos em Português Brasileiro usando Máquina de Vetores de Suporte em Solução Multiclasse*. In: X Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2013, Fortaleza, p. 1-12
- FERREIRA, L. P. C.; DOSCIATTI, M. M.; PARAISO, E. C. *Estudo do Impacto de um Corpus Desbalanceado na Identificação de Emoções em Textos*. In: Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2014, São Carlos, Porto Alegre: SBC, 2014. p. 394-400.
- FERREIRA, L. P. C.; DOSCIATTI, M. M.; NIEVOLA, J. C.; PARAISO, E. C. *Using a Genetic Algorithm Approach to Study the Impact of Imbalanced Corpora in Sentiment Analysis*. In: AAAI International FLAIRS Conference, 2015, Hollywood. The 28th International FLAIRS Conference, 2015. p. 163-168.
- DOSCIATTI, M. M.; FERREIRA, L. P. C.; PARAISO, E. C. *Anotando um Corpus de Notícias para a AS: um Relato de Experiência*. In: X Brazilian Symposium in Information and Human Language Technology (STIL), 2015, Natal, Brasil.

O método apresentado neste trabalho também possibilitará a realização de diversos estudos futuros acerca das emoções quando expressas em textos e, sobretudo, sobre as influências sociais e culturais relacionadas às emoções em textos. Além dessas questões, com as atividades que foram desenvolvidas nesta pesquisa, é possível sugerir alguns outros trabalhos relacionados com a pesquisa. São eles:

1. Construção de um método de encadeamento de emoções. Este método tem como objetivo identificar padrões de encadeamento de emoções nos textos. Por exemplo: Se em um determinado domínio foi identificado que a maioria dos documentos de um corpus possuem sentenças com a seguinte sequência de emoções: *neutro, neutro, alegria, neutro, neutro, tristeza*. Se esses textos fossem lidos por um avatar,

que expressa as emoções encontradas por meio de expressões faciais, quando ocorresse uma mudança muito brusca em relação à sequência das emoções, o método de encadeamento poderia proporcionar uma transição mais suave entre uma emoção e outra.

2. No corpus de notícias, pretende-se estudar a emoção secundária e os graus de intensidade, indicados pelos anotadores e até o presente momento não utilizados efetivamente. Além disso, pretende-se ampliar o número de textos do corpus.
3. Possibilitar ao método de identificação de emoções usar uma classificação multirótulo, ou seja, classificar os textos com mais de uma emoção.
4. Avaliar o método com corpora de outros domínios com os textos anotados com as seis emoções básicas e *neutro*. No idioma Português Brasileiro ainda não se tem disponível esses corpora e isto implica em construí-los.
5. Usar uma abordagem de Aprendizagem Profunda no método de identificação de emoções.
6. Realizar a anotação formal de um corpus composto de por 1.244 textos de blogs, sendo 600 deles extraídos de blogs da região Nordeste do Brasil e os demais 644 textos, extraídos de blogs da região Sul do Brasil. Todos os comentários se referem ao tema "futebol". O objetivo deste trabalho é utilizar este corpus e o método de identificação de emoções em textos para avaliar se as questões culturais podem influenciar na forma como as pessoas expressam as emoções em textos.

Referências

- AGHBARI, Z. AL. Array-index: a plug&search K nearest neighbors method for high-dimensional data. *Data & Knowledge Engineering*, v. 52, p. 333–352, 2005.
- ALM, C. O.; ROTH, D.; SPROAT, R. Emotions from text : machine learning for text-based emotion prediction. *Human Language Technology Conference/Conference on Empirical Methods in Natural Language Processing*, p. 579–586, 2005.
- ALM, E. C. O. Affect in Text and Speech. Thesis, p. 119, 2008.
- ALVARES, R. V; CRISTINA, A.; GARCIA, B.; FERRAZ, I. STEMBR : A Stemming Algorithm for the Brazilian Portuguese Language. *Progress in Artificial Intelligence*, v. 3808, p. 693–701, 2005.
- ALVES, A. L. F.; BAPTISTA, C. de; FIRMINO, A. A.; OLIVEIRA, M. G. de; PAIVA, A. C. de. A Comparison of SVM Versus Naive-Bayes Techniques for Sentiment Analysis in Tweets: A Case Study with the 2013 FIFA Confederations Cup Categories and Subject Descriptors. *WebMedia'14 Proceedings of the 20th Simpósio Brasileiro de Sistemas Multimídia e Web*, p. 123–130, 2014.
- AMAN, S.; SZPAKOWICZ, S. Identifying expressions of emotion in text. *Text, Speech and Dialogue*, v. 4629, p. 196–205, 2007.
- AMER, M. R. SIDDIQUIE, B.; RICHEY, C.; DIVAKARAN, A. Emotion Detection in Speech Using Deep Networks. p. 3752–3756, 2014.
- ARANHA, C. N. Uma Abordagem de Pré- Processamento Automático para Mineração de Textos em Português: Sob o Enfoque da Inteligência Computacional. Tese, p. 1–143, 2007.
- ARAÚJO, M. GONÇALVES, P.; CHA, M.; BENEVENUTO, F. iFeel: A Web System that Compares and Combines Sentiment Analysis Methods. *International World Wide Web Conference Committee (IW3C2)*, p. 75–78, 2014.
- ARNOLD, M. B. Emotion and personality. Vol. I. Psychological aspects. *Emotion and personality Psychological aspects*, v. 1, 1960.
- ARTSTEIN, R.; POESIO, M. Bias decreases in proportion to the number of annotators. *Proceedings of FG-MoL 2005*, p. 141–150, 2005.
- ARTSTEIN, R.; POESIO, M. Inter-Coder Agreement for Computational Linguistics. *Computational Linguistics*, v. 34, n. 4, p. 555–596, 2008.

ASUR, S.; HUBERMAN, B. A. Predicting the Future with Social Media. 2010 IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology, p. 492–499, 2010.

BAEZA-YATES, R.; RIBEIRO-NETO, B. Recuperação de Informação Conceitos e Tecnologia das Máquinas de Busca. 2013.

BALAHUR, A. STEINBERGER, R.; GOOT, E. V. D.; POULIQUEN, B.; KABADJOV, M. Opinion mining on newspaper quotations. IEEE/WIC/ACM International Conference on Web Intelligence and Intelligent Agent Technology, v. 3, p. 523–526, 2009.

BALAHUR, A. STEINBERGER, R.; KABADJOV, M.; ZAVARELLA, V.; GOOT, E. V. D.; HALKIA, M.; POULIQUEN, B.; BELYAEVA, J. Sentiment analysis in the news. Proceedings of the Seventh International Conference on Language Resources and Evaluation (LREC'10), p. 2216–2220, 2010.

BALAHUR, A.; HERMIDA, J. M.; MONTOYO, A. Building and exploiting EmotiNet, a knowledge base for emotion detection based on the appraisal theory model. IEEE Transactions on Affective Computing, v. 3, n. 1, p. 88–101, 2012.

BALAHUR, A.; MIHALCEA, R.; MONTOYO, A. Computational approaches to subjectivity and sentiment analysis: Present and envisaged methods and applications. Computer Speech and Language, v. 28, n. 1, p. 1–6, 2014.

BALAHUR, A.; STEINBERGER, R. Rethinking Sentiment Analysis in the News: from Theory to Practice and back. Workshop on Opinion Mining and Sentiment Analysis (WOMSA), 13th Conference of the Spanish Association for Artificial Intelligence, p. 1–12, 2009.

BARANAUSKAS, J. A.; MONARD, M. C. Reviewing Some Machine Learning Concepts and Methods. Technical Reports, 2000.

BARBOSA, I. A. M. DINIZ, Y. C.; GAJADHAR, A. A. T.; BARBOSA, Y. A. M.; FORMIGA, A. A. Análise de Múltiplos Sentimentos em Textos Baseada em Lexicon. Encontro Nacional de Inteligência Artificial e Computacional (ENIAC), 2014.

BARROS, L.; RODRIGUEZ, P.; ORTIGOSA, A. Automatic Classification of Literature Pieces by Emotion Detection A Study on Quevedo's Poetry. Humaine Association Conference on Affective Computing and Intelligent Interaction, p. 141–146, 2013.

BATISTA, G. E.; PRATI, R. C.; MONARD, M. C. Balancing strategies and class overlapping. Advances in Intelligent Data Analysis, p. 24–35, 2005.

BAUTIN, M.; VIJAYARENU, L.; SKIENA, S. International Sentiment Analysis for News and Blogs. Proceedings of the International Conference on Weblogs and Social Media ICWSM, p. 19–26, 2008.

- BECKER, J. L. Estatística Básica: Transformando Dados em Informação. Bookman, p. 502, 2015.
- BECKER, K.; TUMITAN, D. Introdução à Mineração de Opiniões: Conceitos, Aplicações e Desafios. Lectures of the 28th Brazilian Symposium on Databases, p. 27–52, 2013.
- BENGIO, Y.; COURVILLE, A.; VINCENT, P. Representation learning: A review and new perspectives. IEEE Transactions on Pattern Analysis and Machine Intelligence, p. 1–30, 2013.
- BOLLEN, J.; MAO, H.; ZENG, X. Twitter mood predicts the stock market. Journal of Computational Science, v. 2, n. 1, p. 1–8, 2011.
- BORTH, D.; JI, R.; CHEN, T.; BREUEL, T.; CHANG, S. Large-scale visual sentiment ontology and detectors using adjective noun pairs. ACM International Conference on Multimedia, p. 223–232, 2013.
- BOSER, B. E.; GUYON, I. M.; VAPNIK, V. N. A Training Algorithm for Optimal Margin Classifiers. Proceedings of the 5th Annual ACM Workshop on Computational Learning Theory, p. 144–152, 1992.
- BOWMAN, S. R.; MANNING, C. D.; POTTS, C. Tree-structured composition in neural networks without tree-structured architectures. arxiv, 2015.
- BRADLEY, M. M.; LANG, P. J. Affective Norms for English Words (ANEW): Instruction Manual and Affective Ratings. Technical Report, 1999.
- BROOKS, M. ; ARAGON, C. R.; KUKSENOK, K.; TORKILDSON, M. K.; PERRY, D.; ROBINSON, J. J.; SCOTT, T. J.; ANICELLO, O.; ZUKOWSKI, A.; HARRIS, P. Statistical affect detection in collaborative chat. CSCW 2013, p. 317, 2013.
- CAMBRIA, E.; SPEER, R.; HAVASI, C.; HUSSAIN, A. SenticNet : A Publicly Available Semantic Resource for Opinion Mining. AAAI Symposium Series - Commonsense Knowledge, p. 14–18, 2010.
- CAMPOS, A. L. N. Modelagem de Processos com BPMN. Brasport, 2013.
- CAVALCANTI, D. C.; PRUDÊNCIO, R. B. C.; PRADHAN, S. S.; SHAH, J. Y. PIETROBON, R. S. Análise de Sentimento em Citações Científicas para Definição de Fatores de Impacto Positivo. Proceedings of the IV International Workshop on Web and Text Intelligence (WTI), p. 1–10, 2012.
- CHANG, C.; LIN, C. LIBSVM : A Library for Support Vector Machines. ACM Transactions on Intelligent Systems and Technology (TIST), v. 2, p. 1–39, 2011.
- CHAVES, M. S.; FREITAS, L. A.; SOUZA, M.; VIEIRA, R. PIRPO: An algorithm to deal with polarity in portuguese online reviews from the accommodation sector. Lecture Notes in Computer Science, p. 296–301, 2012.

CHAWLA, N.; BOWYER, K. SMOTE: Synthetic Minority Over-sampling Technique. *Journal of Artificial Intelligence Research*, v. 16, p. 321–357, 2002.

CHOW, C. On optimum recognition error and reject tradeoff. *IEEE Transactions on Information Theory*, v. 16, n. 1, 1970.

COHEN, J. A coefficient of agreement of nominal scales. *Educational and Psychological Measurement*, v. 20, n. 1, p. 37–46, 1960.

CONRADO, M. DA S. O efeito do uso de diferentes formas de extração de termos na compreensibilidade e representatividade dos termos em coleções textuais na língua portuguesa. Tese, 2009.

CUONG, N. V.; LINH, N. T. T.; THUY, H. Q.; HIEU, P. X. A Maximum Entropy Model for Text Classification. *Proceedings of International Conference on Internet Information Retrieval 2006*, p. 143–149, 2006.

DAMASIO, A. R. Descartes' error: Emotion, reason and the human brain. p. 314, 1994.

DAMASIO, A. R. Ao encontro de Espinosa: as emoções sociais e a neurologia do sentir. 2003.

DARWIN, C. *The Expression of the Emotions in Man and Animals*. 1872.

DAVE, K.; LAWRENCE, S.; PENNOCK, D. M. Mining the peanut gallery: Opinion extraction and semantic classification of product reviews. *Proceedings of the 12th international conference on World Wide Web*, p. 519–528, 2003.

DAVIDSON, R. J. Affective neuroscience and psychophysiology: Toward a synthesis. *Psychophysiology*, v. 40, n. 5, p. 655–665, 2003.

DE VRIES, A. P.; MAMOULIS, N.; NES, N.; KERSTEN, M. Efficient k-NN search on vertically decomposed data. *Proceedings of the 2002 ACM SIGMOD international conference on Management of data - SIGMOD '02*, p. 322, 2002.

DENIL, M.; TRAPPENBERG, T. Overlap versus imbalance. *Lecture Notes in Computer Science*, p. 220–231, 2010.

DEVITT, A.; AHMAD, K. Sentiment polarity identification in financial news: A cohesion-based approach. *Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics*, v. 45, n. 1, p. 984, 2007.

DING, X.; LIU, B.; YU, P. S. A holistic lexicon-based approach to opinion mining. *Proceedings of the international conference on Web search and web data mining - WSDM '08*, p. 231, 2008.

- DODDS, P. S.; DANFORTH, C. M. Measuring the happiness of large-scale written expression: Songs, blogs, and presidents. *Journal of Happiness Studies*, v. 11, n. 4, p. 441–456, 2009.
- EKMAN, P. An argument for basic emotions. *Cognition & Emotion*, v. 6, n. 3, p. 169–200, 1992.
- EKMAN, P. Facial expression and emotion. *The American psychologist*, v. 48, n. 4, p. 384–392, 1993.
- EKMAN, P.; FRIESEN, W. *Pictures of Facial Affect*. Consulting Psychologists Press, 1976.
- EL AYADI, M.; KAMEL, M. S.; KARRAY, F. Survey on speech emotion recognition: Features, classification schemes, and databases. *Pattern Recognition*, v. 44, n. 3, p. 572–587, 2011.
- EL-MANZALAWY, Y.; HONAVAR, V. WLSVM: Integrating LibSVM into Weka Environment, 2005. Disponível em: <<http://www.cs.iastate.edu/~yasser/wlsvm>>
- GAMMA;E.; HELM, R.; JOHNSON, R.; VLISSIDES, J.; BOOCH, G. *Design Patterns Elements of Reusable Object-Oriented Software*. Addison-Wesley Professional, 1994.
- ESTABROOKS, A.; JO, T.; JAPKOWICZ, N. A multiple resampling method for learning from imbalanced data sets. *Computational Intelligence*, v. 20, n. 1, p. 18–36, 2004.
- ESULI, A.; SEBASTIANI, F. SENTIWORDNET: A Publicly Available Lexical Resource for Opinion Mining. *Proceedings of the 5th Conference on Language Resources and Evaluation*, p. 417–422, 2006.
- EUGENIO, B. DI; GLASS, M. The Kappa Statistic: A Second Look. *Computational Linguistics*, v. 30, n. 1, p. 95–101, 2004.
- EVANGELISTA, T. R.; PADILHA, T. P. P. Monitoramento de Posts Sobre Empresas de E-Commerce em Redes Sociais Utilizando Análise de Sentimentos. 2014.
- FACELI, K.; LORENA, A. C.; GAMA, J.; CARVALHO, A. C. P. L. F. *Inteligência Artificial: Uma Abordagem de Aprendizado de Máquina*. Livros Técnicos e Científicos, 2011.
- FEHR, B.; RUSSELL, J. A. Concept of emotion viewed from a prototype perspective. *Journal of Experimental Psychology: General*, v. 113, n. 3, p. 464–486, 1984.
- FELDMAN, R.; SANGER, J. *The Text Mining Handbook: Advanced Approaches in Analyzing Unstructured Data*. v. 34, p. 410, 2007.
- FELLOUS, J. M. From Human Emotions to Robot Emotions. 2004 AAAI Spring Symposium, *Architectures for Modeling Emotion: Cross-Disciplinary Foundations*, v. Technical, p. 37, 2004.

FERNANDEZ, R. A computational model for the automatic recognition of affect in speech. Thesis, 2004.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. *Ciência da Informação*, v. 35, n. 1, p. 25–30, 2006.

FERREIRA, A. B. DE H. *Dicionário Aurélio da Língua Portuguesa*. 2010.

FREITAS, C. Sobre a construção de um léxico da afetividade para o processamento computacional do português. *Revista Brasileira de Linguística Aplicada*, v. 13, n. 4, p. 1031–1059, 2013.

FREITAS, C.; MOTTA, E.; MILIDIÚ, R. L.; CÉSAR, J. Sparkling Vampire... lol! Annotating Opinions in a Book Review Corpus. *New language technologies and linguistic research: a two-way road*, p. 128–146, 2014.

FREITAS, L. A.; VIEIRA, R. Ontology based feature level opinion mining for portuguese reviews. *Proceedings of the 22nd international conference on World Wide Web companion*, p. 367–370, 2013a.

FREITAS, L.; VIEIRA, R. Comparison Portuguese Opinion Lexicons in Feature-Based Sentiment Analysis. *Conference on Intelligent Text Processing and Computational Linguistics (CICLing 2013)*, v. 4, n. 1, p. 147–158, 2013b.

FRIJDA, N. H. The emotions. *The Emotions*, p. 544, 1986.

FUMERA, G.; ROLI, F.; GIACINTO, G. Reject option with multiple thresholds. *Pattern Recognition*, v. 33, n. 12, p. 2099–2101, 2000.

GARCIA, V.; SANCHEZ, J.; MOLLINEDA, R. An empirical study of the behavior of classifiers on imbalanced and overlapped data sets. *Progress in Pattern Recognition, Image Analysis and Applications, Proceedings*, v. 4756, p. 397–406, 2007.

GHAZI, D.; INKPEN, D.; SZPAKOWICZ, S. Hierarchical versus flat classification of emotions in text. *Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text*, p. 140–146, 2010.

GHAZI, D.; INKPEN, D.; SZPAKOWICZ, S. Prior and contextual emotion of words in sentential context. *Computer Speech & Language*, v. 28, n. 1, p. 76–92, jan. 2014.

GO, A.; BHAYANI, R.; HUANG, L. Twitter Sentiment Classification using Distant Supervision. Technical report, Stanford, v. 150, n. 12, p. 1–6, 2009.

GODBOLE, N.; SRINIVASIAH, M. Large-scale sentiment analysis for news and blogs. *Conference on Weblogs and Social Media (ICWSM 2007)*, p. 219–222, 2007.

GOMES, H.; NETO, M. DE C.; HENRIQUES, R. Text Mining: Análise de Sentimentos na classificação de notícias. *Information Systems and Technologies (CISTI)*, p. 1–6, 2013.

GONÇALVES, P.; ARAÚJO, M.; BENEVENUTO, F.; CHA, M. Comparing and combining sentiment analysis methods. Proceedings of the first ACM conference on Online social networks - COSN '13, p. 27–38, 2013.

GONÇALVES, P.; BENEVENUTO, F.; CHA, M. PANAS-t: A Psychometric Scale for Measuring Sentiments on Twitter. p. 10, 2013.

GONZALEZ, M.; TOSCANI, D.; ROSA, L.; DORNELES, R.; LIMA, V. L. S. Normalização de itens lexicais baseada em sufixos. Workshop em tecnologia da informação e da linguagem humana, 2003.

GRAVES, A.; MOHAMED, A.; HINTON, G. Speech Recognition With Deep Recurrent Neural Networks. ICASSP, n. 3, p. 6645-6649, 2013.

GRAY, J. A. Neuropsychology of anxiety. 1982.

GROOT, R. DE. Data Mining for Tweet Sentiment Classification. Thesis, 2012.

GROSSMAN, D. A.; FRIEDER, O. Information Retrieval Algoritmos e heurística. 2004.

GUO, G; WANG, H.; BELL, D.; BI, Y.; GREER, K. Using kNN model for automatic text categorization. Soft Computing, v. 10, n. 5, p. 423-430, 2005.

HABERNAL, I.; PTÁČEK, T.; STEINBERGER, J. Supervised sentiment analysis in Czech social media. Information Processing and Management, v. 50, n. 5, p. 693–707, 2014.

HADDI, E.; LIU, X.; SHI, Y. The Role of Text Pre-processing in Sentiment Analysis. Procedia Computer Science, v. 17, p. 26–32, 2013.

HALL, M.; NATIONAL, H.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. The WEKA Data Mining Software: An Update. SIGKDD Explorations, v. 11, n. 1, p. 10–18, 2009.

HAN, E. S.; KARYPIS, G.; KUMAR, V. Text Categorization Using Weight Adjusted k-Nearest Neighbor Classification. 5th Pacific-Asia Conference on Knowledge Discovery and Data Mining (PAKDD), p. 53–65, 2001.

HANGAL, S.; LAM, M. S. Sentiment Analysis on Personal Email Archives. Proceedings of the 24th annual ACM symposium on User interface software and technology, 2011.

HARMAN, D. How Effective Is Suffixing? Journal of the American Society for Information Science, v. 42, n. 1, p. 7–15, 1991.

HAYKIN, S. Neural Networks: A Comprehensive Foundation. Prentice Hall, 1999.

HEARST, M. A.; SCHÖLKOPF, B.; DUMAIS, S.; OSUNA, E.; PLATT, J. Trends and Controversies - Support Vector Machines. IEEE Intelligent Systems, v. 13, n. 4, p. 18–28, 1998.

HENDY, N. A.; FARAG, H. Emotion Recognition Using Neural Network: A Comparative Study. World Academy of Science, Engineering and Technology, 2013.

