

RECONHECIMENTO DE SENTIMENTO EM TEXTO ABORDADO  
ATRAVÉS DA COMPUTAÇÃO AFETIVA

Bruno Adam Osiek

Tese de doutorado apresentada ao Programa de Pós-graduação em Engenharia de Sistemas e Computação, COPPE, da Universidade Federal do Rio de Janeiro, como parte dos requisitos necessários para a obtenção do título de Doutor em Engenharia de Sistemas e Computação.

Orientador: Geraldo Bonorino Xexéo

Rio de Janeiro

Junho de 2014

RECONHECIMENTO DE SENTIMENTO EM TEXTO ABORDADO  
ATRAVÉS DA COMPUTAÇÃO AFETIVA

Bruno Adam Osiek

TESE SUBMETIDA AO CORPO DOCENTE DO INSTITUTO ALBERTO LUIZ  
COIMBRA DE PÓS-GRADUAÇÃO E PESQUISA DE ENGENHARIA (COPPE) DA  
UNIVERSIDADE FEDERAL DO RIO DE JANEIRO COMO PARTE DOS  
REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE DOUTOR EM  
CIÊNCIAS EM ENGENHARIA DE SISTEMAS E COMPUTAÇÃO.

Examinada por:

---

Prof. Geraldo Bonorino Xexéo, D. Sc.

---

Prof. Jano Moreira de Souza, Ph. D.

---

Prof. Luís Alfredo Vidal de Carvalho, D. Sc.

---

Prof. Geraldo Zimbrão da Silva, D. Sc.

---

Prof. Marco Antônio Casanova, Ph. D.

---

Prof. Sean Wolfgang Matsui Siqueira, D. Sc.

---

Prof. Maria Cláudia de Freitas, D. Sc.

RIO DE JANEIRO, RJ – BRASIL

JUNHO DE 2014

Osiek, Bruno Adam

Reconhecimento de sentimento em texto abordado através da computação afetiva/ Bruno Adam Osiek. – Rio de Janeiro: UFRJ/COPPE, 2014.

XVI, 175 p.: il.; 29,7 cm.

Orientador: Geraldo Bonorino Xexéo

Tese (doutorado) – UFRJ/ COPPE/ Programa de Engenharia de Sistemas e Computação, 2014.

Referências Bibliográficas: p. 131-142.

1. Análise de sentimento. 2. Estrutura Cognitiva de Emoções. 3. Teoria de Avaliatividade. 4. Canal de ruído. 5. Computação Afetiva I. Xexéo, Geraldo Bonorino. II. Universidade Federal do Rio de Janeiro, COPPE, Programa de Engenharia de Sistemas e Computação. III. Título.

À minha mulher, Daniela. Por tudo que fez, pelo seu apoio, pelo seu amor e pelo meu filho Hugo que gera em seu corpo.

Lobo, saudade eterna.

## **Agradecimentos**

Estou convicto, depois de passar por esse processo de doutoramento, que tal empreendimento não é possível sem a ajuda de muitos. Entre o risco do esquecimento e a injustiça de não agradecer a quase todos, prefiro agradecer.

Agradeço ao Prof. Geraldo Bonorino Xexéo por sua orientação, por sua competência, por sua amizade, por suas ideias, por sua crença nessa pesquisa desde o seu início, por sua paciência no trato comigo, pelos seus conselhos, por seu esforço em ajudar a viabilizar financeiramente essa pesquisa e pelo ser humano que é. Sem sua ajuda eu não teria chegado aqui.

Agradeço ao Prof. Jano Moreira de Souza pelas ideias, pelo suporte financeiro a essa pesquisa, por todas as portas que abriu e por aquelas que ainda abrirá e por sua amizade.

Agradeço ao Prof. Luiz Alfredo Vidal de Carvalho por ter me orientado no início dessa caminhada.

Agradeço aos meus amigos e sócios Ricardo Oliveira Barros e José Augusto Rodrigues Neto pelas orientações, por ouvirem minhas lamentações, pela paciência no convívio, por permitirem minha ausência para desenvolver essa pesquisa e por terem levado a nossa GPE durante esse período.

Agradeço as contribuições do Thalles Rodrigues, do Filipi Xavier, da Paula Nascimento e do Felipe Fonseca no desenvolvimento e implementação dos artefatos que suportaram o experimento.

Agradeço ao Carlos Eduardo Mello por suas ideias e pelos cafés que comigo tomou.

Agradeço a Patrícia Leal, Solange Santos e Ana Paula Rabello por me ajudarem em todos os processos administrativos, sem os quais chegar a defesa dessa tese seria impossível.

Agradeço a todos os componentes da equipe da GPE que direta ou indiretamente contribuíram com essa pesquisa.

Agradeço a todos os membros da banca por dela participarem e pelas contribuições que dela emergirem.

Agradeço ao CNPq por ter em parte financiado esse trabalho.

Resumo da Tese apresentada à COPPE/UFRJ como parte dos requisitos necessários à obtenção do grau de Doutor em Ciências (D. Sc.).

## RECONHECIMENTO DE SENTIMENTO EM TEXTO ABORDADO ATRAVÉS DA COMPUTAÇÃO AFETIVA

Bruno Adam Osiek

Junho/2014

Orientador: Geraldo Bonorino Xexéo

Programa: Engenharia de Sistemas e Computação

Essa tese propõe, implementa e avalia uma nova abordagem para a análise de sentimento em texto. Reconhecimento de sentimento é a expressão utilizada para referenciar essa abordagem, por entender que o processo de externalização de uma emoção sofre ruído ao ser modulado pelo autor em função do seu objetivo, do público-alvo e do canal de comunicação da mensagem. O reconhecimento de sentimento é resolvido, adaptando o canal de ruído proposto por Shannon para a transmissão de mensagens. Para isso são desenvolvidos dois modelos. Um consiste no linguístico emocional, que calcula a verossimilhança de um texto (diretamente observado) dado a emoção subjacente (oculta). O outro calcula a probabilidade a priori de um sentimento no texto, probabilidade computada de um corpus anotado. O sentimento resultante consiste no argumento da função de máximo, considerando três polaridades (positiva, negativa e neutra), entre a multiplicação das probabilidades dos dois modelos. Os resultados alcançados mostram a eficiência dessa abordagem enquanto apontam novos caminhos para sua evolução.



Abstract of Thesis presented to COPPE/UFRJ as a partial fulfillment of the requirements for the degree of Doctor of Science (D. Sc.).

## SENTIMENT REGOGNITION IN TEXT THROUGH AFFECTIVE COMPUTING

Bruno Adam Osiek

June/2014

Advisor: Geraldo Bonorino Xexéo

Department: Systems and Computer Engineering

This thesis proposes, implements and evaluates a new paradigm for sentiment analysis in text. Sentiment recognition is the phrase coined to reference it, because it considers that the externalization of an emotion is subject to noise, due to the author's objectives, target audience and communication venue to transmit the message. The sentiment recognition problem is solved by adapting the noisy channel proposed by Shannon for message communication. To enable this goal two new models are proposed. One is the linguistic emotional model that computes the likelihood of an observed text, given its underlying emotion (hidden). The other one computes the a priori probability of a sentiment in an annotated corpus. The resulting sentiment is the argument of the maximum function, considering three possible polarities (positive, negative and neutral), that multiplies the probabilities from both models. The results achieved demonstrate the efficiency of this new approach while enumerating points of enhancement.

# Índice

1	Introdução.....	1
1.1	Motivação.....	6
1.2	A definição do problema.....	10
1.3	Objetivos do trabalho.....	11
1.4	Breve descrição da tese.....	11
1.5	Descrição dos capítulos.....	12
2	Revisão bibliográfica.....	14
2.1	Termos utilizados para referenciar análise de sentimento.....	14
2.2	Análise de Sentimento.....	16
2.2.1	Origem e evolução das pesquisas nessa área.....	16
2.2.2	Aplicações da análise de sentimento.....	19
2.2.2.1	Análise de sentimento em sistemas de Q&A.....	19
2.2.2.2	Análise de Sentimento em sistemas de recomendação.....	20
2.2.2.3	Deteccção de mensagens de ódio.....	20
2.2.2.4	Suporte a sistemas de publicidade on-line.....	21
2.2.2.5	Análise de sentimento em citações.....	21
2.2.2.6	Análise de sentimento na iteração homem-máquina.....	21
2.2.2.7	Análise de sentimento na política.....	22
2.2.2.8	Análise de sentimento em “eRulemaking”.....	24
2.2.3	Subjetividade e polaridade em texto opinativo.....	25
2.2.4	O futuro das pesquisas em análise de sentimentos.....	25
2.3	Computação Afetiva.....	29
3	Teorias relevantes à pesquisa.....	34
3.1	Introdução à gramática sistêmica funcional.....	34
3.2	Teoria de avaliatividade em linguagem.....	37
3.2.1	Os sistemas de escolha na teoria de avaliação em linguagem.....	38
3.2.2	Viabilidade da aplicação da teoria em português.....	42
3.3	Semântica diferencial.....	43
3.4	Teorias de emoção.....	45
3.4.1	Uma visão geral das teorias de emoção.....	45
3.5	Atributos para a escolha de uma teoria de emoção.....	49
3.5.1	O “Relógio de Areia” das emoções.....	51
3.6	A estrutura cognitiva de emoções.....	53
3.6.1	As variáveis centrais do modelo.....	55
3.6.2	As variáveis globais do modelo.....	56
3.6.3	As variáveis locais.....	57
3.6.4	Tratamento computacional.....	58
3.6.4.1	Regra para cálculo da intensidade do grupo BEM ESTAR.....	58
3.6.4.2	Regra para o cálculo da intensidade para o grupo BASEADO EM PROGNÓSTICO.....	59
3.6.4.3	Regra para o cálculo da intensidade para o grupo ATRIBUIÇÃO.....	59
3.7	O canal de ruído de Shannon.....	60
3.8	Extração de Informação (EI).....	60
4	Proposta de inferência de estados emocionais utilizando canal de ruído.....	63
4.1	O ruído no processo de comunicação.....	64
4.2	Modelo de externalização de um sentimento através da linguagem.....	65
4.3	O modelo de ruído para a análise de sentimento.....	66

4.4	Comparação da utilização do canal de ruído em NLP com o RS.....	68
4.5	Síntese das teorias para a composição do RS.....	70
5	Os modelos propostos neste trabalho.....	72
5.1	Proposta do modelo de emoção (ME).....	72
5.2	Proposta para o modelo linguístico emocional (MLE).....	74
5.2.1	Desejabilidade.....	74
5.2.2	Louvabilidade.....	76
5.2.3	Atratividade.....	79
5.3	O alinhamento entre as teorias de linguística e de emoção.....	81
5.3.1	O alinhamento entre julgamento e ação de agentes.....	84
5.3.2	O alinhamento entre apreciação e aspectos dos objetos.....	84
5.3.3	O alinhamento entre afeto e consequência de evento.....	85
5.4	Quadro resumo do alinhamento.....	87
5.5	Composição de estados emocionais em sentimento.....	88
5.6	Os grupos avaliativos.....	91
5.7	A extração dos grupos avaliativos.....	94
6	O experimento, resultados e avaliação.....	98
6.1	Metodologia.....	98
6.2	Corpus anotado.....	99
6.2.1	O ReLi.....	100
6.3	Referência para a comparação do desempenho do modelo.....	105
6.4	O classificador de referência.....	106
6.5	Desempenho do modelo de emoção.....	107
6.6	Desempenho do modelo linguístico emocional (MLE).....	111
6.6.1	A extração dos grupos avaliativos.....	111
6.6.2	Treino do Modelo Linguístico Emocional.....	115
6.6.2.1	Normalização.....	116
6.6.2.2	Inicialização da matriz de emissão de símbolo B.....	117
6.6.2.3	Os resultados do MLE.....	117
6.7	O desempenho do reconhecedor de emoção.....	118
6.8	Avaliação.....	121
7	Conclusão e trabalhos futuros.....	125
7.1	Resumo das contribuições originais.....	126
7.2	Trabalhos futuros.....	128
8	Referências Bibliográficas.....	131

## Apêndices

A.1	Palavras do sistema de julgamento.....	143
B.1	Palavras do sistema de atração.....	144
C.1	Palavras do sistema de afeto.....	145
D.1	Palavras do sistema de força.....	146
E.1	GATE.....	147
F.1	Regras em JAPE para identificação dos grupos avaliativos.....	150
G.1	Modelos de Markov.....	153
G.1.1	Um exemplo de modelos de Markov.....	153
G.2	Modelo oculto de Markov – HMM.....	154
G.2.1	Um exemplo de HMM.....	156
G.2.2	Probabilidade de uma observação dado um modelo.....	158
G.2.3	Definição da sequência de estados percorridos.....	158
G.2.4	Maximização dos parâmetros do modelo.....	159
H.1	Support Vector Machine – SVM.....	160
I.1	Distância simétrica de Kullback-Leibler (DKL).....	165
J.1	Teste de independência entre as sentenças – Log Likelihood Ratio.....	170
J.2	Entropia mútua.....	171
K.1	Arquitetura de um sistema de extração da informação.....	172
L.1	Desempenho modelo ME por autor.....	175

## Índice de Figuras

Figura 1.1: Desempenho do reconhecedor de sentimento.....	12
Figura 2.1: Correlação de Pearson para a concordância entre os anotadores.....	32
Figura 2.2: Resultado dos sistemas para a anotação de valência.....	32
Figura 3.1: Modelo estratificado do contexto social.....	35
Figura 3.2: Estrutura de constituintes da estrutura léxico-gramatical em SFL.....	37
Figura 3.3: Sistema de atitude.....	40
Figura 3.4: Sistema de graduação.....	42
Figura 3.5: Exemplo de escala na semântica deferencial.....	43
Figura 3.6: Espaço tridimensional das medidas EPA.....	44
Figura 3.7: “The hourglass of emotion” (extraído de(CAMBRIA et al., 2012)).....	52
Figura 3.8: O modelo OCC de (ORTONY; CLORE; COLLINS, 1988).....	53
Figura 3.9: As especificações dos tipos de emoção do modelo OCC.....	55
Figura 3.10: O canal de ruído de Shannon adaptado de (MANNING; SCHUETZE, 1999).....	60
Figura 4.1: Modelo de externalização da emoção através da linguagem.....	66
Figura 4.2: Modelo de externalização da emoção simplificado.....	67
Figura 4.3: Adaptação do modelo de externalização de emoção para o canal de ruído..	67
Figura 4.4: Canal de Ruído (SHANNON, 2001) para tratar o reconhecimento de sentimento RS.....	68
Figura 4.5: Candidatos a grupos avaliativos.....	70
Figura 4.6: Grupos avaliativos.....	70
Figura 4.7: Exemplo de grupo avaliativo observado e estado emocional oculto.....	71
Figura 5.1: Amostra dos 20 atributos com maior LLR.....	73
Figura 5.2: Especificação das emoções do grupo BEM-ESTAR.....	74
Figura 5.3: Função de Desejabilidade.....	76
Figura 5.4: Especificação das emoções do grupo ATRIBUIÇÃO.....	77
Figura 5.5: Função de Louvabilidade.....	78
Figura 5.6: Especificações do grupo de emoções ATRAÇÃO.....	79
Figura 5.7: Função de Atratividade.....	80
Figura 5.8: Modelo OCC simplificado, adaptado de (ORTONY; CLORE; COLLINS, 1988).....	82
Figura 5.9: Proposta de alinhamento entre o modelo OCC e o sistema de atitude.....	83
Figura 5.10: Julgamento e apreciação constituídos como afeto.....	86
Figura 5.11: Resumo do alinhamento entre modelo OCC e teoria de avaliatividade em linguagem.....	87
Figura 5.12: Composição de estados emocionais com HMM.....	88
Figura 5.13: Exemplo da composição de estados emocionais com grupos avaliativos...89	89
Figura 5.14: Parâmetros de uma HMM para o modelo MLE.....	89
Figura 5.15: Relação entre estados emocionais, sentimento e estado neutro.....	91
Figura 5.16: Lista dos 10 substantivos com maior escore de cada polaridade.....	94
Figura 5.17: Atributos dos grupos avaliativos.....	94
Figura 5.18: Exemplo de grupos avaliativos.....	96
Figura 6.1: Desenho esquemático de teste de validação cruzada "5-fold".....	99
Figura 6.2: Resumo do Corpus ReLi Original e do Experimento.....	101
Figura 6.3: Percentual da polaridade das sentenças.....	101

Figura 6.4: Sentença descritiva anotada.....	102
Figura 6.5: Sentença descritiva não anotada.....	103
Figura 6.6: Concordância entre os anotadores do ReLi.....	103
Figura 6.7: DKL no ReLi para filme e charmoso.....	104
Figura 6.8: Resultados para classificação de referência.....	107
Figura 6.9: Comparação do desempenho do modelo de emoção de acordo com teste de independência.....	109
Figura 6.10: Resultados do ME com atributos selecionados pelo LLR.....	109
Figura 6.11: Resultado do ME.....	110
Figura 6.12: Processo para a extração dos grupos avaliativos.....	111
Figura 6.13: Entradas e saídas do processo de extração de grupos avaliativos.....	112
Figura 6.14: Grupos avaliativos candidatos anotados.....	113
Figura 6.15: Grupos avaliativos anotados.....	113
Figura 6.16: Atributos de um grupo avaliativo candidato não considerado grupo avaliativo.....	114
Figura 6.17: Atributos do grupo avaliativo "mais interessante".....	114
Figura 6.18: Matriz de confusão do MLE.....	118
Figura 6.19: Resultado do MLE.....	118
Figura 6.20: Distribuição das probabilidades das polaridades dos modelos ME e MLE.....	119
Figura 6.21: Desempenho do reconhecedor de emoção variando lambda.....	120
Figura 6.22: Matriz de confusão para o reconhecedor de sentimento.....	120
Figura 6.23: Desempenho do RE.....	121
Figura 6.24: Efeito do MLE sobre o ME na classificação.....	121
Figura 6.25: Variação entre os modelos ME e RS.....	121
Figura 6.26: Resumo desempenho de acurácia e medida F1.....	122
Figura 6.27: Comparação LIWC/SO-Cal com RS.....	122
Figura 6.28: Comparação de desempenho variando o número de estados do modelo MLE.....	123
Figura 6.29: Comparação do desempenho do modelo MLE com 2 e 3 estados.....	123
Figura H.1: Representação do SVM.....	161
Figura I.1: Frequência das palavras em um corpus.....	167
Figura I.2: Probabilidade das palavras por classe.....	167
Figura I.3: DKL entre neutro e a referência.....	168
Figura I.4: DKL entre negativo e a referência.....	168
Figura I.5: DKL entre positivo e a referência.....	168
Figura I.6: A polaridade de uma palavra segunda a maior DKL.....	168
Figura I.7: A inserção da DKL no modelo EPA.....	169
Figura J.1: Matriz para o cálculo de LLR.....	171
Figura K.1: Arquitetura de sistema de EI extraída de (TURMO; AGENO; CATALÀ, 2006).....	173
Figura L.1: Desempenho do modelo ME base de desenvolvimento.....	175

## Índice de tabelas

Tabela 4.1: Resumo dos problemas e PLN abordados com o canal de ruído.....	69
Tabela 4.2: Reconhecimento de emoção como um problema de PLN abordados com o canal de ruído.....	69
Tabela 5.1: Resumo do tipo de emoção FELICIDADE.....	75
Tabela 5.2: Resumo do tipo de emoção TRISTEZA.....	75
Tabela 5.3: Resumo do tipo de emoção ORGULHO.....	77
Tabela 5.4: Resumo do tipo de emoção VERGONHA.....	77
Tabela 5.5: Resumo do tipo de emoção ADMIRAÇÃO.....	77
Tabela 5.6: Resumo do tipo de emoção REPREENSÃO.....	78
Tabela 5.7: Resumo do tipo de emoção GOSTAR.....	80
Tabela 5.8: Resumo do tipo de emoção DESGOSTAR.....	80
Tabela 6.1: Acurácia do LIWC em nível de opinião.....	106
Tabela 6.2: Acurácia do LIWC em nível de sentença.....	106
Tabela J.1: Teste de independência entre sentenças positivas, negativas e neutras.....	170

## Lista de Acrônimos<sup>1</sup>

BoW	Bag of Words
CO	Coreference
DKL	Distância simétrica de Kullback-Leibler
EI	Extração de Informação
EPA	Evaluation Potency Activity
GA	Grupo Avaliativo
HMM	Hidden Markov Models
IA	Inteligência Artificial
LLR	Log Likelihood Ration
ME	Modelo de Emoção
MFCC	Mel Frequency Cepstral Coefficients
MI	Mutual Information
MLE	Modelo Linguístico Emocional
MUC	Message Understanding Conference
NB	Naive Bayes
NE	Named Entity
NLP	Natural Language Processing
OCC	Ortony, Clore, Collins
OCR	Object Character Recognition
PLN	Processamento de Linguagem Natural
POS	Part of Speech
RS	Reconhecedor de Sentimento
SFL	Systemic Function Lingistic
SO-Cal	Semantic Orientation Calculator
SVM	Support Vector Machine

---

<sup>1</sup> A tradução dos acrônimos que não estão em português encontra-se no corpo da tese.



# 1 Introdução

Conhecer a opinião dos outros é parte importante do processo decisório de muitos indivíduos (PANG; LEE, 2008). Esses indivíduos têm atualmente na “*World Wide Web*” um conjunto grande de opiniões. Nesse contexto é difícil para uma única pessoa saber se a reação da maioria das pessoas é favorável ou desfavorável ao alvo do seu interesse.

O objetivo desse trabalho é projetar, desenvolver e avaliar o desempenho de um agente artificial na determinação da polaridade (positiva, negativa ou neutra) de um texto avaliativo. Texto avaliativo, no escopo dessa pesquisa, é aquele em que o autor externaliza a sua opinião, ou de outra pessoa, sobre um evento, sobre um agente ou sobre um objeto.

Agente artificial consiste em um agente cuja função de comportamento (abstração matemática) é implementada através do programa do agente processado em um sistema físico (RUSSELL; NORVIG, 1995)<sup>2</sup>.

Com um bom desempenho na determinação da polaridade do texto avaliativo o agente artificial ajudará um indivíduo em conhecer a opinião dos outros no seu processo decisório.

Todavia a necessidade de conhecer a opinião alheia em um processo decisório não consiste em fenômeno recente. Em 1810 o crítico E. T. A. Hoffmann publicou um artigo no jornal “*Allgemeine Musikalische Zeitung*”<sup>3</sup>, em que utilizando figuras de linguagem disse:

“Raios radiantes cortam a noite profunda dessa região, e nos fazem conscientes das sombras gigantes que, em um movimento de ida e volta, fecham-se sobre nós, destruindo tudo dentro da gente exceto a dor da expectativa interminável – essa expectativa que afunda e sucumbe com o prazer que emerge no meio de sons tão jubilantes. Somente através dessa dor, que enquanto consome mas não destrói o amor, a esperança e a alegria, tenta explodir em nosso peito através de um estrondoso grito proveniente de todas as nossas paixões, podemos viver como espectadores cativados desses espíritos.”<sup>4</sup>

---

2 Nessa tese esse sistema físico é um computador.

3 Consultado em [http://en.wikipedia.org/wiki/Allgemeine\\_Musikalische\\_Zeitung](http://en.wikipedia.org/wiki/Allgemeine_Musikalische_Zeitung) em 07/07/2011.