HOLZMAN, L. E.; POTTENGER, W. M. Classification of emotions in internet chat: An application of machine learning using speech phonemes. Technical Report LU-CSE-03-002, v. 27, 2003.

HSU, C.; CHANG, C.; LIN, C. A Practical Guide to Support Vector Classification. v. 1, n. 1, p. 1–16, 2010.

HU, M.; LIU, B. Mining opinion features in customer reviews. American Association for Artificial Intelligence, 2004a.

HU, M.; LIU, B. Mining and summarizing customer reviews. Proceedings of the 2004 ACM SIGKDD international conference on Knowledge discovery and data mining KDD 04, v. 04, p. 168, 2004b.

HU, X.; DOWNIE, J. S.; EHMANN, A. F. Lyric text mining in music mood classification. American Music, v. 183, p. 411–416, 2009.

IZARD, C. E. The face of emotion. p. 468, 1971.

JAMES, W. What is an Emotion? Mind, v. 9, n. 34, p. 188–205, 1884.

JIANG, S.; PANG, G.; WU, M.; KUANG, L. An improved K-nearest-neighbor algorithm for text categorization. Expert Systems with Applications, v. 39, n. 1, p. 1503–1509, 2012.

JO, T. NTC (Neural Text Categorizer): Neural Network for Text Categorization. International Journal of Information Studies, v. 2, n. 2, p. 83–96, 2010.

JOACHIMS, T. Text categorization with support vector machines: Learning with many relevant features. Machine Learning: ECML-98, v. 1398, n. 2, p. 137 – 142, 1998.

JONES, K. S. A Statistical Interpretation of Term Specificity And its Application in Retrieval. Journal of Documentation, v. 28, n. 1, p. 11–21, 1972.

JURAFSKY, D.; MARTIN, J. H. Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics, and Speech Recognition. Speech and Language Processing An Introduction to Natural Language Processing Computational Linguistics and Speech Recognition, v. 21, p. 0–934, 2000.

KAGAN, J. Behavioral Inhibition as a temperamental category. In: Handbook of Affective Sciences. new York: Oxford University Press, 2003. p. 320–331.

KAHN, J. P.; VAYENA, E.; MASTROIANNI, A. C. Opinion: Learning as we go: Lessons from the publication of Facebook’s social-computing research. Proceedings of the National Academy of Sciences, v. 111, n. 38, p. 13677–13679, 2014.

KAJI, N.; KITSUREGAWA, M. Automatic Construction of Polarity-tagged Corpus from HTML Documents. n. July, p. 452–459, 2006.

KAJI, N.; KITSUREGAWA, M. Building Lexicon for Sentiment Analysis from Massive Collection of HTML Documents. Proceedings of the 2007 Joint Conference on Empirical Methods in Natural Language Processing and Computational Natural Language Learning, v. 43, p. 1075–1083, 2007.

KANG, H.; YOO, S. J.; HAN, D. Senti-lexicon and improved Naïve Bayes algorithms for sentiment analysis of restaurant reviews. Expert Systems with Applications, v. 39, n. 5, p. 6000–6010, 2012.

KIM, S.; REY, M.; HOVY, E. Determining the Sentiment of Opinions. 2004.

KIM, S. K. S.; HAN, K. H. K.; RIM, H. R. H.; MYAENG, S. H. M. S. H. Some Effective Techniques for Naive Bayes Text Classification. IEEE Transactions on Knowledge and Data Engineering, v. 18, n. 11, p. 1457–1466, 2006.

KIM, Y. E.; Schmidt, E. M.; Migneco, R.; Morton, B. G.; Richardson, P.; Scott, J.; Speck, J.;

TURNBULL, D. Music Emotion Recognition: a State of the Art Review. Information Retrieval, n. Ismir, p. 255–266, 2010.

KIRITCHENKO, S.; ZHU, X.; MOHAMMAD, S. M. Sentiment Analysis of Short Informal Texts. Journal of Artificial Intelligence Research, v. 50, p. 1–15, 2014.

KOHAVI, R.; PROVOST, F. Glossary of Terms. Machine Learning, v. 30, n. 2/3, p. 271–274, 1998.

KRIPPENDORFF, K. H. Content Analysis: An Introduction to Its Methodology. Education, v. 79, p. 440, 1980.

KRISTENSEN, C. H.; GOMES, C. F. A.; JUSTO, A. R.; VIEIRA, K. Normas brasileiras para o Affective Norms for English Words. Trends Psychiatry Psychother, v. 33, p. 135–146, 2011.

KUBAT, M., MATWIN, S. Addressing the curse of imbalanced training sets: one-sided selection. Proceedings of the Fourteenth International Conference on Machine Learning, p. 179–186, 1997.

LANDAUER, T. K.; FOLTZ, P. W.; LAHAM, D. An introduction to latent semantic analysis. Discourse Processes, v. 25, p. 259–284, jan. 1998.

LANG, P. J. The Emotion Probe. American Psychologist Association, v. 50, n. 5, p. 372–385, 1995.

LAWRENCE, S; BURNS, I; BACK, A.; TSOI, A. C.; GILES, C. L. Neural network classification and prior class probabilities. Neural Networks, p. 299–313, 1998.

- LAZARUS, R. S. *Emotion e adaptation*. Oxford University Press, 1991.
- LEE, H.; BHD, C. EPULZE S. Chinese Sentiment Analysis Using Maximum Entropy. Proceedings of the Workshop on Sentiment Analysis where AI meets Psychology (SAAIP), IJCNLP 2011, p. 89–93, 2011.
- LEWIS, D. D. A Comparison of Two Learning Algorithms for Text Categorization. Third Annual Symposium on Document Analysis and Information Retrieval, p. 81–93, 1994.
- LI, T.; OGIHARA, M. Detecting emotion in music. Proceedings of the International Symposium on Music Information Retrieval, p. 239–240, 2003.
- LI, T.; OGIHARA, M.; TZANETAKIS, G. *Music Data Mining*. CRC Press, p. 384, 2011.
- LIBRALON, G. L. Modelagem computacional para reconhecimento de emoções baseada na análise facial. Tese, 2014.
- LIMA, A. C. E. S.; DE CASTRO, L. N. Automatic sentiment analysis of Twitter messages. Proceedings of the 2012 4th International Conference on Computational Aspects of Social Networks, p. 52–57, 2012.
- LIN, H. T.; LIN, C. J.; WENG, R. C. A note on Platt’s probabilistic outputs for support vector machines. *Machine Learning*, v. 68, n. 3, p. 267–276, 2007.
- LIU, B. *Sentiment Analysis and Opinion Mining*. Cambridge University Press, 2012.
- LIU, B. *Opinions, Sentiment, and Emotion in Text*. Cambridge University Press, p. 381, 2015.
- LIU, H.; LIEBERMAN, H.; SELKER, T. A Model of Textual Affect Sensing using Real-World Knowledge. *Cognition*, p. 125–132, 2003.
- LÓPEZ, R. E.; AVANÇO, L. V.; FILHO, P. P. B.; BOKAN, A. Y.; CARDOSO, P. C. F.; DIAS, M. S.; NOBREGA, F. A. A.; CABEZUDO, M. A. S.; SOUZA, J. W. C.; ZACARIAS, A. C. I.; SENO, E. M. R.; FELIPPO, A. D.; PARDO, T. A. S. A Qualitative Analysis of a Corpus of Opinion Summaries based on Aspects. p. 62–71, 2015.
- LORENA, A. C. *Investigação de estratégias para a geração de máquinas de vetores de suporte multilclasses*. 2006.
- LOVINS, J. B. Development of a stemming algorithm. *Mechanical Translation and Computational Linguistics*, v. 11, n. June, p. 22–31, 1968.
- MA, G.; LUO, J. Is a Picture Worth 1000 Votes? Analyzing the Sentiment of Election Related Social Photos. 2013 IEEE International Conference on Multimedia and Expo (ICME), p. 1–6, 2013.

MACHAJDIK, J.; HANBURY, A. Affective image classification using features inspired by psychology and art theory. Proceedings of the international conference on Multimedia MM 10, p. 83–92, 2010.

MALHEIROS, Y. Emotte: Uma Ferramenta De Análise de Sentimentos para o Twitter. XX Brazilian Symposium on Multimedia and the Web - Webmedia 2014, 2014.

MANNING, C. D.; RAGHAVAN, P.; SCHÜTZE, H. Introduction to Information Retrieval. Cambridge University Press, v. 1, p. 496, 2008.

MANNING, C.; KLEIN, D. Optimization, maxent models, and conditional estimation without magic. Proceeding NAACL-Tutorials '03 Proceedings of the 2003 Conference of the North American Chapter of the Association for Computational Linguistics on Human Language Technology: Tutorials, v. 5, p. 8, 2003.

MARINI, A.; KOERICH, A. L. Estratégias de Rejeição para Problemas Multiclasses. Conferencia Latinoamericana de Informática (CLEI 2008), p. 162–171, 2008.

MARTINAZZO, B. Um Método de Identificação de Emoções em Textos Curtos para o Português do Brasil. biblioteca.pucpr.br, 2010.

MARTINAZZO, B.; DOSCIATTI, M. M.; PARAISO, E. C. Identifying Emotions in Short Texts for Brazilian Portuguese. IV International Workshop on Web and Text Intelligence (WTI 2012), 2011.

MARTINAZZO, B.; PARAISO, E. C. Identificação de Emoções em Notícias Curtas. Conferencia Latinoamericana de Informática (CLEI 2010), 2010.

MCCALLUM, A.; NIGAM, K. A Comparison of Event Models for Naive Bayes Text Classification. AAAI/ICML-98 Workshop on Learning for Text Categorization, p. 41–48, 1998.

MCDUGALL, W. An Introduction to Social Psychology. 1926.

MEDHAT, W.; HASSAN, A.; KORASHY, H. Sentiment analysis algorithms and applications: A survey. Ain Shams Engineering Journal, v. 5, n. 4, p. 1093–1113, 2014.

MEHRABIAN, A. Framework for a comprehensive description and measurement of emotional states. Genetic, social, and general psychology monographs, v. 121, n. 3, p. 339–361, 1995.

MICHAEL S. GAZZANIGA; TODD F. HEATHERTON. Psicológica: Mente, Cérebro e Comportamento. 2005.

MICHIE, E. D.; SPIEGELHALTER, D. J.; TAYLOR, C. C. Machine Learning , Neural and Statistical Classification. Technometrics, v. 37, n. 4, p. 459, 1994.

MLADENIĆ, D.; GROBELNIK, M. Feature selection for unbalanced class distribution and Naive Bayes. *Proceedings of the Sixteenth International Conference on Machine Learning*, p. 258–267, 1999.

MLADENIĆ, D.; GROBELNIK, M. Feature selection on hierarchy of web documents. *Decision Support Systems*, v. 35, n. 1, p. 45–87, 2003.

MOHAMMAD, S. Portable Features for Classifying Emotional Text. *Proceedings of the 2012 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, p. 587–591, 2012a.

MOHAMMAD, S. M. *Sentiment Analysis of Mail and Books*. 2011.

MOHAMMAD, S. M. From once upon a time to happily ever after: Tracking emotions in mail and books. *Decision Support Systems*, v. 53, n. 4, p. 730–741, 2012b.

MOHAMMAD, S.; YANG, T. Tracking Sentiment in Mail: How Genders Differ on Emotional Axes. In *Proceedings of the ACL 2011 Workshop on Computational Approaches to Subjectivity and Sentiment Analysis (WASSA)*, p. 70–79, 2011.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre Aprendizado de Máquina. In: *Sistemas inteligentes: fundamentos e aplicações*. [s.l.] Editora Manole Ltda, 2003. p. 89–114.

MORAES, R.; VALIATI, J. F.; GAVIÃO NETO, W. P. Document-level sentiment classification: An empirical comparison between SVM and ANN. *Expert Systems with Applications*, v. 40, n. 2, p. 621–633, 2013.

MOWRER, O. H. *Learning theory and behavior*. 1960.

MÜLLER, K. R.; MIKA, S.; RÄTSCH, G.; TSUDA, K.; SCHÖLKOPF, B. An introduction to kernel-based learning algorithms. *IEEE Transactions on Neural Networks*, v. 12, n. 2, p. 181–201, 2001.

MUNEZERO, M.; MONTERO, C. S.; SUTINEN, E.; PAJUNEN, J. Are they different? affect, feeling, emotion, sentiment, and opinion detection in text. *IEEE Transactions on Affective Computing*, v. 5, n. 2, p. 101–111, 2014.

NARAYANAN, V.; ARORA, I.; BHATIA, A. Fast and accurate sentiment classification using an enhanced Naive Bayes model. *International Data Engineering and Automated Learning, Lecture Notes in Computer Science*, v. 8206, p. 194–201, 2013.

NASCIMENTO, P.; AGUAS, R.; KONG, X.; OSIEK, B.; SOUZA, J. Análise de sentimento de tweets com foco em notícias. *Análise de sentimento de tweets com foco em notícias*, 2012.

NASUKAWA, T. Sentiment Analysis: Capturing Favorability Using Natural Language Processing Definition of Sentiment Expressions. *2nd international conference on Knowledge capture*, p. 70–77, 2003.

- NICOLOSI, N. Feature Selection Methods for Text Classification. p. 1–11, 2008.
- NIGAM, K.; LAFFERTY, J.; MCCALLUM, A. Using Maximum Entropy for Text Classification. IJCAI-99 Workshop on Machine Learning for Information Filtering, 1999.
- NIJHOLT, A. Humor and Embodied Conversational Agents. CTIT Technical Report series No. 03-03, 2003.
- O'KEEFE, T.; KOPRINSKA, I. Feature selection and weighting methods in sentiment analysis. Australasian Document Computing Symposium, p. 67, 2009.
- OATLEY, K.; JOHNSON-LAIRD, P. N. Towards a Cognitive Theory of Emotions. *Cognition & Emotion*, v. 1, n. 1, p. 29–50, 1987.
- OMARY, Z.; MTENZI, F. Machine Learning Approach to Identifying the Dataset Threshold for the Performance Estimators in Supervised Learning. v. 3, n. 3, p. 314–325, 2010.
- ORENGO, V. M.; HUYCK, C. A stemming algorithm for the portuguese language. Proceedings Eighth Symposium on String Processing and Information Retrieval, 2001.
- ORTONY, A. On making believable emotional agents believable. *Emotions in humans and artifacts*, p. 189, 2002.
- ORTONY, A.; CLORE, G. L.; COLLINS, A. The cognitive structure of emotions. New York: Cambridge University Press, 1988.
- ORTONY, A.; NORMAN, D.; REVELLE, W. Affect and proto-affect in effective functioning. In: *Who needs emotions? The brain meets the robot.* [s.l.] Oxford University Press, 2004.
- ORTONY, A.; TURNER, T. J. What's basic about basic emotions? *Psychological review*, v. 97, n. 3, p. 315–331, 1990.
- PANG, B.; LEE, L. Opinion Mining and Sentiment Analysis. *Foundations and Trends in Information Retrieval*, v. 2, n. 1–2, p. 1–135, 2008.
- PANG, B.; LEE, L.; VAITHYANATHAN, S. Thumbs up?: sentiment classification using machine learning techniques. *Conference on Empirical methods in natural language processing - EMNLP '02*, v. 10, p. 79–86, 2002.
- PANKSEPP, J. Toward a general psychobiological theory of emotions. *Behavioral and Brain Sciences*, v. 5, n. 03, p. 407, 1982.
- PANKSEPP, J. *Affective Neuroscience: The Foundations of Human and Animal Emotions.* p. 480, 1998.

- PEDERSEN, J. O.; YANG, Y. A Comparative Study on Feature Selection in Text Categorization. Proceedings of the Fourteenth International Conference on Machine Learning, p. 412–420, 1997.
- PESTIAN, J. P.; MATYKIEWICZ, P.; GRUPP-PHELAN, J.; LAVANIER, S. A.; COMBS, J.; KOWATCH, R. Using natural language processing to classify suicide notes. BioNLP 2008: Current Trends in Biomedical Natural Language Processing, p. 1091, 2008.
- PICARD, R. W. Affective Computing. MIT Media Laboratory Perceptual Computing Section, n. 321, 1995.
- PIERRE-YVES, O. The production and recognition of emotions in speech: Features and algorithms. International Journal of Human Computer Studies, v. 59, n. 1-2, p. 157–183, 2003.
- PITRELLI, J. F.; PERRONE, M. P. Confidence modeling for verification post-processing for handwriting recognition. International Workshop on Frontiers in Handwriting Recognition, IWFHR, p. 30–35, 2002.
- PLATT, J. Probabilistic outputs for support vector machines and comparisons to regularized likelihood methods. Advances in large margin classifiers, v. 10, n. 3, p. 61–74, 1999.
- PLUTCHIK, R. A general psychoevolutionary theory of emotion. Emotion: Theory, Research, and Experience, v. 1, p. 3–33, 1980.
- PORTER, M. F. An algorithm for suffix stripping. Readings in information retrieval, v. 14, n. 3, p. 130–137, 1980.
- PRATI, R. C.; BATISTA, G. E.; MONARD, M. C. Class imbalances versus class overlapping: an analysis of a learning system behavior. MICA I 2004: Advances in Artificial Intelligence, p. 312–321, 2004.
- QUINLAN, J. R. C4.5: Programs for Machine Learning. Morgan Kaufmann, v. 1, n. 3, p. 302, 1993.
- RADOVANOVIĆ, M.; IVANOVIĆ, M. Text Mining: Approaches and Applications. Novi sad journal of mathematics (NSJOM), v. 38, n. 3, p. 227–234, 2008.
- RAMASUNDARAM, S.; VICTOR, S. P. Text Categorization by Backpropagation Network. International Journal of Computer Applications, v. 8, n. 6, 2010.
- RANGEL, F.; ROSSO, P. On the Identification of Emotions and Authors' Gender in Facebook Comments on the Basis of their Writing Style. CEUR Workshop Proceedings, 2013.
- READ, J. Using Emoticons to reduce Dependency in Machine Learning Techniques for Sentiment Classification. ACL Student Research workshop, n. June, p. 43–48, 2005.

- ROLLS, E. T. *The Brain and Emotion*. 1998.
- ROMAN, N. T. *Emoção e a Sumarização Automática de Diálogos*. Tese, 2007.
- ROSEMAN, I. J. Appraisal Determinants of Emotions: Constructing a More Accurate and Comprehensive Theory. *Cognition and Emotion*, v. 10, n. 3, p. 241–278, 1996.
- RUIZ, M. E.; SRINIVASAN, P. Automatic Text Categorization Using Neural Networks. *Proceedings of the 8th ASIS/SIGCR Workshop on Classification Research*, p. 59–72, 1997.
- RUSSELL, J. A. A circumplex model of affect. *Journal of Personality and Social Psychology*, v. 39, n. 6, p. 1161–1178, 1980.
- SALTON, G.; BUCKLEY, C. Term-weighting approaches in automatic text retrieval. *Information Processing & Management*, v. 24, n. 5, p. 513–523, 1988.
- SCHERER, K. R.; SCHORR, A.; JOHNSTONE, T. *Appraisal Processes in Emotion: Theory, Methods, Research*. EUA: Oxford University Press, 2001.
- SCHRODER, M. *Speech and Emotion Research An Overview of Research Frameworks and a Dimensional Approach to Emotional Speech Synthesis*. 2004.
- SEBASTIANI, F. Machine Learning in Automated Text Categorization. *ACM Computing Surveys*, v. 34, n. 1, p. 1–47, 2002.
- SEBE, N.; LEW, M.; HUANG, T. The state-of-the-art in human-computer interaction. *Computer Vision in Human-Computer Interaction*, v. 2, p. 1–6, 2004.
- SEGARAN, T. *Programming Collective Intelligence: Building Smart Web 2.0 Applications*. Book, p. 334, 2007.
- SEOL, Y.-S.; KIM, D.-J.; KIM, H.-W. Emotion Recognition from Text Using Knowledge-based ANN. *The 23rd International Technical on Circuits/Systems, computers and Communications*, 2008.
- SEVERYN, A.; MOSCHITTI, A. Twitter Sentiment Analysis with Deep Convolutional Neural Networks. *SIGIR 2015 Proceedings*, 2015.
- SHALLOWAY, A.; TROTT, J. R. *DESIGN PATTERNS EXPLAINED*. [s.l: s.n.].
- SHARMA, A.; DEY, S. A comparative study of feature selection and machine learning techniques for sentiment analysis. *Proceedings of the 2012 ACM Research in Applied Computation Symposium (RACS 2012)*, p. 1–7, 2012.
- SIERSDORFER, S.; HARE, J.; MINACK, E.; DENG, F. Analyzing and Predicting Sentiment of Images on the Social Web. *Proceedings of the 18th ACM international conference on Multimedia*, 2010.

SILVA, M. J.; CARVALHO, P.; SARMENTO, L. Building a sentiment lexicon for social judgement mining. *Lecture Notes in Computer Science*, v. 7243 LNAI, p. 218–228, 2012.

SINCLAIR, J. *Corpus and Text - Basic Principles*. *Developing Linguistic Corpora: a Guide to Good Practice*, p. 1–16, 2004.

SMITH, C. A.; LAZARUS, R. S. Appraisal components, core relational themes, and the emotions. *Cognition & Emotion*, v. 7, n. 3-4, p. 233–269, 1993.

SOCHER, R.; PERELYGIN, A.; WU, J.; CHUANG, J.; MANNING, C. D.; NG, A.; POTTS, C. Recursive Deep Models for Semantic Compositionality Over a Sentiment Treebank. *Proceedings of the 2013 Conference on Empirical Methods in Natural Language Processing*, p. 1631–1642, 2013.

SONG, G.; YE, Y.; DU, X.; HUANG, X.; BIE, S. Short Text Classification: A Survey. *Journal of Multimedia*, v. 9, n. 5, p. 635–643, 2014.

SOUZA, M.; VIEIRA, R.; CHISHMAN, R.; ALVES, I. M. Construction of a Portuguese Opinion Lexicon from multiple resources. *Proceedings of the 8th Brazilian Symposium in Information and Human Language Technology*, p. 59–66, 2011.

SOUZA, M.; VIEIRA, R. Sentiment Analysis on Twitter Data for Portuguese Language. *Computational Processing of the Portuguese Language*, v. 7243, p. 241–247, 2012.

SPASIC, I.; BURNAP, P.; GREENWOOD, M.; ARRIBAS-AYLLON, M. A Naive Bayes approach to classifying topics in suicide notes. *Biomed Inform Insights*, v. 5, p. 87–97, 2012.

STONE, P. J.; DUNPHY, D. C.; SMITH, M. S.; OGILVIE, D. M. *The General Inquirer: A Computer Approach to Content Analysis*. *American Sociological Review*, 1966.

STRAPPARAVA, C.; MIHALCEA, R. Semeval-2007 task 14: Affective text. *Proc. of SemEval-2007*, n. June, p. 70–74, 2007.

STRAPPARAVA, C.; MIHALCEA, R. Learning to identify emotions in text. *Proceedings of the 2008 ACM symposium on Applied computing - SAC '08*, p. 1556, 2008.

STRAPPARAVA, C.; VALITUTTI, A. WordNet-Affect: an affective extension of WordNet. *Proceedings of the 4th International Conference on Language Resources and Evaluation*, p. 1083–1086, 2004.

SU, J.; SHIRAB, J. S.; MATWIN, S. Large Scale Text Classification using Semi-supervised Multinomial Naive Bayes. *Proceedings of the 28th International Conference on Machine Learning (ICML-11)*, p. 97–104, 2011.

SUN, Y.; WONG, A. K. C.; KAMEL, M. S. Classification of Imbalanced Data: A Review. *International Journal of Pattern Recognition and Artificial Intelligence*, v. 23, n. 04, p. 687–719, 2009.

TABOADA, M. BROOKE, J.; TOFILOSKI, M.; VOLL, K.; STEDE, M. Lexicon-Based Methods for Sentiment Analysis. *Computational Linguistics*, v. 37, n. 2, p. 267–307, 2011.

TAN, P.; STEINBACH, M.; KUMAR, V. Introdução ao Data Mining Mineração de Dados. *Ciência Moderna*, 2009.

TANG, D.; WEI, F.; QIN, B.; LIU, T.; ZHOU, M. Coooolll: A Deep Learning System for Twitter Sentiment Classification. *SEMEVAL-2014*, p. 208–212, 2014.

TAUSCZIK, Y. R.; PENNEBAKER, J. W. The Psychological Meaning of Words: LIWC and Computerized Text Analysis Methods. *Journal of Language and Social Psychology*, v. 29, n. 1, p. 24–54, 2010.

THELWALL, M.; BUCKLEY, K.; PALTOGLOU, G. Sentiment strength detection for the social web. *Journal of the American Society for Information Science and Technology*, v. 63, n. 1, p. 163–173, 2012.

THOMAS, B.; A., D. K.; P., V. Synthesized Feature Space for Multiclass Emotion Classification. *First International Conference on Networks & Soft Computing*, p. 188–192, 2014.

TOMKINS, S. S. *Affect Theory. Approaches To Emotion*, p. 163–196, 1984.

TROUSSAS, C. VIRVOU, M.; ESPINOSA, K. J.; LLAGUNO, K. CARO, J. Sentiment analysis of Facebook statuses using Naive Bayes Classifier for language learning. *IISA 2013 - 4th International Conference on Information, Intelligence, Systems and Applications*, p. 198–205, 2013.

TURKMENOGLU, C.; TANTUG, A. C. Sentiment Analysis in Turkish Media. *Workshop on Issues of Sentiment Discovery and Opinion Mining*, 2014.

TURNEY, P. D. Thumbs Up or Thumbs Down? Semantic Orientation Applied to Unsupervised Classification of Reviews. n. July, p. 8, 2002.

UNLUTURK, M. S.; OGUZ, K.; ATAY, C. Emotion Recognition Using Neural Networks. 2010.

VERVERIDIS, D.; KOTROPOULOS, C. Emotional speech recognition: Resources, features, and methods. *Speech Communication*, v. 48, n. 9, p. 1162–1181, 2006.

VIERA, A. F. G.; VIRGIL, J. Uma revisão dos algoritmos de radicalização em língua portuguesa. *Information Research*, v. 12, n. 3, 2007.

VILELA, P. DE C. S. Classificação de sentimento para notícias sobre a Petrobras no mercado financeiro. *Tese*, 2011.

WANG, H.; CAN, D.; KAZEMZADEH, A.; BAR, F.; NARAYANAN, S. A System for Real-time Twitter Sentiment Analysis of 2012 U.S. Presidential Election Cycle. *Proceedings*

of the 50th Annual Meeting of the Association for Computational Linguistics, p. 115–120, 2012.

WANG, Y.; CAN, D.; KAZEMZADEH, A.; BAR, F.; NARAYANAN, S. Unsupervised Sentiment Analysis for Social Media Images. International Joint Conference on Artificial Intelligence, 2015.

WANG, Y.; WANG, Z. O. A fast KNN algorithm for text categorization. Proceedings of the Sixth International Conference on Machine Learning and Cybernetics, ICMLC 2007, v. 6, n. August, p. 3436–3441, 2007.

WATSON, D.; WIESE, D.; VAIDYA, J.; TELLEGEN, A. The two general activation systems of affect: Structural findings, evolutionary considerations, and psychobiological evidence. *Journal of Personality and Social Psychology*, v. 76, n. 5, p. 820–838, 1999.

WATSON, J. B. Behaviorism. 1930.

WEINER, B.; GRAHAM, S. An attributional approach to emotional development. In: *Emotions, cognition, and behavior*. New York: Cambridge University Press, 1984. p. 167–191.

WIEBE, J. Annotating Expressions of Opinions and Emotions in Language. *Computer*, n. 2003, p. 1–54, 2005.

WIEBE, J. M.; BRUCE, R. F.; O'HARA, T. P. Development and use of a gold standard data set for subjectivity classifications. Proceedings of the 37th Annual Meeting of the Association for Computational Linguistics (ACL'99), p. 246–253, 1999.

WIEBE, J.; MIHALCEA, R. Word Sense and Subjectivity. Conference on Computational Linguistics and the 44th annual meeting of the Association for Computational Linguistics, p. 1065–1072, 2006.

WU, B.; ZHONG, E.; HORNER, A.; YANG, Q. Music Emotion Recognition by Multi-label Multi-layer Multi-instance Multi-view Learning. Proceedings of the ACM International Conference on Multimedia, p. 117–126, 2014.

WU, T.; LIN, C.; WENG, R. C. Probability Estimates for Multi-class Classification by Pairwise Coupling. *Journal of Machine Learning*, v. 5, p. 975–1005, 2004.

WU, Y. Disambiguating Dynamic Sentiment Ambiguous Adjectives. n. August, p. 1191–1199, 2010.

YANG, N.; MURALEEDHARAN, R.; KOHL, J.; DEMIRKOL, I.; HEINZELMAN, W. Speech-based emotion classification using multiclass SVM with hybrid kernel and thresholding fusion. 2012 IEEE Workshop on Spoken Language Technology, SLT 2012 - Proceedings, p. 455–460, 2012.

YANG, Y.; YANG, Y. An Evaluation of Statistical Approaches to Text Categorization. *Information Retrieval*, v. 1, p. 69–90, 1999.

YANG, Y.-H.; CHEN, H. H. Machine Recognition of Music Emotion: A Review. *ACM Transactions on Intelligent Systems and Technology*, v. 3, n. 3, p. 1–30, 2012.

YIN, L.; SAVIO, D. Learned Text Categorization by Backpropagation Neural Network. Hong Kong University Thesis, n. August, 1996.

YOU, Q.; LUO, J.; JIN, H.; YANG, J. Robust Image Sentiment Analysis using Progressively Trained and Domain Transferred Deep Networks. *The Twenty-Ninth AAAI Conference ...*, 2015.

YOU, Q.; LUO, J. Towards social imagematics: sentiment analysis in social multimedia. *Proceedings of the Thirteenth International Workshop on Multimedia Data Mining*, n. August, 2013.

YUAN, F.; YANG, L.; YU, G. A New Density-Based Method for Reducing the Amount of Training Data in k-NN Text Classification. *International Conference on Machine Learning and Cybernetics*, 2007.

YUAN, J.; MCDONOUGH, S.; YOU, Q.; LUO, J. Sentribute: Image Sentiment Analysis from a Mid-level Perspective. *Proceedings of the Second International Workshop on Issues of Sentiment Discovery and Opinion Mining*, 2013.

ZHANG, L.; GHOSH, R.; DEKHIL, M.; HSU, M.; LIU, B. Combining lexiconbased and learning-based methods for twitter sentiment analysis. *HP Laboratories, Technical ...*, 2011.

ZHANG, L.; LIU, B. Identifying Noun Product Features that Imply Opinions. *Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics Human Language Technologies*, n. 2008, p. 575–580, 2011.

ZHANG, L.; YAO, T. Filtering Junk Mail with A Maximum Entropy Model. *Iccpol*, p. 446–453, 2003.

ZHU, S.; JI, X.; XU, W.; GONG, Y. Multi-labelled classification using maximum entropy method. *Proceedings of the 28th annual international*, p. 274–281, 2005.

Apêndices

APÊNDICE 1 - Orientações aos Rotuladores

ORIENTAÇÕES AOS ROTULADORES

A atividade de rotulação de textos significa atribuir o rótulo de uma determinada categoria a um determinado texto. No caso desta pesquisa, que trata da identificação das emoções em textos escritos no idioma Português do Brasil, existem sete rótulos possíveis, sendo eles: **alegria**, **tristeza**, **raiva**, **medo**, **desgosto**, **surpresa** e **neutro**, que poderão ser atribuídos aos textos. A cada texto do corpus poderá ser atribuído apenas **UM** rótulo, ou seja, aquele que representa a emoção predominante no texto (ou nenhuma emoção, no caso do rótulo **neutro**). Após a escolha do rótulo, o rotulador deverá atribuir a intensidade da emoção (ou neutralidade) presente no texto. Essa intensidade pode ser **alta**, **média** ou **baixa**.

Na Figura 1 é apresentada a interface do software construído especificamente para tarefa de rotulação dos textos.

O software faz o controle da rotulação gerenciando todo o processo de forma que os textos sejam rotulados **duas** vezes e a cada vez por um rotulador diferente. Os rotuladores cadastrados receberão **20** textos a cada vez para rotular. O rotulador deve indicar a emoção predominante e a sua intensidade em cada texto. É opcional a escolha de uma emoção e intensidade secundários para o texto. Foi disponibilizado essa opção para aqueles textos que possuem mais de uma emoção predominante, mesmo assim é opcional o preenchimento desta. O corpus utilizado nesta pesquisa foi construído com textos extraídos de notícias do site www.globo.com

EmoçõesBR @ Rotulação

Show entries Search:

| # | Texto | Rótulo |
|---|---|--------|
| 1 | Britânica pega 14 semanas de prisão por matar gato no micro-ondas. Mulher de 23 anos sofre de problemas psicológicos. Ela admitiu ato após gato ter comido um peixe. | |
| Emoção primária: <input type="button" value="Alegria"/> <input type="button" value="Desgosto"/> <input type="button" value="Medo"/> <input type="button" value="Raiva"/> <input type="button" value="Surpresa"/> <input type="button" value="Tristeza"/> <input type="button" value="Neutro"/> | | |
| Intensidade primária: <input type="button" value="Baixa"/> <input type="button" value="Media"/> <input type="button" value="Alta"/> | | |
| Emoção secundária (Opcional): <input type="button" value="Alegria"/> <input type="button" value="Desgosto"/> <input type="button" value="Medo"/> <input type="button" value="Raiva"/> <input type="button" value="Surpresa"/> <input type="button" value="Tristeza"/> <input type="button" value="Neutro"/> | | |
| Intensidade secundária (Opcional): <input type="button" value="Baixa"/> <input type="button" value="Media"/> <input type="button" value="Alta"/> | | |
| 2 | Câmera flagra ladrão dentro de loja de roupas em MG: Perfumaria, que fica ao lado, também foi invadida. Ele está sendo procurado pela polícia. | |
| 3 | Indústria 'empurra' novas drogas, sem garantir que são melhores que antigas: Interesses comerciais acabam muitas vezes atrapalhando tratamentos. Opinião é de psiquiatra americano, em artigo no jornal "New York Times". | |
| 4 | Primeiro centro de pesquisa brasileiro da Boeing é inaugurado em São José. Objetivo é desenvolver projetos em parceria com setor aeroespacial. Empresa é a maior do mundo no setor; Brasil é o 6º país a receber centro. | |
| 5 | Arqueólogos encontram vestígios com mais de 1.200 anos em MG: Pesquisadores localizaram amostras de vegetais em Montes Claros. Com projeto, cientistas querem aproximar comunidade das descobertas. | |
| 6 | Energia do impacto sobre Felipe Massa foi 30% da letal, estima engenheiro: Perito em acidentes automotivos ressalva que adotou premissas. Detalhes que só a perícia vão revelar indicarão números exatos. | |
| 7 | Homem rouba 2 bolsas e é espancado por 10 pessoas em Araraquara, SP. Suspeito de 36 anos está em estado grave e respira com aparelhos. Esse foi o 2º caso de espancamento registrado na cidade em 9 dias. | |
| 8 | Corpo de coreano morto em obra do metrô deixa a capital baiana. Segundo consulado, corpo de Kim Jong Pyo segue para a Coreia na sexta. Vítima morreu após choque próximo à Estação Acesso Norte. | |
| 9 | Quarto jacaré é encontrado na Região Metropolitana do Recife, esta semana. mal da espécie papo amarelo tem 1,5 metro e foi levado ao Ibama. | |
| 10 | Novo radar vai detectar voos em baixa altitude na fronteira amazônica: Equipamento pode identificar rotas de até 40 alvos simultaneamente. Aviões serão localizados se voarem abaixo de 300 metros de altura. | |

Showing 1 to 10 of 10 entries Previous Next

Figura 1: Interface do software para rotulação de textos

As emoções por si só têm natureza altamente subjetiva e, dessa forma, identificar a emoção predominante em um texto pode ser uma tarefa ambígua. Diante disso, selecionamos alguns exemplos de textos do corpus de notícias, mostrados na Tabela 1, que foram rotulados pela equipe do projeto "*Identificando emoções em Textos escritos em Português do Brasil*", afim de direcionar ou padronizar a atividade de rotulação. A maioria dos textos apresentados na Tabela 1, assim como os demais textos do corpus, apresentam mais de uma emoção por texto. O desafio do rotulador, neste caso, é identificar a emoção predominante e a sua intensidade. Por exemplo, no texto "*Presos suspeitos de degolar menina de 14 anos que recusou casamento. A polícia afegã prendeu dois homens acusados de decapitar uma adolescente com uma faca em Kunduz, província que fica no norte do Afeganistão*", o fato dos suspeitos do crime estarem presos pode representar uma boa notícia porém, o texto como um todo possui mais palavras relacionadas com a emoção **tristeza** do que com a emoção **alegria** assim, nesse caso, o ideal é que o rotulador opte pela emoção que possui mais palavras relacionadas a ela, no caso deste texto, a emoção **tristeza**.

A metodologia utilizada pela equipe do projeto ao rotular os textos da exibidos na Tabela 1 foi primeiramente identificar a emoção em cada sentença do texto, em seguida identificar a emoção que obteve o maior número de ocorrências no texto como um todo e, por fim, determinar essa emoção como sendo a predominante do texto. Porém, em muitos textos ocorre um empate no número de emoções encontradas nas sentenças e nessas situações, optou-se pela escolha intuitiva da emoção "mais forte" analisando o texto de um modo geral.

Independente da metodologia utilizada pela equipe do projeto para rotular os textos da Tabela 1, o rotulador pode criar a sua própria metodologia de rotulação. Caso o rotulador tenha dúvida de quais palavras se referem a uma ou a outra emoção, a lista de palavras de cada emoção que estão no Anexo I poderá auxiliar na escolha da emoção.

Tabela 1. Exemplo de rotulação de textos²⁴

| | TEXTO | ANÁLISE POR SENTENÇA | EMOÇÃO PREDOMINANTE | INTENSIDADE |
|----|---|--|---------------------|-------------|
| 1 | Mãe e bebê caem em rio do Recife e dupla consegue resgatar criança. Mulher ainda está desaparecida e bombeiros trabalham nas buscas. No momento do acidente, chovia muito e nível do Rio Tejiipió havia subido. | Sentença 1: tristeza e alegria Sentença 2: tristeza Sentença 3: neutro | tristeza | alta |
| 2 | Igreja alemã indícia religiosos por pedofilia. A Igreja Católica alemã anunciou nesta sexta-feira que 66 de seus religiosos foram indiciados por abusos sexuais cometidos num período de dez anos. | Sentença 1: alegria e desgosto Sentença 2: desgosto | desgosto | alta |
| 3 | Jacaré de 3,5 metros é capturado em quintal de casa no Amazonas. Animal foi encontrado em quintal de residência em Itacoatiara. Corpo de Bombeiros capturou e soltou o animal no Rio Amazonas. | Sentença 1: surpresa Sentença 2: surpresa Sentença 3: neutro | surpresa | média |
| 4 | Estudante queimada em sessão de bronzamento recebe alta, em Goiás. Mãe comemora recuperação: 'Ela está bem emocionalmente, animada'. Treze mulheres se queimaram ao passar óleo de coco com canela, em Jataí. | Sentença 1: tristeza e alegria Sentença 2: alegria Sentença 3: desgosto | alegria | média |
| 5 | Polícia apreende sete quilos de crack em MS: Droga estava escondida em mala, que era levada em bagageiro de ônibus. Apreensão foi feita na BR-262 em Corumbá. | Sentença 1: alegria e desgosto Sentença 2: desgosto Sentença 3: alegria | desgosto | média |
| 6 | Após dez anos desaparecidas, jovens são encontradas nos Estados Unidos. Amanda Berry, Michelle Knight e Gina DeJesus sumiram quando eram adolescentes e foram encontradas em bairro residencial de Cleveland, Ohio. | Sentença 1: surpresa e alegria Sentença 2: tristeza e surpresa | surpresa | alta |
| 7 | Mulheres que ajudaram a encontrar Bin Laden vivem sob ameaça no Paquistão. Agentes de saúde perderam seus empregos e são consideradas 'traidoras'. | Sentença 1: alegria e medo Sentença 2: tristeza | medo | média |
| 8 | Pai mantém bebê refém por oito horas em MS: Comerciante teria entrado com criança em banheiro. Ele liberou refém e foi detido. | Sentença 1: raiva Sentença 2: raiva Sentença 3: alegria | raiva | alta |
| 9 | Cobra de 2,5 metros e 23 filhotes são encontrados em creche na Austrália. Incidente ocorreu em creche na cidade de Darwin. Cobra enorme havia feito seu ninho em uma das paredes. | Sentença 1: surpresa e medo Sentença 2: neutro Sentença 3: surpresa e medo | surpresa | alta |
| 10 | Australiana acha 7 cobras venenosas no armário | Sentença 1: surpresa e medo | surpresa | alta |

²⁴ Para auxiliar no processo de rotulação dos textos da Tabela 1 foram utilizadas seis listas de palavras relacionadas às emoções (VER ANEXO I) baseadas no léxico *WordNetAffect* [Strapparava e Mihalcea, 2008] e que foram adaptadas para o Português Brasileiro por [Martinazzo, 2010].