4 Tradução livre.

Esse texto repercutiu positivamente para o sucesso da, outrora<sup>5</sup> mal recebida pela crítica, “Sinfonia no. 5 em C menor, Op. 67” de Ludwig van Beethoven.<sup>6</sup> A crítica foi importante para Beethoven no século 19 e permanece importante hoje em qualquer atividade.

Existem vários exemplos como esse. A opinião das pessoas sobre produtos, serviços, políticas governamentais, empresas, pessoas e instituições de ensino, entre tantas outras, é importante. Entretanto, como será discutido ao longo dessa tese, não é fácil para um indivíduo consumir um texto como o de Hoffmann e concluir se sua avaliação foi positiva, negativa ou neutra. Tanto a necessidade no processo decisório quanto a dificuldade mencionada motivam o conjunto grande de pesquisas, mais de 7.000 segundo (FELDMAN, 2013), na área de análise de sentimento ou mineração de opinião (cuja descrição é objeto do capítulo 2) onde está contextualizada essa tese.

O processo decisório quando procuramos por recomendação emerge, por exemplo, no momento em que precisamos levar nosso carro no mecânico, quando procuramos comprar um eletrodoméstico, quando queremos experimentar um novo restaurante ou quando assistiremos a um concerto. No passado o alcance dessa procura era limitado ao círculo de pessoas conhecidas e ao conjunto relativamente pequeno, comparado com o atual, de mídia impressa.

Na medida em que novas mídias de comunicação surgiram diminuimos essa limitação. Entretanto jornal, revista, rádio e televisão possuem uma característica intrínseca: consiste num canal de comunicação unidirecional. Conseqüentemente tanto a iteração entre os agentes de comunicação (o emissor da mensagem e seu receptor) quanto a réplica (o avaliado responder à crítica) tem pouco espaço para emergirem nesses meios.

A chegada da “*World Wide Web*” muda esse quadro. Em uma dimensão o espaço para a interação limitada (os avaliados podiam replicar através de cartas a avaliação de um crítico) nos meios de comunicação mencionados é substancialmente ampliado. Fóruns de discussão consistem em um exemplo de como essa interação acontece na Web.

Em uma segunda dimensão, consequência direta da primeira, o avaliado, consciente de uma crítica, por exemplo negativa, surgida nesse espaço poder reagir

---

5 Um ano e meio antes

6 Consultado em [http://en.wikipedia.org/wiki/Symphony\\_No.\\_5\\_%28Beethoven%29#cite\\_ref-6](http://en.wikipedia.org/wiki/Symphony_No._5_%28Beethoven%29#cite_ref-6) em 07/07/2011.

rapidamente dentro do contexto adequado. Isso amplia a discussão, enriquecendo com conteúdo o consumidor dessa informação.

O surgimento das redes sociais cria uma terceira dimensão caracterizada por um canal de comunicação multidirecional. Nesse canal muitos falam com muitos. O sentimento de uma pessoa em relação a uma experiência vivenciada é rapidamente compartilhado em sua rede de relacionamento. Interação é uma característica marcante nessa dimensão, resgatando a experiência do passado, porém ampliando o limite daquele restrito círculo de amigos ou do número reduzido de publicações escritas.

Sabendo que pessoas influenciam outras com suas opiniões (KATZ; LAZARSELD, 2006), se almeja determinar se essa opinião é positiva, negativa ou neutra, dado o impacto do conjunto de opiniões, incluindo a reputação de quem opina, tem sobre pessoas, organizações e governos (THOMAS HOFFMAN, 2008). A passagem exposta sobre a “Sinfonia no. 5” de Beethoven é um exemplo de como a opinião de uma pessoa influenciou, no caso positivamente, o trabalho de outra. Porém não consiste em uma proposta desse trabalho pesquisar o porquê que a opinião de uma pessoa influencia outra e nem como esse processo emerge e concretiza-se.

Essa pesquisa objetiva fornecer recursos para um agente artificial reconhecer sentimento. Se faz necessária uma definição de termos, eventualmente utilizados como sinônimos, para melhor caracterizá-los. Nessa introdução se trabalha com o sentido contemporâneo desses conceitos que, segundo (FRANCISCO DA SILVA BORBA, 2004), são:

1. Emoção: “reação breve e forte a um fato”;
2. Sentimento: “faculdade de perceber ou apreciar; percepção; senso”<sup>7</sup>; e
3. Afetividade: “conjunto de fenômenos psíquicos que se manifestam sob a forma de emoções, sentimentos e paixões acompanhados de sensação de agrado ou desagrado”.

A definição formal do que é sentimento e emoção no escopo dessa tese se encontra na seção 3.6.

A luz do texto de Hoffmann alguns aspectos relevantes alguns aspectos se ressaltam.

---

7 Na literatura não há consenso do que sejam esses conceitos. Alguns autores ampliam o conceito de sentimento com uma dimensão temporal: longa duração.

O primeiro consiste na emoção do autor com relação ao objeto de sua crítica. Em 1918 Hoffmann assistiu a uma apresentação da sinfonia e não passou incólume à exposição a “sons tão jubilantes”. O autor se emocionou. Se infere isso, pois a utilização da expressão “...destruindo tudo dentro da gente...” é uma reação forte e, dada a duração aproximada de trinta minutos<sup>8</sup>, breve.

O segundo é a dificuldade de classificar o tipo de afetividade do autor. Sabemos que essa existe, pois o autor se emocionou. Entretanto, como se trata de um fenômeno psíquico, não temos acesso direto a ele.

Contudo Hoffmann expressa sua afetividade, através da linguagem escrita: “... que enquanto consome mas não destrói o amor, a esperança e a alegria, tenta explodir em nosso peito através de um estrondoso grito proveniente de todas as nossas paixões...”. Esse é o terceiro aspecto relevante, ou seja, embora não tenhamos acesso direto à afetividade, temos acesso indireto através das palavras.

O quarto consiste na polaridade dessa afetividade. Podemos inferir através do texto que o concerto agradou o autor pela expressão “...dor da expectativa interminável – essa expectativa que afunda e sucumbe com o prazer que emerge...”, ou seja, o que desagrada desaparece na medida que emerge o que agrada.

O quinto consiste no impacto do artigo, que influenciou, dada a reputação de ambos: autor e jornal, positivamente na aceitação da obra de Beethoven pelo público. Esse aspecto, a reputação, é relevante, pois esse artigo mudou o que outrora não foi devidamente percebido em sua estreia<sup>9</sup>, entretanto dimensioná-la ou encontrar sua relevância para um indivíduo não faz parte do escopo dessa tese

Entretanto uma opinião também é objeto de consumo. E como tal está sujeita à procura. Se não existirem pessoas interessadas essa não será consumida. Isso traz outro ator importante no contexto dessa pesquisa que é o consumidor da opinião.

Esse tipo de informação faz parte do processo de decisão. Porém, tanto no século 19 quanto hoje, existem alguns desafios para esse ator. Um deles é encontrar opiniões relevantes. A relevância aqui é relativa à sua relação com o objeto alvo da crítica, à sua motivação na busca pela informação, ao contexto onde está inserida e ao estabelecimento por inferência da sua relação com o contexto (SARACEVIC, 1996).

---

8 [http://pt.wikipedia.org/wiki/Sinfonia\\_n.%C2%BA\\_5\\_%28Beethoven%29](http://pt.wikipedia.org/wiki/Sinfonia_n.%C2%BA_5_%28Beethoven%29)

9 Ensaíada uma vez pela orquestra e executada em um dia muito frio em meio a uma programação longa.

Um consumidor buscando informação para adquirir um novo “*smart phone*” para uso pessoal tem necessidades distintas daquele que procura para uso corporativo. Os aspectos importantes na avaliação da culinária baiana são diferentes daqueles que avaliam a culinária gaucha. Um fotógrafo profissional necessitando de um novo equipamento procurará por avaliações mais abrangentes e profundas do que um fotógrafo amador. Um torcedor de futebol procura na crítica esportiva textos compatíveis com o seu grau de escolaridade e, se seu time jogou e ganhou procurará por artigos que exaltem o porquê seu time ganhou em detrimento de outros que destaquem as razões pelas quais o seu adversário perdeu.

Em todos os contextos acima o que agrada a alguns não necessariamente agradará a outros. O que é considerado positivo por uns pode ser considerado negativo por outros. Uma avaliação positiva do produto de um fornecedor pode ser considerada negativa por seu concorrente. Civilizações em conflito tem afetividades distintas sobre um mesmo fato. A classificação afetiva de uma opinião é dependente de contexto.

Um grande desafio nessa área reside no desempenho do agente artificial, ou seja, no seu desempenho em classificar corretamente a polaridade de um texto avaliativo. Artigos como (WRIGHT, 2009) e (GOLDEN, 2011) discutem a precisão das ferramentas existentes, sua real eficácia e a validade de sua utilização no processo de decisão, dada a precisão. As razões para isso são variadas. A primeira é que qualquer sistema automático tem, normalmente, seu desempenho avaliado tendo como parâmetro o desempenho humano, que, dependendo da tarefa, da qualidade do texto, do treinamento dos avaliadores, do grau de subjetividade varia de 72% (WIEBE; WILSON; CARDIE, 2006) a 85% (GOLDEN, 2011). É o agente humano preciso? Essa resposta depende do contexto. O desempenho do agente artificial está limitado ao próprio desempenho do ser humano. Os três exemplos que seguem ampliam essa discussão:

1. A máquina fotográfica tem excelente desempenho em ambientes bem iluminados;
2. A máquina fotográfica tem baixo desempenho em ambientes com pouca iluminação; e
3. A máquina fotográfica tem excelente desempenho em ambientes bem iluminados, porém tem baixo desempenho em ambientes pouco iluminados.

Enquanto podemos classificar o texto do exemplo (1) acima como positivo e o do exemplo (2) como negativo, teremos dificuldade na classificação do exemplo (3). Dependendo do que for mais importante, a pessoa pode classificá-lo como positivo ou negativo.

Em adição às dificuldades inerentes ao próprio ser humano existem algumas adicionais difíceis de serem interpretadas pelo agente artificial, sumarizadas por (GRIMES, 2008) da seguinte forma:

“O desafio tem sua raiz na enorme variabilidade e sutilezas da linguagem escrita e falada: o significado que os seres humanos pegam imediatamente do contexto é muito difícil para o computador detectar. Como pode o software discernir de forma confiável fatos e sentimentos a luz não somente de abreviações, má ortografia, regras gramaticais feridas, mas também na existência do sarcasmo, ironia, expressões idiomáticas, gírias e, bem, a personalidade?”

## 1.1 Motivação

Na seção 1 se falou do grande número de pessoas interagindo na “*World Wide Web (WWW)*” gerando as opiniões em textos avaliativos. Sendo esse número grande, caracteriza-se uma das motivações, que consiste na ajuda para indivíduo conhecer o posicionamento da maioria das pessoas em relação ao objeto do seu interesse.

O texto a seguir, principalmente a expectativa de Mark Zuckerberg<sup>10</sup> na última sentença, ajuda a ilustrar a ordem de grandeza do número de pessoas interagindo na WWW.

“Os 470 milhões de usuários já retiraram US\$ 33 bilhões em receita das operadoras com SMS que ficaram ricas cobrando taxas gordas por texto. WhatsApp é gratuito no primeiro ano e depois passa a cobrar US\$ 1,00 por ano. Sem propaganda, sem cartazes, sem “*upgrade*” para versões “*premium*”. Nas últimas discussões Zuckerberg prometeu aos fundadores do WhatsApp “pressão zero” para fazer dinheiro, dizendo, - Eu adoraria que vocês conectassem de 4 a 5 bilhões de pessoas nos próximos 5 anos.”(OLSON, 2014).

Alguns dados do Facebook ampliam a ilustração da magnitude dos números na

---

<sup>10</sup> Fundador do Facebook.

WWW. Se o Facebook fosse um país, seu 1,310 bilhão<sup>11</sup> de usuários formariam a segunda maior população do planeta<sup>12</sup>. Quarenta e oito por cento deles o acessam o diariamente, gastando 640 milhões de minutos por mês. Cada habitante desse país tem em média 130 amigos, está conectado a 80 comunidades. Nesse país seriam falados 70 idiomas.

Os números da WWW crescem continuamente. Uma pesquisa feita nos E.U.A para marcar os 25 anos da “*World Wide Web*” (RAINIE, 2014), cujo objetivo era apurar a evolução do uso da WWW desde a sua criação, apontou que em 1995 apenas 14% dos americanos adultos acessavam a Internet contra 87% em 2014. Em 2014 53% alegaram que seria muito difícil deixar de utilizar a Internet enquanto apenas 35% deles alegaram ser muito difícil deixar de ver televisão. Para 67% dos usuários as comunicações online, através de e-mail, mensagem de texto ou mídia social fortaleceram suas relações familiares enquanto enfraqueceram para 18%.

Na nona edição do TIC Domicílios realizada entre setembro de 2013 e fevereiro de 2014 em 16.000 domicílios no Brasil (“CGI.br – Comitê Gestor da Internet no Brasil”, 2013), concluiu que 31% (mais do que o dobro dos 15% em 2011) das pessoas com mais de 10 anos de idade acessam a internet pelo celular, representando uma população de 52,5 milhões de pessoas.

O fenômeno, que consiste na interação, compartilhamento e colaboração entre pessoas conectadas na Web em redes sociais, comunidades online, blogs e wikis, emerge um volume grande de conteúdo não estruturado que (MITROVIĆ; PALTOGLOU; TADIĆ, 2010)) apelidaram de “a definitiva fonte de informação” para o próprio estudo desse fenômeno. Entretanto extrair informação, opinião e sentimento desse conteúdo não é uma tarefa simples (CAMBRIA et al., 2011).

Para exemplificar a importância da opinião para as pessoas em números foi realizado um estudo pela comScore (COMSCORE; THE KELSEY GROUP, 2007), uma empresa de pesquisa de marketing na Internet, com 2.000 americanos adultos apontou o seguinte:

- Consumidores estão dispostos a pagar no mínimo 20% a mais por serviços avaliados como “excelente”, ou 5 estrelas, em relação a serviços avaliados como “bom”, ou 4 estrelas;

---

11 Dados extraídos de <http://www.statisticbrain.com/facebook-statistics/> em 28/04/2014

12 Perdendo para a China por apenas 54 milhões de pessoas. Dados obtidos em [http://en.wikipedia.org/wiki/List\\_of\\_countries\\_by\\_population](http://en.wikipedia.org/wiki/List_of_countries_by_population) em 28/04/2014

- Entre os pesquisados 24% relataram que leram críticas online antes de adquirir um serviço prestado offline;
- Dos que leram as críticas online mais de 75% afirmaram que o conteúdo lido influenciou na decisão de compra; e
- Desses últimos, 97% reportaram que a crítica era correta.

A importância do conjunto das opiniões para as organizações é exemplificado pelo Aberdeen Group, um grupo de pesquisa e análise de companhias e produtos de tecnologia da informação, que realizou um estudo entre dezembro de 2007 e janeiro de 2008 (ZABIN; JEFFERIES, 2008) para identificar o desempenho das empresas com as melhores práticas no monitoramento de mídias sociais e encontrou o seguinte:

- 86% das empresas líderes<sup>13</sup> melhoraram seu desempenho entre as atividades de marketing e a entrega dos resultados para as pessoas que decidem;
- 94% das empresas líderes melhoraram o nível geral de satisfação dos seus clientes;
- 84% das empresas líderes melhoraram sua habilidade geral em avaliar e reduzir riscos; e
- 84% das empresas líderes aumentaram o número de ações derivadas das percepções que emergiram da análise e monitoramento das mídias sociais.

A importância da opinião das pessoas para os políticos foi ilustrada em um artigo da Pew Internet (SMITH, 2011), que descreve o engajamento dos eleitores americanos em 2010. Se observou que 73% dos internautas adultos acessaram a internet na campanha para<sup>14</sup>:

- 58% para obter notícias sobre política. Adicionalmente 32% dos entrevistados informaram que obtiveram essas notícias apenas online;
- 53% para participar de atividades políticas específicas como compartilhar vídeo e verificar se as informações ditas por um político estavam corretas; e
- 22% usaram o Twitter ou outras redes sociais com propósito político.

O artigo aponta para uma tendência desses usuários de obterem informação de sites que compartilham seus pontos de vista. Como será discutido na revisão

<sup>13</sup> Tradução livre para o conceito Best-in-Class

<sup>14</sup> O total ultrapassa os 100% porque internautas podem ter participado de mais de uma atividade.



bibliográfica as técnicas utilizadas em análise de sentimento tem desempenho satisfatório na classificação de ponto de vista (POV – “Point of View”).

Em uma extensa pesquisa (CABRAL; HORTAÇSU, 2006) modelam o mecanismo de reputação do eBay, derivam um conjunto de implicações baseado no modelo, validado empiricamente. Os autores concluem que após receber uma avaliação negativa o crescimento das vendas diminui significativamente e, o que é pior, o número de críticas negativas aumenta significativamente implicando numa diminuição das vendas e de preço. Outro achado é que um vendedor com 1.000 avaliações positivas afere um incremento médio de preço na ordem de 5% em relação ao praticado pelos demais vendedores.

Na seção 1 foi mencionada a importância da opinião em políticas governamentais. Nesse caso a opinião é adjetivada como opinião pública, que consiste no alvo da comunicação governamental (BARBARA PFETSCH, 1999). Esta é definida por (HARTNETT, July) como “os valores políticos, atitudes ou opiniões do público em geral de um país ou outra unidade política, entendendo que nesses estão padrões de votação ou comportamento político...”. Em artigo baseado em um caso real do Governo Federal (AZEVEDO, 2007) define comunicação governamental como “...instrumento de valorização das ações de governo e dos poderes públicos, sendo sentida pela sociedade, e que contém elementos que ajudam na sustentação e legitimação política de determinada gestão”. Os autores (BARBARA PFETSCH, 1999) caracterizam a estratégia de comunicação como um “...processo iterativo onde as mensagens são moldadas, avaliadas, testadas e revisadas até alcançarem o efeito desejado. Este processo envolve (1) o estabelecimento de objetivos e opções de comunicação, (2) entender o ambiente, (3) escolher e implantar a opção de comunicação com maior probabilidade de atingir o objetivo desejado e (4) avaliar a eficácia da comunicação”.

A quarta etapa desse processo de comunicação consiste em mais uma motivação dessa pesquisa. Um exemplo da importância e como as mídias sociais servem como canal de comunicação de políticas governamentais é encontrado em (“AIDS.gov Communication Strategy Internal Working Plan”, [s.d.]).

Nesse canal é importante conhecer quem opina, sobre o que opina, a opinião propriamente dita e sua polaridade para reagir aos estímulos provenientes dessas mídias eficazmente. Portanto esse trabalho tem motivações baseadas nas necessidades das pessoas, das famílias, das organizações, dos políticos ou dos governos de interagirem

nas diversas mídias sociais, que consistem em um novo canal de comunicação.

## 1.2 A definição do problema

Para chegarem a uma definição do que consiste o problema da mineração de opinião ou análise de sentimento (PANG; LEE, 2008) partem da necessidade de se integrá-lo a uma máquina de busca geral e dividem o problema em quatro. São eles:

1. O primeiro problema consiste em classificar a consulta, ou seja, determinar se o usuário está procurando por uma opinião ou crítica;
2. Fora o problema, ainda aberto, de determinar quais são os documentos relevantes, é preciso encontrar quais documentos contém opinião ou quais as porções do documento que contém texto opinativo;
3. De posse dos documentos ou porção dele é necessário extrair a opinião e determinar seu sentimento geral. Um texto pode conter opinião sobre diferentes aspectos de um produto ou serviço e encontrar a opinião geral consiste em um desafio; e
4. Sumarização dos resultados. Usuários podem utilizar escalas de avaliações distintas, elencar as principais opiniões de um conjunto de documentos, agregar pontos de concordância ou discordância, identificar os opinantes e o peso de sua opinião entre os outros opinantes.

Recentemente (FELDMAN, 2013) define o problema de maneira geral como sendo “a tarefa de encontrar as opiniões de autores sobre entidades específicas”. Adiciona aos problemas já expostos um quinto: a aquisição de um léxico de sentimento.

Os trabalhos publicados por (PANG; LEE, 2008) e (FELDMAN, 2013) consistem em duas revisões da área de análise de sentimento. Os autores fornecem definições abrangentes dos problemas existentes na área. Assim essa pesquisa foi restrita a dois:

1. Elaborar um dicionário de sentimento dependente de contexto, alinhado com um dos desafios mencionados por (FELDMAN, 2013); e
2. Determinar se a polaridade agregada do conjunto de opiniões em um fragmento de texto é positiva, negativa ou neutra. Consiste em parte do problema 3 na definição de (PANG; LEE, 2008).

### 1.3 Objetivos do trabalho

Em função dos problemas alvos dessa pesquisa, esse trabalho tem como objetivos:

1. Propor uma função de agente artificial;
2. Implementar a função em um programa; e
3. Avaliar seu desempenho.

A extração de sentimentos do contexto é parte da função do agente assim como apoiada por esse artefato classificar a polaridade agregada de opiniões em um segmento de texto.

### 1.4 Breve descrição da tese

Essa tese propõe, implementa e avalia uma nova abordagem para a análise de sentimento em texto. Reconhecimento de sentimento é a expressão utilizada para referenciar essa nova abordagem, por entender que o processo de externalização de uma emoção sofre ruído ao ser modulado pelo autor em função do seu objetivo, do público-alvo e do canal de comunicação da mensagem. O reconhecimento de sentimento é resolvido, adaptando o canal de ruído proposto por (SHANNON, 2001) para a transmissão de mensagens. Para isso são desenvolvidos dois modelos. Um consiste no linguístico emocional (MLE), apoiado em duas teorias: avaliação em linguagem avaliativa de (MARTIN; WHITE, 2005) e a estrutura cognitiva de emoções e seu modelo OCC de (ORTONY; CLORE; COLLINS, 1988), que calcula a verossimilhança de um texto (diretamente observado) dada a emoção subjacente (oculta). O outro calcula a probabilidade a priori de uma emoção no texto, probabilidade computada de um corpus anotado, o ReLi (FREITAS et al., 2012). Esse modelo, chamado de modelo de emoção (ME) consiste na escolha, feita com o teste “*Log Likelihood Ratio*” (LLR), das palavras que melhor caracterizam as sentenças de cada polaridade. O sentimento, então, consiste no argumento da função de máximo, considerando as três polaridades (positiva, negativa e neutra), entre a multiplicação das probabilidades dos dois modelos. Os resultados alcançados pelo reconhecedor de sentimento (RS) estão listados na figura 1.1.