| | | | | |
|----|---|---|----------|-------|
| | do filho de três anos. Caso ocorreu em Townsville, na Austrália. Menino achou ovos no jardim e os guardou no guarda-roupa. | Sentença 2: neutro Sentença 3: surpresa e medo | | |
| 11 | Banhistas encontram pinguim em Guaratuba, no litoral paranaense. Animal fez a alegria dos banhistas que estavam aproveitando a praia. A recomendação dos biólogos é para não tocar no pinguim. | Sentença 1: surpresa Sentença 2: alegria Sentença 3: neutro | surpresa | média |
| 12 | Agente suspeito de facilitar tortura contra menor é preso em Cuiabá. Agente é suspeito de permitir estupro contra menor no Complexo Pomeri. Suspeito se entregou à polícia e, por meio da defesa, negou crime. | Sentença 1: raiva e alegria Sentença 2: raiva Sentença 3: alegria e raiva | raiva | alta |
| 13 | Andorinhas mudam rotina em cidade paraense: Elas chegam a Parauapebas e dão espetáculo no céu. Entretanto, sujeira deixada pelas aves incomoda moradores. | Sentença 1: neutro Sentença 2: alegria Sentença 3: desgosto | desgosto | baixa |
| 14 | Lobo-marinho 'dança' ao som de gaita na Baía de Paranaguá, no Paraná. Dentista que seguia de barco para Ilha de Eufrasina registrou a cena. Ele ficou cerca de duas horas brincando e tocando gaita para o animal. | Sentença 1: alegria Sentença 2: alegria Sentença 3: alegria | alegria | alta |
| 15 | Explosão em mesquita mata 15 no Irã: Atentado também deixou cerca de 50 feridos. País tem eleições presidenciais em 12 de junho. | Sentença 1: tristeza Sentença 2: tristeza e medo Sentença 3: neutro | tristeza | alta |
| 16 | Babá é acusada de esfaquear duas crianças em apartamento de NY. Duas crianças foram esfaqueadas e encontradas mortas pela mãe na banheira de um apartamento de luxo de Nova York na tarde de quinta-feira. | Sentença 1: raiva Sentença 2: tristeza | tristeza | alta |
| 17 | Sandra Annenberg sai da quarentena após contrair nova gripe: Exames confirmaram diagnóstico nesta terça-feira (28). Jornalista apresentou sintomas da doença desde dia 22 de julho. | Sentença 1: alegria e desgosto Sentença 2: desgosto Sentença 3: desgosto | desgosto | média |
| 18 | Motorista de ônibus é flagrado lendo jornal enquanto dirigia na Bélgica. Vídeo foi postado no dia 29 de novembro no YouTube. Usuário destacou que o comportamento do motorista era grave. | Sentença 1: desgosto e surpresa Sentença 2: neutro Sentença 3: desgosto | desgosto | alta |
| 19 | Menores de 2, 3 e 9 anos são assassinados pelo próprio pai em Palmas. Vanderlei de Lima matou as crianças com golpe de faca e disse que o fez por estarem passando necessidade. | Sentença 1: tristeza e raiva Sentença 2: raiva | raiva | alta |
| 20 | Mulher é encontrada em uma mala na zona norte de São Paulo. O corpo de uma mulher foi encontrado dentro de uma bolsa de nylon na zona norte da capital, na manhã deste domingo (5). | Sentença 1: surpresa e tristeza Sentença 2: surpresa e tristeza | surpresa | alta |
| 21 | Cobra jararaca é encontrada enrolada em carrinho de bebê no Paraná. Ainda assustada com o incidente, a dona de casa Solange Fretta disse que acordou, tomou café e ao levar o copo até a lavanderia, se deparou com a serpente. | Sentença 1: medo e surpresa Sentença 2: medo | medo | alta |
| 22 | Garimpeiro amador encontra pepita de ouro gigante na Austrália. Minério de 5,5 quilos avaliado em R\$ 645 mil foi desenterrado em cidade onde corrida do ouro já dura 162 anos. | Sentença 1: surpresa e alegria Sentença 2: surpresa e alegria | surpresa | alta |
| 23 | Mulher recebe transplante de rosto pela primeira | Sentença 1: alegria | tristeza | alta |

| | | | | |
|----|---|--|----------|-------|
| | vez nos EUA: Mulher levou tiro do marido há cinco anos. No total, ela passou por 30 cirurgias. | Sentença 2: tristeza Sentença 3: tristeza | | |
| 24 | Dia do Trabalho é marcado por protestos pelo mundo: Na Alemanha e Turquia, houve confrontos com a polícia. No México, sindicatos tiveram que suspender ações por conta da doença. | Sentença 1: desgosto Sentença 2: desgosto Sentença 3: desgosto | desgosto | alta |
| 25 | Assaltante chama a polícia após ser ameaçado por vítimas nos EUA. Christopher Lance Moore ficou sob a mira dos donos de casa no Texas. Ele acabou confessando a tentativa frustrada de assalto. | Sentença 1: surpresa Sentença 2: surpresa Sentença 3: alegria | surpresa | alta |
| 26 | Presos suspeitos de degolar menina de 14 anos que recusou casamento. A polícia afegã prendeu dois homens acusados de decapitar uma adolescente com uma faca em Kunduz, província que fica no norte do Afeganistão. | Sentença 1: alegria, tristeza e raiva Sentença 2: alegria e tristeza | tristeza | alta |
| 27 | Japão estreia serviço de doações online para políticos: Serviço chamado 'Love Japan' é lançado a um mês das eleições no país. Iniciativa pretende incentivar o aumento de contribuições individuais. | Sentença 1: surpresa e alegria Sentença 2: neutro Sentença 3: alegria | alegria | baixa |
| 28 | Homem que estuprou menina de 12 anos é preso. Acusado de estuprar e engravidar uma garota de 12 anos, o lavrador Edimilson Rodrigues Souza, o "Baiano", de 56 anos, foi preso, no sábado (8/12). | Sentença 1: tristeza, raiva e alegria Sentença 2: tristeza, raiva e alegria | raiva | alta |
| 29 | Britânica agride namorado ao flagrá-lo no aeroporto com amante. Incidente ocorreu no aeroporto de Birmingham. Mulher pegou 12 meses de liberdade condicional. | Sentença 1: desgosto Sentença 2: neutro Sentença 3: desgosto | desgosto | média |
| 30 | Talibã assume autoria de ataque a bomba no Paquistão: Atentado em Lahore na quarta-feira deixou 24 mortos; grupo ameaça realizar ataques em outras cidades. | Sentença 1: raiva e desgosto Sentença 2: tristeza Sentença 3: medo | tristeza | média |
| 31 | Para mim, não existiu', diz Aldo Rebelo sobre o mensalão: Deputado prestou depoimento como testemunha de Dirceu e Jefferson. Até 5 de junho, 96 testemunhas serão ouvidas em SP. | Sentença 1: raiva Sentença 2: neutro Sentença 3: neutro | neutro | baixa |
| 32 | Homem de 76 anos salva menino de 10 anos de ataque de pit bull: Aposentado ouviu os gritos da criança e saiu de casa para ajudá-lo. Ele e a filha também foram atacados pelo cachorro em Foz do Iguaçu. | Sentença 1: alegria Sentença 2: desgosto Sentença 3: medo | desgosto | média |
| 33 | Japão executa três condenados à morte: Um dos enforcados era chinês. Eles haviam sido condenados por assassinatos e roubos. | Sentença 1: desgosto Sentença 2: neutro Sentença 3: desgosto | desgosto | média |
| 34 | Crime 'bárbaro' de Goiânia é destaque na imprensa britânica: Jornais comentam julgamento de rapaz que esquartejou namorada inglesa. | Sentença 1: desgosto Sentença 2: tristeza | tristeza | alta |
| 35 | Mãe suspeita de agredir filha de 12 anos a pauladas é presa em Teresina. Criança teve traumatismo craniano e está internada, diz polícia. Enfermeira que atendeu a menina denunciou o caso. | Sentença 1: raiva, tristeza e alegria Sentença 2: tristeza Sentença 3: alegria | tristeza | alta |
| 36 | Mãe é flagrada acendendo cigarro para bebê em parque na China. A imagem publicada no blog da jornalista e blogueira Hart Hagerty, em que uma mãe acende um cigarro para seu filho, na China, chocou os internautas. | Sentença 1: raiva Sentença 2: raiva | raiva | alta |
| 37 | Banda que causou incêndio na boate Kiss em | Sentença 1: medo | medo | alta |

| | | | | |
|--------|--|--|----------|------|
| | Santa Maria teme linchamento. O guitarrista da banda Gurizada Fandangueira, Rodrigo Martins, afirmou em entrevista à Rádio Gaúcha que a banda está com medo de sofrer linchamento. | Sentença 2: medo | | |
| 38 | Música ajuda desenvolvimento de bebês prematuros, diz estudo: Pesquisa canadense sugere que música reduz dores e estimula alimentação oral. | Sentença 1: alegria Sentença 2: alegria | alegria | alta |
| 39 | Pacientes podem ser ressuscitados horas após morte, diz médico. Resfriamento do cérebro 'é chave' para evitar decomposição do órgão, que pode voltar à vida até cinco horas após um ataque cardíaco. | Sentença 1: surpresa e alegria Sentença 2: surpresa | surpresa | alta |
| 3 9 | Menino de 2 anos morre após levar tiro da irmã de 3 nos EUA: Menina teria encontrado arma embaixo da cama dos pais e deu tiro no peito do irmão mais novo. | Sentença 1: tristeza Sentença 2: tristeza | tristeza | alta |
| 40 | Cratera em Marte foi formada por vento e água, sugere jipe: Estudo foi publicado no periódico americano "Science". Resultados reúnem dados coletados por sondas no planeta vermelho. | Sentença 1: neutro Sentença 2: neutro Sentença 3: neutro | neutro | alta |

ANEXO I. LISTAS DE PALAVRAS EMOCIONAIS

ALEGRIA

| | | | | | |
|-------------------|---------------|--------------|--------------|-------------------|-----------------|
| abundante | acalmar | aceitável | aclamar | aconchego | adesão |
| admirar | admirar | adorar | afável | afeição | afeto |
| afortunado | agradar | ajeitar | alívio | amabilidade | amado |
| amar | amável | amenizar | ameno | amigável | amistoso |
| amizade | amor | animação | ânimo | anseio | ânsia |
| ansioso | apaixonado | apaziguar | aplausos | apoiar | aprazer |
| apreciar | aprovação | aproveitar | ardor | arrumar | atração |
| atraente | atrair | avidamente | avidez | ávido | belo |
| bem-estar | beneficência | beneficiador | benefício | benéfico | benevolência |
| benignamente | benigno | bom | bondade | bondoso | bonito |
| brilhante | brincadeira | calma | calor | caridade | caridoso |
| carinho | cativar | charme | cheery | clamar | coleguismo |
| comédia | cômico | comover | compaixão | companheirismo | compatibilidade |
| compatível | complacência | completar | compreensão | conclusão | concretização |
| condescendência | confiança | confortante | confortar | congratulação | conquistar |
| consentir | consideração | considerar | consolação | consolo | contentamento |
| contente | coragem | cordial | cuidadoso | cumplicidade | dedicação |
| deleitado | delicadamente | delicadeza | delicado | desejar | despreocupação |
| devoção | devoto | diversão | divertido | elogiado | emoção |
| emocionante | emotivo | empatia | empático | empolgação | enamorar |
| encantado | encantar | encorajado | enfeitar | engraçado | entendimento |
| entusiasmadamente | entusiástico | esperança | esplendor | estima | estimar |
| estimulante | euforia | eufórico | euforizante | exaltar | excelente |
| excitar | expansivo | extasiar | exuberante | exultar | fã |
| facilitar | familiaridade | fascinação | fascínio | favor | favorecer |
| favorito | felicidade | feliz | feira | festejar | festivo |
| fidelidade | fiel | filantropia | filantrópico | fraterno | ganhar |
| generosidade | generoso | gentil | glória | glorificar | gostar |
| gostoso | gozar | gratificante | grato | hilarante | honra |
| humor | impressionar | incentivar | incentivo | inclinação | incrível |
| inspirar | interessar | interesse | irmandade | jovial | jubilante |
| júbilo | lealdade | legítimo | leveza | louvar | louvável |
| louvavelmente | lucrativo | lucro | maravilhoso | melhor | obter |
| obteve | orgulho | paixão | parabenizar | paz | piadoso |
| positivo | prazenteiro | prazer | predileção | preencher | preferência |
| preferido | privilegio | promissor | prosperidade | proteção | proteger |
| protetor | proveito | querer | radiante | realizar | recomendável |
| recompensa | reconhecer | recreação | recrear | recreativo | recrear |
| respeitar | ressuscitar | revigorar | risada | risonho | romântico |
| romantismo | saciar | saciável | satisfação | satisfatoriamente | satisfatório |
| satisfazer | satisfeito | sedução | seduzir | sereno | simpaticamente |
| simpático | sobrevivência | sobreviver | sorte | sortudo | sucesso |
| surpreender | tenro | ternura | torcer | tranquilo | tranquilo |
| triumfal | triumfante | triumfo | vantagem | vantajoso | vencedor |
| veneração | ventura | vida | vigor | virtude | virtuoso |
| vitória | vitorioso | viver | vivo | zelo | zeloso |

TRISTEZA

| | | | | | |
|------------|--------------|------------------|-------------|------------|--------------|
| abandonar | abatido | abominável | aborrecer | abortar | aflição |
| afligir | aflito | agoniar | amargo | amargor | amargura |
| ansiedade | arrepender | arrependidamente | atrito | azar | cabisbaixo |
| chorão | choro | choroso | coitado | compassivo | compunção |
| contrição | contristador | contrito | culpa | defeituoso | degradante |
| deplorável | deposição | depravado | depressão | depressivo | deprimente |
| deprimir | derrota | derrubar | desalentar | desamparo | desanimar |
| desânimo | desapontar | desconsolo | descontente | desculpas | desencorajar |
| desespero | desgaste | desgosto | desgraça | | |

RAIVA

| | | | | | |
|-------------|------------|----------|------------|-------------|-------------|
| abominação | aborrecer | agredido | agredir | agressão | agressivo |
| amaldiçoado | amargor | amargura | amolar | angústia | animosidade |
| antipatia | antipático | asco | assassinar | assassinato | assediar |
| assédio | atormentar | avarento | avareza | aversão | beligerante |

| | | | | | |
|------------|------------|----------------|-------------|--------------|---------------|
| bravejar | chateação | chato | cobiçoso | cólera | colérico |
| complicar | contrariar | contrariedade | corrupção | corrupto | crucificar |
| demoníaco | demônio | descaso | descontente | descontrole | desenganar |
| desgostar | desgraça | desprezar | desprezar | destruição | destruir |
| detestar | diabo | diabólico | doido | encolerizar | energicamente |
| enfurecido | enfuriante | enlouquecer | enraivecer | escandalizar | escândalo |
| escoriar | exasperar | execração | ferir | frustração | frustrar |
| fúria | furioso | furor | ganância | ganancioso | guerra |
| guerreador | guerrilha | hostil | humilhar | implicância | implicar |
| importunar | incomodar | incômodo | indignar | infernizar | inimigo |
| inimizade | injúria | injurado | injustiça | insulto | inveja |
| ira | irado | irascibilidade | irascível | irritar | louco |
| loucura | magoar | mal | maldade | maldição | maldito |
| maldizer | maldoso | maleficência | maléfico | malevolência | malévolo |
| malícia | malicioso | malignidade | maligno | maltratar | maluco |
| malvadeza | malvado | matar | mesquinho | misanthropia | misantrópico |
| molestar | moléstia | mortal | morte | mortífero | mortificar |
| nervoso | odiar | odiável | ódio | odioso | ofendido |
| ofensa | opressão | opressivo | oprimir | perseguição | perseguir |
| perturbar | perverso | provocar | rabugento | raivoso | rancor |
| reclamar | repressão | reprimir | repulsa | repulsivo | resmungar |
| ressentido | revolta | ridículo | tempestuoso | tirano | tormento |
| torturar | ultrage | ultrajar | vexatório | vigoroso | vingança |
| vingar | vingativo | violência | violento | zangar | |

MEDO

| | | | | | |
|-------------|------------------|-----------------|----------------|--------------|-----------------|
| abominável | afugentar | alarmar | alerta | ameaça | amedrontar |
| angustia | angústia | angustiadamente | ansiedade | ansioso | apavorar |
| apreender | apreensão | apreensivo | arrepio | assombrado | assombro |
| assustado | assustadoramente | atemorizar | aterrorizante | brutal | calafrio |
| chocante | chocante | consternado | covarde | cruel | crueldade |
| cruelmente | cuidado | cuidadosamente | cuidadoso | defender | defensor |
| defesa | derrotar | desconfiado | desconfiança | desencorajar | desespero |
| deter | envergonhado | escandalizado | escuridão | espantoso | estremecedor |
| estremecer | expulsar | feio | friamente | fugir | hesitar |
| horrendo | horripilante | horível | horriavelmente | horror | horrorizar |
| impaciência | impaciente | impiedade | impiedoso | indecisão | inquieto |
| insegurança | inseguro | intimidar | medonho | medroso | monstruosamente |
| mortalha | nervoso | pânico | pavor | premonição | preocupar |
| presságio | pressentimento | recear | receptivamente | receio | receoso |
| ruim | suspeita | suspense | susto | temer | temeroso |
| temor | tensão | tenso | terrificar | terrível | terrivelmente |
| terror | timidamente | timidez | tímido | tremor | vigiar |
| vigilante | | | | | |

DESGOSTO

| | | | | | |
|-------------|------------|-------------|--------------|--------------|---------------|
| abominável | adoentado | amargamente | antipatia | antipático | asco |
| asqueroso | aversão | chateação | chatear | desagradável | desagrado |
| desprezível | detestável | doença | doente | enfermidade | enjoativo |
| enjoo | enjoo | feio | fétido | golfar | grave |
| gravidade | grosseiro | grosso | horível | ignóbil | ilegal |
| incomodar | incômodo | indecente | indisposição | indisposto | inescrupuloso |
| maldade | maldoso | malvado | mau | náusea | nauseabundo |
| nauseante | nausear | nauseoso | nojento | | |

SURPRESA

| | | | | | |
|--------------|---------------|-------------|-------------|---------------|-----------------|
| admirar | afeição | apavorante | assombro | chocado | chocante |
| desconcertar | deslumbrar | embasbacar | emudecer | encantamento | enorme |
| espanto | estupefante | estupefato | estupefazer | expectativa | fantasticamente |
| fantástico | horripilante | imaginário | imenso | impressionado | incrível |
| maravilha | milagre | ótimo | pasmo | perplexo | prodígio |
| sensacional | surpreendente | surpreender | suspense | susto | temor |
| tremendo | | | | | |

APÊNDICE 2 - Lista de *stopwords* da língua Portuguesa

a, abaixo, acerca, acima, ante, ao, aonde, aos, após, aquela, aquelas, aquele, aqueles, aquilo, as, assim, até, atrás, caso, cima, com, como, conforme, conseguinte, contudo, da, daí, dali, daquela, daquelas, daquele, daqueles, daqui, daquilo, das, de, dela, delas, dele, deles, dentro, depois, desde, desse, desses, desta, destas, deste, destes, disso, disto, do, dos, dum, duma, dumas, duns, durante, e, em, embaixo, enquanto, entanto, entre, entretanto, exceto, fora, forma, frente, graças, isso, já, junto, lado, logo, mas, mediante, mesmo, modo, na, naquela, naquelas, naquele, naqueles, naquilo, nas, nas, nem, nessa, nessas, nesse, nesses, nesta, nestas, neste, nestes, nisso, nisto, no, nos, nos, numas, nuns, o, ora, os, ou, outra, outro, para, pela, pelas, pelo, pelos, perante, perto, pois, por, porém, porquanto, porque, portanto, qual, quando, que, quer, redor, respeito, segundo, sem, sempre, senão, sendo, sob, sobre, também, tão, todavia, trás, um, uma, umas, uns, visto

APÊNDICE 3 - Lista de *stopwords* da língua Inglesa

i, me, my, myself, we, us, our, ours, ourselves, you, your, yours, yourself, yourselves, he, him, his, himself, she, her, hers, herself, it, its, itself, they, them, their, theirs, themselves, what, which, who, whom, this, that, these, those, am, is, are, was, were, be, been, being, have, has, had, having, do, does, did, doing, will, would, shall, should, can, could, may, might, must, ought, i'm, you're, he's, she's, it's, we're, they're, i've, you've, we've, they've, i'd, you'd, he'd, she'd, we'd, they'd, i'll, you'll, he'll, she'll, we'll, they'll, isn't, aren't, wasn't, weren't, hasn't, haven't, hadn't, doesn't, don't, didn't, won't, wouldn't, shan't, shouldn't, can't, cannot, couldn't, mustn't, let's, that's, who's, what's, here's, there's, when's, where's, why's, how's, daren't, needn't, oughtn't, mightn't, a, an, the, and, but, if, or, because, as, until, while, of, at, by, for, with, about, against, between, into, through, during, before, after, above, below, to, from, up, down, in, out, on, off, over, under, again, further, then, once, here, there, when, where, why, how, all, any, both, each, few, more, most, other, some, such, no, nor, not, only, own, same, so, than, too, very, one, every, least, less, many, now, ever, never, say, says, said, also, get, go, goes, just, made, make, put, see, seen, whether, like, well, back, even, still, way, take, since, another, however, two, three, four, five, first, second, new, old, high, long

APÊNDICE 4 - Pseudocódigo de Busca Automática de Limiar de Rejeição CHOW

Algoritmo "Limiar_CHOW"

```

tipo
Probabilidade=registro
classe:CARACTERE
probPositivo:REAL
probNegativo:REAL
fimregistro

Var
classes: VETOR[0..2] de CARACTERE
instancias: VETOR[0..10] de Probabilidade
i: INTEIRO
probabilidade: REAL
distanciaEuclidiana, menorDistancia: REAL
acertou: LOGICO

limiar, limiarAuxiliar: REAL // Limiar de rejeição
precisao: REAL // Precisão da busca de limiar
CA: REAL // Correta Aceitação
CR: REAL // Correta Rejeição
FA: REAL // Falsa Aceitação
FR: REAL // Falsa Rejeição
FAR, FRR: REAL // taxa de acerto e Taxa de erro

Inicio

classes[0] <- "Positivo"
classes[1] <- "Negativo"

para i de 0 ate 10 faca
    instancias[i].classe <- classes[RandI(2)]

    instancias[i].probPositivo <- Rand()
    instancias[i].probPositivo <- instancias[i].probPositivo * 0.70

    se instancias[i].classe = classes[1] entao
        instancias[i].probPositivo <- instancias[i].probPositivo + 0.3
    fimse

    instancias[i].probNegativo <- 1 - instancias[i].probPositivo
    escreval(instancias[i].classe, " - ", instancias[i].probPositivo, " - ", ins-
tancias[i].probNegativo)
fimpara

escreva("Precisão da busca: ")
leia(precisao)

limiarAuxiliar <- 0
menorDistancia <- 999

// Testa diferentes limiares de acordo com a precisao
enquanto limiarAuxiliar <= 1 faca
    // Reseta as variaveis de contagem
    CA <- 0
    CR <- 0
    FA <- 0
    FR <- 0

    // Calcula a taxa de acerto e a taxa de erro
    para i de 0 ate 10 faca

        se instancias[i].probPositivo > instancias[i].probNegativo entao

```

```

        probabilidade <- instancias[i].probPositivo
        se instancias.classe = classes[0] entao
            acertou <- VERDADEIRO
        senao
            acertou <- FALSO
        fimse
    senao
        probabilidade <- instancias[i].probNegativo
        se instancias.classe = classes[1] entao
            acertou <- VERDADEIRO
        senao
            acertou <- FALSO
        fimse
    fimse

    se acertou entao
        se probabilidade >= limiarAuxiliar entao
            // Corretamente aceita
            CA <- CA + 1
        senao
            // Incorretamente rejeitada
            FR <- FR + 1
        fimse
    senao
        se probabilidade >= limiarAuxiliar entao
            // Incorretamente aceita
            FA <- FA + 1
        senao
            // Corretamente rejeitada
            CR <- CR + 1
        fimse
    fimse

    fimpара

    // Taxa de falsa aceitação
    FAR <- FA / (FA + CR)

    // Taxa de falsa rejeição
    FRR <- FR / (FR + CA)

    // Distancia de FAR e FRR da origem
    distanciaEuclidiana <- Quad(Exp(FAR, 2) + Exp(FRR, 2))

    se distanciaEuclidiana < menorDistancia entao
        menorDistancia <- distanciaEuclidiana
        limiar <- limiarAuxiliar
    fimse

    limiarAuxiliar <- limiarAuxiliar + precisao
fimenquanto

escreval("LIMIAR: ", limiar)

Fimalgoritmo

```

APÊNDICE 5 - Outros Experimentos Realizados com o Método de Identificação de Emoções em Textos usando o Corpus de Notícias

Os experimentos realizados com o método e apresentados detalhadamente nas próximas seções foram realizados usando o corpus de notícias que foi descrito no Capítulo 5. As configurações de pré-processamento dos dados textuais fazem referência à Tabela 8.1, que está disponível na primeira seção do Capítulo 8. Também a Tabela 8.2, que apresenta a descrição das informações dos CRCs, será utilizada nestas seções.

Para todos os experimentos que serão apresentados será estabelecido que o classificador SVM da primeira camada foi configurado com kernel RBF padrão ($cost=1$, $gamma=0$), probabilidades estimadas= $true$ e gera as probabilidades estimadas por meio de Validação Cruzada com dez partes.

1) Experimentos com o Método ao Classificar Textos com Seis Emoções Básicas e Neutro

Os objetivos destes experimentos são: 1) Avaliar o impacto dos filtros de redução de dimensionalidade e de seleção de características no classificador SVM multiclasse; 2) Avaliar o CRCA que usa limiar de rejeição e limiar de confusão e validar os CRCs; 3) Avaliar o CRCA que rejeita todas as instâncias na primeira camada e usa de limiar de confusão para criar os CRCs da segunda camada; 4) Avaliar o método ao classificar textos que não tiveram concordância e ao classificar textos com total concordância, separadamente; 5) Verificar o desempenho do classificador SVM multiclasse ao ser treinado e avaliado com um conjunto de dados composto de uma mesma quantidade de textos sem concordância e com concordância.

Os experimentos foram realizados usando 1.600 textos para treinamento, 200 textos para teste e 200 textos para validação.

O primeiro experimento desta seção visa avaliar o impacto dos filtros de redução de dimensionalidade e de seleção de características no classificador SVM multiclasse da primeira camada do método. Dessa forma, o classificador SVM multiclasse é avaliado primeiramente sem o uso dos filtros e na sequência com o uso deles.

O classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e avaliado com o conjunto de teste. Os dados submetidos ao classificador são pré-processados usando a configuração de pré-processamento *Config_Pre_13* da Tabela 8.1 (disponível no Capítulo 8), que não faz uso de filtros de redução de dimensionalidade e de seleção de características. O desempenho obtido com o classificador SVM multiclasse, pode ser visualizado na Tabela 1.

Tabela 2: Desempenho do classificador SVM multiclasse ao usar um pré-processamento sem filtros

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|--------------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,50 | 0,78 | 0,61 | 43 | 2 | 2 | 6 | 2 | 0 | 0 |
| Alegria (A) | 0,00 | 0,00 | 0,00 | 13 | 0 | 0 | 5 | 0 | 0 | 0 |
| Repugnância (Re) | 0,56 | 0,19 | 0,29 | 12 | 1 | 5 | 5 | 2 | 0 | 1 |
| Tristeza (T) | 0,51 | 0,80 | 0,63 | 3 | 2 | 0 | 37 | 2 | 1 | 1 |
| Medo (M) | 0,50 | 0,27 | 0,35 | 4 | 0 | 0 | 11 | 6 | 0 | 1 |
| Raiva (R) | 0,67 | 0,25 | 0,36 | 1 | 0 | 1 | 4 | 0 | 2 | 0 |
| Surpresa (S) | 0,77 | 0,40 | 0,53 | 10 | 0 | 1 | 4 | 0 | 0 | 10 |
| Média | 0,51 | 0,52 | 0,47 | Características = 9.379 | | | | | | |
| Acurácia | 51,5% | | | | | | | | | |

Ao ser treinado e avaliado com textos pré-processados usando a configuração *Config_Pre_1* da Tabela 8.1, que faz uso de filtros de redução de dimensionalidade e de seleção de características, o classificador SVM da primeira camada obteve o resultado apresentado na Tabela 2.

Tabela 3: Desempenho do classificador SVM multiclasse ao usar pré-processamento com filtros

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|------------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,66 | 0,73 | 0,69 | 40 | 6 | 3 | 5 | 0 | 0 | 1 |
| Alegria (A) | 0,32 | 0,33 | 0,32 | 6 | 6 | 1 | 2 | 1 | 1 | 1 |
| Repugnância (Re) | 0,57 | 0,50 | 0,53 | 5 | 2 | 13 | 2 | 2 | 0 | 2 |
| Tristeza (T) | 0,63 | 0,76 | 0,69 | 2 | 2 | 2 | 35 | 3 | 0 | 2 |
| Medo (M) | 0,53 | 0,41 | 0,46 | 3 | 0 | 1 | 6 | 9 | 1 | 2 |
| Raiva (R) | 0,50 | 0,25 | 0,33 | 2 | 0 | 1 | 2 | 0 | 2 | 1 |
| Surpresa (S) | 0,55 | 0,44 | 0,49 | 3 | 3 | 2 | 4 | 2 | 0 | 11 |
| Média | 0,57 | 0,58 | 0,57 | Características = 805 | | | | | | |
| Acurácia | 58,0% | | | | | | | | | |

Comparando o desempenho do classificador SVM multiclasse que usa filtros no pré-processamento (Tabela 1) com o desempenho do SVM multiclasse que não faz o uso de filtros no pré-processamento (Tabela 2), foi possível observar que houve um aumento considerável da acurácia, e principalmente da média ponderada de F1. Além disso, ocorreu uma diminuição notável do número de características. Para comprovar que há diferença estatística significativa entre a média de F1 obtida sem o uso de filtros e a média de F1 obtida com o uso de filtros, foi aplicado o Teste Z (Diferença de Proporções) em um nível de significância de 5%.

O p-valor obtido com o teste é igual a 0,04. Dessa forma, é possível afirmar que existe uma melhora significativa de F1 quando se usa no método uma configuração de pré-processamento com filtros de redução de dimensionalidade e de seleção de características.

Embora a média de F1 aumentou quando se usou os filtros de redução de dimensionalidade e de seleção de características, percebeu-se que as classes *raiva* e *surpresa* tiveram o F1 reduzido. O baixo número de instâncias da classe *raiva* e o alto grau de entropia da classe *surpresa* podem ter contribuído para que o F1 seja reduzido em um cenário com menos características, que é o caso quando se aplicam os filtros.

O segundo experimento desta seção visa avaliar o CRCA que utiliza um limiar de rejeição na primeira camada do método e um limiar de confusão para criar os CRCs da segunda camada. Neste experimento, o classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e o CRCA é avaliado com o conjunto de teste. Além disso, o CRCA também é avaliado com o conjunto de validação.

Os dados da primeira camada são pré-processados usando a configuração *Config_Pre_1* da Tabela 8.1. Na segunda camada, o CRCA é configurado para criar CRCs binários e utilizar a ER CHOW, a qual obtém automaticamente, um limiar de rejeição = 0,54. O método aplica este limiar de rejeição nos dados do conjunto de treinamento e calcula o grau de confusão de cada CRC em função das probabilidades estimadas das instâncias rejeitadas. O grau de confusão dos CRCs, obtido na etapa de treinamento, é mostrado na Tabela 3.

Tabela 4: Grau de confusão dos CRCs obtido durante o treinamento do CRCA

| CRC | Instâncias | Corretas na 1ª maior probabilidade | Corretas na 2ª maior probabilidade | Corretas nas demais probabilidades | % de confusão |
|--------------|------------|------------------------------------|------------------------------------|------------------------------------|---------------|
| AxRe | 11 | 5 | 2 | 4 | 28,6 |
| AxM | 6 | 2 | 0 | 4 | 0,00 |
| AxN | 76 | 43 | 14 | 19 | 24,6 |
| AxR | 3 | 1 | 0 | 2 | 0,00 |
| AxS | 47 | 27 | 12 | 8 | 30,8 |
| AxT | 18 | 9 | 3 | 6 | 25,0 |
| RexM | 19 | 8 | 5 | 6 | 38,5 |
| RexN | 123 | 59 | 24 | 40 | 28,9 |
| RexR | 21 | 8 | 8 | 5 | 50,0 |
| RexS | 30 | 18 | 5 | 7 | 21,7 |
| RexT | 79 | 30 | 18 | 31 | 37,5 |
| MxN | 19 | 6 | 6 | 7 | 50,0 |
| MxR | 5 | 1 | 2 | 2 | 66,7 |
| MxS | 15 | 9 | 3 | 3 | 25,0 |
| MxT | 78 | 29 | 19 | 30 | 39,6 |
| NxR | 1 | 0 | 1 | 0 | 100,0 |
| NxS | 51 | 22 | 16 | 13 | 42,1 |
| NxT | 65 | 27 | 14 | 24 | 34,1 |
| RxT | 35 | 15 | 7 | 13 | 31,8 |
| RxS | 4 | 0 | 2 | 2 | 100,0 |
| SxT | 60 | 21 | 15 | 24 | 41,7 |
| Total | 766 | 340 | 176 | 250 | |

Observando-se o grau de confusão dos CRCs apresentado na Tabela 3, percebe-se que na maioria deles, o grau de confusão é superior a 20%. Com base nisso, estabeleceu-se no CRCA um limiar de confusão = 20%. Dessa forma, todos os CRCs com grau de confusão igual ou superior a este limiar são criados no CRCA para classificar os dados da segunda camada do método.

Os CRCs são classificadores SVM binários configurados com *kernel* RBF padrão ($cost=1$, $gamma=0$), probabilidades estimadas=*false* e os dados são pré-processados usando a configuração *Config_Pre_6* da Tabela 8.1. Além disso, cada CRC obtém um novo conjunto de características.

Ao ser avaliado com o conjunto de teste, o CRCA rejeitou 102 instâncias na primeira camada, que foram classificadas na segunda camada pelos 19 CRCs criados durante o treinamento, conforme o limiar de confusão estabelecido. O desempenho do CRCA pode ser visto na Tabela 4 e os resultados obtidos com os CRCs são mostrados na Tabela 5.

Tabela 5: Desempenho do CRCA ao avaliar o conjunto de teste

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-----------|--------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,63 | 0,82 | 0,71 | 45 | 2 | 2 | 4 | 0 | 0 | 2 |
| Alegria (A) | 0,36 | 0,28 | 0,31 | 9 | 5 | 1 | 2 | 0 | 1 | 0 |
| Repugnância (Re) | 0,59 | 0,39 | 0,47 | 7 | 2 | 10 | 4 | 2 | 0 | 1 |
| Tristeza (T) | 0,62 | 0,80 | 0,70 | 2 | 1 | 1 | 37 | 3 | 0 | 2 |
| Medo (M) | 0,53 | 0,41 | 0,46 | 4 | 1 | 1 | 6 | 9 | 0 | 1 |
| Raiva (R) | 0,00 | 0,00 | 0,00 | 1 | 0 | 2 | 4 | 0 | 0 | 1 |

| | | | | | | | | | | |
|-----------------|--------------|-------------|-------------|-----------------------------|---|---|---|---|---|----|
| Surpresa (S) | 0,65 | 0,52 | 0,58 | 3 | 3 | 0 | 3 | 3 | 0 | 13 |
| Média | 0,56 | 0,60 | 0,57 | Características: 805 | | | | | | |
| Acurácia | 59,5% | | | | | | | | | |

Tabela 6: Desempenho dos CRCs ao classificar as instâncias do conjunto de teste

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|---------------|-----------------|---------------------------|-------------------------|---------------------------|-----------|-----------------------------|-------------|-----------------------|
| AxRe | 28,6 | 221 | 357 | 3 | 3 | 2 | 0 | 66,7 | 100,0 |
| AxN | 24,6 | 352 | 580 | 20 | 14 | 10 | 6 | 50,0 | 70,0 |
| AxS | 30,8 | 253 | 349 | 8 | 6 | 5 | 2 | 62,5 | 75,0 |
| AxT | 25,0 | 293 | 510 | 2 | 1 | 1 | 1 | 50,0 | 50,0 |
| RexM | 38,5 | 193 | 388 | 2 | 1 | 0 | 1 | 0,0 | 50,0 |
| RexN | 28,9 | 366 | 643 | 10 | 5 | 4 | 5 | 40,0 | 50,0 |
| RexR | 50,0 | 248 | 277 | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| RexS | 21,7 | 235 | 412 | 8 | 4 | 4 | 4 | 50,0 | 50,0 |
| RexT | 37,5 | 300 | 573 | 8 | 6 | 5 | 2 | 62,5 | 75,0 |
| MxN | 50,0 | 233 | 611 | 2 | 2 | 2 | 0 | 100,0 | 100,0 |
| MxR | 66,7 | 78 | 245 | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| MxS | 25,0 | 278 | 380 | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| MxT | 39,6 | 292 | 541 | 10 | 5 | 4 | 5 | 40,0 | 50,0 |
| NxR | 100,0 | 259 | 500 | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| NxS | 42,1 | 399 | 635 | 5 | 4 | 4 | 1 | 80,0 | 80,0 |
| NxT | 34,1 | 363 | 796 | 10 | 4 | 4 | 6 | 40,0 | 40,0 |
| RxT | 31,8 | 172 | 430 | 5 | 5 | 2 | 0 | 40,0 | 100,0 |
| RxS | 100,0 | 151 | 269 | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| SxT | 41,7 | 296 | 565 | 6 | 3 | 2 | 3 | 33,3 | 50,0 |
| TOTAL | | | | 102 | 66 | 50 | 36 | | |

Na sequência, foi utilizado o conjunto dos dados de validação para comparar o desempenho dos CRCs com o desempenho do classificador SVM multiclasse. O desempenho dos CRCs ao classificar as instâncias rejeitadas do conjunto de validação pode ser visto na Tabela 6 e o desempenho do classificador SVM multiclasse ao classificar as instâncias rejeitadas do conjunto de validação pode ser visto na Tabela 7.

Tabela 7: Desempenho dos CRCs ao classificar as instâncias rejeitadas do conjunto de validação

| CRC | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxRe | 3 | 0 | 0 | 3 | 0,0 | 0,00 |
| AxM | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| AxN | 16 | 10 | 9 | 6 | 56,3 | 62,5 |
| AxR | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| AxS | 4 | 4 | 3 | 0 | 75,0 | 100,0 |
| AxT | 4 | 1 | 0 | 3 | 0,0 | 25,0 |
| RexM | 3 | 2 | 1 | 1 | 33,3 | 66,7 |
| RexN | 12 | 8 | 7 | 4 | 58,3 | 66,7 |
| RexR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| RexS | 5 | 3 | 3 | 2 | 60,0 | 60,0 |

| | | | | | | |
|--------------|------------|-----------|-----------|-----------|-------|-------|
| RexT | 6 | 3 | 3 | 3 | 50,0 | 50,0 |
| MxN | 5 | 4 | 4 | 1 | 80,0 | 80,0 |
| MxR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| MxS | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| MxT | 10 | 7 | 4 | 3 | 40,0 | 70,0 |
| NxR | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| NxS | 6 | 4 | 2 | 2 | 33,3 | 66,7 |
| NxT | 12 | 5 | 4 | 7 | 33,3 | 41,7 |
| RxT | 4 | 3 | 1 | 1 | 25,0 | 75,0 |
| RxS | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| SxT | 6 | 4 | 2 | 2 | 33,3 | 66,7 |
| Total | 101 | 62 | 45 | 39 | | |

Tabela 8: Desempenho do classificador SVM multiclasse ao classificar as instâncias rejeitadas do conjunto de validação

| CRC | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|-------------------------|---------------------------|-----------|-----------------------------|-------------|-----------------------|
| AxRe | 3 | 0 | 0 | 3 | 0,0 | 0,00 |
| AxM | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| AxN | 16 | 10 | 5 | 6 | 31,3 | 62,5 |
| AxR | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| AxS | 4 | 4 | 2 | 0 | 50,0 | 100,0 |
| AxT | 4 | 1 | 1 | 3 | 25,0 | 25,0 |
| RexM | 3 | 2 | 1 | 1 | 33,3 | 66,7 |
| RexN | 12 | 9 | 7 | 3 | 58,3 | 75,0 |
| RexR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| RexS | 5 | 3 | 2 | 2 | 40,0 | 60,0 |
| RexT | 6 | 3 | 3 | 3 | 50,0 | 50,0 |
| MxN | 5 | 4 | 2 | 1 | 40,0 | 80,0 |
| MxR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| MxS | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| MxT | 10 | 7 | 3 | 3 | 30,0 | 70,0 |
| NxR | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| NxS | 6 | 4 | 2 | 2 | 33,3 | 66,7 |
| NxT | 12 | 4 | 3 | 8 | 25,0 | 33,3 |
| RxT | 4 | 3 | 0 | 1 | 0,0 | 75,0 |
| RxS | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| SxT | 6 | 4 | 2 | 2 | 33,3 | 66,7 |
| Total | 101 | 62 | 36 | 39 | | |

No processo de validação, o CRCA classifica os dados rejeitados com os CRCs, somente se o desempenho deles for igual ou superior ao desempenho obtido com o classificador SVM multiclasse. Dessa forma, na segunda camada do CRCA foram usados apenas 17 CRCs, sendo que esses foram selecionados por apresentarem um desempenho igual ou superior ao classificador SVM multiclasse. O desempenho dos CRCs, no processo de validação do CRCA, pode ser visualizado na Tabela 8 e o desempenho do CRCA no processo de validação é mostrado na Tabela 9.

Tabela 9: CRCs usados no processo de validação do CRCA

| CRC | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|-------------------------|---------------------------|-----------|-----------------------------|-------------|-----------------------|
| AxRe | 3 | 0 | 0 | 3 | 0,0 | 0,0 |
| AxN | 16 | 10 | 9 | 6 | 56,3 | 62,5 |
| AxS | 4 | 4 | 3 | 0 | 75,0 | 100,0 |
| RexM | 3 | 2 | 1 | 1 | 33,3 | 66,7 |
| RexN | 12 | 8 | 7 | 4 | 58,3 | 66,7 |
| RexR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| RexS | 5 | 3 | 3 | 2 | 60,0 | 60,0 |
| RexT | 6 | 3 | 3 | 3 | 50,0 | 50,0 |
| MxN | 5 | 4 | 4 | 1 | 80,0 | 80,0 |
| MxR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| MxS | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| MxT | 10 | 7 | 4 | 3 | 40,0 | 70,0 |
| NxR | 1 | 0 | 0 | 1 | 0,0 | 0,0 |
| NxS | 6 | 4 | 2 | 2 | 33,3 | 66,7 |
| NxT | 12 | 5 | 4 | 7 | 33,3 | 41,7 |
| RxT | 4 | 3 | 1 | 1 | 25,0 | 75,0 |
| SxT | 6 | 4 | 2 | 2 | 33,3 | 66,7 |
| Total | 96 | 56 | 45 | 36 | | |

Tabela 10: Desempenho do CRCA no processo de validação

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-----------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,63 | 0,82 | 0,71 | 45 | 2 | 2 | 4 | 0 | 0 | 2 |
| Alegria (A) | 0,36 | 0,28 | 0,31 | 9 | 5 | 1 | 2 | 0 | 1 | 0 |
| Repugnância (Re) | 0,59 | 0,39 | 0,47 | 7 | 2 | 10 | 4 | 2 | 0 | 1 |
| Tristeza (T) | 0,62 | 0,80 | 0,70 | 2 | 1 | 1 | 37 | 3 | 0 | 2 |
| Medo (M) | 0,53 | 0,41 | 0,46 | 4 | 1 | 1 | 6 | 9 | 0 | 1 |
| Raiva (R) | 0,00 | 0,00 | 0,00 | 1 | 0 | 2 | 4 | 0 | 0 | 1 |
| Surpresa (S) | 0,65 | 0,52 | 0,58 | 3 | 3 | 0 | 3 | 3 | 0 | 13 |
| Média | 0,56 | 0,60 | 0,57 | Características: 805 | | | | | | |
| Acurácia | 59,5% | | | | | | | | | |

Observando-se o desempenho dos CRCs ao classificar os dados rejeitados do conjunto de validação (Tabela 6) e o classificador SVM multiclasse ao classificar os dados rejeitados do conjunto de validação (Tabela 7), constatou-se que o desempenho dos CRCs é superior ao desempenho do classificador SVM multiclasse na maioria dos casos. Percebeu-se também, que o resultado final do CRCA avaliado com o conjunto de teste foi igual ao resultado final do CRCA avaliado com o conjunto de validação, isto indica uma uniformidade nos dados do corpus.

De um modo geral, o uso dos CRCs na segunda camada do método proporciona uma melhor acurácia na classificação, e, além disso, possibilita que sejam realizadas melhorias individuais nestes classificadores a fim de melhorar o seu desempenho e, conseqüentemente, melhorar o desempenho global do CRCA, ao contrário do que ocorre no classificador SVM multiclasse da primeira camada, que já opera em sua capacidade máxima. Em vista disso e dando continuidade ao segundo experimento, o próximo passo é obter melhorias no desempenho individual dos CRCs visando atingir a sua capacidade máxima.

A primeira ação para melhorar os CRCs foi obter para cada CRC da Tabela 8, a melhor configuração de pré-processamento (Tabela 8.1). Os CRCs nos quais a configuração de pré-processamento impactou na melhora do desempenho são apresentados na Tabela 10.

Tabela 11: CRCs que tiveram melhora em função da configuração do pré-processamento

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acer-tou | Encami-nhadas incorre-tamente | Acer-tou (%) | Capa-cidade máxima (%) |
|------|---------------|-----------------|---------------------------|-------------------------|---------------------------|----------|-------------------------------|--------------|------------------------|
| AxRe | 28,6 | 221 | 357 | 3 | 3 | 3 | 0 | 100,0 | 100,0 |
| AxS | 30,8 | 253 | 349 | 8 | 6 | 6 | 2 | 75,0 | 75,0 |
| RexM | 38,5 | 193 | 388 | 2 | 1 | 1 | 1 | 50,0 | 50,0 |
| RxT | 31,8 | 172 | 430 | 5 | 5 | 3 | 0 | 60,0 | 100,0 |

Os CRCs AxRe (configurado com *Config_Pre_4*), AxS (configurado com *Config_Pre_9*) e MxRe (configurado com *Config_Pre_4*) atingiram a sua capacidade máxima. O CRC RxT (configurado com *Config_Pre_3*) obteve uma melhora parcial de sua capacidade. Os demais CRCs não obtiveram melhora no desempenho e assim, manteve-se a configuração *Config_Pre_6* atribuída inicialmente. O desempenho do CRCA, com os CRCs da Tabela 10 modificados, pode ser visualizado na Tabela 11.