	MEDIDA F1		
	ME	MLE	RS
Positiva	0,6276	0,6432	0,6667
Negativa	0,1852	0,4480	0,5135
Neutra	0,8607	0,7818	0,8655
Acurácia	0,7799	0,7006	0,7967

*Figura 1.1: Desempenho do reconhecedor de sentimento.*

## 1.5 Descrição dos capítulos

O capítulo 2 consiste na revisão bibliográfica e está dividido em duas partes. A primeira trata da análise de sentimento. São abordadas as técnicas mais utilizadas para a classificação das polaridades dos documentos. Adicionalmente são discriminadas as principais aplicações como em sistemas de perguntas e respostas, mineração de opinião, detecção de ódio, em publicidade e em política. Dada a correlação entre subjetividade e opinião foi separada uma seção para elencar as pesquisas que abordam a análise de sentimento, filtrando texto objetivo dos subjetivos. Essa parte termina com uma visão do futuro das pesquisas nessa área.

A segunda parte do capítulo 2 define o que é a computação afetiva, sua origem e as pesquisas relacionadas com a modelagem, reconhecimento de emoção em texto e algumas aplicações com seus desempenhos. O capítulo enumera alguns dos desafios que a computação afetiva aborda, incluindo a própria dificuldade para o ser humano de identificar uma emoção específica. Uma recente revisão da área descreve os esforços para aproximar as pesquisas em psicologia e inteligência artificial para avançar as pesquisas nessa área considerada multidisciplinar.

No capítulo 3 estão descritas as teorias que suportam essa tese. Começa com uma pequena descrição da gramática sistêmica funcional para descrever a teoria, dela derivada, de avaliação em linguagem avaliativa. Descreve a estrutura cognitiva de emoções. Essa duas teorias suportam o desenvolvimento do modelo linguístico emocional proposto nessa tese. O capítulo continua descrevendo a semântica diferencial que apoia o desenvolvimento de alguns dos dicionários. O capítulo contém um breve resumo das principais linhas de pensamento relativo à emoção para descrever algumas escolhas feitas no processo de modelagem. O canal de ruído de Shannon é brevemente

abordado, pois a solução aqui proposta parte de uma abstração dele. Por último é descrita sucintamente do que consiste a extração de informação.

O capítulo 4 descreve a solução proposta nessa tese. Enumera os tipos de ruído na externalização de emoção, propõe um modelo de ruído para o reconhecimento de emoção e termina descrevendo a função do agente reconhecedor de sentimento.

No capítulo 5 estão descritos os modelos linguístico emocional e suas variáveis centrais de desejabilidade, louvabilidade e atratividade. O modelo de emoção com sua função para a escolha das melhores palavras que descrevem textos positivos, negativos e neutros é desenvolvido. Um alinhamento teórico entre esse modelos é proposto. Adicionalmente são propostos e descritos os grupos avaliativos e seus atributos com marcadores de emoção no texto.

O capítulo 6 começa com a descrição da metodologia utilizada na execução dos experimentos. Continua descrevendo o experimento e resultados alcançados com o modelo linguístico emocional, com o modelo de emoção e com o reconhecedor de sentimento. O capítulo prossegue com uma avaliação dos resultados alcançados. Compara-os com o desempenho alcançado por outra proposta no mesmo corpus.

No capítulo 7 enumeram-se as contribuições originais dessa tese, listam-se os trabalhos futuros e termina com uma proposta de caminho a ser seguido na evolução das pesquisas que se iniciam com essa tese.

## 2 Revisão bibliográfica

Esse capítulo está dividido em duas partes. Na primeira se revisa a área de pesquisa referente à análise de sentimento e na segunda se aborda a área de pesquisa referenciada como computação afetiva. Se optou por essa divisão, pois na primeira o foco central das pesquisas é o tratamento do texto, utilizando técnicas oriundas da área de processamento de linguagem natural (NLP)<sup>15</sup>. Na segunda o foco reside na modelagem e implementação de sistemas que modelam estruturas que permitem o processamento de emoções por agentes artificiais, seja identificando-as ou simulando-as.

A área da análise de sentimento é referenciada na literatura de várias maneiras e se julgou adequado esclarecer esses termos antes de apresentar sua revisão bibliográfica, sendo esse o objetivo da seção 2.1.

### 2.1 Termos utilizados para referenciar análise de sentimento

Análise de sentimento é referenciada de diversas formas na literatura, gerando confusão. Muitas vezes um novo termo é criado para incorporar o alvo de uma aplicação que utiliza técnicas de análise de sentimento, outras vezes para agregar tarefas adicionais. Esse é o caso do texto a seguir, extraído de (ZABIN; JEFFERIES, 2008), que apresenta o conceito “monitoramento e análise de mídias sociais”:

“A aplicação do aforismo de Sócrates – O começo da sabedoria está na definição de termos – é recomendada no mundo do monitoramento e análise das mídias sociais onde falta qualquer coisa que se assemelhe com o aceite universal de terminologia. (...) No fim o termo “monitoramento e análise de mídias sociais” é em si uma muleta verbal. Preenche temporariamente essa lacuna até que algo melhor (e mais curto) surja...”

O termo monitoramento induz a busca constante de texto nas mídias sociais. Essa tarefa de varredura faz parte dos mecanismos de busca e recuperação da informação (BRI). Já a análise, considerando as aplicações existentes, tem duas dimensões: uma consiste na análise da topologia da rede social e a segunda na análise do texto. Essa segunda é aderente à análise de sentimento.

---

<sup>15</sup> Acrônimo para “*Natural Language Processing*”.

Os autores PANG e LEE (2008), em uma influente revisão bibliográfica da área de análise de sentimento, após elencarem uma extensa lista de termos, incluindo o monitoramento e análise de mídias sociais, mencionam que dois: “mineração de opinião”; e “análise de sentimento” englobam os demais e são “paralelos”, pois tratam do mesmo grupo de problemas. A distinção é a de que o primeiro termo emergiu em grupos de pesquisa cujas soluções propostas estão apoiadas em técnicas oriundas da linha de pesquisa busca e recuperação da informação. Já o segundo termo nasceu de grupos de pesquisa preocupados com o mesmo problema, porém apoiando as suas soluções em processamento de linguagem natural.

GRASSI et al. (2011) acrescentam a essa discussão o termo “*Sentic Computing*”, uma abordagem multidisciplinar para mineração de opinião e análise de sentimento...”. O termo “*Sentic*” deriva do latim “*sentire*” e foi primeiro introduzido por (CLYNES, 1977) como sinônimo de emoção.

CAMBRIA et al.(2011), diferenciam “análise de sentimento” e “mineração de opinião”, escrevendo que “Apesar de discutidas como sendo a mesma disciplina no sentido de extrair as atitudes das pessoas de texto, a mineração de opinião foca na detecção da polaridade da opinião enquanto a análise de sentimento na inferência da emoção”.

No contexto desse trabalho adotou-se o termo “análise de sentimento”. Existem algumas razões para isso.

A primeira deriva da interpretação da definição contemporânea de sentimento. Sendo a capacidade de apreciar e aferir senso, alinha-se com os objetivos dessa pesquisa (seção 1.3).

Em “*The Language of Evaluation: Appraisal in English*” (MARTIN; WHITE, 2005) uma das teorias em que se baseia essa pesquisa, o sentimento consiste na avaliação positiva ou negativa da atitude, sendo atitude o tipo de avaliação, que pode ser afetividade, julgamento ou apreciação (novamente alinhando-se ao sentido contemporâneo). Em contrapartida o termo opinião segue a linha de (HUNSTON; THOMPSON, 2001), que distingue opinião em duas dimensões:

- Opinião sobre entidades são atitudes e envolvem sentimentos positivos e negativos; e
- Opinião sobre proposições que são epistêmicas e envolvem grau de certeza.

Este trabalho objetiva avaliar apenas a primeira dimensão da opinião acima listada, ou seja, o sentimento. Como o termo opinião envolve as duas dimensões optou-se por não utilizar mineração de opinião.

A terceira razão reside no fato de que análise de sentimento consiste na expressão mais comumente utilizada pelos usuários e fornecedores das ferramentas que propõem a extração de sentimento de texto (seja de forma manual ou automática). Em um estudo feito pela Ideya (“Social Media Monitoring Tools and Services - 2nd. Edition”, 2011) esse termo consistia em um dos atributos-chave de comparação entre 282 ferramentas distintas em detrimento, aparentemente, de mineração de opinião.

## **2.2 Análise de Sentimento**

Na seção 2.2.1 se descreve alguns marcos importantes que ampliaram o interesse nessa área de pesquisa. A seção 2.2.2 se listam as pesquisas por área de aplicação: sistemas de perguntas e respostas (seção 2.2.2.1); aplicação em sistemas de recomendação (seção 2.2.2.2); sistemas de detecção de mensagens de ódio (seção 2.2.2.3); marketing on-line (seção 2.2.2.4); em citações (seção 2.2.2.5); melhoria na interação homem-máquina (seção 2.2.2.6); em política (seção 2.2.2.7); e em gestão de políticas governamentais (seção 2.2.2.8). Uma estratégia que apresentou significativa melhoria no desempenho dos sistemas de análise de sentimento foi considerar que opiniões estão em textos subjetivos e, conseqüentemente, dividiu-se o problema em detectar a subjetividade para posterior classificação polar (abordada na seção 2.2.3). A revisão é concluída com uma visão do futuro das pesquisas em análise de sentimento (seção 2.2.4).

### **2.2.1 Origem e evolução das pesquisas nessa área**

Embora seja difícil precisar o começo das pesquisas nessa área, se credita seu início à pesquisa em extração de crenças (o que A conhece a respeito de B) e “ponto de vista” de texto, utilizando técnicas da IA simbolista no processamento de linguagem natural (WILKS; BIEN, 1984).

Em pesquisa pelo aperfeiçoamento da relevância de crenças para o usuário de documentos recuperados em mecanismos de busca e recuperação de informação, se procurou conhecer o significado de sentenças através de um “modelo metafórico de



forma que a única interpretação necessária para determinar a direcionalidade de sentenças é feita em relação ao modelo.” (HEARST, 1992), onde direcionalidade consiste em modelos do tipo “A apoia B” ou “A não apoia B”.

Já o “ponto de vista (POV)”<sup>16</sup> envolve a distância emocional entre o narrador e o personagem. A narrativa subjetiva, mais próxima do personagem expressa seu estado privado (utilizando expressões como: “ele sentiu”, “ele pensou”). A narrativa objetiva em contraponto mais distante do personagem expressa grau de certeza sobre o personagem (utilizando expressões como “aparentemente ele” e “como se ele fosse”) (USPENSKY, 1973). Essa divisão da narrativa serviu como arcabouço para tratar o problema de classificar ponto de vista como um problema de segmentação de texto, resolução de referência e crença. A ideia consistiu em associar cada sentença subjetiva (o ponto de vista) ao um sintagma nominal (o seu agente) utilizando classificadores probabilísticos. O problema de classificar as sentenças subjetivas das objetivas foi identificado e, como o problema anterior, abordado utilizando classificadores probabilísticos baseado em máxima verosimilhança de dados incompletos via algoritmo de maximização da esperança (EM)<sup>17</sup> (WIEBE; RAPAPORT, 1988), (WIEBE, 1990), (WIEBE, 1994), (WIEBE; BRUCE, 1995) e (WIEBE; BRUCE; O’HARA, 1999)

O problema com classificadores em geral reside no alto custo de treinamento. Uma forma de reduzi-lo é utilizando léxicos. Alguns trabalhos (ZHANG; YE, 2008), (TABOADA et al., 2011) e (BALAGE FILHO; ALEXANDRE SALGUEIRO PARDO; M. ALUÍSIO, 2013) se apoiam em léxicos, que contêm a polaridade associada a um termo, que atua como base para a classificação. Entretanto (WIEBE; WILSON; BELL, 2001) pesquisaram a importância de colocações<sup>18</sup> na classificação de textos opinativos. Adjetivos e verbos extraídos dessas colocações enriqueceram o léxico aumentando a precisão da classificação polar do texto em 21%, no caso somente de incluído os adjetivos, e 16%, no caso de incluídos somente os verbos.

Com o objetivo de apoiar o processo de decisão, em adição a pura recuperação de texto relevante com o mesmo objetivo, (SUBASIC; HUETTNER, 2001) mapeiam tipos semânticos (“*semantic typing*”) a determinadas categorias de afeto. A centralidade e intensidade dessas categorias são combinadas produzindo os “*affect sets*”, que são

---

16 Pont of View em inglês

17 Acrônimo para “Expectation Maximization”.

18 Colocações, sob a ótica do processamento estatístico de linguagem natural, consiste em duas ou mais palavras aparecerem em conjunto no texto com uma probabilidade maior do que seria esperado se fosse por acaso. Exemplos são “tocar a campainha” e “caiu a ficha”.

“*fuzzy sets*” representando o atributo qualitativo de afetividade do documento, dando uma “dimensão humana” ao texto.

O ano de 2001 marcou a conscientização generalizada do problema. Três fatores estão por trás desse movimento (PANG; LEE, 2008):

1. A disponibilidade de banco de dados e o desenvolvimento de sites agregadores de opinião; e
2. O surgimento de métodos de aprendizado de máquina no processamento de linguagem natural e recuperação da informação;
3. A realização de que se trata de um problema que impõe desafios para a pesquisa com aplicações na área comercial e de inteligência.

O conceito de orientação semântica de um documento apoiou a classificação de um documento contendo opiniões e foi introduzido e calculado por (TURNERY, 2001) como sendo a PMI<sup>19</sup> entre um sintagma e a palavra excelente menos a PMI entre o mesmo sintagma e palavra ruim. A classificação do documento como recomendado ou não consistia na média do valor calculado para todos os sintagmas. O autor construiu uma base com documentos extraídos do site Epinions<sup>20</sup> contendo quatro domínios distintos (cinema, automóveis, bancos e destinos turísticos) com acurácia variando de 84% para automóveis e 66% para cinemas.

A pesquisa relatada por (DINI; MAZZINI, 2002) também utiliza técnicas de EI, porém adiciona análise sintática (basicamente a extração de sintagmas nominais, verbais e adverbiais) e preenchem, através de um conjunto de 43 regras, uma estrutura semântica, que contém a entidade, polaridade, qualificação, expressão, contexto e origem do documento. Os autores sugerem como evolução estender a estrutura semântica utilizada para outra, que apelidaram de “*full semantic structure*”, muito parecida com FRAME (“Minsky’s Frame System Theory”, 1975), possibilitando a inferência na base de conhecimento preenchida.

O trabalho descrito em (MORINAGA et al., 2002) divide a solução do problema da análise de sentimento em três fases: na primeira consiste na busca por opinião na web; na segunda, que chamam de extração de opinião, filtram, utilizando léxico, os documentos que contêm opinião, rotulando se é positiva/negativa e o grau de certeza de que se trata de uma opinião; e na terceira utilizam técnicas de mineração de texto para

19 Point-wise mutual information

20 <http://www.epinions.com/>

inferir a reputação geral do produto em questão. Uma contribuição significativa desse trabalho foi segregar o problema de determinar se um texto contém ou não opinião. Muitos trabalhos nessa época assumiam que a base de documentos continha apenas opiniões.

(PANG; LEE; VAITHYANATHAN, 2002) trataram o problema de análise de sentimento como um problema de classificação por tópicos, sendo que esses consistiam em apenas duas classes, ou seja, a polaridade de opinião (negativa/positiva)<sup>21</sup>. Popularam uma base de críticas sobre filmes, e utilizaram 3 classificadores: rede Bayesiana ingênua, máxima entropia e SVM (“*Support Vector Machine*”). Concluíram que as técnicas de aprendizado de máquinas utilizadas na classificação tiveram desempenho semelhante ao do ser humano, entretanto com desempenho abaixo daqueles aferidos quando essas mesmas técnicas são utilizadas na classificação de documentos por tópicos.

O surgimento de sites agregadores de opinião inspirou pesquisas como a de (DAVE; LAWRENCE; PENNOCK, 2003) cujo objetivo consistiu na automação dos processos por trás desses sites. Enquanto foram exitosos na extração dos atributos dos produtos e de suas respectivas avaliações (através de notas ou número de estrelas) de sites estruturados, um contraponto ao trabalho de (DINI; MAZZINI, 2002), utilizando técnicas de EI, não conseguiram desempenho equivalente da classificação polar das sentenças. Porém relataram que a identificação dos atributos mais importantes foi relevante na elaboração de sumários.

## **2.2.2 Aplicações da análise de sentimento**

### **2.2.2.1 Análise de sentimento em sistemas de Q&A**

Os autores (CARDIE et al., 2003) e (WIEBE et al., 2003) estendem as pesquisas em sistemas de Q&A<sup>22</sup>, que tratavam apenas da recuperação de documentos factuais para responder as perguntas do tipo “Quem descobriu o Brasil?”, introduzindo o conceito de MPQA (“*Multi-Perspective Question-Answering*”). Como resultado esperado os sistemas MPAQ poderiam responder a perguntas do tipo “Qual foi a reação mundial sobre o relatório do EUA sobre direitos humanos? ”. Abordam o problema utilizando técnicas oriundas da Extração de Informação (EI), e apelidaram de “*opinion-*

<sup>21</sup> Na base foram inseridas críticas classificadas como neutras, porém descartadas na pesquisa.

<sup>22</sup> Question and Answer ou perguntas e respostas

*oriented information extraction*”, propondo um cenário de extração, consistindo do agente emissor da opinião, sua polaridade<sup>23</sup> e sua intensidade. Com isso desenvolveram uma base de dados para apoiar uma variedade de tarefas de MPQA. Em adição a essas pesquisas (YU; HATZIVASSILOGLU, 2003) propõem a separação de documentos que contém opinião daqueles que contém fatos, tanto em nível do próprio documento como em nível de sentença, utilizando um classificador baseado em redes bayesianas. Em outro trabalho (RILOFF, 2005) o autor propõe a retirada, através de filtros específicos, de sentenças subjetivas como forma de melhorar o desempenho de sistemas de EI.

Outros trabalhos nessa área são apresentados em (STOYANOV; CARDIE; WIEBE, 2005), (SOMASUNDARAN et al., 2007) onde os autores preocupados em diferenciar sistemas de Q&A factuais dos opinativos, mesclam identificação de subjetividade baseada em regra, aprendizagem de máquina e filtros de fonte de opinião para melhorar o desempenho desses sistemas. Em (LITA et al., 2005) os autores propõem a utilização de atributos como a credibilidade do autor, subjetividade e dados temporais entre outros para melhorar o desempenho desses sistemas.

#### **2.2.2.2 Análise de Sentimento em sistemas de recomendação**

Como já apresentado em (SMITH, 2011) usuários tendem a coletar opinião de sites ou pessoas que compartilham seu ponto de vista. Nesse sentido (TERVEEN et al., 1997) e (TATEMURA, 2000) desenvolveram sistemas, PHOAKS e “Virtual Reviewers” respectivamente, que filtram e recomendam, baseado no papel do usuário, seus pontos de vista e preferências recursos da web, no caso do PHOAKS, e filmes, no caso do “Virtual Reviewer”. Ponto de vista e preferência são baseados nos recursos ou filmes vistos e classificados pelo próprio usuário. São sistemas colaborativos na medida em que a filtragem é feita na contribuição de terceiros. O “*Virtual Reviewer*”, adicionalmente, oferece ao usuário um sumário das críticas encontradas, sendo essa a inspiração para o seu nome.

#### **2.2.2.3 Detecção de mensagens de ódio**

Consiste numa das motivações do grande desenvolvimento que essa área

---

<sup>23</sup> Os autores na verdade rotularam polaridade como tipo de opinião.

experimentou após setembro de 2001. Entretanto trabalhos nessa área antecedem essa data e um bom exemplo é descrito em (SPERTUS, 1997) que desenvolveu o sistema SMOKEY que, apoiado em atributos sintáticos e semânticos constrói um vetor com 47 elementos, extraídos baseados em regras, para cada sentença de uma mensagem e usando árvore de decisão rotulam um e-mail como “inflamado” ou não. (WARNER; HIRSCHBERG, 2012) identificam um padrão para identificação de mensagens de ódio, que consiste no fato de um pequeno conjunto de palavras, esteriótipos”, com alta frequência. Cada conjunto é específico para o alvo do ódio.

#### **2.2.2.4 Suporte a sistemas de publicidade on-line**

Publicidade normalmente aparece no contexto de uma página web. A propaganda apresentada deve ser compatível com o conteúdo da página e, adicionalmente, se há nesse conteúdo afetividade negativa a um determinado produto ou serviço, sua propaganda deve ser evitada. Trabalho como o de (NASUKAWA; YI, 2003) e (JIN et al., 2007) endereçam essa questão.(PICARD, 1995).

#### **2.2.2.5 Análise de sentimento em citações**

Determinar o ponto de vista de um autor, jornal ou site ou, ainda, inferir a polaridade de uma crítica sobre um produto ou um tópico exigem técnicas que podem ser aplicadas em diversas áreas. Por exemplo em (TABOADA; GILLIES; MCFETRIDGE, 2006) os autores monitoram as críticas feitas sobre as obras de 6 autores ao longo de 50 anos e calculam o quanto elas foram determinantes para sua respectiva fama ou obscuridade. Outro exemplo é apresentado em (PIAO et al., 2006), onde os autores procuraram encontrar a opinião de quem cita um trabalho em relação ao próprio trabalho citado.

#### **2.2.2.6 Análise de sentimento na iteração homem-máquina**

Um trabalho significativo para essa pesquisa é descrito em (LIU; LIEBERMAN; SELKER, 2003). Nele os autores empregam uma base de conhecimento, chamada de “*Open Mind*” (SINGH, 2001), sobre fatos, descrições e histórias do mundo real obtida através do preenchimento de “*templates*” em linguagem natural. Utilizando heurísticas,

os autores filtram a base para conter apenas assertivas que contenham afetividade, associando adjetivos (como feliz, triste e amedrontado), substantivos (como depressão, prazer e alegria) e verbos (como assustar, amar e chorar) às emoções básicas de Ekman: alegria; tristeza; raiva, medo, nojo; e surpresa (EKMAN, 1993). Quatro modelos foram propostos e criados baseados na base de conhecimento: *sujeito-verbo-objeto-objeto*; *unigrama nível-conceito*; *valência nível-conceito*; e *unigrama modificador*. As sentenças foram rotuladas de acordo com esses modelos e também foram utilizadas técnicas de atenuação para melhor representar a transição de emoção entre sentenças. O modelo foi testado em um sistema de e-mail. Vinte pessoas escreveram e-mails sobre acontecimentos relevantes. Ao final de cada sentença escrita o sistema apresentava três interfaces distintas, sendo uma com a emoção aferida pelo sistema (“*EmpathyBuddy*”), a segunda uma emoção escolhida aleatoriamente e uma terceira sempre neutra. Os usuários avaliaram as interfaces segundo quatro quesitos: divertido, iterativo, inteligente e satisfação, sendo que o sistema derivado desse trabalho foi o melhor avaliado, exceto no quesito iteratividade onde a interface aleatória foi melhor avaliada.