Tabela 12: Desempenho do CRCA após modificação de pré-processamento dos CRCs

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,63 | 0,82 | 0,71 | 45 | 2 | 2 | 4 | 0 | 0 | 2 |
| Alegria (A) | 0,46 | 0,28 | 0,35 | 9 | 5 | 1 | 2 | 0 | 1 | 0 |
| Repugnância (Re) | 0,63 | 0,46 | 0,53 | 7 | 1 | 12 | 4 | 1 | 0 | 1 |
| Tristeza (T) | 0,63 | 0,80 | 0,71 | 2 | 1 | 1 | 37 | 3 | 0 | 2 |
| Medo (M) | 0,56 | 0,41 | 0,47 | 4 | 0 | 1 | 6 | 9 | 0 | 2 |
| Raiva (R) | 0,50 | 0,13 | 0,20 | 1 | 0 | 2 | 3 | 0 | 1 | 1 |
| Surpresa (S) | 0,64 | 0,56 | 0,60 | 3 | 2 | 0 | 3 | 3 | 0 | 14 |
| Média | 0,60 | 0,62 | 0,59 | Características: 805 | | | | | | |
| Acurácia | 61,5% | | | | | | | | | |

A segunda ação para melhorar os CRCs foi submetê-los aos outros algoritmos de classificação disponíveis na ferramenta. São eles: *Naive Bayes*, J48 e IBK. Os CRCs que obtiveram melhora no desempenho a usar esses algoritmos de classificação são mostrados na Tabela 12.

Tabela 13: Desempenho dos CRCs que obtiveram melhora ao usar outros algoritmos de classificação

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acer-tou | Encami-nhadas incorre-tamente | Acer-tou (%) | Capaci-dade Máxima (%) |
|------|---------------|-----------------|---------------------------|-------------------------|---------------------------|----------|-------------------------------|--------------|------------------------|
| RexN | 28,9 | 366 | 643 | 10 | 5 | 5 | 5 | 50,0 | 50,0 |
| MxT | 39,6 | 292 | 541 | 10 | 5 | 5 | 5 | 50,0 | 50,0 |
| RxT | 31,8 | 172 | 430 | 5 | 5 | 4 | 0 | 80,0 | 100,0 |
| SxT | 41,7 | 296 | 565 | 6 | 3 | 3 | 3 | 50,0 | 50,0 |

O CRC RexN atingiu a sua capacidade máxima ao usar o algoritmo *Naive Bayes* e CRC MxT, ao usar o algoritmo IBK. Os CRCs RxT e SxT obtiveram melhora parcial ao usar o algoritmo J48. O desempenho final do CRCA, com os CRCs da Tabela 12 modificados, pode ser visualizado na Tabela 13.

Tabela 14: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,65 | 0,82 | 0,73 | 45 | 2 | 2 | 4 | 0 | 0 | 2 |
| Alegria (A) | 0,45 | 0,28 | 0,34 | 8 | 5 | 2 | 2 | 0 | 1 | 0 |
| Repugnância (Re) | 0,62 | 0,50 | 0,55 | 6 | 1 | 13 | 4 | 1 | 0 | 1 |
| Tristeza (T) | 0,66 | 0,80 | 0,73 | 2 | 1 | 1 | 37 | 3 | 0 | 2 |
| Medo (M) | 0,59 | 0,45 | 0,51 | 4 | 0 | 1 | 5 | 10 | 0 | 2 |
| Raiva (R) | 0,67 | 0,25 | 0,36 | 1 | 0 | 2 | 2 | 0 | 2 | 1 |
| Surpresa (S) | 0,65 | 0,60 | 0,63 | 3 | 2 | 0 | 2 | 3 | 0 | 15 |
| Média | 0,57 | 0,64 | 0,62 | Características: 805 | | | | | | |
| Acurácia | 63,5% | | | | | | | | | |

Considerando um nível de significância de 5%, foi aplicado o Teste Z (Diferença de Proporções) para comparar o desempenho do método ao classificar os dados do conjunto de teste: 1) usando apenas o classificador SVM multiclasse para classificar os dados na primeira camada do método, que obteve acurácia de 58%; e 2) usando o CRCA com limiar de rejeição e limiar de confusão para classificar os dados na primeira e segunda camada do método, que obteve acurácia de 63,5%.

Embora o CRCA apresentou um desempenho visivelmente melhor que o classificador SVM multiclasse, o resultado do teste apresentou um p-valor igual a 0,26 em relação à acurácia, não se pode afirmar que existe uma diferença significativa entre os dois classificadores que justifique a escolha de um ou de outro para classificar textos com as seis emoções básicas e *neutro*.

O terceiro experimento desta seção visa avaliar o CRCA que rejeita todas as instâncias na primeira camada e as classifica na segunda camada. Porém, utiliza na segunda camada apenas os CRCs que apresentaram um grau de confusão igual ou superior a 20%.

Os dados da primeira camada são pré-processados usando a configuração *Config_Pre_1* da Tabela 8.1. Na segunda camada, o CRCA é configurado para rejeitar todas as instâncias e usar um limiar de confusão = 20%. Assim, após geradas as probabilidades estimadas do conjunto de teste pelo classificador SVM multiclasse, as instâncias rejeitadas são encaminhadas para os 12 CRCs disponíveis.

Os CRCs são classificadores SVM binários configurados com *kernel* RBF padrão (*cost*=1, *gamma*=0), probabilidades estimadas=*false* e os dados são pré-processados usando a configuração *Config_Pre_6* da Tabela 8.1. Cada CRC obtém um novo conjunto de características.

O desempenho do CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada, pode ser visualizado na Tabela 14 e o desempenho individual dos CRCs pode ser visto na Tabela 15.

Tabela 15: Desempenho do CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|--------------|-------------|-------------|-----------------------------|---|----|----|----|---|----|
| | Precisão | Cobertura | F1 | N | A | Re | T | M | R | S |
| Neutro (N) | 0,64 | 0,75 | 0,69 | 41 | 6 | 3 | 4 | 0 | 0 | 1 |
| Alegria (A) | 0,33 | 0,39 | 0,36 | 6 | 7 | 2 | 2 | 0 | 1 | 0 |
| Repugnância (Re) | 0,55 | 0,42 | 0,48 | 6 | 2 | 11 | 3 | 3 | 0 | 1 |
| Tristeza (T) | 0,66 | 0,80 | 0,73 | 2 | 3 | 0 | 37 | 3 | 0 | 1 |
| Medo (M) | 0,56 | 0,46 | 0,50 | 4 | 1 | 1 | 5 | 10 | 0 | 1 |
| Raiva (R) | 0,67 | 0,25 | 0,36 | 2 | 0 | 2 | 1 | 0 | 2 | 1 |
| Surpresa (S) | 0,72 | 0,52 | 0,61 | 3 | 2 | 1 | 4 | 2 | 0 | 13 |
| Média | 0,61 | 0,61 | 0,60 | Características: 805 | | | | | | |
| Acurácia | 60,5% | | | | | | | | | |

Tabela 16: Desempenho dos CRCs ao classificar as instâncias rejeitadas mais confusas

| CRC | Limiar de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|--------------------|-----------------|---------------------------|-------------------------|---------------------------|-----------|-----------------------------|-------------|-----------------------|
| AxS | 23,1 | 253 | 349 | 16 | 12 | 11 | 4 | 68,8 | 75,0 |
| AxT | 21,7 | 293 | 510 | 4 | 2 | 2 | 2 | 50,0 | 50,0 |
| RexM | 28,0 | 193 | 388 | 5 | 3 | 2 | 2 | 40,0 | 60,0 |
| RexR | 25,0 | 248 | 277 | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| RexT | 26,4 | 300 | 573 | 14 | 11 | 10 | 3 | 71,4 | 78,6 |
| MxN | 38,8 | 233 | 611 | 3 | 3 | 3 | 0 | 100,0 | 100,0 |
| MxR | 33,3 | 78 | 245 | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| NxR | 33,3 | 259 | 500 | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| NxS | 36,5 | 389 | 635 | 6 | 4 | 4 | 2 | 66,7 | 66,7 |
| NxT | 25,0 | 363 | 796 | 13 | 7 | 5 | 6 | 38,5 | 53,8 |
| RxS | 40,0 | 151 | 269 | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| SxT | 32,7 | 296 | 565 | 7 | 4 | 2 | 3 | 28,6 | 57,1 |
| TOTAL | | | | 71 | 47 | 40 | 24 | | |

Procurou-se melhorar o desempenho dos CRCs obtendo-se a melhor configuração de pré-processamento da Tabela 8.1 para cada um dos CRCs. Os CRCs que apresentaram melhora no desempenho são apresentados na Tabela 16.

Tabela 17: CRCs que tiveram melhora em função da configuração do pré-processamento

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxS | 253 | 349 | 16 | 12 | 12 | 4 | 75,0 | 75,0 |
| RexM | 193 | 388 | 5 | 3 | 3 | 2 | 60,0 | 60,0 |
| NxT | 363 | 796 | 13 | 7 | 6 | 6 | 46,2 | 53,8 |

Os CRCs AxS (configurado com *Config_Pre_24*) e RexM (configurado com *Config_Pre_4*) atingiram a sua capacidade máxima e o CRC e NxT (configurado com *Config_Pre_20*) obteve uma melhora parcial da sua capacidade. Para os CRCs que não obtiveram melhorias no desempenho foi mantida a configuração *Config_Pre_6*. Também não houve me-

lhorias nos CRCs ao submetê-los aos outros algoritmos de classificação (*Naive Bayes*, J48 e IBK). Assim, o desempenho final do CRCA pode ser visualizado na Tabela 17.

Tabela 18: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,65 | 0,76 | 0,70 | 42 | 6 | 3 | 3 | 0 | 0 | 1 |
| Alegria (A) | 0,37 | 0,39 | 0,38 | 6 | 7 | 2 | 2 | 0 | 1 | 0 |
| Repugnância (Re) | 0,57 | 0,46 | 0,51 | 6 | 2 | 12 | 3 | 2 | 0 | 1 |
| Tristeza (T) | 0,67 | 0,80 | 0,73 | 2 | 2 | 0 | 37 | 3 | 0 | 2 |
| Medo (M) | 0,59 | 0,46 | 0,51 | 4 | 1 | 1 | 5 | 10 | 0 | 1 |
| Raiva (R) | 0,67 | 0,25 | 0,36 | 2 | 0 | 2 | 1 | 0 | 2 | 1 |
| Surpresa (S) | 0,70 | 0,56 | 0,62 | 3 | 1 | 1 | 4 | 2 | 0 | 14 |
| Média | 0,62 | 0,62 | 0,61 | Características: 805 | | | | | | |
| Acurácia | 62,0% | | | | | | | | | |

O Teste Z (Diferença de Proporções) foi aplicado, em um nível de significância de 5%, para comparar o desempenho do método ao classificar o conjunto de teste: 1) usando apenas o classificador SVM multiclasse da primeira camada, que obteve acurácia de 58%; e 2) usando o CRCA que rejeita todas as instâncias e usa um limiar de rejeição = 20%, que obteve acurácia de 62,0%.

O resultado do teste estatístico apresentou um p-valor igual a 0,41 e assim, não se pode afirmar que existe uma diferença significativa entre os dois classificadores que justifique a escolha de um ou de outro.

A partir deste ponto da seção, foram realizados experimentos que visam verificar o desempenho do método ao ser avaliado com textos que tiveram/não tiveram concordância entre os anotadores durante o processo de anotação.

O quarto experimento usa uma amostra de 994 textos do corpus de notícias. Esses textos tiveram discordância entre os anotadores durante a primeira e a segunda anotação.

Os textos foram pré-processados usando a configuração *Config_Pre_3* da Tabela 8.1. O desempenho do classificador SVM multiclasse, ao avaliar o conjunto de textos por meio de Validação Cruzada com dez partes, pode ser visualizado na Tabela 18.

Tabela 19: Desempenho do classificador SVM multiclasse avaliado com textos sem concordância entre os anotadores

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,63 | 0,81 | 0,71 | 218 | 6 | 22 | 3 | 11 | 3 | 6 |
| Alegria (A) | 0,39 | 0,24 | 0,29 | 36 | 20 | 6 | 1 | 3 | 8 | 10 |
| Repugnância (Re) | 0,52 | 0,46 | 0,49 | 46 | 5 | 83 | 8 | 16 | 9 | 12 |
| Tristeza (T) | 0,67 | 0,60 | 0,63 | 16 | 5 | 15 | 103 | 17 | 11 | 5 |
| Medo (M) | 0,57 | 0,52 | 0,55 | 13 | 3 | 11 | 23 | 67 | 6 | 5 |
| Raiva (R) | 0,41 | 0,55 | 0,47 | 4 | 2 | 8 | 7 | 1 | 30 | 3 |
| Surpresa (S) | 0,57 | 0,51 | 0,54 | 12 | 11 | 14 | 8 | 2 | 6 | 54 |
| Média | 0,57 | 0,58 | 0,57 | Características: 500 | | | | | | |
| Acurácia | 57,8% | | | | | | | | | |

O quinto experimento desta seção usa uma amostra de 994 textos do corpus de notícias. Estes textos tiveram concordância entre os anotadores durante a primeira e a segunda anotação.

Os textos foram pré-processados usando a configuração *Config_Pre_3* da Tabela 8.1. O desempenho do classificador SVM multiclasse, ao avaliar o conjunto de textos por meio de Validação Cruzada com dez partes, pode ser visualizado na Tabela 19.

Tabela 20: Desempenho do classificador SVM multiclasse avaliado com textos com concordância entre os anotadores

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-----------|-----------------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,74 | 0,86 | 0,80 | 253 | 8 | 8 | 9 | 5 | 0 | 11 |
| Alegria (A) | 0,48 | 0,29 | 0,36 | 32 | 28 | 8 | 12 | 1 | 1 | 15 |
| Repugnância (Re) | 0,45 | 0,50 | 0,48 | 14 | 1 | 33 | 13 | 1 | 0 | 4 |
| Tristeza (T) | 0,73 | 0,80 | 0,77 | 24 | 7 | 10 | 240 | 8 | 0 | 10 |
| Medo (M) | 0,51 | 0,32 | 0,39 | 6 | 2 | 4 | 27 | 23 | 0 | 11 |
| Raiva (R) | 0,50 | 0,13 | 0,21 | 0 | 0 | 4 | 6 | 1 | 2 | 2 |
| Surpresa (S) | 0,63 | 0,61 | 0,62 | 13 | 12 | 6 | 21 | 6 | 1 | 91 |
| Média | 0,66 | 0,67 | 0,66 | Características: 551 | | | | | | |
| Acurácia | 67,4% | | | | | | | | | |

Analisando-se os resultados dos dois últimos experimentos foi possível verificar que o método obteve melhor desempenho ao utilizar os textos que tiveram total concordância durante a anotação.

Aplicou-se o Teste Z (Diferença de Proporções), em um nível de significância de 5%, para verificar se a acurácia de 67,4%, obtida com o método ao ser avaliado com o conjunto de textos com total concordância é significativamente maior que 57,8%, que se refere a acurácia obtida com o método ao ser avaliado com o conjunto de textos sem concordância.

O resultado do teste apresentou p-valor igual a 0,000004. Portanto, é possível concluir que o método obteve um desempenho significativamente superior ao ser treinado e avaliado com textos que tiveram total concordância entre os anotadores durante o processo de anotação.

No sexto experimento, os conjuntos de textos usados nos dois experimentos anteriores foram unidos em um único conjunto, composto de 1.988 textos, a fim de avaliar o método ao usar uma mesma quantidade de textos que tiveram/não tiveram concordância no processo de anotação.

Os textos foram pré-processados usando a configuração *Config_Pre_3* da Tabela 8.1. O desempenho do classificador SVM multiclasse, ao avaliar o conjunto de textos por meio de Validação Cruzada com dez partes, pode ser visualizado na Tabela 20.

Tabela 21: Desempenho do classificador SVM multiclasse avaliado com textos com e sem concordância entre os anotadores

| Classe | SVM | | | Matriz de Confusão | | | | | | |
|------------------|-----------------|------------------|-----------|--------------------|----------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>N</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Neutro (N) | 0,64 | 0,80 | 0,72 | 433 | 21 | 23 | 24 | 14 | 0 | 25 |
| Alegria (A) | 0,43 | 0,31 | 0,36 | 68 | 57 | 12 | 16 | 6 | 8 | 16 |
| Repugnância (Re) | 0,53 | 0,40 | 0,46 | 69 | 11 | 105 | 33 | 19 | 12 | 11 |
| Tristeza (T) | 0,63 | 0,69 | 0,66 | 43 | 16 | 21 | 312 | 34 | 14 | 13 |

| | | | | | | | | | | |
|-----------------|--------------|------|------|-----------------------------|----|----|----|-----|----|-----|
| Medo (M) | 0,56 | 0,50 | 0,53 | 21 | 3 | 6 | 58 | 110 | 8 | 14 |
| Raiva (R) | 0,37 | 0,33 | 0,35 | 9 | 1 | 14 | 25 | 1 | 27 | 5 |
| Surpresa (S) | 0,61 | 0,53 | 0,57 | 29 | 25 | 18 | 27 | 13 | 5 | 133 |
| Média | 0,58 | 0,59 | 0,58 | Características: 484 | | | | | | |
| Acurácia | 59,2% | | | | | | | | | |

Aplicou-se o Teste Z (Diferença de Proporções), em um nível de significância de 5%, para verificar existe diferença significativa entre a acurácia de 59,2%, obtida no método ao ser avaliado com um conjunto de 1.988 textos (sendo 994 com concordância e 994 sem concordância) e a acurácia de 67,4%, obtida no método ao ser avaliado com o conjunto de 994 textos que tiveram concordância durante a anotação.

O resultado do teste apresentou p-valor igual a 0,00001 e permitiu concluir que o desempenho do método foi melhor quando se usou textos com total concordância. Dessa forma, foi possível observar que textos que tiveram discordância durante anotação prejudicaram o processo de aprendizagem.

Analisando-se os resultados dos três últimos experimentos desta seção, foi possível observar que ao testar o método com a porção de textos do corpus de notícias que tiveram total concordância obteve-se uma taxa de acerto de 67,4%, o que pode ser considerado um bom resultado visto que o método é usado para identificar emoções em textos escritos em Português Brasileiro e identifica categorias de emoções usando uma abordagem totalmente livre de léxicos de termos emocionais. Porém, neste caso, o fato do método ter sido treinado somente com textos que tiveram total concordância não reflete a realidade dos dados reais e assim, a acurácia de 59,2%, apresentada na Tabela 20, representa um resultado mais realista.

2) Experimentos com o Método ao Classificar Textos com as Seis Emoções Básicas

Os objetivos dos experimentos desta seção consistem: 1) Avaliar o impacto dos filtros de redução de dimensionalidade e de seleção de características no classificador da primeira camada; 2) Avaliar o CRCA que usa limiar de rejeição e limiar de confusão e validar os CRCs; 3) Avaliar o CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada.

Nesta seção, os experimentos foram realizados com os textos do corpus de notícias que se referem às classes *alegria*, *tristeza*, *raiva*, *repugnância*, *medo* e *surpresa*. Foram usados 1.167 textos para o treinamento, e 145 para teste e 146 textos para validação.

O primeiro experimento desta seção visa avaliar o impacto dos filtros de redução de dimensionalidade e de seleção de características no método. Dessa forma, o classificador SVM multiclasse da primeira camada do método será avaliado primeiramente sem o uso dos filtros e na sequência com o uso deles.

O classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e avaliado com o conjunto de teste. Os dados submetidos ao classificador são pré-processados usando a configuração de pré-processamento *Config_Pre_13*, que não utiliza filtros de redução de dimensionalidade e de seleção de características. O resultado obtido com o classificador SVM multiclasse, ao usar um pré-processamento sem filtros, pode ser visualizado na Tabela 21.

Tabela 22: Desempenho do classificador SVM multiclasse ao usar um pré-processamento sem filtros

| Classe | SVM | | | Matriz de Confusão | | | | | |
|--------|-----------------|------------------|-----------|--------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>R</i> | <i>M</i> | <i>S</i> |

| | | | | | | | | | |
|------------------|--------------|-------------|-------------|--------------------------------|---|----|---|---|----|
| Alegria (A) | 0,14 | 0,06 | 0,08 | 1 | 0 | 15 | 0 | 0 | 2 |
| Repugnância (Re) | 0,69 | 0,35 | 0,46 | 2 | 9 | 13 | 0 | 1 | 1 |
| Tristeza (T) | 0,40 | 0,83 | 0,54 | 3 | 1 | 38 | 1 | 2 | 1 |
| Raiva (R) | 0,67 | 0,25 | 0,36 | 0 | 2 | 4 | 2 | 0 | 0 |
| Medo (M) | 0,67 | 0,27 | 0,39 | 0 | 0 | 15 | 0 | 6 | 1 |
| Surpresa (S) | 0,72 | 0,52 | 0,61 | 1 | 1 | 10 | 0 | 0 | 13 |
| Média | 0,53 | 0,48 | 0,45 | Características = 7.464 | | | | | |
| Acurácia | 47,6% | | | | | | | | |

O classificador SVM multiclasse ao ser treinado e avaliado com textos pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1, que usa filtros de redução de dimensionalidade e de seleção de características, obteve o desempenho apresentado na Tabela 22.

Tabela 23: Desempenho do classificador SVM multiclasse ao usar pré-processamento com filtros

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-------------|------------------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Alegria (A) | 0,33 | 0,44 | 0,38 | 8 | 1 | 2 | 2 | 1 | 4 |
| Repugnância (Re) | 0,61 | 0,54 | 0,57 | 4 | 14 | 5 | 3 | 0 | 0 |
| Tristeza (T) | 0,67 | 0,67 | 0,67 | 4 | 3 | 31 | 5 | 1 | 2 |
| Medo (M) | 0,46 | 0,50 | 0,48 | 2 | 2 | 4 | 11 | 1 | 2 |
| Raiva (R) | 0,33 | 0,25 | 0,29 | 0 | 2 | 2 | 1 | 2 | 1 |
| Surpresa (S) | 0,59 | 0,52 | 0,55 | 6 | 1 | 2 | 2 | 1 | 13 |
| Média | 0,55 | 0,55 | 0,55 | Características = 545 | | | | | |
| Acurácia | 54,5% | | | | | | | | |

Analisando o desempenho do classificador SVM multiclasse que usa filtros no pré-processamento (Tabela 21) e o desempenho do SVM multiclasse que não usa filtros no pré-processamento (Tabela 22), foi possível observar que houve um aumento relevante da acurácia, e da média de F1. Além disso, ocorreu uma diminuição considerável no número de características. Para verificar se existe diferença significativa entre a média de F1 sem filtros e a média de F1 com filtros, foi aplicado o Teste Z (Diferença de Proporções), em um nível de significância de 5%.

O p-valor obtido com o teste é igual a 0,02 e permite afirmar que existe uma melhora significativa de F1 ao se usar no método uma configuração de pré-processamento com filtros de redução de dimensionalidade e de seleção de características. Assim, conclui-se que o uso desses filtros são fundamentais no método ao classificar textos com as emoções básicas. Porém, também neste experimento, as classes *raiva* e *surpresa* tiveram o F1 reduzido ao fazer uso dos filtros. O baixo número de instâncias da classe *raiva* e o alto grau de entropia da classe *surpresa* continuam contribuindo para que este fato tenha ocorrido.

O segundo experimento desta seção visa avaliar o CRCA que utiliza um limiar de rejeição na primeira camada e um limiar de confusão para criar os CRCs da segunda camada. Neste experimento, o classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e o CRCA é avaliado com o conjunto de teste. Além disso, o CRCA também é avaliado com o conjunto de validação.

Os dados da primeira camada são pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1. Na segunda camada, o CRCA é configurado para criar CRCs biná-

rios e utilizar a ER CHOW, a qual obtém automaticamente, um limiar de rejeição = 0,56. O método aplica o limiar de rejeição nos dados do conjunto de treinamento e calcula o grau de confusão para cada CRC em função das probabilidades estimadas das instâncias rejeitadas.

Estabelecendo-se um limiar de confusão = 20%, todos os CRCs com grau de confusão igual ou superior a este limiar serão criados para classificar os dados da segunda camada. Os CRCs são classificadores SVM binários configurados com *kernel* RBF padrão (*cost*=1, *gamma*=0), probabilidades estimadas=*false* e pré-processam os dados usando a configuração *Config_Pre_9* da Tabela 8.1. Cada CRC obtém um novo conjunto de características.

Ao ser avaliado com o conjunto de teste, o CRCA rejeitou 61 instâncias na primeira camada. Dessas, 57 foram classificadas na segunda camada pelos 12 CRCs criados durante o treinamento e quatro delas, como não havia nenhum CRC disponível, foram classificadas pelo classificador SVM multiclasse. O desempenho do CRCA é mostrado na Tabela 23 e os resultados obtidos com os CRCs são mostrados na Tabela 24.

Tabela 24: Desempenho do CRCA ao avaliar o conjunto de teste

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-------------|------------------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Alegria (A) | 0,56 | 0,50 | 0,53 | 9 | 3 | 3 | 1 | 1 | 1 |
| Repugnância (Re) | 0,65 | 0,58 | 0,61 | 1 | 15 | 5 | 3 | 0 | 2 |
| Tristeza (T) | 0,63 | 0,74 | 0,68 | 2 | 1 | 34 | 4 | 1 | 4 |
| Medo (M) | 0,48 | 0,46 | 0,47 | 1 | 2 | 6 | 10 | 1 | 2 |
| Raiva (R) | 0,40 | 0,25 | 0,31 | 0 | 1 | 3 | 0 | 2 | 2 |
| Surpresa (S) | 0,58 | 0,60 | 0,59 | 3 | 1 | 3 | 3 | 0 | 15 |
| Média | 0,58 | 0,59 | 0,58 | Características = 545 | | | | | |
| Acurácia | 58,6% | | | | | | | | |

Tabela 25: Desempenho dos CRCs ao classificar as instâncias do conjunto de teste

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encamiñadas | Tem capacidade de acertar | Acer-tou | Encamiñadas incorretamente | Acer-tou (%) | Capacidade Máxima (%) |
|--------------|---------------|-----------------|---------------------------|------------------------|---------------------------|-----------|----------------------------|--------------|-----------------------|
| AxRe | 33,3 | 314 | 357 | 7 | 6 | 6 | 1 | 85,7 | 85,7 |
| AxS | 37,5 | 282 | 349 | 7 | 5 | 5 | 2 | 71,4 | 71,4 |
| AxT | 35,1 | 430 | 510 | 2 | 0 | 0 | 2 | 0,0 | 0,00 |
| AxM | 28,6 | 193 | 325 | 0 | 0 | 0 | 0 | 0,0 | 0,00 |
| RexM | 53,3 | 255 | 388 | 5 | 3 | 2 | 2 | 40,0 | 60,0 |
| RexS | 27,0 | 291 | 412 | 10 | 7 | 5 | 3 | 50,0 | 70,0 |
| RexT | 43,0 | 313 | 573 | 6 | 4 | 2 | 2 | 33,3 | 66,7 |
| MxS | 61,5 | 314 | 380 | 2 | 2 | 2 | 0 | 100,0 | 100,0 |
| MxT | 42,0 | 302 | 541 | 9 | 4 | 3 | 5 | 33,3 | 44,4 |
| RxT | 39,1 | 168 | 430 | 3 | 1 | 1 | 2 | 33,3 | 33,3 |
| RxS | 40,0 | 269 | 269 | 2 | 1 | 0 | 1 | 0,0 | 50,0 |
| SxT | 46,3 | 404 | 565 | 4 | 2 | 0 | 2 | 0,0 | 50,0 |
| TOTAL | | | | 57 | 35 | 26 | 22 | | |

Na sequência, foi utilizado o conjunto dos dados de validação para comparar o desempenho dos CRCs com o desempenho do classificador SVM multiclasse. O desempenho dos CRCs ao classificar as instâncias rejeitadas do conjunto de validação pode ser visto na Tabela 25 e o desempenho do classificador SVM multiclasse ao classificar as instâncias rejeitadas do conjunto de validação pode ser visto na Tabela 26.

Tabela 26: Desempenho dos CRCs ao classificar as instâncias rejeitadas do conjunto de validação

| CRC | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|-------------------------|---------------------------|-----------|-----------------------------|-------------|-----------------------|
| AxRe | 9 | 8 | 5 | 1 | 55,6 | 88,9 |
| AxS | 8 | 4 | 3 | 4 | 37,5 | 50,0 |
| AxT | 6 | 3 | 2 | 3 | 33,3 | 50,0 |
| AxM | 3 | 2 | 0 | 1 | 0,0 | 66,7 |
| AxR | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| RexM | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| RexS | 4 | 2 | 1 | 2 | 25,0 | 50,0 |
| RexT | 13 | 7 | 4 | 6 | 30,8 | 53,8 |
| RexR | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| MxS | 4 | 3 | 2 | 1 | 50,0 | 75,0 |
| MxT | 11 | 8 | 7 | 3 | 63,6 | 72,7 |
| MxR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| RxT | 4 | 4 | 1 | 0 | 25,0 | 100,0 |
| RxS | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| SxT | 7 | 4 | 1 | 3 | 14,3 | 57,1 |
| Total | 74 | 49 | 27 | 25 | | |

Tabela 27: Desempenho do classificador SVM multiclasse ao classificar as instâncias rejeitadas do conjunto de validação

| CRC | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxRe | 9 | 8 | 6 | 1 | 66,7 | 88,9 |
| AxS | 8 | 4 | 4 | 4 | 50,0 | 50,0 |
| AxT | 6 | 3 | 1 | 3 | 16,7 | 50,0 |
| AxM | 3 | 2 | 0 | 1 | 0,0 | 66,7 |
| AxR | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| RexM | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| RexS | 4 | 2 | 1 | 2 | 25,0 | 50,0 |
| RexT | 13 | 7 | 4 | 6 | 30,8 | 53,8 |
| RexR | 1 | 0 | 0 | 1 | 0,0 | 100,0 |
| MxS | 4 | 3 | 1 | 1 | 25,0 | 75,0 |
| MxT | 11 | 8 | 3 | 3 | 27,3 | 72,7 |
| MxR | 1 | 1 | 1 | 0 | 100,0 | 100,0 |
| RxT | 4 | 4 | 1 | 0 | 25,0 | 100,0 |
| RxS | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| SxT | 7 | 4 | 1 | 3 | 14,3 | 57,1 |

| | | | | | | |
|--------------|-----------|-----------|-----------|-----------|--|--|
| Total | 74 | 49 | 23 | 25 | | |
|--------------|-----------|-----------|-----------|-----------|--|--|

No processo de validação, o CRCA classifica os dados rejeitados com os CRCs somente se o desempenho deles for igual ou superior ao desempenho obtido com o classificador SVM multiclasse. Dessa forma, na segunda camada do CRCA foram usados apenas 10 CRCs, sendo que esses foram selecionados por terem um desempenho igual ou superior ao classificador SVM multiclasse. No processo de validação, o desempenho dos CRCs pode ser visualizado na Tabela 27 e o desempenho do CRCA é mostrado na Tabela 28.

Tabela 28: CRCs usados no processo de validação do CRCA

| CRC | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|--------------------------------|----------------------------------|----------------|------------------------------------|--------------------|------------------------------|
| AxT | 6 | 3 | 2 | 3 | 33,3 | 50,0 |
| AxM | 3 | 2 | 0 | 1 | 0,0 | 66,7 |
| RexM | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| RexS | 4 | 2 | 1 | 2 | 25,0 | 70,0 |
| RexT | 13 | 7 | 4 | 6 | 30,8 | 53,8 |
| MxS | 4 | 3 | 2 | 1 | 50,0 | 75,0 |
| MxT | 11 | 8 | 7 | 3 | 63,6 | 72,7 |
| RxT | 4 | 4 | 1 | 0 | 25,0 | 100,0 |
| RxS | 1 | 1 | 0 | 0 | 0,0 | 100,0 |
| SxT | 7 | 4 | 1 | 3 | 14,3 | 57,1 |
| Total | 54 | 35 | 18 | 19 | | |

Tabela 29: Desempenho do CRCA no processo de validação

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-----------|------------------------------|-----------|----------|----------|----------|----------|
| | Precisão | Cobertura | F1 | A | Re | T | R | M | S |
| Alegria (A) | 0,36 | 0,44 | 0,40 | 8 | 3 | 3 | 1 | 1 | 2 |
| Repugnância (Re) | 0,62 | 0,50 | 0,55 | 3 | 13 | 5 | 0 | 3 | 2 |
| Tristeza (T) | 0,63 | 0,74 | 0,68 | 4 | 1 | 34 | 1 | 4 | 2 |
| Raiva (R) | 0,40 | 0,25 | 0,31 | 0 | 1 | 3 | 2 | 0 | 2 |
| Medo (M) | 0,48 | 0,46 | 0,47 | 1 | 2 | 6 | 1 | 10 | 2 |
| Surpresa (S) | 0,55 | 0,48 | 0,51 | 6 | 1 | 3 | 0 | 3 | 12 |
| Média | 0,54 | 0,55 | 0,54 | Características = 545 | | | | | |
| Acurácia | 54,5% | | | | | | | | |

Observando o desempenho dos CRCs ao classificar os dados rejeitados do conjunto de validação (Tabela 25) e o classificador SVM multiclasse ao classificar os dados rejeitados do conjunto de validação (Tabela 26), constatou-se que o desempenho dos CRCs é superior ao desempenho do classificador SVM multiclasse na maioria dos casos.

Dando continuidade ao segundo experimento, a primeira ação para melhorar os CRCs foi obter para cada CRC da Tabela 24 a melhor configuração de pré-processamento (Tabela 8.1). Os CRCs nos quais a configuração do pré-processamento impactou na melhora do desempenho são apresentados na Tabela 29.

Tabela 30: CRCs que tiveram melhoria em função da configuração do pré-processamento

| CRC | % de confusão | Caracterís- | Instâncias de treina- | Instâncias en- | Tem capaci- | Acer- | Encami- | Acer- | Capaci- |
|------------|----------------------|--------------------|------------------------------|-----------------------|--------------------|--------------|----------------|--------------|----------------|
| | | terís- | treina- | cami- | dade de | tu | nhadas | tu | dade |
| | | | | | | | inorre- | (%) | Máxima |

| | | tics | mento | nhadas | acertar | | tamente | | (%) |
|------|------|------|-------|--------|---------|---|---------|------|------|
| RexM | 53,3 | 255 | 388 | 5 | 3 | 3 | 2 | 60,0 | 60,0 |
| RexT | 43,0 | 313 | 573 | 6 | 4 | 3 | 2 | 50,0 | 66,7 |
| MxT | 42,0 | 302 | 541 | 9 | 4 | 4 | 5 | 44,4 | 44,4 |
| RxS | 40,0 | 269 | 269 | 2 | 1 | 1 | 1 | 50,0 | 50,0 |

Os CRCs RexM (configurado com *Config_Pre_13*), MxT (configurado com *Config_Pre_4*) e RxS (configurado com *Config_Pre_10*) atingiram a sua capacidade máxima. O CRC RexT (configurado com *Config_Pre_6*) obteve uma melhora parcial da capacidade. Os demais CRCs não obtiveram melhoria no desempenho e, assim, manteve-se a configuração *Config_Pre_9*. O desempenho do CRCA, com os CRCs da Tabela 29 modificados, pode ser visualizado na Tabela 30.

Tabela 31: Desempenho do CRCA após modificação de configuração de pré-processamento dos CRCs

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-----------|-----------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Alegria (A) | 0,56 | 0,50 | 0,53 | 9 | 3 | 4 | 0 | 1 | 1 |
| Repugnância (Re) | 0,63 | 0,65 | 0,64 | 1 | 17 | 4 | 2 | 0 | 2 |
| Tristeza (T) | 0,67 | 0,74 | 0,70 | 2 | 1 | 34 | 4 | 1 | 4 |
| Medo (M) | 0,55 | 0,50 | 0,52 | 1 | 3 | 4 | 11 | 1 | 2 |
| Raiva (R) | 0,50 | 0,38 | 0,43 | 0 | 1 | 2 | 1 | 3 | 1 |
| Surpresa (S) | 0,60 | 0,60 | 0,60 | 3 | 2 | 3 | 2 | 0 | 15 |
| Média | 0,61 | 0,614 | 0,61 | Características = 545 | | | | | |
| Acurácia | 61,4% | | | | | | | | |

A segunda ação para melhorar os CRCs foi submetê-los aos outros algoritmos de classificação disponíveis na ferramenta. O CRC RexS foi o único que obteve melhora no desempenho, atingindo a sua capacidade máxima e, neste caso, usando o algoritmo J48. O desempenho final do CRCA pode ser visto na Tabela 31.

Tabela 32: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|--------------|-----------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>M</i> | <i>R</i> | <i>S</i> |
| Alegria (A) | 0,563 | 0,500 | 0,529 | 9 | 3 | 4 | 0 | 1 | 1 |
| Repugnância (Re) | 0,667 | 0,692 | 0,679 | 1 | 18 | 4 | 2 | 0 | 1 |
| Tristeza (T) | 0,667 | 0,739 | 0,701 | 2 | 1 | 34 | 4 | 1 | 4 |
| Medo (M) | 0,550 | 0,500 | 0,524 | 1 | 3 | 4 | 11 | 1 | 2 |
| Raiva (R) | 0,500 | 0,375 | 0,429 | 0 | 1 | 2 | 1 | 3 | 1 |
| Surpresa (S) | 0,640 | 0,640 | 0,640 | 3 | 1 | 3 | 2 | 0 | 16 |
| Média | 0,622 | 0,628 | 0,623 | Características = 545 | | | | | |
| Acurácia | 62,8% | | | | | | | | |

O Teste Z (Diferença de Proporções) foi aplicado, em um nível de significância de 5%, para comparar o desempenho do método ao classificar os dados do conjunto de teste: 1) usando apenas o classificador SVM multiclasse da primeira camada, que obteve acurácia de 54,5%; e 2) usando o CRCA com limiar de rejeição e limiar de confusão, que obteve acurácia de 62,8%.

Em relação a acurácia, embora seja aparente a diferença entre ambos, o resultado do teste estatístico apresentou um p-valor igual a 0,15 e dessa forma, não se pode afirmar que existe uma diferença significativa entre os dois classificadores que justifique a escolha de um ou de outro para classificar textos com as seis emoções básicas.

O terceiro experimento desta seção visa avaliar o CRCA que rejeita todas as instâncias na primeira camada e as classifica na segunda camada com os CRCs que apresentaram um grau de confusão igual ou superior a 20% durante o treinamento. Neste experimento, o classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e o CRCA é avaliado com o conjunto de teste.

Os dados da primeira camada são pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1. Na segunda camada, o CRCA é configurado para rejeitar todas as instâncias e usar limiar de confusão = 20%. Assim, após geradas as probabilidades estimadas dos dados do conjunto de teste pelo classificador SVM multiclasse, as instâncias rejeitadas são encaminhadas para os 11 CRCs disponíveis.

Os CRCs são classificadores SVM binários configurados com *kernel* RBF padrão (*cost*=1, *gamma*=0), probabilidades estimadas=*false* e os dados são pré-processados usando a configuração *Config_Pre_9* da Tabela 8.1. Para cada CRC é gerado um novo conjunto de características.

O desempenho do CRCA, que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada, pode ser visto na Tabela 32 e o desempenho individual dos CRCs pode ser visto na Tabela 33.

Tabela 33: Desempenho do CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>R</i> | <i>M</i> | <i>S</i> |
| Alegria (A) | 0,75 | 0,50 | 0,60 | 9 | 2 | 3 | 0 | 1 | 3 |
| Repugnância (Re) | 0,70 | 0,62 | 0,65 | 0 | 16 | 5 | 0 | 4 | 1 |
| Tristeza (T) | 0,62 | 0,78 | 0,69 | 2 | 1 | 36 | 2 | 2 | 3 |
| Raiva (R) | 0,40 | 0,25 | 0,31 | 0 | 2 | 3 | 2 | 0 | 1 |
| Medo (M) | 0,47 | 0,41 | 0,44 | 0 | 2 | 7 | 1 | 9 | 3 |
| Surpresa (S) | 0,61 | 0,68 | 0,64 | 1 | 0 | 4 | 0 | 3 | 17 |
| Média | 0,61 | 0,61 | 0,61 | Características = 545 | | | | | |
| Acurácia | 61,4% | | | | | | | | |

Tabela 34: Desempenho dos CRCs ao classificar as instâncias rejeitadas

| CRC | Limiar de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|--------------------|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxRe | 21,2 | 314 | 357 | 15 | 12 | 12 | 3 | 80,0 | 80,0 |
| AxS | 28,0 | 282 | 349 | 19 | 15 | 13 | 4 | 68,4 | 78,9 |
| AxT | 26,3 | 430 | 510 | 4 | 0 | 0 | 4 | 0,0 | 0,00 |
| AxM | 28,6 | 193 | 325 | 1 | 0 | 0 | 1 | 0,0 | 0,00 |
| RexM | 29,4 | 255 | 388 | 9 | 6 | 5 | 3 | 55,6 | 66,7 |
| RexT | 27,2 | 313 | 573 | 15 | 11 | 9 | 4 | 60,0 | 73,3 |
| MxS | 35,7 | 314 | 380 | 5 | 5 | 4 | 0 | 80,0 | 100,0 |
| MxT | 22,2 | 302 | 541 | 37 | 29 | 23 | 8 | 62,2 | 78,4 |
| RxT | 23,7 | 168 | 430 | 12 | 10 | 8 | 2 | 66,7 | 83,3 |

| | | | | | | | | | |
|--------------|------|-----|-----|------------|-----------|-----------|-----------|------|------|
| RxS | 33,3 | 269 | 269 | 4 | 2 | 1 | 2 | 25,0 | 50,0 |
| SxT | 36,8 | 404 | 565 | 7 | 5 | 3 | 2 | 42,9 | 71,4 |
| Total | | | | 128 | 95 | 78 | 33 | | |

A primeira ação para melhorar os CRCs foi obter a melhor configuração de pré-processamento da Tabela 8.1 para cada um dos CRCs. Os CRCs que apresentaram melhora no desempenho são apresentados na Tabela 34.

Tabela 35: CRCs que tiveram melhora em função da configuração do pré-processamento

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|------|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxS | 282 | 349 | 19 | 15 | 14 | 4 | 73,7 | 78,9 |
| RexS | 291 | 412 | 12 | 9 | 7 | 3 | 58,3 | 75,0 |
| RexT | 313 | 573 | 15 | 11 | 10 | 4 | 66,7 | 73,3 |
| MxS | 314 | 380 | 5 | 5 | 5 | 0 | 100,0 | 100,0 |
| MxT | 302 | 541 | 37 | 29 | 25 | 8 | 67,5 | 78,4 |
| RxS | 269 | 269 | 4 | 2 | 2 | 2 | 50,0 | 50,0 |

Os CRCs MxS (configurado com *Config_Pre_14*) e RxS (configurado com *Config_Pre_23*) atingiram a sua capacidade máxima. Os CRCs AxS (configurado com *Config_Pre_25*), RexS (configurado com *Config_Pre_2*), RexT (configurado com *Config_Pre_11*) e MxT (configurado com *Config_Pre_14*) atingiram melhora parcial da sua capacidade. Para os CRCs que não obtiveram melhora no desempenho foi mantida a configuração *Config_Pre_9*. O desempenho do CRCA, com os CRCs modificados da Tabela 34, pode ser visualizado na Tabela 35.