Dois estudos, (LISCOMBE; AL., 2005) e (TOKUHISA; TERASHIMA, 2006) trataram da questão da afetividade para melhorar a iteração entre homem e unidade de resposta audível. O segundo adiciona aos atributos normalmente utilizados como: léxicos; atributos de prosódica (como ritmo, intonação); e atos de diálogo, ou seja, o diálogo como função do discurso (como afirmar, negar, repetir, perguntar, ordenar e responder)<sup>24</sup> atributos contextuais para melhor identificar o estado afetivo do interlocutor humano.

Na mesma linha, (NOVIELLI, 2009), treina um classificador baseado em HMM (“*Hidden Markov Models*”), para rotular os discursos de acordo com o seu ato de diálogo. O algoritmo foi implementado em um sistema de orientação sobre alimentação saudável. Seu objetivo era manter o engajamento do interlocutor na conversa.

### **2.2.2.7 Análise de sentimento na política**

Muitos trabalhos foram realizados nessa área. Interessante notar, talvez pela quantidade de informação disponibilizada diariamente na web, que serviram de base para elaborar e testar novos algoritmos.

---

<sup>24</sup> Os autores reportam que os rótulos utilizados foram específicos do corpus utilizado HMIHY 0300

O conceito de “orientação cultural” foi explorado em (EFRON, 2004), e definido como o grau de associação entre um objeto e a comunidade em uma área polarizada. Eles utilizam PMI para determinar nesse modelo grupos de documentos com orientação esquerdista ou direitista.

Em (BANSAL; CARDIE; LEE, 2008) os autores estendem a utilização do método do menor corte em um grafo para identificar dentro dos debates ocorridos no congresso americano, quais políticos apoiam ou não uma determinada posição, ou seja, concomitantemente identificam grupo de políticos que apoiam ou não uma posição. Exploraram o conceito de similaridade e dissimilaridade em um mesmo grafo, originalmente proposto por (GOLDBERG, 2007), que permite a classificação em múltiplas classes. (GOLDBERG, 2007) testaram o algoritmo numa base para classificar a filiação política de indivíduos em um fórum de discussão. Em base de dados parecida com a de (BANSAL; CARDIE; LEE, 2008), (THOMAS; PANG; LEE, 2006) utilizam o SVM para determinar através do discurso se um indivíduo apoia ou não uma determinada proposta em votação.

Em contrapartida (MULLEN; MALOUF, 2006) reportam que em “*weblogs*” sobre políticos, “*post*” respondendo diretamente a outros tem uma tendência para a discórdia. Fizeram experimentos utilizando rede Bayesiana ingênua para classificação de sentimento e não alcançaram bons resultados. Os autores suspeitam que nesse tipo de ambiente a diferença de palavras utilizadas nos “*post*” antagônicos é pequena, diminuindo a eficiência dos algoritmos nesse cenário. Os autores entendem que utilizando estruturas semânticas e sintáticas podem contornar o problema da semelhança das palavras, melhorando o desempenho.

Uma contribuição interessante para a área é proposta por (LAVER; BENOIT; COLLEGE, 2003), pois os autores trabalham com probabilidades baseadas em frequência das palavras para chegar a resultado equivalente, ou seja, determinar a orientação política de um texto sem utilizar recurso de processamento de linguagem natural. A vantagem reside em um menor custo computacional e na portabilidade do algoritmo para outras línguas<sup>25</sup>. Adicionalmente informam medidas de incerteza sobre os resultados calculados, fornecendo ao usuário base para a tomada de decisão.

A crescente utilização de ferramentas de “*microblogging*”, como o twitter, levaram (MEJOVA; SRINIVASAN; BOYNTON, 2013) a pesquisar a influência dessa

---

<sup>25</sup> Os autores testaram o algoritmo em alemão.

mídia nos resultados das primárias do Partido Republicano para a corrida presidencial de 2011. Os autores encontram nas discussões uma “retórica negativa, atada com sarcasmo e humor e dominadas por um pequeno grupo de usuários” cuja influência no sentimento relativo aos candidatos não influenciou o resultado final da corrida. Utilizam dois classificadores em sequência. O primeiro, SVM, tem como atributos n-gramas e classifica as mensagens em “a favor”, “contra” ou neutro. Os resultados, que variaram no intervalo de [-1, 1] apresentaram baixa cobertura. Para melhorar o desempenho os autores inseriram duas variáveis: linha de corte e viés. Linha de corte consistiu em um valor, abaixo do qual a classe não seria considerada. Viés consistiu em ampliar ou diminuir o intervalo que caracterizaria uma classe. O resultado dessa nova classificação serviu de entrada para um classificador de regressão logística que gerou o resultado final. De uma acurácia de 0,269 (SVM sem as variáveis) e 0,476 (SVM com as variáveis) os autores alcançam a acurácia final de 0,544 (SVM com variáveis e regressão logística). Com esse resultado eles concluem que análise de sentimento em política, com base no Twitter, consiste em uma tarefa difícil e que a utilização de classificadores “*out-of-the-box*” somente alcança resultados satisfatórios com ajustes.

#### **2.2.2.8 Análise de sentimento em “eRulemaking”**

“E-Rulemaking” consiste em uma área multidisciplinar que discute o uso de tecnologias de informação no suporte, tanto para os legisladores quanto para o público, ao processo de elaboração das políticas públicas (SHULMAN, 2005).

Em (KWON; SHULMAN; HOVY, 2006) o objetivo consistiu em extrair de milhares de e-mail, mensagens, comentários, faxes e outros formulários dados qualitativos e quantitativos das opiniões emitidas no processo de regulamentação do uso de mercúrio pela Agência de Proteção Ambiental nos EUA. Em um projeto, chamado de “*Rule Writer Workbench*”, os desenvolvedores almejam uma ferramenta de extração de informação, incluindo opiniões, para apoiar as agências responsáveis por elaborarem regulamentos a serem aprovados pelo legislativo (SHULMAN et al., 2005). O crescente número de “*weblogs*” sobre leis, apelidados e “*blawgs*”, motivam os autores em (CONRAD; SCHILDER, 2007) a estudarem e desenvolverem métodos para busca de textos opinativos nesses blogs e deles extraírem opiniões.



### **2.2.3 Subjetividade e polaridade em texto opinativo**

Segundo (PANG; LEE, 2008, p. 5) a “análise de subjetividade consiste no reconhecimento de linguagem opinativa de forma a distingui-la da linguagem objetiva”. O conceito de subjetividade, mais particular sentenças subjetivas, ganha destaque com a definição dada em (WIEBE, 1990) como sendo “aquelas que apresentam a experiência consciente de um personagem em uma história. Elas expressam a avaliação, emoção, julgamento, incertezas, crenças e outras atitudes e afetividades. Tipos de sentenças subjetivas incluem aquelas que retratam o pensamento ou percepção do personagem e reportam seus estados privados como ver, desejar ou se sentir mal, ou seja, estados perceptivos ou psicológicos que não estão abertos a verificação ou observação” (WIEBE, 1990, p. 401).

Com exceção do caso particular da identificação da polaridade de uma opinião em corpus contendo apenas textos opinativos, as pesquisas mais recentes, principalmente após (PANG; LEE, 2004) dividem o processamento em duas fases. Na primeira filtram o conteúdo objetivo, eliminando-o e, na segunda classificam sua polaridade. Vale observar que recentemente essa discussão foi estendida para agrupar esses estados de acordo com as dimensões de onde emergem, visando facilitar sua compreensão (CHEN, 2008).

O “problema de distinguir subjetividade de objetividade mostrou-se mais difícil do que a classificação polar, então melhorias na classificação de subjetividade prometem impactar positivamente na classificação de sentimento.”(MIHALCEA; BANEJA, 2007, p. 2). A correlação entre sentenças subjetivas e o uso de adjetivos foi identificada em (HATZIVASSILOGLU; WIEBE, 2000) tornando comum a rotulação da classe gramatical de palavras no processamento da análise de sentimento. Uma recente revisão sumariza as pesquisas de detecção de subjetividade para a classificação de sentimento onde outras classes de palavras, como verbos e advérbios, são utilizadas com essa finalidade (LIU, 2010).

### **2.2.4 O futuro das pesquisas em análise de sentimentos**

Em sua revisão dessa área de pesquisa (FELDMAN, 2013) aponta para 6 questões que as pesquisas precisam endereçar. São elas:

1. O cálculo do sentimento geral de uma sentença, chamado de “sentimento composto”. Isso passa por encontrar as palavras mais associadas com o sentimento expresso e encontrar as diferentes formas de utilização de inversores;
2. A resolução automática de entidade (produtos tem diversos nomes e são utilizados no mesmo documento ou em documentos distintos) não está resolvida. Diretamente relacionado a esse problema está a resolução de anáfora que, segundo o autor, impacta substancialmente no agrupamento de aspectos de um produto (“duração da bateria” e “consumo de energia” se referem ao mesmo aspecto de um telefone celular);
3. Um texto pode abordar entidades distintas e encontrar qual porção refere-se a qual entidade é importante e “a acurácia atual está longe de ser satisfatória”;
4. A classificação de sarcasmo;
5. Textos com ruído (erros ortográficos, erros gramaticais, uso indevido de pontuação e uso de gírias); e
6. Classificação de sentimento em sentenças objetivas. As pesquisas tendem a separar as sentenças em objetivas e subjetivas descartando o primeiro grupo para a análise de sentimento.

Na discussão dos novos caminhos para a análise de sentimento e mineração de opinião (CAMBRIA et al., 2013) levantam a pouca pesquisa existente no que apelidam de “análise multimodal de sentimento e opinião”, entendendo multimodal como evidências extraídas de áudio, vídeo e texto.

A visão dos autores é a de que essa área de pesquisa se distinguirá do processamento de linguagem natural (NLP)<sup>26</sup>, pois, diferentemente de sumarização e categorização de texto, essa linha de pesquisa se preocupa com inferência semântica e afetiva associadas com linguagem natural, sem necessariamente precisar de uma compreensão profunda do documento analisado. Vislumbram que cada vez mais os trabalhos evoluirão para a análise baseada em conceito, conteúdo e contexto, suportadas por técnicas eficientes para o processamento do grande volume de conteúdo que apelidam de “*big social data*”.

Na dimensão conteúdo apontam para o desafio de avaliar a confiabilidade da opinião e de sua origem.

---

26 Acrônimo para “Natural Language Processing”

O desafio da dimensão conceito está alinhado com o desafio 2 (enumerado acima) porém acrescentando a necessidade de se criar uma base de conhecimento comum que possa, por um lado, melhorar o agrupamento de conceitos e permitir inferir que “quarto pequeno consiste em uma opinião negativa de um hotel, enquanto fila pequena consiste em um sentimento positivo de uma agência de correio”.

A dimensão contexto está ligada ao consumidor da informação e as futuras pesquisas deverão adequar a mineração da opinião às preferências e necessidades das pessoas.

Os autores enriquecem os desafios acrescentando a importância de “misturar” as teorias de emoção oriundas da psicologia com processamento de linguagem natural, “almejando uma melhor compreensão das regras que governam sentimento, assim como as evidências que podem converter esses conceitos da realização para a verbalização na mente humana”.

Esse desafio, de como sentimento realizado é convertido em discurso, consiste na essência da tese aqui apresentada.

Em uma revisão publicada recentemente (WHITE; CAMBRIA, 2014) os autores interpretam a “*Jumping S-Curves*” (NUNES; BREENE, 2011), para mostrar a visão da evolução de três curvas, sendo uma referente à sintática, a segunda referente à semântica e a terceira referente à pragmática.

Posicionam a maioria das pesquisas em curso na curva sintática, centrada no conceito de “*bag-of-words*” (HARRIS, 1981) base dos atuais sistemas de busca e recuperação da informação. Essa curva é constituída de três categorias: detecção de palavras-chave; afinidade lexical e métodos estatísticos.

Os artefatos usados na detecção de palavras-chave são dicionários (como os utilizados nessa tese), corpus anotados (como os utilizados para treinar classificadores de classe gramatical de palavras), algoritmos ordenadores de relevância (como os utilizados pelos principais sistemas de busca e recuperação de informação). Enquanto são bons atributos para recuperar textos falham no desafio 2 acima.

Afinidade lexical atribui probabilidades de palavras pertencerem a uma classe. Enquanto são boas para perceber que o substantivo “acidente” tem conotação negativa como em “sofreu um acidente”, falham em perceber a conotação positiva de “evitou um acidente”. Essa falha se alinha com o desafio 1 acima descrito.

NLP estatística consiste na terceira categoria da curva sintática e se caracteriza pelo uso de diferentes algoritmos de aprendizagem de máquina (modelos de linguagem, maximização da esperança, “*Conditional Random Fields*” (CRF) e “*Support Vector Machines*” (SVM)) para encontrar uma função de atribuição de uma palavra a um conjunto. Os autores apontam como principal lacuna nessa categoria sua incapacidade de atribuir valor semântico à coocorrência de palavras de baixa frequência, levando a necessidade desses algoritmos de serem treinados em corpus grande. Essa lacuna reduz o desempenho desses classificadores em pequenas unidades de texto como sentenças ou cláusulas.

O próximo salto será para a curva semântica<sup>27</sup>, caracterizada pelo modelo “*bag-of-concepts*” (CAMBRIA; HUSSAIN, 2012). Os autores também classificam em três categorias a curva semântica: NLP latente (os autores utilizam a palavra endógena), NLP taxonômica e NLP de bases de conhecimento (os autores utilizam a palavra em inglês “*noetic*”<sup>28</sup>).

NLP latente utiliza técnicas de aprendizagem de máquina para aproximar conceitos existentes em um grande número de documentos. As técnicas mais comuns são: “*Latent Semantic Analysis*” (LANDAUER; FOLTZ; LAHAM, 1998); “*Latent Dirichlet Allocation*” (BLEI; NG; JORDAN, 2003)

A NLP taxonômica objetiva a construção de ontologias extraídas da Web compreender a hierarquia semântica associada com expressões em linguagem natural. Os autores enumeram várias bases, sendo a mais conhecida a “*WordNet*” (MILLER, 1995).

A NLP baseada em conhecimento “engloba todas as abordagens inspiradas na mente”. Se diferencia da NLP taxonômica por tentar coletar comportamentos particulares de objetos, eventos e pessoas. Os autores enumeram algumas pesquisas que utilizaram redes neuronais e computação afetiva (os autores utilizam a palavra em inglês “*sentic*”) (CAMBRIA; HUSSAIN, 2012).<sup>29</sup>

Especulam que no futuro<sup>30</sup> acontecerá o salto para a curva pragmática, cujo paradigma será caracterizado por “*bag-of-narratives*”. Segundo essa revisão da

---

27 Seu apogeu deve ocorrer por volta do ano 2050.

28 Não encontrei em nenhum texto uma explicação para a não utilização dos termos (latente e conhecimento) encontrados na literatura. Por isso não os adoto.

29 A palavra “*sentic*” em inglês vem do latim “*sentire*”, utilizada em (PICARD, 1995) para não usar a palavra emoção, dada a discordância existente em sua definição. Resolvi utilizar o termo afetiva.

30 Pela curva plotada no artigo seria próximo ao ano 2100.

literatura modelagem computacional terá papel central no entendimento de narrativas, componente importante da interação entre humanos. Embora estejamos longe das pesquisas consistentes na pragmática existem iniciativas em inteligência artificial, mais particularmente no entendimento dos processos cognitivos que levam à representação do conhecimento, raciocínio baseado em senso comum, aprendizagem e a própria NLP.

## 2.3 Computação Afetiva

Na introdução do periódico “*IEEE Transactions on Affective Computing*”<sup>31</sup> o autor (GRATCH, 2010) define computação afetiva como “... o campo de estudo cuja preocupação consiste na compreensão, reconhecimento e utilização de emoções humanas e outros fenômenos afetivos no desenho de sistemas tecnológicos.”

Nessa seção se passa a tratar de emoções. A relação entre emoção e sentimento neste trabalho é discutida na seção 5.5 e ilustrada na figura 5.15.

(PICARD, 1995) introduziu o termo “Computação Afetiva”, o definindo como sendo a “computação relacionada a, que emerge de ou influencia emoções”. Ela ainda discute a importância das emoções no processo de decisão e enumera algumas aplicações, tais como aquelas voltadas para entretenimento, aprendizagem assistida por computador e interação homem-máquina, que podem se beneficiar do seu tratamento e reconhecimento.

Partindo do princípio de que emoções não podem ser diretamente observadas, uma modelagem do problema proposta envolve a utilização de HMM (“*Hidden Markov Models*”)<sup>32</sup>, onde os estados afetivos emitem sinais (PICARD, 1995). Esses sinais, como expressão facial, atributos do discurso falado e o conteúdo do texto escrito, são diretamente observáveis e servem de referência para o estado subjacente.

Mais recentemente a autora, ao discriminar algumas das principais limitações da computação afetiva, enumera alguns desafios: no reconhecimento de emoção face à sua natureza privada e à própria dificuldade humana de reconhecê-la; na sua modelagem considerando sua própria evolução pelas ciências cognitivas; e na expressão das

---

31 <http://www.computer.org/portal/web/tac>

32 HMM consiste em uma máquina de estados cujas funções de transição de estado e função de emissão de sinais são probabilísticas (RABINER, 1989). No apêndice G é dada uma introdução desse classificador probabilístico.

emoções, pois o corpo, através da sua fisiologia, consiste no seu principal meio de comunicação (PICARD, 2003)

O reconhecimento de todas emoções possíveis é difícil tanto para o ser humano quanto para o agente artificial. A dificuldade de anotar o tipo de emoção foi classificado por (ALM; ROTH; SPROAT, 2005) como “difícil”, reportando terem encontrado na literatura acordo entre os anotadores variando de 21% a 51%. Essa variação depende do contexto. Entretanto, vários autores, limitando o seu número ou a sua polaridade, reportam avanços significativos em algumas tarefas.

Existem algumas abordagens básicas para o problema, sendo que muitas envolvem alguma combinação delas (LIU; LIEBERMAN; SELKER, 2003). A mais comum consiste na utilização de um léxico que associa palavras a emoções (RUMBELL et al., 2008) e (NICOLOV; SALVETTI; IVANOVA, 2008). Uma evolução consiste em afiliação lexical onde é atribuída uma distribuição de probabilidade de emoções para um item lexical (FAHRNI; KLENNER, 2008). Outra abordagem consiste no processamento estatístico de linguagem natural, utilizando métodos estatísticos como “*Latent Semantic Analysis*” (LSA) (STRAPPARAVA; VALITUTTI; STOCK, 2006) (KIM; VALITUTTI; CALVO, 2010) (BELLEGARDA, 2010) e (CAMBRIA et al., 2011), sendo que neste último os autores mesclam técnicas de “Web Semântica” para aprimorar a extração de afetividade em texto.

Adicionalmente muitos pesquisadores constroem modelos para uma determinada área de conhecimento ou tarefa específica, com desempenho satisfatório para o problema focado, porém de difícil generalização (RITCHIE et al., 2008), (OSHERENKO, 2008), (BALAHUR; MONTOYO, 2008), (SOKOLOVA; LAPALME, 2008)

DANISMAN e ALPKOCAK(2008) complementam o acima descrito agrupando as abordagens para a solução do problema de reconhecimento de emoção humana em três grupos: uso de palavras-chave; NLP estatístico; e o uso de ontologias. Entretanto enumeram alguns pontos fracos. No uso de palavras-chave a fraqueza consiste no limitado número de palavras em texto com valor emocional (LUTFI et al., 2007); e em NLP estatística o grande volume de dados necessários para o treinamento dos classificadores estatísticos. Enquanto enumeram dois recursos linguísticos (ConceptNet (LIU; SINGH, 2004) e LIWC (PENNEBAKER; FRANCIS, 1999))<sup>33</sup> não apontam

---

33 Versão do ConceptNet em português (ANACLETO et al., 2006)

nenhuma fraqueza. Os autores propõem a utilização de “Vector Space Model” (VSM) para classificação de sentenças em uma de seis classes, onde cada uma representa um tipo de emoção.

SemEval, um acrônimo para “*Semantic Evaluation*”, consiste em uma série de avaliações de sistemas que efetuam análise semântica<sup>34</sup>. O evento de 2007 foi o único, até 2014, onde foi proposta a tarefa de “Texto Afetivo” cujo foco específico era inferir a classificação de emoções (raiva, angústia, medo, alegria, tristeza e surpresa) e sua polaridade (positiva e negativa) de manchetes de sites de notícias. O corpus foi dividido em duas partes, sendo que aquela reservada ao desenvolvimento continha 250 entradas e a de teste 1000 entradas. Para cada manchete era associada um tipo de emoção. Sua polaridade variava em uma escala de [-100, 100], onde os valores limítrofes indicavam a máxima intensidade. Foi atribuído o valor zero apenas para as manchetes que não continham emoções (definição da neutralidade). O corpus foi anotado por 6 pessoas com a correlação de Pearson para a concordância entre elas apresentado na figura 2.1. Na figura 2.2 é apresentando um quadro, resumindo o desempenho dos sistemas participantes. Na avaliação desses resultados (STRAPPARAVA; MIHALCEA, 2007) os autores concluem: que a tarefa de anotar emoções é difícil, concordando com (ALM; ROTH; SPROAT, 2005); e que o desempenho apresentados pelos sistemas sugerem espaço para futuras melhorias.

O time “*ClaC*” apresentou dois sistemas. O primeiro utilizava um dicionário com polaridade das palavras e uma função nebulosa calculava o grau de aderência de cada manchetes a uma polaridade. O segundo, “*ClaC-NB*”, os mesmos atributos alimentaram uma rede Bayesiana naïve que efetuava a classificação. O time UPAR7 desenvolveu um sistema baseado em regra onde as manchetes eram analisadas sintaticamente para posterior inferência da polaridade da emoção encontrada. O SICS montou vetores termo x polaridade de um fórum de discussão. As palavras mais frequentes em outro corpus de notícias foram retiradas de cada manchete, constituindo o vetor, cuja distância era calculada para cada vetor termo x polaridade. O time SWAT desenvolveu um classificador baseado em modelo de linguagem com 1-grama.