Tabela 36: CRCA com CRCs modificados em relação ao pré-processamento

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|--------------|-------------|-------------|-----------------------|----|----|---|---|----|
| | Precisão | Cobertura | F1 | A | Re | T | R | M | S |
| Alegria (A) | 0,75 | 0,50 | 0,60 | 9 | 2 | 4 | 0 | 0 | 3 |
| Repugnância (Re) | 0,74 | 0,65 | 0,69 | 0 | 17 | 6 | 0 | 2 | 1 |
| Tristeza (T) | 0,61 | 0,83 | 0,70 | 2 | 1 | 38 | 2 | 0 | 3 |
| Raiva (R) | 0,50 | 0,38 | 0,43 | 0 | 2 | 2 | 3 | 1 | 0 |
| Medo (M) | 0,64 | 0,41 | 0,50 | 1 | 1 | 8 | 1 | 9 | 2 |
| Surpresa (S) | 0,68 | 0,76 | 0,72 | 0 | 0 | 4 | 0 | 2 | 19 |
| Média | 0,66 | 0,66 | 0,65 | Características = 545 | | | | | |
| Acurácia | 65,5% | | | | | | | | |

A segunda ação para melhorar os CRCs foi submeter os CRCs aos algoritmos de classificação *Naive Bayes*, J48 e IBK. Os CRCs que obtiveram melhora no desempenho são mostrados na Tabela 36.

Tabela 37: Desempenho dos CRCs que obtiveram melhora com outros algoritmos de classificação

| CRC | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|-----|-----------------|---------------------------|-------------------------|---------------------------|---------|-----------------------------|-------------|-----------------------|
| AxR | 306 | 214 | 2 | 2 | 2 | 0 | 100,0 | 100,0 |
| RxT | 168 | 430 | 12 | 10 | 9 | 2 | 75,0 | 83,3 |

Os CRCs RexN e RxT obtiveram melhora no desempenho ao usar o algoritmo *Naive Bayes*. O resultado final do CRCA pode ser visualizado na Tabela 37.

Tabela 38: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | | | | |
|------------------|-----------------|------------------|-------------|-----------------------|-----------|----------|----------|----------|----------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>A</i> | <i>Re</i> | <i>T</i> | <i>R</i> | <i>M</i> | <i>S</i> |
| Alegria (A) | 0,75 | 0,50 | 0,60 | 9 | 2 | 4 | 0 | 0 | 3 |
| Repugnância (Re) | 0,74 | 0,65 | 0,69 | 0 | 17 | 6 | 0 | 2 | 1 |
| Tristeza (T) | 0,62 | 0,83 | 0,71 | 2 | 1 | 38 | 2 | 0 | 3 |
| Raiva (R) | 0,57 | 0,50 | 0,53 | 0 | 2 | 1 | 4 | 1 | 0 |
| Medo (M) | 0,64 | 0,41 | 0,50 | 1 | 1 | 8 | 1 | 9 | 2 |
| Surpresa (S) | 0,68 | 0,76 | 0,72 | 0 | 0 | 4 | 0 | 2 | 19 |
| Média | 0,67 | 0,66 | 0,65 | Características = 545 | | | | | |
| Acurácia | 66,2% | | | | | | | | |

O Teste Z (Diferença de Proporções) foi usado, em um nível de significância de 5%, para comparar o desempenho do método ao classificar os dados do conjunto de teste: 1) usando apenas o classificador SVM multiclasse da primeira camada, que obteve acurácia de 54,5%; e 2) usando o CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada, que obteve acurácia de 66,2%.

O teste estatístico apresentou um p-valor igual a 0,04, o que permite afirmar que existe diferença significativa entre os dois classificadores. Dessa forma, o CRCA que rejeita todas as instâncias na primeira camada e usa limiar de confusão para criar os CRCs da segunda camada, pode ser usado com sucesso na classificação de textos com as seis emoções básicas.

3) Experimentos com o Método ao Classificar Textos com a Polaridade das Emoções e Neutro

Os objetivos dos experimentos desta seção consistem: 1) Avaliar o impacto dos filtros de redução de dimensionalidade e de seleção de características no classificador SVM multiclasse do método; 2) Avaliar o CRCA que usa limiar de rejeição.

Nestes experimentos, os textos da classe *alegria* foram renomeados para *positivo* e os textos das classes *tristeza*, *repugnância*, *medo* e *raiva* foram renomeados para *negativo*. Os textos da classe *surpresa* não foram utilizados nestes experimentos por se tratarem de textos que podem ter uma polaridade *positiva* ou *negativa* e assim precisariam passar novamente por um processo de anotação. Foram utilizados 1.573 textos para o treinamento e 175 textos para o teste.

O primeiro experimento desta seção visa avaliar o impacto dos filtros de redução de dimensionalidade e de seleção de características no método. Dessa forma, o classificador SVM multiclasse da primeira camada do método é avaliado primeiramente sem o uso dos filtros e na sequência com o uso deles.

O classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e avaliado com o conjunto de teste. Os dados submetidos ao classificador são pré-processados usando a configuração de pré-processamento *Config_Pre_13*, que não utiliza filtros de redução de dimensionalidade e de seleção de características.

O classificador SVM multiclasse foi configurado com *kernel* RBF padrão (*cost*=1, *gamma*=0) e probabilidades estimadas = *true* e gera as probabilidades estimadas por meio de Validação Cruzada com dez partes. O desempenho obtido com o classificador SVM multiclasse, sem o uso de filtros no pré-processamento, pode ser visualizado na Tabela 38.

Tabela 39: Desempenho do classificador SVM multiclasse ao usar pré-processamento sem filtros

| Classe | SVM | | | Matriz de Confusão | | |
|-----------------|-----------------|------------------|-------------|--------------------------------|-----------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Neutro</i> | <i>Positivo</i> | <i>Negativo</i> |
| Neutro | 0,65 | 0,59 | 0,62 | 32 | 3 | 19 |
| Positivo | 0,50 | 0,16 | 0,24 | 8 | 3 | 8 |
| Negativo | 0,78 | 0,91 | 0,84 | 9 | 0 | 93 |
| Média | 0,71 | 0,73 | 0,71 | Características = 8.978 | | |
| Acurácia | 73,1% | | | | | |

O classificador SVM multiclasse ao ser treinado e avaliado com os textos pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1, obteve o resultado apresentado na Tabela 39.

Tabela 40: Desempenho do classificador SVM multiclasse ao usar pré-processamento com filtros

| Classe | SVM | | | Matriz de Confusão | | |
|-----------------|-----------------|------------------|-------------|------------------------------|-----------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Neutro</i> | <i>Positivo</i> | <i>Negativo</i> |
| Neutro | 0,68 | 0,78 | 0,72 | 42 | 1 | 11 |
| Positivo | 0,20 | 0,05 | 0,08 | 9 | 1 | 9 |
| Negativo | 0,82 | 0,86 | 0,84 | 11 | 3 | 88 |
| Média | 0,71 | 0,75 | 0,72 | Características = 966 | | |
| Acurácia | 75,0% | | | | | |

Analisando o desempenho do classificador SVM multiclasse que usa filtros no pré-processamento (Tabela 39) e o desempenho do SVM multiclasse que não usa filtros no pré-processamento (Tabela 38), foi possível observar que, embora houve uma diminuição significativa do número de características, isto não impactou diretamente na acurácia e no F1. O alto grau de desbalanceamento das classes pode ter contribuído para tal situação, uma vez que as classes minoritárias se beneficiaram ao se ter um número maior de características.

O segundo experimento visa avaliar o CRCA, que utiliza um limiar de rejeição para rejeitar as instâncias da primeira camada, e as classifica pelos CRCs da segunda camada. Neste experimento, o classificador SVM multiclasse da primeira camada é treinado com o conjunto de treinamento e o CRCA é avaliado com o conjunto de teste.

Os dados da primeira camada são pré-processados usando a configuração *Config_Pre_4* da Tabela 8.1. Na segunda camada, o CRCA é configurado para criar CRCs binários e utiliza a ER CHOW, que obtém automaticamente o limiar de rejeição = 0,73. Os CRCs são classificadores SVM binários configurados com *kernel* RBF padrão (*cost*=1, *gamma*=0),

probabilidades estimadas=*false* e os dados são pré-processados usando a configuração *Config_Pre_24* da Tabela 8.1. Para cada CRC é obtido um novo conjunto de características.

Ao ser avaliado com o conjunto de teste, o CRCA rejeitou 73 instâncias na primeira camada, que foram classificadas pelos três CRCs da segunda camada. O desempenho do CRCA é mostrado na Tabela 40 e os resultados obtidos com os CRCs são mostrados na Tabela 41.

Tabela 41: Desempenho do CRCA ao avaliar o conjunto de teste

| Classe | SVM | | | Matriz de Confusão | | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Neutro</i> | <i>Positivo</i> | <i>Negativo</i> |
| Neutro | 0,71 | 0,65 | 0,68 | 35 | 0 | 19 |
| Positivo | 0,25 | 0,05 | 0,10 | 7 | 1 | 11 |
| Negativo | 0,75 | 0,90 | 0,82 | 7 | 3 | 92 |
| Média | 0,69 | 0,73 | 0,70 | Características = 966 | | |
| Acurácia | 73,1% | | | | | |

Tabela 42: Desempenho dos CRCs ao classificar as instâncias mais confusas do conjunto de teste

| CRC | % de confusão | Características | Instâncias de treinamento | Instâncias encaminhadas | Tem capacidade de acertar | Acertou | Encaminhadas incorretamente | Acertou (%) | Capacidade Máxima (%) |
|--------------|---------------|-----------------|---------------------------|-------------------------|---------------------------|-----------|-----------------------------|-------------|-----------------------|
| PosXNeu | 15,5 | 407 | 653 | 9 | 7 | 6 | 2 | 66,7 | 77,8 |
| NegXNeu | 29,8 | 772 | 1408 | 55 | 33 | 28 | 22 | 50,9 | 60,0 |
| NegXPos | 22,1 | 660 | 1085 | 9 | 8 | 6 | 1 | 66,7 | 88,9 |
| TOTAL | | | | 73 | 48 | 40 | 25 | | |

Nenhum dos CRCs da Tabela 8.55 obteve melhora em relação a configuração de pré-processamento e apenas os CRCs NegXNeu e PosXNeg obtiveram melhora no desempenho ao usar outro algoritmo de classificação, neste caso, o *Naive Bayes*. O desempenho final do CRCA pode ser visto na Tabela 42.

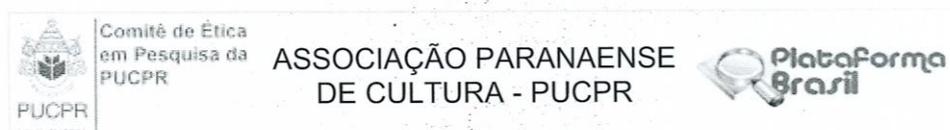
Tabela 43: Desempenho final do CRCA

| Classe | SVM | | | Matriz de Confusão | | |
|-----------------|-----------------|------------------|-------------|-----------------------|-----------------|-----------------|
| | <i>Precisão</i> | <i>Cobertura</i> | <i>F1</i> | <i>Neutro</i> | <i>Positivo</i> | <i>Negativo</i> |
| Neutro | 0,70 | 0,82 | 0,75 | 42 | 1 | 9 |
| Positivo | 0,29 | 0,11 | 0,15 | 8 | 2 | 9 |
| Negativo | 0,83 | 0,85 | 0,84 | 11 | 4 | 87 |
| Média | 0,73 | 0,76 | 0,74 | Características = 966 | | |
| Acurácia | 76% | | | | | |

Neste experimento, o desempenho do classificador SVM multiclasse foi visivelmente superior ao desempenho do CRCA. O desbalanceamento das classes, altamente presente na classificação multiclasse, se intensificou ainda mais na classificação binária.

Anexos

ANEXO 1 - Parecer consubstanciado do Comitê de Ética em Pesquisa da PUCPR



PARECER CONSUBSTANCIADO DO CEP

DADOS DO PROJETO DE PESQUISA

Título da Pesquisa: MÉTODO PARA A IDENTIFICAÇÃO DE EMOÇÕES EM TEXTOS EM PORTUGUÊS DO BRASIL USANDO MÁQUINA DE VETORES DE SUPORTE EM SOLUÇÃO MULTICLASSE

Pesquisador: Mariza Miola Dosciatti

Área Temática:

Versão: 3

CAAE: 24764813.7.0000.0020

Instituição Proponente: Pontifícia Universidade Católica do Parana - PUCPR

Patrocinador Principal: Financiamento Próprio

DADOS DO PARECER

Número do Parecer: 543.309

Data da Relatoria: 26/02/2014

Apresentação do Projeto:

Trata-se de projeto em terceira versão no qual se pretende apresentar um método para a identificação automática das emoções encontradas em textos escritos em Português do Brasil. As emoções a serem identificadas nos textos se referem às seis emoções básicas de Ekman e Friesen (EKMAN e FRIESEN, 1978) sendo elas alegria, tristeza, raiva, medo, desgosto e surpresa. Neste método, será proposto o uso do algoritmo Support Vector Machine (SVM) para tratar o problema de forma multiclasse (as seis emoções básicas além de uma sétima classe chamada de neutro). Para testar o método proposto, corpora de textos, como notícias jornalísticas e blogs estão sendo construídos.

Objetivo da Pesquisa:

Objetivo Primário:

O objetivo principal desta pesquisa é propor um método que identifique em um texto as seis emoções básicas contidas em textos escritos em Português do Brasil.

Objetivo Secundário:

Os objetivos específicos compreendem: Construir um conjunto de dados composto de textos; Avaliar os elementos inter-regionais no tratamento das emoções, verificando se há ou não diferenças regionais na expressão das emoções em textos em Português do Brasil; Propor uma

Endereço: Rua Imaculada Conceição 1155
Bairro: Prado Velho **CEP:** 80.215-901
UF: PR **Município:** CURITIBA
Telefone: (41)3271-2292 **Fax:** (41)3271-2292 **E-mail:** nep@pucpr.br





Continuação do Parecer: 543.309

forma de amenizar o problema do desbalanceamento natural das classes dos corpora; Desenvolver um prototipo para validacao e avaliacao do metodo proposto.

Avaliação dos Riscos e Benefícios:

Riscos:

Levando-se em conta que e uma pesquisa, e os resultados positivos ou negativos somente serao obtidos apos a sua realizacao. Assim, o tempo despendido pelos sujeitos participantes neste experimento podera ser em vao, visto que a pesquisa pode nao revelar resultados significativos.

Benefícios:

Em relacao aos sujeitos participantes, os benefiçozios seraçoz indiretos, tais como: com a construçoz de um metodo capaz de identificar automaticamente as emocçozes em textos escritos em Portuguezs do Brasil, o sujeito participante, assim como qualquer indiviçozduo da comunidade poderaçoz usufruir desta pesquisa podendo aplicar o meçoztodo em diversos contextos, como por exemplo, animaçozaçoz de figuras animadas (avatars), extraçozaçoz de informaçozes relacionadas a emocçozaçoz de indiviçozduos em textos postados em redes sociais, dentre outras aplicaçozes.

Comentários e Considerações sobre a Pesquisa:

O TCLE continha a frase "Tambem estou ciente que nao terei qualquer despesa e que nao serei ressarcido portanto por participar da pesquisa" que estava inadequada e necessitaria ser alterada.

Considerações sobre os Termos de apresentação obrigatória:

O TCLE foi reajustado adequadamente.

Recomendações:

O TCLE foi reajustado adequadamente.

Conclusões ou Pendências e Lista de Inadequações:

Aprovado.

Situação do Parecer:

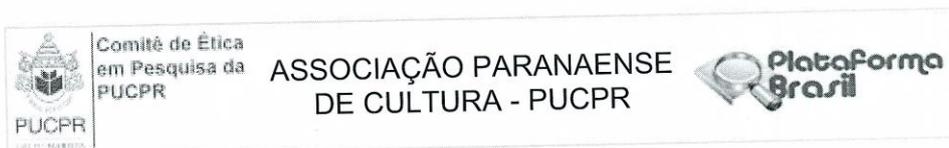
Aprovado

Necessita Apreciação da CONEP:

Não

Endereço: Rua Imaculada Conceição 1155
 Bairro: Prado Velho CEP: 80.215-901
 UF: PR Município: CURITIBA
 Telefone: (41)3271-2292 Fax: (41)3271-2292 E-mail: nep@pucpr.br





Continuação do Parecer: 543.309

Considerações Finais a critério do CEP:

Lembramos aos senhores pesquisadores que, no cumprimento da Resolução 466/12, o Comitê de Ética em Pesquisa (CEP) deverá receber relatórios anuais sobre o andamento do estudo, bem como a qualquer tempo e a critério do pesquisador nos casos de relevância, além do envio dos relatos de eventos adversos, para conhecimento deste Comitê. Salientamos ainda, a necessidade de relatório completo ao final do estudo. Eventuais modificações ou emendas ao protocolo devem ser apresentadas ao CEPPUCPR de forma clara e sucinta, identificando a parte do protocolo a ser modificado e as suas justificativas. Se a pesquisa, ou parte dela for realizada em outras instituições, cabe ao pesquisador não iniciá-la antes de receber a autorização formal para a sua realização. O documento que autoriza o início da pesquisa deve ser carimbado e assinado pelo responsável da instituição e deve ser mantido em poder do pesquisador responsável, podendo ser requerido por este CEP em qualquer tempo.

CURITIBA, 27 de Fevereiro de 2014


 Assinador por:
NAIM AKEL FILHO
 (Coordenador)



Endereço: Rua Imaculada Conceição 1155
 Bairro: Prado Velho CEP: 80.215-901
 UF: PR Município: CURITIBA
 Telefone: (41)3271-2292 Fax: (41)3271-2292 E-mail: nep@pucpr.br

ANEXO 2 - Termo de Consentimento Livre e Esclarecido

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO

Eu, **(nome do sujeito da pesquisa, nacionalidade, idade, estado civil, profissão, endereço, RG)**, estou sendo convidada a participar de um estudo denominado "*Método para a Identificação de Emoções em Textos em Português do Brasil Usando Máquina de Vetores de Suporte em Solução Multiclasse*", cujo objetivo principal e justificativa é desenvolver um método capaz de identificar seis emoções básicas contidas em textos escritos em Português do Brasil. A Análise de Sentimento é o estudo de opiniões, sentimentos e emoções expressas em diferentes mídias, dentre elas os textos. Nesta área, que ganhou impulso com a difusão da web, pesquisas vêm sendo desenvolvidas e grande parte delas visam criar métodos computacionais que sejam capazes de identificar fatores afetivos em textos. A maioria das pesquisas disponíveis atualmente são desenvolvidas para a língua Inglesa, focando principalmente na identificação da valência nos textos, ou seja, se os textos são "positivos" ou "negativos". Dessa forma, métodos que sejam capazes de identificar emoções em textos escritos em Português do Brasil e que classifiquem emoções em categorias (alegria, tristeza, raiva, etc.) são uma contribuição relevante para a área.

A minha participação no referido estudo será no sentido de rotular os textos. O processo de rotulação nesta pesquisa consiste em atribuir a cada texto uma ou mais das seguintes classes: alegria, tristeza, raiva, medo, desgosto, surpresa ou neutro. Os textos para os quais este processo deverá ser realizado contém extensões variáveis. Estou ciente que os dados coletados serão utilizados para constituir uma base que será disponibilizada para a comunidade de pesquisadores da área. Tal base não contém qualquer referência que possa identificar os voluntários da pesquisa.

Fui alertado de que, da pesquisa a se realizar, posso esperar alguns benefícios indiretos, tais como: com a construção de um método capaz de identificar automaticamente as emoções em textos escritos em Português do Brasil, eu, assim como qualquer indivíduo da comunidade poderei usufruir desta pesquisa podendo aplicar o método em diversos contextos, como por exemplo, animação de figuras animadas (avatars), extração de informações relacionadas a emoção de indivíduos em textos postados em redes sociais, dentre outras aplicações.

Recebi, por outro lado, os esclarecimentos necessários sobre os possíveis desconfortos e riscos decorrentes do estudo, levando-se em conta que é uma pesquisa, e os resultados positivos ou negativos somente serão obtidos após a sua realização. Assim, estou ciente que o tempo despendido neste experimento poderá ser em vão, visto que a pesquisa pode

não revelar resultados significativos.

Estou ciente de que minha privacidade será respeitada, ou seja, meu nome ou qualquer outro dado ou elemento que possa, de qualquer forma, me identificar, será mantido em sigilo.

Também estou ciente que não terei qualquer despesa por participar da pesquisa. No entanto, caso eu tenha qualquer despesa decorrente da participação na pesquisa, haverá ressarcimento em dinheiro.

Também fui informado de que posso me recusar a participar do estudo, ou retirar meu consentimento a qualquer momento, sem precisar justificar, e de, por desejar sair da pesquisa, não sofrerei qualquer prejuízo à assistência que venho recebendo.

Os pesquisadores envolvidos com o referido projeto são Prof. Dr. Emerson Cabrera Paraiso professor responsável pela pesquisa e membro permanente do Programa de Pós-Graduação em Informática da PUCPR e Mariza Miola Dosciatti aluna de doutorado do Programa de Pós-Graduação em Informática da PUCPR, e com eles poderei manter contato pelo telefone (41) 3271-1676 ou (41) 9843-2779.

É assegurada a assistência durante toda pesquisa, bem como me é garantido o livre acesso a todas as informações e esclarecimentos adicionais sobre o estudo e suas consequências, enfim, tudo o que eu queira saber antes, durante e depois da minha participação.

Enfim, tendo sido orientado quanto ao teor de todo o aqui mencionado e compreendido a natureza e o objetivo do já referido estudo, manifesto meu livre consentimento em participar, estando totalmente ciente de que não há nenhum valor econômico, a receber ou a pagar, por minha participação.

Também estou ciente que para participar da pesquisa preciso ter idade igual ou maior que dezoito anos.

Em caso de reclamação ou qualquer tipo de denúncia sobre este estudo devo ligar para o CEP PUCPR (41) 3271-2292 ou mandar um *email* para nep@pucpr.br

Local e data.

(nome e assinatura do sujeito da pesquisa)

Mariza Miola Dosciatti

Prof. Dr. Emerson Cabrera Paraiso