---

34 <http://en.wikipedia.org/wiki/SemEval>

Emoção	k
Raiva	49,55
Desgosto	44,51
Medo	63,81
Alegria	59,91
Tristeza	68,19
Surpresa	36,07
Valência	k
Valência	78,01

Figura 2.1: Correlação de Pearson para a concordância entre os anotadores

	Acurácia	Precisão	Cobertura	F1
ClaC	55,10	61,42	9,20	16,00
UPAR7	55,00	57,54	8,78	15,24
SWAT	53,20	45,71	3,42	6,36
ClaC-NB	31,20	31,18	66,38	42,43
SICS	29,00	28,41	60,17	38,60

Figura 2.2: Resultado dos sistemas para a anotação de valência

REISENZEIN et al.(2013), depois de uma breve revisão da literatura, entendem que as pesquisas na área da computação afetiva emergem de duas disciplinas: psicologia e inteligência artificial. Para facilitar a comunicação entre elas, propõe um arcabouço, apoiado somente na IA simbolista em detrimento da conexionista<sup>35</sup>, constituído de três partes. Na primeira listam propostas para sistematizar as diversas teorias psicológicas de emoção que servem como plantas para a criação e comparação de modelos computacionais. Na segunda discutem como formalizar as teorias psicológicas de emoção através de uma linguagem formal, independente de implementação. A linguagem proposta serviriam para formalizar as premissas de modelos computacionais. Na terceira parte do arcabouço consideram opções para modelar emoções em arquiteturas de agentes, incluindo arquitetura de agentes afetivos.

Embora não consista no objetivo dessa pesquisa é importante ressaltar alguns trabalhos que almejam implementar emoção na geração do discurso, visando tornar a relação homem-máquina mais natural (VAN DER SLUIS; MELLISH, 2008), (WILLIAMS; POWER; PIWEK, 2008)e (WHITEHEAD; CAVEDON, 2010).

<sup>35</sup> Isso se deveu a experiência dos autores envolvidos.



O desempenho do agente artificial é baixo, dado o relativamente baixo desempenho do agente humano. Isso mostra o longo caminho que precisa ser percorrido pelas disciplinas (psicologia, neurociência, linguística e ciência da computação) para melhorar a compreensão humana do que seja esse conceito e concomitante melhoria do desempenho dos agentes artificiais. É nessa área que a tese aqui proposta contribui.

## 3 Teorias relevantes à pesquisa

### 3.1 Introdução à gramática sistêmica funcional

Em um texto existe uma distância, caracterizada em (WHITELAW; PATRICK; HERKE-COUCHMAN, 2006) como distância interpessoal, que é definida como “... uma medida sendo construída pelo texto na relação entre a pessoa que fala ou escreve e seu endereçado”. Na literatura existem várias razões que tentam justificar esse distanciamento. Algumas são: a dificuldade do próprio indivíduo, introspectivamente, inferir o que realmente sentiu; do objetivo do autor com o texto onde, por exemplo, sua motivação seja influenciar pessoas para adotarem uma posição que seja de seu interesse; da dificuldade inerente na utilização da língua para estruturar a realização de estados privados; ou mesmo o receio do autor de expressar o que realmente sentiu. Não obstante as pessoas comunicam, com grau variado de êxito, as suas emoções através da linguagem escrita ou falada.

O objetivo aqui consiste em: 1) extrair de um texto em linguagem natural os constituintes do cenário de extração que nesse caso engloba quem opinou (o opinante), sobre o que/quem opinou (o opinado) e a opinião; e 2) classificar essa opinião como positiva ou negativa. Para isso utilizaremos um modelo que atribua uma estrutura linguística e, dessa estrutura, identificar os referidos constituintes e a polaridade da opinião.

Se propõe o arcabouço teórico “*Systemic Functional Linguistic (SFL)*”, desenvolvido ao longo de vários anos por M.A.K. Halliday (o estudo desse arcabouço no qual essa dissertação se baseou (EGGINS, 2004)), e a sua extensão para a avaliação em linguagem avaliativa, intitulada “*Evaluation of Language: Appraisal in English*” (MARTIN; WHITE, 2005)

SFL, visualmente descrita na figura 3.1, é utilizada em contexto computacional há algumas décadas (O’DONNELL; BATEMAN, 2005) e seus principais atrativos para isso são: “... a ênfase da teoria de tratar o significado em contexto; a representação da linguagem em termos de rede de sistemas; a noção de sistemas em constante adaptação à atualização e uso contínuo; sua dependência em discursos textuais reais para explicar suas categorias de significado e a estrutura de suas redes de sistemas; e um detalhado

tratamento de sua gramática e seu relacionamento com a semântica.” (KAPPAGODA et al., 2009).

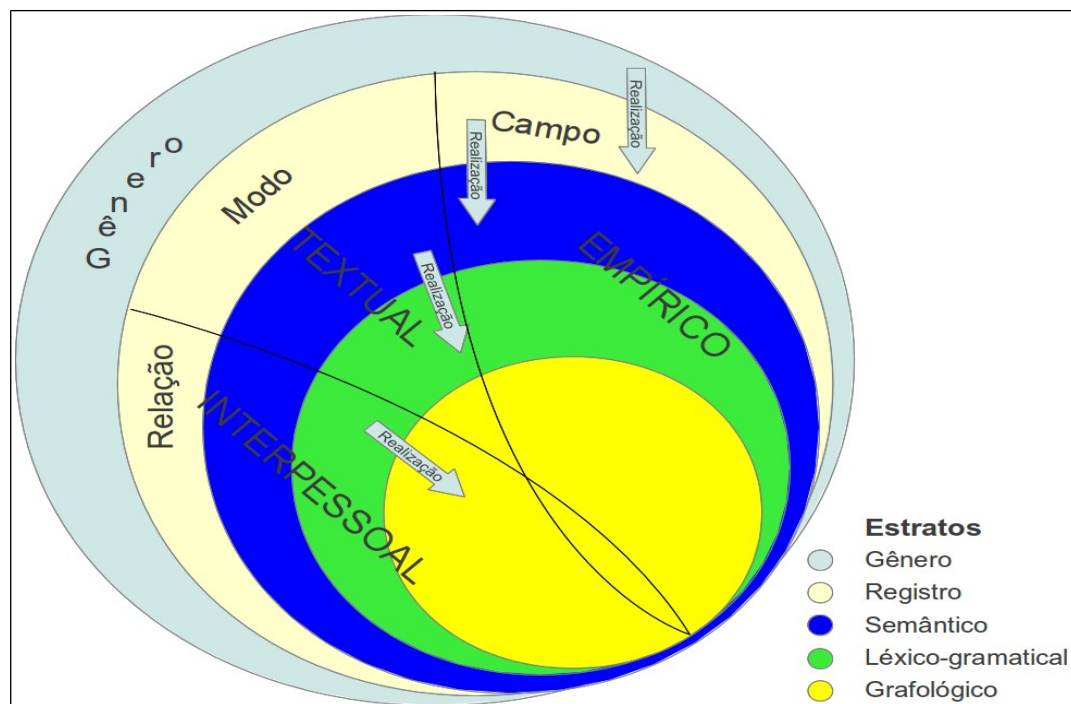


Figura 3.1: Modelo estratificado do contexto social

SFL divide o contexto em dois níveis. O mais abstrato é chamado de contexto social que consiste em processos e formas convencionais de comunicação em uma comunidade ou sociedade. Esse contexto é realizado em texto em um estrato chamado gênero. O segundo é o contexto situacional, que consiste em um modelo com três variáveis: campo, que identifica as pessoas envolvidas e sobre o que elas falam; relação, que identifica o relacionamento entre a pessoa que fala e seu interlocutor; e modo, que consiste na organização e desenvolvimento de uma conversa. O contexto situacional é realizado em texto no estrato registro.

Exemplificando com duas saudações: “Oi cara!” e “Oi meu!”. No contexto situacional as duas expressões seriam rotuladas na variável campo como saudação. A distinção seria no contexto social onde a primeira caracterizaria a escolha de uma saudação feita por cariocas enquanto a segunda caracterizaria a escolha de uma saudação feita por paulistanos.

Começando no estrato de registro indo até o mais baixo que consiste no estrato fonológico e grafológico existem três vertentes de significados apelidados de metafunção. A vertente interpessoal deriva da variável relação no estrato registro,

tratando no nível semântico, léxico-gramatical e grafológico a relação entre os interlocutores. A vertente empírica<sup>36</sup> deriva da variável campo no estrato registro, tratando também nos estratos: semântico, léxico-gramatical e grafológico quem são os interlocutores e sobre o que falam. A vertente textual deriva da variável modo no estrato registro, tratando nos estratos: semântico, léxico-gramatical e grafológico daquilo que transcende a estrutura gramatical (ex.: identificar e rastrear um indivíduo ao longo do discurso).

No estrato semântico estão os três sistemas de significados. O primeiro, semântica do discurso na vertente textual, trata do sistema que almeja:

- Identificação: rastrear os interlocutores;
- Negociação: rastrear as informações, bens e serviços trocados;
- Experiencial: rastrear a relação lexical para analisar a realidade; e
- Conjunção: rastrear a conexão entre mensagens via adição, comparação, temporalidade e casualidade.

O segundo sistema de significado, semântica da relação na vertente interpessoal, que busca interpretar a estrutura retórica, a coerência, a avaliação/sentimento no discurso. É nesse estrato e vertente que se desenvolverá o sistema de classificação polar da afetividade.

O terceiro sistema de significado consiste no sistema conceitual que, na vertente experiencial, busca encontrar os elementos como entidades e eventos no discurso. É nesse estrato e vertente que se desenvolverá o sistema de extração do opinante, opinado e a opinião.

Seguindo na estratificação vem o estrato léxico-gramatical. Nele trata-se de composição e constituintes, onde palavras compõe grupos que compõem cláusulas, conforme exemplificado na figura 3.2, extraída de (KAPPAGODA et al., 2009).

---

36 Em inglês essa metafunção é chamada de “ideational”.

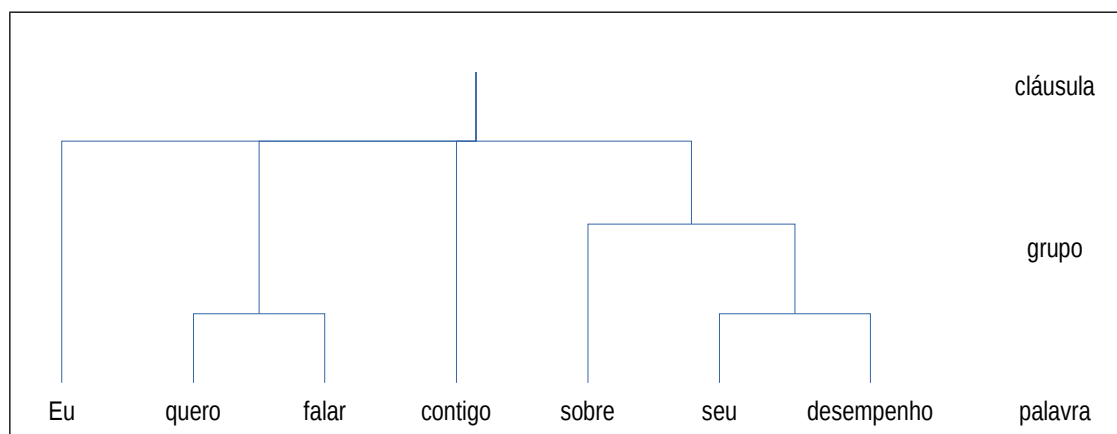


Figura 3.2: Estrutura de constituintes da estrutura léxico-gramatical em SFL

### 3.2 Teoria de avaliatividade em linguagem

A “Teoria de avaliatividade em linguagem” consiste numa extensão do arcabouço da SFL e foca em linguagem utilizada em avaliação, atitude ou emoção. Procura explicar como essa linguagem implica o nível de engajamento e posicionamento que um interlocutor detém em relação a uma proposta exposta em um diálogo. Esse posicionamento permite ao autor iterar com seu interlocutor (real ou potencial). Possui três tipos de avaliação: afeto, que focaliza emoções; julgamento, uma avaliação de cunho ético; e apreciação, uma avaliação de cunho estético. Construindo um léxico para cada tipo de avaliação é possível classificar segmentos de texto em um dos três tipos de avaliação (MARTIN; WHITE, 2005).

Uma aplicação dessa teoria em análise de sentimento é proposta em (WHITELAW *et al.*, 2005)<sup>37</sup>. Nesse artigo os autores comparam seu classificador polar de sentimento em crítica de filmes na mesma base utilizada por (PANG; LEE, 2004) obtendo resultados considerados o estado da arte.

O estudo científico da emoção é dominado por teorias que caracterizam tanto a sua experiência como a sua respectiva resposta expressiva e psicológica como subjetiva. A premissa implícita é a de que certas emoções emergem automaticamente como respostas a determinados tipos de eventos ou situações. Teorias com essa abordagem desconsideram o fato de que pessoas tem um conjunto distinto de emoções quando submetidas a experiências parecidas ou, ainda, quando o mesmo indivíduo tem emoções

<sup>37</sup> A data desse artigo é anterior a data da publicação da Appraisal Theory referenciada, pois a teoria estudada consiste numa evolução daquela utilizada para apoiar o artigo.

distintas em momentos diferentes. O objetivo da “*Appraisal Theory*” consiste em preencher essa lacuna, tendo como fundamento central o fato das emoções serem evocadas de acordo com a interpretação ou avaliação subjetiva de importantes situações ou eventos (SCHERER, 2001).

Para qualificar o desafio à frente dessa pesquisa reproduziu-se o seguinte texto.

“Para classificar emoções adotou-se a estratégia de mapear o terreno como um sistema de oposições<sup>38</sup>. Não está claro para nós, tendo sido treinados como gramáticos, como motivar uma classificação orientada a léxico desse tipo, nem fomos capazes de encontrar estratégias relevantes de argumentação no campo da linguística ou lexicografia baseada em corpus. Assim, nosso mapa de sentimento, para julgamento afetividade e apreciação, tem que ser tratado nesta fase como hipótese sobre a organização dos respectivos significados – oferecido como um desafio a todos os interessados com o desenvolvimento do raciocínio adequado, [oferecido] como um ponto de referência para aqueles com classificações alternativas e [oferecido] como uma ferramenta para aqueles que precisam efetuar análise da avaliatividade no discurso.”(MARTIN; WHITE, 2005, p. 46)

### **3.2.1 Os sistemas de escolha na teoria de avaliação em linguagem**

Dada a extensão e complexidade do sistema de avaliação proposto por (MARTIN; WHITE, 2005) nessa seção serão descritos apenas os componentes do sistema relevantes e utilizados na pesquisa.

O sistema de avaliação consiste em um subsistema de semântica interpessoal que faz parte da vertente empírica da SFL. O sistema de avaliação é, por sua vez, constituído de três subsistemas: engajamento; atitude e graduação. O sistema de engajamento trata do posicionamento do autor em um contexto, tendo como referência seus valores. Esses posicionam tanto a sua argumentação como sua contra-argumentação. O sistema de engajamento é importante pra identificação, por exemplo, se o autor é a favor ou contra um objeto, agente ou evento. Esse sistema não é relevante na identificação da afetividade proposta nessa tese.

O segundo sistema, que compõe o sistema de avaliação, consiste no sistema de

---

<sup>38</sup> Esse sistema para afetividade é extenso e optou-se por não representá-lo. Entretanto na figura 2.1 esse sistema é utilizado para graduação.

atitude. A figura 3.3 apresenta sua representação gráfica.

No sistema de atitude existem três escolhas. A primeira, que é o sistema de apreciação, trata da avaliação estética, na verdade a percepção do seu valor pelo agente que sente, em relação a objetos. O segundo consiste no sistema de afeto que trata da percepção das reações emocionais do agente que sente em relação ao fenômeno causador da emoção. A terceira escolha consiste no sistema de julgamento, que trata da avaliação ética. Essa consiste na avaliação do comportamento de um agente de acordo com princípios normativos da sociedade onde o avaliador está inserido.

O sistema de apreciação, por sua vez, é composto de cinco subsistemas. São eles:

- Composição complexidade: Trata da avaliação do grau de complexidade de um objeto. Trata de valores como o quão difícil foi acompanhar um objeto (exemplo: um curso), o quão difícil foi compreender um texto, o quão complicado foi utilizar um sistema. Na figura 3.3 é dado um conjunto de palavras cujo significado respondem as perguntas colocadas.
- Composição equilíbrio: Trata da avaliação do quanto as partes que constituem um objeto o fazem de maneira equilibrada. Um exemplo seria avaliar a decoração de uma sala como harmoniosa.

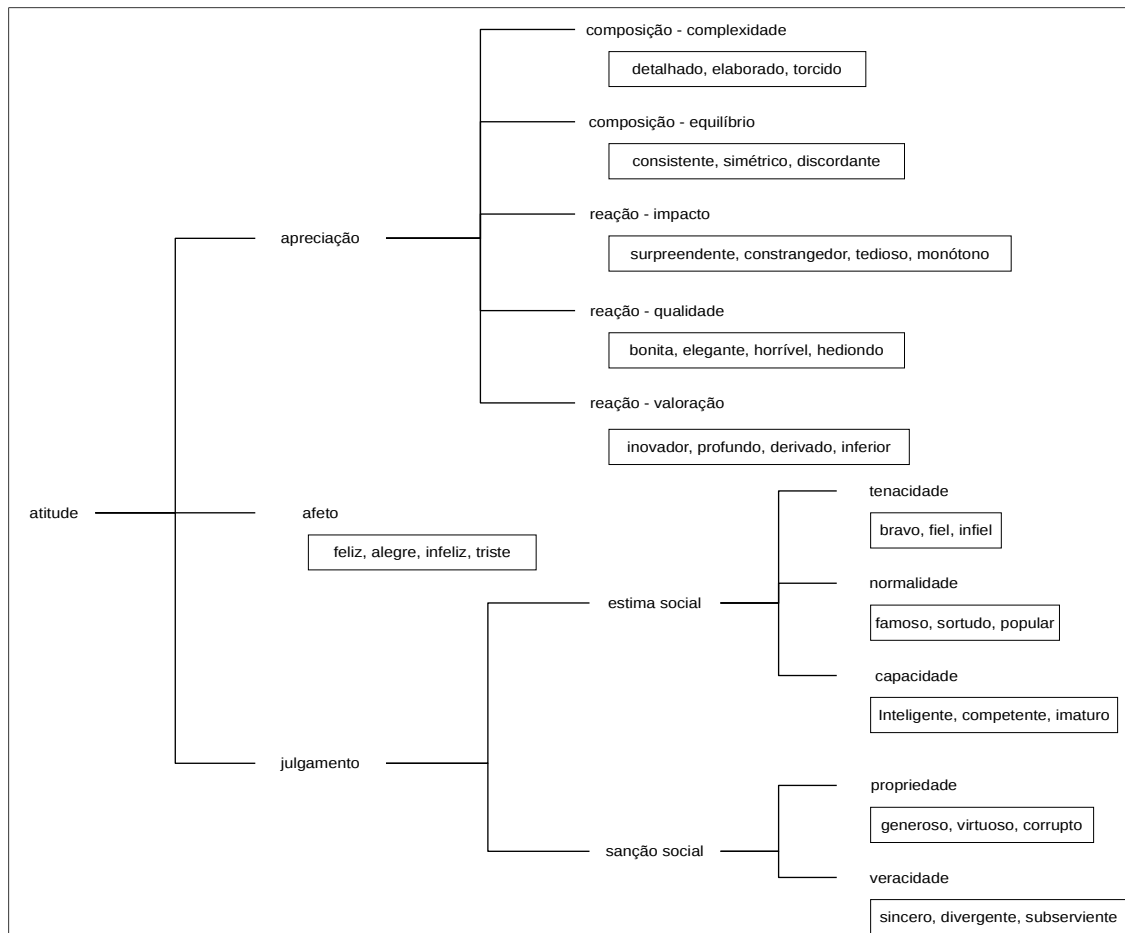


Figura 3.3: Sistema de atitude

- Reação impacto: Trata da avaliação do quanto o objeto cativou, ou prendeu, a atenção do avaliador. Um exemplo seria: não consegui largar o livro.
- Reação qualidade: Trata da avaliação do quanto a pessoa gostou do objeto. Pergunta relativa a esse subsistema seria o quanto um objeto é bom para o que se propõe;
- Reação valoração: Trata da avaliação do próprio valor do objeto para o avaliador. Um exemplo seria: valeu a compra desse telefone.

O sistema de juízo é composto por dois subsistemas: estima social; e sanção social. O subsistema sanção social é dividido em três escolhas:

- Tenacidade: Julga o quanto o agente é independente ou o quanto de esforço um indivíduo está disposto a investir. Exemplo seria: ela é trabalhadora
- Normalidade: Julga o comportamento de um indivíduo, ou seja, o quanto esse comportamento desvia da normalidade positivamente (famoso) ou



negativamente (impopular);

- Capacidade: Julga a capacidade de um indivíduo alcançar resultados. A palavra competente é um exemplo dessa dimensão;
- Propriedade: Julga o quanto um indivíduo é agradável ou desagradável. Adjetivos como virtuoso e generoso qualificam essa dimensão.
- Veracidade: Julga o quão honesto é um indivíduo. O adjetivo sincero caracteriza essa dimensão.

O sistema de afeto expressa o estado emocional de uma pessoa. Esses estados podem ser subdivididos em real (onde o estado constitui uma reação a um fenômeno real – o medo por estar no meio de um tumulto violento) ou irreal (onde o estado constitui uma reação a um fenômeno que ainda não aconteceu – o desejo de que seu time favorito ganhe o campeonato). Há também uma distinção entre se esse afeto consiste em um processo mental (o prazer de degustar um vinho) ou comportamental (sorrir ao provar um vinho). O sistema de afeto também é dividido pelos diferentes padrões lexicais. Na sentença “Ela o atrai” o agente causador da emoção vem antes do agente que sente a emoção. Na sentença “Eu amei o livro” o agente que sente vem antes do agente causador da emoção. No escopo dessa tese se resolveu tratar afeto nesse nível, sem descer para seus subsistemas.

O sistema de avaliação tem o terceiro subsistema que é o de graduação. A figura 3.4 apresenta um quadro resumindo da estrutura desse subsistema utilizada nessa pesquisa.

O sistema de graduação é dividido em dois subsistemas: força e foco. Basicamente esses dois sistemas trabalham com intensificadores e atenuadores. No subsistema força os intensificadores e atenuadores são representados como através de advérbios como muito e pouco. No sistema de foco a intensificação é representada através de padrões. Um exemplo seria a utilização em sequência de vários adjetivos para qualificar um atributo de um objeto. Outro seria expressar uma incerteza (atenuador de foco) sobre o atributo de um objeto. Nessa tese o sistema de graduação foi utilizado até o nível de intensificação e atenuação.

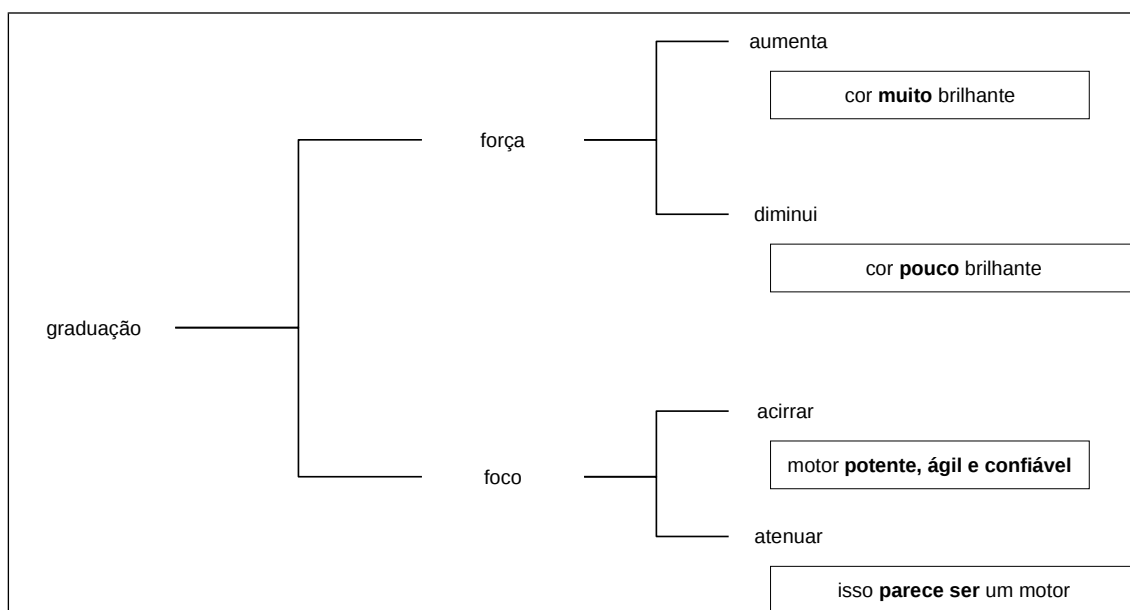


Figura 3.4: Sistema de graduação

### 3.2.2 Viabilidade da aplicação da teoria em português

Até o momento em que se encerraram as pesquisas dessa tese foram encontrados dois artigos que discutiram a aplicação dessa teoria em português. O primeiro (LOPES; VIAN JR, 2007) consiste em uma resenha do livro original (MARTIN; WHITE, 2005) em inglês. Ao final da resenha os autores concluem “... a obra é mais do que bem-vinda, uma vez que fornece valiosos subsídios para os estudiosos em gramática sistêmico-funcional em um campo vastíssimo e cheio de meandros e nuances que, com certeza, trarão perspectivas de estudos profícuos para os trabalhos em língua portuguesa.”


O segundo texto (VIAN JR., 2008) consiste em um artigo que discute para o português o sistema de graduação, a realização léxico gramatical de posturas avaliativas e propõe o termo avaliatividade como tradução de “*appraisal*”. O autor expressa em sua conclusão “Considerando as várias categorias propostas por Martin and White (2005), todas elas se aplicam ao português do Brasil, e nós somente temos que adicionar aspectos lexicais e certas flexões que não existem na língua inglesa...”

A conclusão sobre a viabilidade do uso dessa teoria (MARTIN; WHITE, 2005) para o português no escopo desse trabalho alinha-se com as conclusões apontadas nos artigos dessa seção.

### 3.3 Semântica diferencial

O objetivo dessa metodologia reside em suportar teoricamente uma medida de cada um dos atributos que constitui o modelo linguístico emocional. O resumo, de que trata essa seção, foi extraído de (HEISE, 1970).

A semântica diferencial mede a reação das pessoas, tendo com estímulo palavras e conceitos, em termos de escalas bipolares definidas com adjetivos contrastantes colocados nas extremidades da referida escala. Um exemplo dessa escala está na figura 3.5. Normalmente a posição marcada com o rótulo “0” tem sua intensidade considerada neutra, com rótulo 1 considerada leve, com rótulo 2 considerada moderada e com rótulo 3 considerada extrema.



*Figura 3.5: Exemplo de escala na semântica diferencial*

Uma escala como essa mede tanto a direção, no caso bom versus ruim, como a intensidade. Essa metodologia é aplicada empiricamente. Conceitos são oferecidos a pessoas que graduam sua intensidade na escala.

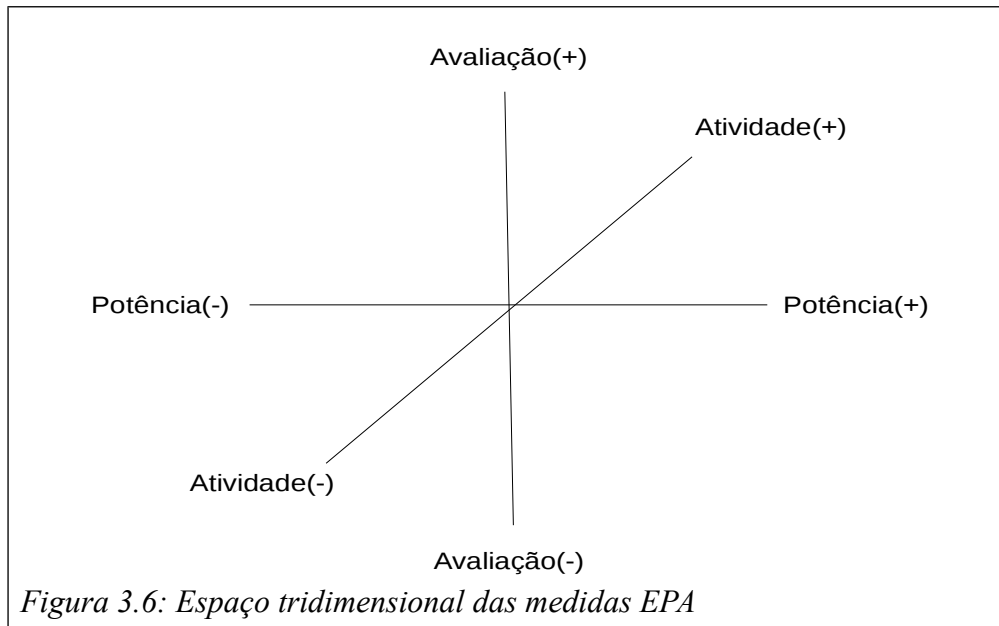
O autor enumera cinco considerações envolvendo a semântica diferencial:

- Escalas com adjetivos bipolares são meios fáceis de obter informação da reação de uma pessoa;
- Os valores na escala estão correlacionados a três dimensões básicas que são: avaliação, potência e atividade. O conjunto dessas dimensões é chamado de EPA, oriundo das iniciais dessas dimensões em inglês.<sup>39</sup>
- Usando poucas escalas se obtém medidas confiáveis da resposta de uma pessoa a alguma coisa. Um conceito é associado com várias escalas em uma dimensão, sendo o resultado dessa dimensão a média obtida dessas escalas.

<sup>39</sup> “Evaluation”, “Potency” e “Activity” (EPA)

- Medidas EPA são apropriadas quando o interesse é obter respostas afetivas a um estímulo. Essas medidas servem para comparar reações a vários conceitos díspares como reação a pessoas, poemas e cores.
- Vários estudos comprovam a eficácia dessas medidas.

É conveniente entender as dimensões EPA formando um espaço tridimensional conforme a figura 3.6



Nessa metodologia não há descrição formal das dimensões. Entretanto são oferecidos adjetivos contrastantes e conceitos associados. Por exemplo:

- Avaliação está associada a adjetivos contrastantes como bom – ruim, doce – amargo e bonito – feio. Conceitos associados no lado positivo foram doutor, família, feliz, paz e sucesso. Já conceitos no lado negativo foram aborto, divórcio, fraude, ódio e doença.
- Potência está associada a adjetivos contrastantes como grande – pequeno, forte – fraco e profundo – raso. Conceitos associados no lado poderoso foram guerra, exército, montanha, poder e ciência. Já conceitos no lado fraco foram bebê, gato, beijo, amor e arte.
- Atividade está associada a adjetivos contrastantes como rápido – lento, vivo – morto e barulho – silêncio. Conceitos associados a grande atividade foram perigo, ataque, fogo, tornado e guerra. Já conceitos associados à baixa atividade

foram calma, caracol, ovo, pedra e dormir.

As medidas EPA de um estímulo servem como coordenadas nesse espaço, sendo seu ponto uma representação gráfica da resposta afetiva a um estímulo.

O autor adverte para o uso cuidadoso do número de escalas em cada dimensão, pois elas devem ser relevantes e independentes. Na metodologia não existe um mecanismo de medir esses dois parâmetros e a recomendação é utilizar um conjunto já validado empiricamente.

Um estudo comprovou o aumento da eficiência dessas medidas utilizando escalas adverbiais, como sempre versus nunca e extremamente versus levemente.

Para encontrar uma medida única que caracterize a intensidade de um conceito foi proposta a fórmula, que consiste na norma do vetor no espaço EPA:

$$I = \sqrt{e^2 + p^2 + a^2}$$

### **3.4 Teorias de emoção**

A importância de uma teoria de emoção no contexto dessa tese reside em subsidiar um modelo, computacionalmente tratável, que alinhe atributos linguísticos com atributos de emoção em textos, permitindo separar aqueles que contém uma opinião daqueles que não as contém, identificando em seguida sua polaridade.

#### **3.4.1 Uma visão geral das teorias de emoção**

O resumo das diversas teorias de emoção que se segue está baseado em três textos: (ORTONY; CLORE; COLLINS, 1988); (DE SOUSA, 2014); e (BAILLIE, 2002). Seu objetivo consiste na contextualização da teoria utilizada a luz das diversas correntes de pensamento.

Vale ressaltar, considerando os textos em que o resumo se apoia, que algumas linhas de estudo da emoção não foram apreciadas. Particularmente não se descreve a visão da emoção sob a ótica das diversas correntes psicanalíticas e da neurociência. Se entende que essas linhas de pensamento trazem contribuições e serão alvo de estudo na continuação das pesquisas que se iniciam nessa tese.

O que é emoção? (BAILLIE, 2002) especula em sua tese de doutorado que a origem da não convergência em uma definição universalmente aceita deriva do fato de a palavra ser utilizada em diferentes domínios, tais como; neurologia; psicologia; e

inteligência artificial para “descrever um largo espectro de estados cognitivos e fisiológicos do ser que sente”.

Os autores (REISENZEIN et al., 2013) especulam que uma definição de emoção deve estar atrelada a uma teoria de emoção. A inexistência de uma teoria universalmente aceita, acarreta a ausência de uma definição.

Já (DE SOUSA, 2014) partindo das diversas abordagens teóricas reflete que emoção pode ser um processo fisiológico, ou percepção desse processo, de ser um estado neuropsicológico, de ser uma disposição adaptativa, de ser um julgamento avaliativo ou de ser um processo dinâmico. Vendo essas definições como parciais o autor propõe reformular a pergunta “Para o que serve a emoção?”. Emoção seria percebida no momento da ruptura das “funções adaptativas” como pensamento, percepção e planejamento racional. Serviria, então, para em um primeiro momento escolher uma subfunção reativa ao que levou à ruptura e, em um segundo momento, para desempenhar a função escolhida.

Entretanto uma definição se faz necessária, e, por nessa pesquisa se ter optado por sua teoria, foi escolhida a dada por (ORTONY; CLORE; COLLINS, 1988) onde “emoção consiste na reação com valência a evento, agente ou objeto, com sua natureza particular sendo determinada pelo modo como as situações que as provocam são percebidas” pelo ser que sente. Nesse caso valência consiste no atrativo intrínseco (valência positiva) ou aversão (valência negativa) ao referido evento, agente ou objeto<sup>40</sup>.

Essa escolha alinha essa pesquisa no paradigma da teoria cognitiva. (ORTONY; CLORE; COLLINS, 1988) chama o adjetivo que qualifica a teoria, no caso cognitiva, de variável, enquanto (DE SOUSA, 2014) o chama de “abordagem”.

A variável cognitiva de (ORTONY; CLORE; COLLINS, 1988) é dividida em duas abordagens por (DE SOUSA, 2014): “psicológica e evolutiva” e a teoria cognitiva propriamente dita.

A “psicológica e evolutiva”, na prática é uma subdivisão em duas classes: a psicológica e a evolutiva. Em sua subdivisão psicológica, o autor descreve que “emoção envolve avaliação” e que dessa avaliação emerge atração ou aversão dependendo da forma que é percebida pelo agente que a sente. O autor caracteriza teorias avaliativas como uma abordagem funcional à emoção, pois as avaliações levam a reações com a

---

40 [http://es.wikipedia.org/wiki/Valencia\\_\(psicolog%C3%ADa\)](http://es.wikipedia.org/wiki/Valencia_(psicolog%C3%ADa))

finalidade de tratar com específicos tipos de situações com algum significado para o indivíduo. Essa caracterização de emoção se alinha com a definição dada acima. Já na subdivisão evolutiva a pergunta que emerge é “Por que temos tipos de emoções?”. Essa pergunta leva a uma resposta evolutiva onde “emoção consiste em uma adaptação cujo propósito é resolver um problema ecológico básico com o qual o organismo se depara”. Nessa subdivisão o autor classifica teorias que abordam a emoção como forma de expressão, valorizando a sua utilidade na comunicação com outros indivíduos. Segundo o autor seu caráter evolutivo fica acentuado por teóricos dessa abordagem terem se inspirado em Darwin, que entende que a “expressão emocional é uma importante parte do programa afetivo que consiste em respostas complexas encontradas em todas as populações humanas que são controladas por mecanismos operando debaixo da consciência humana”. Nessa linha o autor lista a teoria de (EKMAN, 1993) que trata com expressões, na literatura chamada de emoções básicas que são: alegria, tristeza, medo, raiva, surpresa e desgosto.

A segunda abordagem de (DE SOUSA, 2014) se diferencia da abordagem “psicológica e evolutiva” pelo fato dos teóricos dessa linha entenderem que emoção envolve uma atitude propositiva, ou seja, envolve alguma espécie de atitude direcionada a uma proposição. Essa posição identifica emoção com julgamento. Um exemplo seria que um indivíduo somente pode sentir raiva de outro se julgar que o último é o responsável por uma ofensa.

Exceto pela subdivisão evolutiva da primeira abordagem a teoria de (ORTONY; CLORE; COLLINS, 1988) encontra semelhanças com as duas abordagens descritas em (DE SOUSA, 2014).

Segundo (DE SOUSA, 2014) as emoções básicas, acima listadas, seriam mecanismos integrados e implementados por circuitos naturais no cérebro de humanos, em particular, mas também no de todos os mamíferos. Os teóricos que seguem esse princípio entendem que as demais emoções seriam resultantes da composição ou mistura dessas emoções básicas.

(ORTONY; CLORE; COLLINS, 1988) rejeitam a ideia de que exista esse conjunto de emoções. Enquanto entendem que algumas, como alegria, tristeza, raiva e medo são encontradas em todas as culturas, rejeitam a universalidade das demais. Questionam se as emoções não básicas consistem em uma composição das básicas, levantando a dificuldade de se encontrar da emoção resultante as suas constituintes. Se

as emoções não básicas constituírem uma mistura das básicas, deveria ser observável na própria emoção resultante as suas componentes. Questionam também se emoções resultantes necessariamente ocorrem depois das básicas, não podendo ocorrer antes. Demonstram a inexistência de acordo entre os teóricos que advogam que essas constituem um conjunto ao enumerarem seu desacordo quanto as emoções componentes desse conjunto. Terminam argumentando que essas perguntas e divergências não aferem um caráter coeso dos atributos que afeririam a uma emoção ser caracterizada como básica.

(DE SOUSA, 2014) aborda a discussão do papel das emoções no processo racional. Os inúmeros caminhos existentes para alcançar um objetivo poderiam levar a uma explosão de alternativas tornando infinito o processo de escolha do caminho adequado. Os teóricos chamam esse o “Problema da Moldura”<sup>41</sup>. Emoção constituiria em um mecanismo de restrição e direcionamento da atenção ao, em primeiro, definir os parâmetros a serem considerados na decisão e, em segundo, no processo decisório salientar uma pequena porção das alternativas, restringindo o número de caminhos para alcançar o objetivo. O autor opina que “a capacidade de experienciar uma emoção parece ser indispensável na condução de uma vida racional no tempo”. Levanta um estudo em neurociência (DAMASIO, 2005) onde indivíduos com lesões no córtex pré-frontal e somatossensorial com reduzida capacidade de sentirem emoção tiveram sua capacidade de decidir sobre questões práticas significativamente comprometidas. O autor conclui que “emoções são importantes para a racionalidade mesmo que elas não sejam consideradas racionais ou irracionais”.

A diversidade de teorias, sejam oriundas da psicologia, filosofia ou neurociência, tornam a compreensão da emoção em algo que (BAILLIE, 2002) chamou de “caos”. Não obstante (DE SOUSA, 2014) aponta para alguns pontos onde todas as teorias convergem na íntegra ou, pelo menos, em parte. Resumidamente as teorias concordam que emoção consiste em um fenômeno consciente, enquanto a disposição para manifestá-la, em alguns casos, pode ser inconsciente. Envolve mais manifestações corporais do que outros estados conscientes, mas não pode ser compreendida apenas fisiologicamente. Varia em intensidade, duração, valência e tipo. Muitas vezes se manifesta através do desejo, podendo ser modulada pelo humor. Tem uma reputação de ser antagônica à racionalidade enquanto é crucial na definição de objetivos e prioridades. Tem papel importante na qualidade e regulamentação da vida em sociedade.

41 Tradução livre do inglês “Frame Problem”.



### 3.5 Atributos para a escolha de uma teoria de emoção

Com a diversidade de teorias elencou-se um conjunto de atributos que permitissem escolher a mais aderente aos objetivos dessa pesquisa. Foram eles:

1. Alinhamento com o paradigma das teorias de avaliação, a exemplo da teoria de linguagem. O recorte semelhante da realidade (reação a eventos, julgamento das ações de agentes e atratividade de objetos) facilitaria, ou mesmo, permitiria o alinhamento mencionado;
2. A relevância do uso da linguagem como evidência para estados emotivos, em detrimento de teorias que avaliam reações corporais internas (como variação do ritmo cardíaco) ou expressões faciais;
3. Uma estrutura que permita agrupar o, praticamente ilimitado, número de situações com potencial para gerar emoções, diminuindo o tamanho da base de conhecimento para caracterizar cada um deles;
4. Uma estrutura que permita agrupar as inúmeras formas de se expressar uma mesma emoção, seja através do emprego de uma palavra ou cláusula;
5. Que possa ser utilizada por um agente artificial para inferir/raciocinar sobre emoção; e
6. Ter sido bastante referenciada, uma evidência indireta de sua aplicabilidade.

O propósito aqui é justificar como o modelo de Ortony, Clore e Collins (ORTONY; CLORE; COLLINS, 1988), conhecido na literatura como modelo OCC adere aos atributos acima listados.

A própria definição de emoção dada pelos autores (ver seção 3.4.1) fornece evidências do alinhamento dessa teoria com o atributo 1. Emoção sendo uma reação com valência a uma ocorrência conforme avaliada pelo ser que sente pressupõe cognição. Adicionalmente, como descrito na figura 3.8, seu corte de mundo, exatamente por serem elaboradas sob o paradigma da teoria de atratividade, são semelhantes.

(ORTONY; CLORE; COLLINS, 1988) enumeram quatro tipos de evidências que podem ser utilizadas para a compreensão de emoções. A primeira é chamada de

“linguagem das emoções” que vem “repleta de ambiguidades, sinônimos e uma abundância de lacunas e armadilhas linguísticas”, que no escopo dessa tese se apelida de ruído. Adicionalmente afirmam que “emoções não são coisas linguísticas, mas o mais disponível acesso não fenomenológico a elas é através da linguagem”. Como será discutido na seção 3.6, na estrutura do modelo, os autores propõem palavras que caracterizam tipos de emoção. Essa característica alinha o modelo OCC com o atributo 2. Entretanto ele alertam para o uso cuidadoso da linguagem como evidência para emoção. A segunda fonte de evidências está no preenchimento de questionários onde o indivíduo relata o que sente. Interessante é que até o momento da criação do modelo os autores afirmam não haver uma medida objetiva que pode de forma conclusiva estabelecer a emoção sentida. A premissa para a validade desse tipo de evidência reside no fato de a pessoa ter acesso direto ao que sente, por exemplo medo, tornando válidas as suas respostas. O terceiro tipo de evidência é o comportamental que tem sua importância diminuída pelos autores em função dos objetivos do modelo. Eles ponderam que alguns comportamentos resultantes de emoções podem não ser executados, pois seriam prejudiciais ao alcance de objetivos do agente. Por exemplo reagir com agressão física à raiva. Entretanto os autores não consideram essa modulação que é pertinente nas demais evidências. O quarto tipo de evidência é o fisiológico, mas, enquanto reconhecem sua importância, descartam por fornecerem pouca evidência aos aspectos cognitivos.

Esse modelo, por partir do paradigma da teoria de avaliatividade, recorta o mundo de tal forma que o alinha com o atributo 3. Nesse paradigma o agente reage ao resultado de um evento, às ações de um agente e aos aspectos de um objeto.

O modelo oferece um pequeno dicionário (130 palavras distribuídas em 22 tipos de emoção), mas que serve como ponto de partida para ampliação, de palavras que caracterizam cada tipo de emoção. Isso o alinha com o atributo 4<sup>42</sup>.

A justificativa do alinhamento desse modelo com o atributo 5 é dada em (BAILLIE, 2002) onde o autor afirma que “o modelo se presta admiravelmente a sistemas em IA e, apesar de não ter sido proposto para sintetizar emoções em computador, é utilizado como base em pesquisas na computação afetiva...”.

Até o momento da escrita dessa tese esse modelo havia sido citado em 5.315

---

42 Vale ressaltar que não se utilizou esse dicionário nessa pesquisa, embora haja pretensão de se utilizá-lo na continuação dos trabalhos.

artigos. Isso serviu de “*proxy*” para o atendimento do seu alinhamento com o atributo 6.

### 3.5.1 O “Relógio de Areia” das emoções

Na revisão bibliográfica identificou-se outro modelo que adere a 5 dos 6 atributos de escolha descritos na seção 3.5. Até o momento da escrita dessa tese esse modelo havia sido citado 30 vezes, ferindo o 6<sup>43</sup>. Intitulado “The hourglass of emotions” foi feito para reconhecer, compreender e expressar emoções na interação homem-máquina (CAMBRIA; LIVINGSTONE; HUSSAIN, 2012). Nesse modelo os estados afetivos são desmembrados em quatro dimensões: agradabilidade; atenção; sensibilidade e aptidão. Cada dimensão é dividida em seis níveis, uma escala numérica que varia no intervalo [-3, 3], que fornece a intensidade da emoção. Dada as dimensões e as intensidades os autores classificam 24 emoções, sendo 12 positivas e 12 negativas. A emoção medo, por exemplo, estaria na interseção da dimensão sensibilidade com o nível -2. Para o tratamento de texto, os autores apoiam-se em dicionários que englobam as palavras que caracterizam cada emoção. A figura 3.7 contém uma descrição do modelo.

A intensidade de uma emoção consiste em uma das variáveis de entrada na função que “dispara” uma reação com valência no modelo OCC. Não foi objeto central elaborar um dicionário de palavras. Portanto sua ausência constitui uma lacuna, potencializada pela inexistência da discussão de como extrair sua intensidade da evidência linguística. Na prática, por exemplo, a palavra “medo” tipifica a emoção do tipo medo e os autores sugerem que sua intensidade seja neutra. Já a palavra “apavorado” seria uma emoção do tipo medo, porém com intensidade alta. A palavra “preocupado” seria uma emoção do tipo medo com intensidade baixa.

A discussão proposta por (CAMBRIA; LIVINGSTONE; HUSSAIN, 2012) foi utilizada como um dos dois apoios teóricos, o outro é (HEISE, 1970) para calcular a intensidade de uma emoção. Duas são as diferenças do aqui desenvolvido para o modelo “The hourglass of emotion”. A primeira diferença reside nas dimensões que no caso da tese aqui descrita foi apenas a intensidade. A segunda consiste na escala, que consistiu em um número no intervalo entre [-1,1] (ver seção 3.3).

---

43 Algumas em outros artigos de seus autores.

	Agradabilidade	Atenção	Sensibilidade	Capacidade
3	êxtase	vigilância	fúria	admiração
2	alegria	expectativa	raiva	confiança
1	serenidade	interesse	aborrecimento	aceitação
0	-	-	-	-
-1	melancolia	distração	apreensão	tédio
-2	tristeza	surpresa	medo	aversão
-3	pesar	espanto	terror	repugnância

Figura 3.7: “The hourglass of emotion” (extraído de(CAMBRIA et al., 2012))

### 3.6 A estrutura cognitiva de emoções

O modelo OCC (ORTONY; CLORE; COLLINS, 1988) objetiva estudar como a percepção do mundo por uma pessoa a leva a experienciar uma emoção. Para isso os autores precisaram entender a estrutura do sistema emocional como um todo e a estrutura de cada grupo de emoção em particular. A estrutura resultante está na figura 3.8.

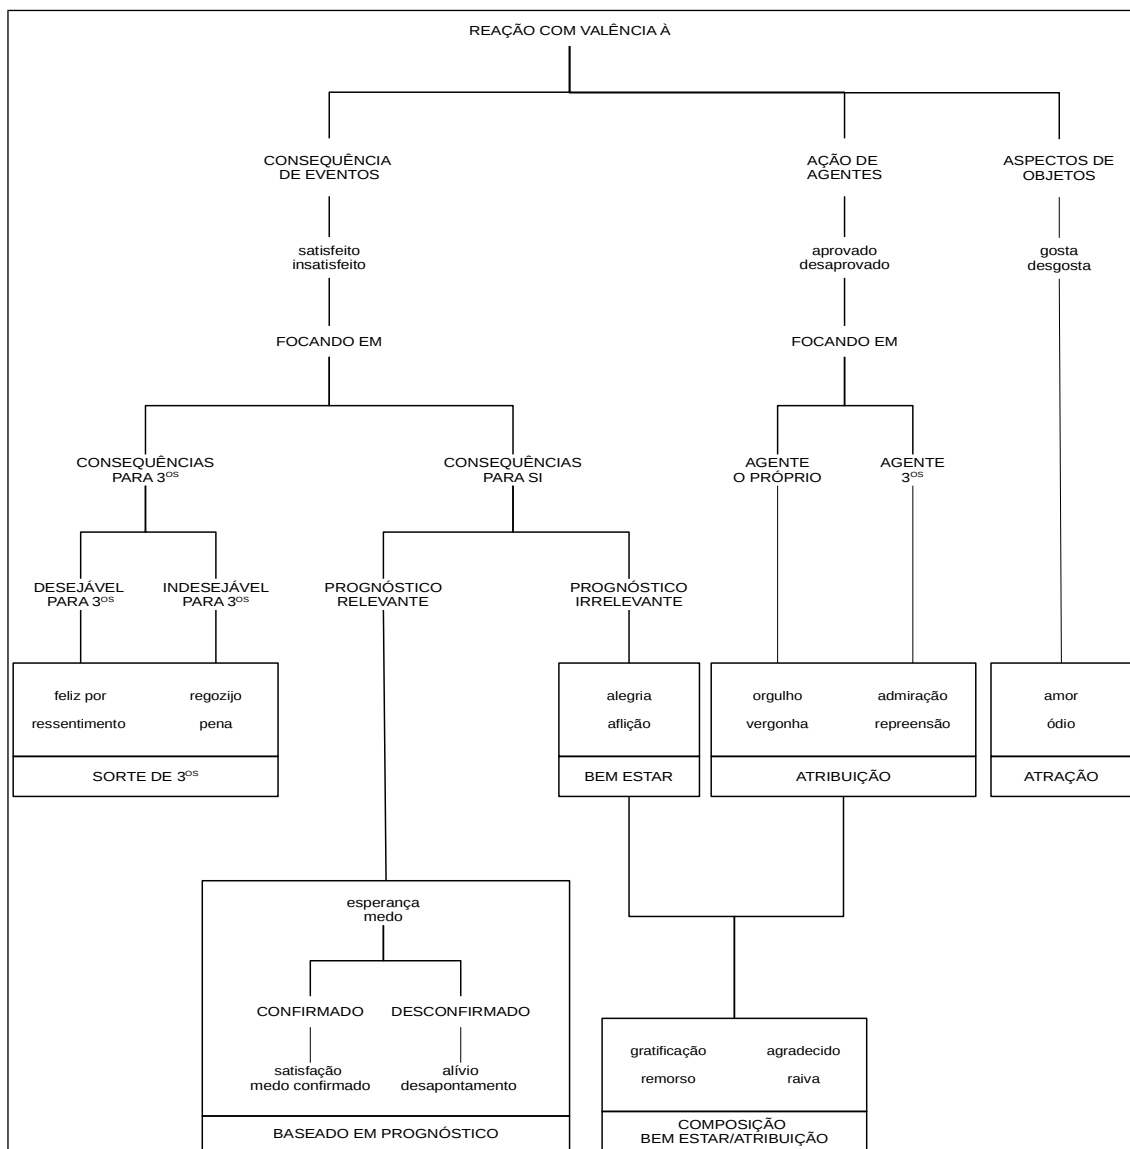


Figura 3.8: O modelo OCC de (ORTONY; CLORE; COLLINS, 1988)

Nessa figura o grupo de tipos de emoção está contido em caixas. Os tipos de emoção estão caracterizados em letras minúsculas e as formas de perceber o mundo em

letras maiúsculas. Cada grupo de emoção é apelidado por um rótulo em letras maiúsculas.

A abordagem para o entendimento do sistema consistiu em representar emoções em um conjunto de grupos substancialmente independentes baseados em sua origem cognitiva. A abordagem para o entendimento da estrutura do grupo consistiu na forma de como as pessoas percebem o mundo ou variações nele. Assim especificaram tantas as condições que provocam emoções como as variáveis que as modulam.

Partindo do princípio de que emoções consistem em reações com valência, o modelo divide os 22 tipos de emoção e três vertentes.

Na primeira se situam os tipos de emoção resultantes da percepção do indivíduo à consequência de um evento. Essa percepção, em seu nível mais alto pode ter a valência positiva (prazer) ou negativa (desprazer). Nesse nível não é possível determinar a emoção do tipo feliz. Para isso é necessário identificar se o foco percebido da consequência do evento recai sobre o próprio indivíduo ou sobre terceiros. Recaindo sobre o próprio é preciso identificar se a consequência desse evento gera uma expectativa no indivíduo ou não. Não gerando uma expectativa, que no modelo é caracterizado como “PROGNÓSTICO IRRELEVANTE”, a consequência do evento resulta na emoção feliz ou triste. Um exemplo seria acertar os números em uma loteria.

Se “PROGNÓSTICO RELEVANTE”, por exemplo o torcedor de um time de futebol que disputará a final de um campeonato, as consequências do evento ainda não são conhecidas (o resultado da partida) gerando esperança. Caso seu time vença, ou seja, a esperança foi confirmada, o indivíduo experienciará satisfação. No caso do seu time perder a partida, ou seja, esperança não confirmada, o indivíduo experienciará desapontamento.

Na segunda se agrupam os tipos de emoção resultantes da percepção do indivíduo em relação à ação de um agente. Essa percepção, em seu nível mais alto pode ter a valência positiva (aprovar) ou negativa (desaprovar). Nesse nível não é possível determinar a emoção do tipo orgulho. Se a ação for do próprio indivíduo esse a experimentar a emoção de orgulho (valência positiva). Se for de outro indivíduo, e essa ação for percebida como reprovável, a emoção experimentada será do tipo censura.

Essas duas primeiras vertentes podem ser compostas gerando emoção do tipo recompensado. Um exemplo seria a emoção sentida por um indivíduo que estudou

muito e passou em um concurso.

Na terceira se agrupam os tipos de emoção resultantes da percepção do indivíduo em relação aos aspectos de um objeto. Essa percepção, em seu nível mais alto pode ter a valência positiva (gostar) ou negativa (desgostar). No grupo de tipos de emoção “ATRAÇÃO” estão as emoções do tipo amar e adiar.

A figura 3.9 contém um resumo descritivo dos 22 tipos de emoções do modelo OCC com suas respectivas especificações.

Grupo	Tipo de Emoção	Descrição
SORTE DE TERCEIROS	Feliz por	(prazer pela) deseabilidade presumida de um evento para terceiros
	Ressentimento	(desprazer pela) deseabilidade presumida de um evento para terceiros
	Regozijo	(prazer pela) indeseabilidade presumida de um evento para terceiros
	Pena	(desprazer pela) indeseabilidade presumida um evento para terceiros
BASEADO EM PROGNÓSTICO	Esperança	(prazer pela) deseabilidade do prognóstico de um evento
	Medo	(desprazer pela) indeseabilidade do prognóstico de um evento
	Satisfação	(prazer pela) confirmação da deseabilidade do prognóstico de um evento
	Medo Confirmado	(desprazer pela) indeseabilidade da confirmação do prognóstico de um evento
	Alívio	(prazer pela) desconformimação da indeseabilidade do prognóstico de um evento
BEM ESTAR	Feliz	(prazer pela) deseabilidade de um evento
	Triste	(desprazer pela) indeseabilidade um evento
ATRIBUIÇÃO	Orgulho	(aprovar) a louvabilidade de sua própria ação
	Vergonha	(desaprovar) a culpabilidade de sua própria ação
	Admiração	(aprovar) a louvabilidade da ação de terceiros
	Repreensão	(desaprovar) a culpabilidade da ação de terceiros
COMPOSIÇÃO BEM ESTAR/ATRIBUIÇÃO	Recompensado	(aprovar a) louvabilidade de sua própria ação e (prazeroso) da deseabilidade do evento relacionado
	Remorso	(desaprovar a) culpabilidade de sua própria ação e (desprazeroso) da indeseabilidade do evento relacionado
	Agrdecido	(aprovar a) louvabilidade da ação de terceiros e (prazeroso pela) deseabilidade do evento relacionado
	Raiva	(desaprovar a) culpabilidade da ação de terceiros e (desprazeroso pela) indeseabilidade do evento relacionado
ATRAÇÃO	Amor	(gostar) da atratividade de um objeto
	Ódio	(desgostar) da desatratividade de um objeto

Figura 3.9: As especificações dos tipos de emoção do modelo OCC

### 3.6.1 As variáveis centrais do modelo

Na especificação de cada tipo de emoção, entre parêntesis, está sua respectiva valência no mais alto nível da hierarquia. Após aparecem seis conceitos centrais. São eles: deseabilidade / indeseabilidade; louvabilidade / culpabilidade; e atratividade / desatratividade. A seguir seguem suas definições.

- Desejabilidade<sup>44</sup> consiste na variável central da vertente “CONSEQUÊNCIA DE EVENTOS” e mede a intensidade da expectativa das consequências benéficas de um evento. A indesejabilidade consiste no seu inverso, ou seja, a intensidade da expectativa de consequências maléficas de um evento

44 Do inglês “desirability”

- Louvabilidade<sup>45</sup> consiste na variável central da vertente “AÇÃO DE AGENTES” e mede a intensidade da aderência a valores éticos das ações das pessoas. A culpabilidade<sup>46</sup> seria seu inverso, ou seja, a intensidade da não aderência aos valores éticos das ações das pessoas.
- Atratividade consiste na variável central da vertente “ASPECTOS DE OBJETOS” e mede a intensidade da avaliação de uma pessoa relativa a atitude, ou seja, sua disposição para gostar de um objeto ou de aspectos de um objeto. Desatratividade seria o seu inverso e mede intensidade da disposição de uma pessoa para desgostar de um objeto ou aspectos de um objeto.

### 3.6.2 As variáveis globais do modelo

No modelo OCC as emoções centrais, já descritas medem o grau de intensidade da emoção. Entretanto existem variáveis globais (afetam todas as emoções) e locais (específicas de cada tipo) que intensificam ou atenuam a emoção.

As variáveis globais são:

- Senso de realidade: Consiste no quanto um evento, agente ou objeto parece real para o indivíduo que sente. Se pode experienciar uma emoção positiva (felicidade) imaginando que se ganhou na loteria. Mas se o prêmio for verdadeiro a emoção será mais intensa.
- Proximidade: Na teoria essa distância é temporal. Podemos sentir uma emoção de um evento ocorrido no passado ou mesmo no futuro. Quanto mais distante do presente o evento estiver mais atenuada é a experiência da emoção. Quanto mais próxima do presente mais intensa é a emoção.
- Inesperabilidade: Imaginando as demais variáveis mantidas é reconhecido o aumento da intensidade de uma emoção se o evento for inesperado, se o agente se comportar de maneira inesperada ou se o objeto tiver aspectos não previstos. É importante não confundir essa variável com a variável local, probabilidade, que modula emoções do grupo “BASEADO EM PROGNÓSTICO”.

“Arousal”<sup>47</sup>, sendo estar em estado de alerta ou de reação a um estímulo,

45 Do inglês “*praiseworthiness*”

46 Do inglês “*blameworthiness*”

47 A tradução encontrada foi excitação, porém preferi manter o termo em inglês uma vez que essa variável não é utilizada para modular as variáveis centrais.



consiste na quarta variável global. Os autores especulam como essa variável pode modular a emoção, mas não a utilizam em nenhum momento no modelo.

### **3.6.3 As variáveis locais**

Diferentemente das variáveis básicas que influenciam as emoções em suas respectivas vertentes e das variáveis globais que influenciam todas as emoções, as variáveis locais modulam grupo de emoções. Por serão enumeradas por grupo.

- Sorte de terceiros: Esse grupo é modulado por três variáveis. A primeira, desejabilidade para o terceiro, que mede o grau de importância de um evento para o terceiro. Essa importância pode ser referenciada conhecendo-se a importância do evento para o terceiro ou inferindo que essa importância é equivalente ao do próprio agente que sente. A segunda é apreço, ou seja, a afinidade entre a pessoa que sente e o terceiro. A terceira é o merecimento que mede o quanto o terceiro mereceu o resultado do evento.
- Baseado em prospecto: Se o evento ainda não ocorreu, ou seja, as emoções são do tipo esperança e medo a variável é a probabilidade. Esse mede qual a probabilidade do evento ocorrer na visão do agente que sente. Ocorrido o evento se tem duas variáveis. A primeira é o esforço investido que tem correlação positiva com a intensidade da emoção. A segunda é realização que intensifica ou atenua a experiência de uma emoção na medida em que os resultados do evento aconteceram em sua plenitude ou em parte.
- Atribuição: Possui duas variáveis locais. A primeira consiste na força da unidade onde a intensidade da emoção é alterada pela associação do agente que sente a emoção com o agente foco da emoção. Um exemplo seria se uma instituição ganhasse um prestigiado prêmio. Se o ser que sente pertencer a essa instituição pode sentir um orgulho mais intenso do que outro que não pertence. A segunda variável é o desvio de expectativa. Essa mede a diferença entre a ação esperada de uma agente e a ação realizada. Se um professor ganha um prêmio importante a admiração do ser que sente tem uma intensidade. Se no lugar do professor for o aluno, a admiração experienciada será intensificada.
- Atração: Uma variável modula as emoções desse grupo que é a familiaridade. Um exemplo que caracteriza essa variável reside no apreço da comida de um

restaurante quando se a degusta pela primeira vez em detrimento das vezes seguintes. Quanto mais familiar for um objeto para o agente que sente, menor será a intensidade da emoção oriunda de um atributo do objeto.

### 3.6.4 Tratamento computacional

Os autores desenvolveram esse modelo pensando na sua aplicação em pesquisas em IA. Nas regras que se seguem as variáveis de cada função tem o seguinte significado:

- $p \rightarrow$  pessoa
- $e \rightarrow$  evento
- $t_n \rightarrow$  tempo
- $a \rightarrow$  agente
- $d \rightarrow$  ação

#### 3.6.4.1 Regra para cálculo da intensidade do grupo BEM ESTAR

$\begin{aligned} &SE \text{ DESEJO}(p, e, t) > 0 \\ &ENTÃO \text{ faça } BE_{POTENCIAL}(p, e, t) = f_j[ DESEJO(p, e, t) , I_g(p, e, t)] \end{aligned}$	(1)
--	-----

Na regra (1) a função *DESEJO* retorna o valor da variável desejabilidade. Sendo esse maior do que zero é atribuído um valor para *BEM ESTAR*<sub>POTENCIAL</sub> ( $BE_{POTENCIAL}$ ) pela função  $f_j$ , que é composta pelo valor absoluto de *DESEJO* e  $I_g$ , função que combina o resultado das variáveis globais.

Para o cálculo da intensidade da emoção feliz aplica-se a regra (2) a seguir.

$\begin{aligned} &SE \text{ } BE_{POTENCIAL}(p, e, t) > BE_{LIMAR}(p, t) \\ &ENTÃO \text{ faça} \\ &BE_{INTENSIDADE}(p, e, t) = BE_{POTENCIAL}(p, e, t) - BE_{LIMAR}(p, t) \\ &CONTRÁRIO \text{ FAÇA } BE_{INTENSIDADE}(p, e, t) = 0 \end{aligned}$	(2)
---	-----

O valor  $BE_{LIMAR}$  é aferido empiricamente.

### 3.6.4.2 Regra para o cálculo da intensidade para o grupo BASEADO EM PROGNÓSTICO

$\begin{aligned} &SE\ PROGNÓSTICO(p, e, t) \wedge DESEJO(p, e, t) < 0 \\ &ENTÃO\ faça \\ &MEDO_{POTENCIAL}(p, e, t) = f_j[ DESEJO(p, e, t) , PROB(p, e, t), I_g(p, e, t)] \end{aligned}$	(3)
--	-----

A regra (3) estabelece que se  $p$  tem o prognóstico de  $e$  em tempo  $t$  e considera  $e$  indesejável então atribua a  $MEDO_{POTENCIAL}$  o valor combinado das parcelas estabelecidas na regra (1), combinada adicionalmente com a função  $PROB(p, e, t)$ , que calcula a modulação da emoção com as variáveis locais.

A atribuição do valor de  $MEDO_{INTENSIDADE}$  é feita de forma análoga ao estabelecido na regra (2) para  $BE_{INTENSIDADE}$ .

### 3.6.4.3 Regra para o cálculo da intensidade para o grupo ATRIBUIÇÃO

$\begin{aligned} &SE\ LOUVAR(p, a, d, t) \wedge NÃO(a=p) \\ &ENTÃO\ faça \\ &ADMIRAR_{POTENCIAL}(p, a, d, t) = \\ &f_a[ LOUVAR(p, a, d, t) , I_g(p, a, d, t), DIFF(a, a-tipo, d, d-tipo)] \end{aligned}$	(4)
--	-----

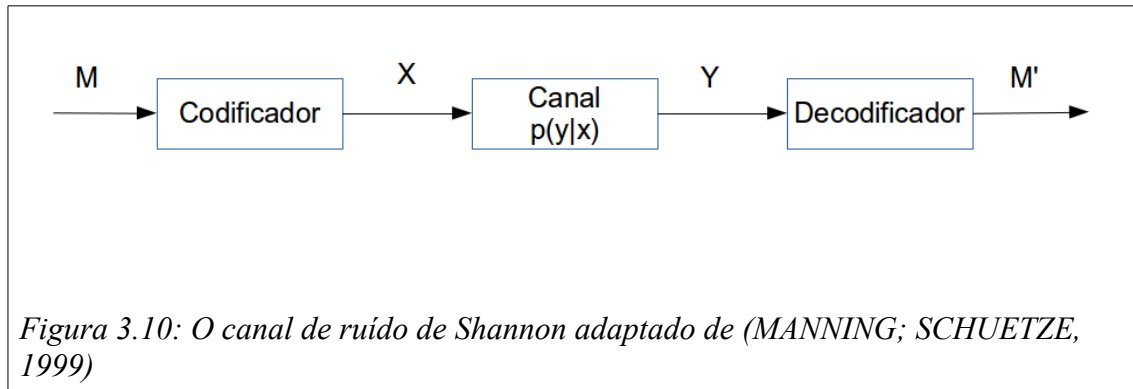
Na regra (4) a função LOUVAR, implementação da variável básica louvabilidade, retorna a intensidade para a pessoa  $p$  da ação  $d$  do agente  $a$  em  $t$  e sendo  $a$  diferente de  $p$ . Sendo verdadeiro a função  $f_a$  retorna o valor de  $ADMIRAR_{POTENCIAL}$ . A função  $DIFF$  consiste na implementação da variável local desvio de expectativa conforme explicada na seção 3.6.3, onde  $a$  é o agente,  $a-tipo$  consiste no papel esperado do agente,  $d$  sua ação e  $d-tipo$  a ação esperada de  $a-tipo$ .

A atribuição do valor de  $ADMIRAR_{INTENSIDADE}$  é feita de forma análoga ao estabelecido na regra (2) para  $BE_{INTENSIDADE}$ .

### 3.7 O canal de ruído de Shannon

O canal de ruído (SHANNON, 2001)<sup>48</sup> visava a transmissão de mensagem via linha telefônica. Seu objetivo consistia na otimização dessa transmissão, tanto em termos de desempenho como em termos de precisão, na presença de ruído.

A figura 3.5 contém um desenho esquemático desse canal



Nesse canal  $M'$  é dada pela seguinte fórmula, onde  $\Gamma$  consiste no conjunto de mensagens:

$$M' = \underset{M \in \Gamma}{\operatorname{argmax}} \underbrace{p(y|x)}_{\text{likelihood}} \times \underbrace{p(x)}_{\text{prior}}$$

Fórmula 1: Mensagem mais provável na presença de ruído

### 3.8 Extração de Informação (EI)

O desenvolvimento das tecnologias de EI, descrita como “Extração da Informação” é o processo de popular um banco de dados através de uma varredura superficial de um texto, procurando por ocorrências de uma classe particular de objetos ou eventos e a relação entre estes objetos e eventos” (RUSSELL; NORVIG, 1995), está ligado à conferência de compreensão de mensagem ou “Message Understanding Conference” (MUC) em inglês. Este conjunto de eventos que aconteceram entre 1987 e 1998 tinha como objetivo padronizar os conceitos, as tarefas de extração e suas respectivas métricas de avaliação, dando aos participantes uma base de estruturação,

<sup>48</sup> Em 2001 a IEEE publicou uma nova edição do texto original de Shannon de 1948. O texto referenciado consiste na edição de 2001.

comparação, consolidação e troca de conhecimento. No MUC-7, segundo (TURMO; AGENO; CATALÀ, 2006), existiam 5 tarefas cujos resultados eram avaliados:

- Reconhecimento de entidades (NE do inglês “Named Entity”) consiste na tarefa de reconhecer conceito independente de domínio tais como nome de pessoas, organizações, locais, datas entre outros;
- Resolução de Correferência (CO do inglês “Coreference”) consistia em reconhecer referências distintas de um mesmo elemento;
- Template de Elementos (TE do inglês “Template Element”) foi proposta, visando à portabilidade das tecnologias desenvolvidas. Para isto foi criado um template com conceitos básicos (pessoas, organizações, etc) que participavam de vários tipos de eventos;
- Template de Relação (TR do inglês “Template Relation”) visava encontrar tipos de relação (local de, empregado de, produto de, etc) entre os TE; e
- Template de Cenário (ST do inglês “Scenario Template”) consistia na descrição de uma classe particular de evento com os seus respectivos TE e TR.

Os sistemas que competiram no MUC-7 tiveram desempenho considerado aceitável para NE, TE e TR, mas inaceitáveis para CO e ST. Estas conclusões serviram de base para as estratégias nas quais os novos frameworks de avaliação se estruturaram. Considerado como a continuação do MUC o ACE2 (NIST ACE, 2007) redefiniu as tarefas para as seguintes:

- Reconhecimento e Detecção de Entidades (EDR do inglês “Entity Detection and Recognition”) que consiste na extração das entidades estipuladas nos textos fornecidos. No MUC existiam dois tipos de entidades: entidade e local, sendo a entidade classificada ainda em organização, pessoa e artefato. No ACE as entidades são classificadas em tipo, subtipo e classe. A tarefa CO do MUC está embutida aqui, pois as classes são referências a uma entidade na forma de nome próprio, substantivo ou pronome;
- Detecção e Reconhecimento de Valores (VAL do inglês “Value Detection and Recognition”) que consiste na extração de todos os valores dos elementos considerados no ACE.
- Detecção e Reconhecimento de Tempo (TERN do inglês “Time Expression

Recognition and Normalization”) que consiste na extração de valores temporais, normalmente de eventos;

- Detecção e Reconhecimento de Relação (RDR do inglês “Relation Detection and Recognition”) que consiste na extração dos relacionamentos entre as entidades;
- Detecção e Reconhecimento de Eventos (VDR do inglês “Event Detection and Recognition”) que consiste na extração de todos eventos com seus argumentos suas entidades e relacionamentos;
- Detecção de Menção de Entidade (EMD do inglês “Entity Mention Detection”) que consiste na extração de todas as menções as entidades especificadas para EDR;
- Detecção de Menção de Relação (RMD do inglês “Relation Mention Detection”) que consiste na extração de todas as menções ao relacionamento definidos em RDR; e
- Detecção de Menção de Evento (VMD do inglês “Event Mention Detection”) que consiste na extração de todos os eventos definidos para VDR.

De certa forma estas tarefas são hierárquicas, pois ter um bom desempenho nas 3 últimas tarefas consiste num pré-requisito para se alcançar desempenho adequado nas 5 primeiras.

## **4 Proposta de inferência de estados emocionais utilizando canal de ruído**

Informalmente, propõe-se partir do princípio que um texto criado com o objetivo de transmitir uma opinião ou sentimento sofre, no processo de criação, um ruído, causados pelas diversas dificuldades impostas ao autor na escrita do texto, sejam elas inerentes ao autor, à linguagem ou ao meio. Assim, se um emissor (Alice) deseja contar para um receptor (Roberto) seus sentimentos em relação a um produto, ela não conseguirá transmitir seus sentimentos, e seu texto o representará com a adição de várias formas de ruído.

Nessa tese se pretende inferir os estados emocionais (de Alice), que não são diretamente observáveis dado seu caráter privado, dos quais emerge um texto escrito (no escopo deste trabalho) em linguagem natural. As premissas para essa inferência são:

1. O texto consiste em uma manifestação sequencial desses estados e, dada a sua natureza explícita, contém evidências dos referidos estados emocionais;
2. A emoção resultante consiste em uma agregação dos referidos estados emocionais;
3. O processo de explicitação de emoção em texto sofre interferências; e
4. Existe um canal de comunicação entre o emissor (Alice) e o receptor (Roberto). O texto consiste na informação que passa por esse canal.

Assim a principal contribuição desta tese consiste em abordar o reconhecimento de uma emoção agregada (que consistirá no sentimento conforme explicado na seção 5.6) de um texto que passou por um canal de ruído.

Essa abordagem levou esse trabalho a modelar o reconhecedor de sentimento (RS), utilizando o canal de ruído de (SHANNON, 2001). Para isso foram necessárias a criação de dois modelos como visto na seção 3.7. O primeiro calcula a verossimilhança de um texto resultar de um sentimento. O segundo modelo calcula a probabilidade do sentimento (probabilidade a priori). O RS escolherá o sentimento cujo resultado da multiplicação de verossimilhança com a probabilidade a priori seja a máxima.

Na seção 4.1 se descreve a interferência apontada na premissa como sendo o ruído no processo de comunicação. Discutidas as fontes de ruído, é proposto um

modelo, na seção 4.2, que descreve o processo que os agregue, considerando as premissas acima colocadas. Na seção 4.3 é proposta uma adaptação desse modelo para utilizar o canal de ruído como a função de agente, ou seja, a abstração matemática do agente artificial, o RS. Na seção 4.4 uma comparação da proposta desse trabalho com outras aplicações em NLP que utilizam o canal de ruído. O capítulo termina na seção 4.5 onde uma síntese com as principais teorias compõe a solução proposta nesse trabalho.

## **4.1 O ruído no processo de comunicação**

Para explicar a solução se faz necessária a definição do que seja ruído no âmbito desse trabalho. (DEVITO, 2011) resumindo o que se encontra na literatura, define que, no processo de comunicação, ruído consiste em qualquer coisa que interfere na comunicação entre o agente que emite a mensagem e o agente que a recebe. O autor enumera quatro tipos:

1. Ruído físico consiste na interferência externa a ambos emissor e receptor da mensagem. Exemplos são interferência na transmissão de um sinal, erros ortográficos introduzidos na transmissão de um arquivo e barulho ambiental.
2. Ruído fisiológico emerge de deficiências ou no emissor ou no receptor da mensagem. Exemplos são surdez, problemas de fala, perda de memória, erros ortográficos ou gramaticais.
3. Ruído psicológico consiste na interferência seja no emissor ou no receptor de processos ou estados mentais como ideias pré concebidas, pensamentos errantes, preconceito e emoção. Um exemplo seria conversar com pessoas que se recusam a escutar argumentos que contrapõem suas crenças.
4. Ruído semântico emerge quando emissor e receptor não compartilham do mesmo sistema de significados. Um exemplo seria um leigo conversar com um médico que utiliza somente termos técnicos.

Na seção 3.2.1 discutiu-se os sistemas de escolha e na seção 3.1 os extratos e vertentes na constituição da SFL. Se entende que o autor ao escolher as palavras de um texto considera a linguagem apropriada ao veículo de comunicação utilizado, o gênero, seus objetivos com a mensagem e o público-alvo. Essas variáveis, ao serem consideradas, interferem na emoção observada no texto.



Em adição ao acima exposto, nessa tese considera-se três dimensões introduzidas em (MARTIN; WHITE, 2005), que não as classificam como ruído, mas que expressam o entendimento relevante nesse contexto.

1. Afeto como codificador de atitude pelo emissor, expondo valores e posicionamentos. Indiretamente almeja ativar no receptor a sua própria avaliação. A retórica utilizada objetiva criar um alinhamento e conexão entre emissor e receptor.
2. Modalidade como expressão de certeza, comprometimento e conhecimento, dando ao escritor ferramental para se apresentarem como especialista ou, ainda como ferramenta para ignorar, ameaçar, responder, rejeitar ou acomodar interlocutores.
3. Intensificação como sistema utilizado pelo escritor para aumentar ou diminuir a força de sua afirmação ou clarear ou escurecer um argumento.

## **4.2 Modelo de externalização de um sentimento através da linguagem**

No modelo OCC, emoção consiste em uma reação com valência a um estímulo do ambiente. O modelo proposto na figura 4.1 é em parte inspirado em (SARACEVIC, 1996) em sua discussão sobre o arcabouço cognitivo no processo de relevância de um documento.

A “EMOÇÃO REAL” resulta do processo de perceber e interpretar um estímulo. Quando emerge o desejo de externalizar sua emoção, o indivíduo a modula, visando transformá-la em linguagem. Esse processo em si já é passível de ruído, dado que a emoção (por exemplo a inveja) pode ser rejeitada pelo agente que sente. Por isso existe um processo apelidado de “CODIFICADOR DE EMOÇÃO”. O resultado desse processo consiste no “DISCURSO EMOÇÃO REAL”. Entretanto essa expressão, ainda privada ao indivíduo, sofrerá uma modulação seja por conter palavras inadequadas ao meio de troca, seja pelo fato de outra emoção (por exemplo a vergonha) interferir no processo de tornar público um estado privado. O processo chamado de “CODIFICADOR DISCURSO” externaliza a expressão. Essa expressão passa pelo “CANAL DE RUÍDO” onde a mensagem pode sofrer as interferências descritas na seção 4.1. A saída desse canal consiste no discurso que finalmente é observado,

chamado de “DISCURSO OBSERVADO”. O agente receptor da mensagem a decodifica, através do “DECODIFICADOR DISCURSO”, procurando inferir a “DISCURSO EMOÇÃO PROVÁVEL”. Desse discurso o “DECODIFICADOR EMOÇÃO” inferirá a provável emoção sentida pelo agente emissor.

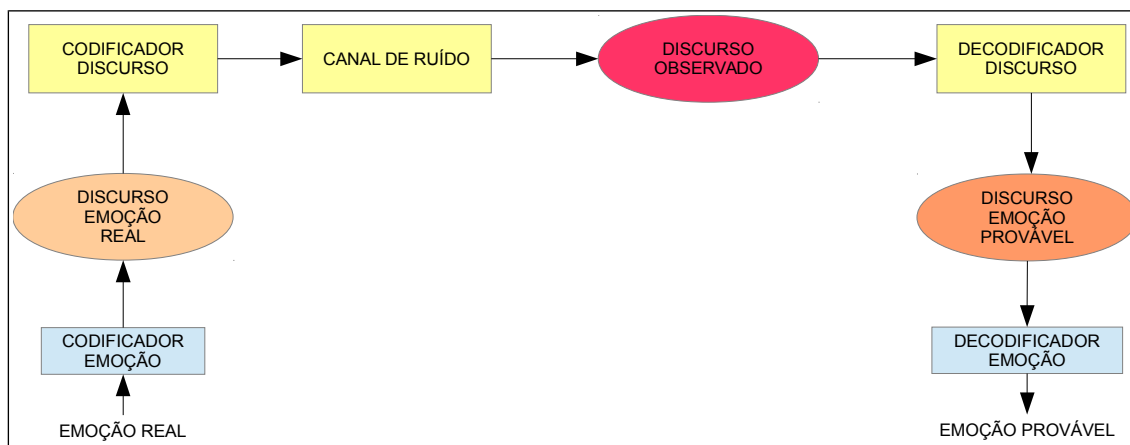


Figura 4.1: Modelo de externalização da emoção através da linguagem

### 4.3 O modelo de ruído para a análise de sentimento

É necessária uma simplificação do modelo de externalização de emoção para tratá-lo através do canal de ruído de Shannon, pois nessa tese retiram-se os atributos dos grupos avaliativos (ver seção 5.7) diretamente do texto. Esse por sua vez emergem de estados emocionais (propostos na seção 5.2). Por isso a simplificação, que está na figura 4.2, consiste na eliminação do “DISCURSO EMOÇÃO REAL” e do “DISCURSO EMOÇÃO PROVÁVEL”, trabalhando-se apenas com o “DISCURSO OBSERVADO”. Nesse modelo o processo começa com um “ESTÍMULO REAL” que é convertido em “EMOÇÃO REAL” pelo “CODIFICADOR EMOÇÃO”. A primeira simplificação reside na conversão da emoção real em discurso observado através de um “CODIFICADOR DISCURSO” e sua passagem pelo “CANAL DE RUÍDO”, eliminando-se do modelo não simplificado o “DISCURSO EMOÇÃO REAL”. Uma segunda simplificação reside na conversão do “DISCURSO OBSERVADO” em “EMOÇÃO PROVÁVEL” através do “DECODIFICADOR DISCURSO”, eliminando-se o “DISCURSO EMOÇÃO PROVÁVEL” no modelo original.

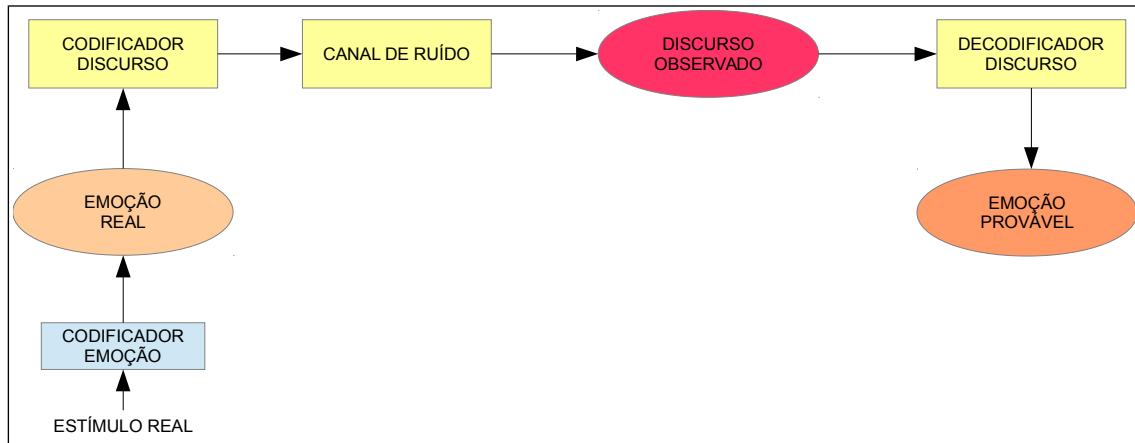


Figura 4.2: Modelo de externalização da emoção simplificado

A figura 4.3 contém uma representação da adaptação do modelo de externalização de emoção simplificado para aderência ao canal de ruído. A caixa “CODIFICADOR” recebe como entrada O “ESTÍMULO REAL” e dela resulta a “EMOÇÃO REAL”  $E$ , que, ao passar pelo canal de ruído é convertida no “DISCURSO OBSERVADO”  $M'$ .  $M'$  é decodificado na “EMOÇÃO PROVÁVEL”  $E'$  pelo “DECODIFICADOR EMOÇÃO”.

Com essas adaptações a figura 4.4 ilustra a implementação do RS para ser tratado pelo “Canal de Ruído” de (SHANNON, 2001).

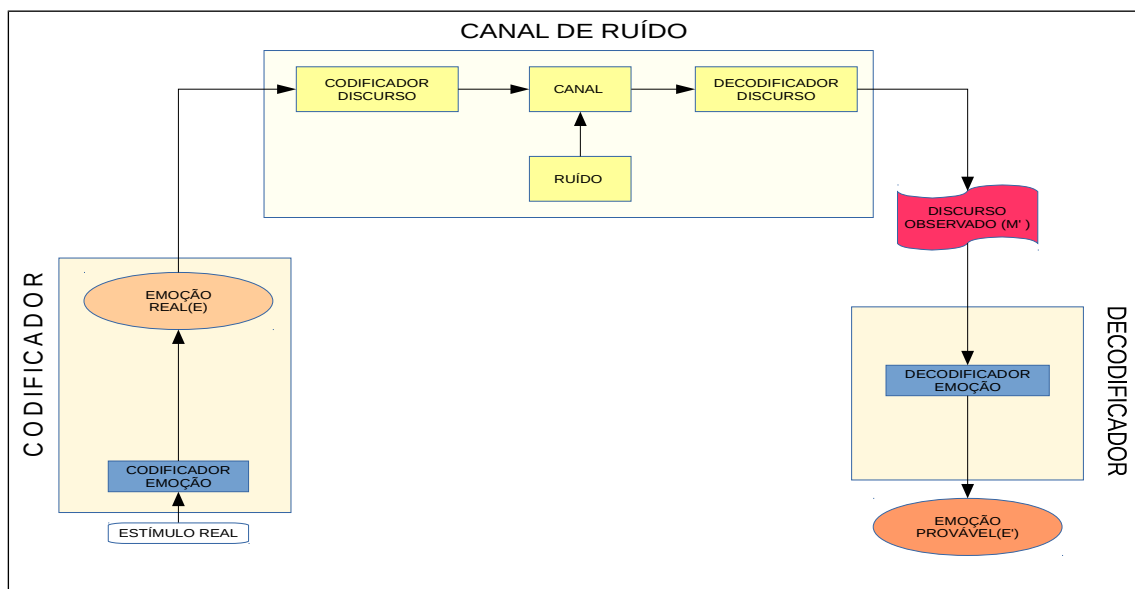


Figura 4.3: Adaptação do modelo de externalização de emoção para o canal de ruído.




Figura 4.4: Canal de Ruído (SHANNON, 2001) para tratar o reconhecimento de sentimento RS

Ajustando a equação 3.1 temos a função do agente artificial RS, cerne dessa tese, descrita na fórmula 2:

$$E' = \underset{E \in \varepsilon}{\operatorname{argmax}} \underbrace{P(M'|E)}_{MLE} \times \underbrace{P(E)}_{ME}$$

Fórmula 2: Função do agente artificial RS

Na fórmula 2  $\varepsilon$  consiste no conjunto de emoções a qual  $E$  pertence e a verossimilhança  $P(M'|E)$  consiste no modelo linguístico emocional tratado na seção 5.2. A probabilidade a priori  $P(E)$  consiste no modelo de emoção abordado na seção 5.1.  $E'$  consiste na emoção que desejamos inferir. Essa será resultante do argumento máximo da multiplicação de dois modelos, sendo um o MLE (modelo linguístico emocional) e o outro o ME (modelo emocional). O objetivo do modelo MLE é calcular a probabilidade de uma mensagem observada  $M'$  emergir de uma emoção  $E$ . A multiplicação será efetuada para cada emoção do conjunto de emoções  $\varepsilon$  e aquela que apresentar o maior resultado será escolhida como a emoção  $E$ .

#### 4.4 Comparação da utilização do canal de ruído em NLP com o RS

O uso do “Canal de Ruído” é utilizado com sucesso em linguística computacional. (MANNING; SCHUETZE, 1999) listam algumas dessas aplicações que constam da tabela 4.1. Nessa tabela  $p(e)$  consiste no modelo a priori e  $p(s|e)$  no modelo de verossimilhança.

Tabela 4.1: Resumo dos problemas e PLN abordados com o canal de ruído

<b>Aplicação</b>	<b>Entrada</b>	<b>Saída</b>	<b>p(e)</b>	<b>p(s e)</b>
Tradução de máquina	$L_1$ sequência de palavras	$L_2$ sequência de palavras	$p(L_1)$ em modelo de linguagem	Modelo de tradução
Reconhecimento ótico de caracteres (OCR) <sup>49</sup>	Texto real	Texto com erros	Probabilidade do texto na língua	Modelo de erros do OCR
Etiquetador de classe gramatical de palavra (POS) <sup>50</sup>	Sequência de rótulos POS	Palavras em linguagem natural	Probabilidade de sequência de POS	$p(\text{palavra} \text{rótulo})$
Reconhecimento de fala	Sequência de palavras	Sinal do discurso	Probabilidade da sequência de palavras	Modelo acústico

A finalidade da tabela 4.2 é comparar como os modelos propostos nessa tese se alinham com outros problemas de processamento de linguagem natural, solucionados utilizando o canal de ruído.

Tabela 4.2: Reconhecimento de emoção como um problema de PLN abordados com o canal de ruído

<b>Aplicação</b>	<b>Entrada</b>	<b>Saída</b>	<b>p(e)</b>	<b>p(s e)</b>
Reconhecimento de sentimento	$L_1$ sequência de palavras	Sequência de grupos avaliativos	ME contendo apenas as palavras com maior dependência para cada tipo de emoção. Implementado utilizando o “log likelihood ratio” e SVM	Modelo MLE implementado utilizando HMM.

Essa tabela, adicionalmente, resume os desafios que constituíram essa pesquisa. O primeiro foi criar um conjunto de atributos que descrevesse os grupos avaliativos. O segundo, no desenvolvimento do modelo de emoção, constituiu em elencar os atributos que melhor descrevessem cada emoção tratada. E o terceiro constituiu no desenvolvimento do MLE e sua respectiva implementação utilizando HMM (a descrição desse classificador está no APÊNDICE G. Esses serão os assuntos tratados no próximo capítulo.

49 Acrônimo em inglês para “Optical Character Recognition”

50 Acrônimo em inglês “Part of Speech Tagging”

## 4.5 Síntese das teorias para a composição do RS

O texto será fragmentado, conforme a teoria de avaliatividade em linguagem (seção 3.2), em grupos avaliativos descritos na seção 5.6 (na seção 5.7 está descrita a forma como os atributos de cada grupo serão extraídas do texto). Esses grupos constituirão na menor porção de texto (observado) que pode emergir de um estado emocional subjacente (oculto).

A figura 4.5 contém uma resenha do ReLi (FREITAS et al., 2012) tratada no GATE (CUNNINGHAM et al., 2011). Os segmentos de textos grifados foram identificados pelo conjunto de regras descritas no apêndice F. Esse conjunto de regras agrupa as palavras de acordo com a sequência de suas classes gramaticais de forma a definir um grupo avaliativo. Mas para essa sequência constituir um grupo avaliativo, em adição à sequência de suas classes gramaticais, é necessário que se encaixe em um dos sistemas de avaliação da teoria de avaliatividade em linguagem. Na figura 4.6 o sistema não identificou “cinematográfico” como pertencente a um dos sistemas de avaliação e portanto foi desconsiderado. Nessa resenha foram considerados grupos avaliativos as sequências: “muito mamão”<sup>51</sup>, “bem diferente”, “incrível”, “um pouco melosa”, “uma ótima” e “com péssima”.

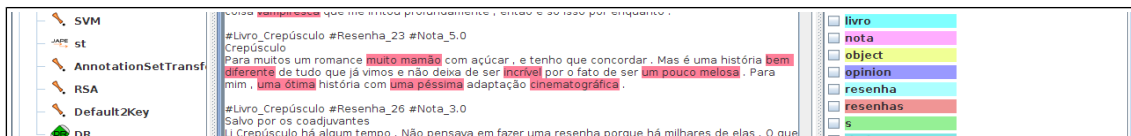


Figura 4.5: Candidatos a grupos avaliativos

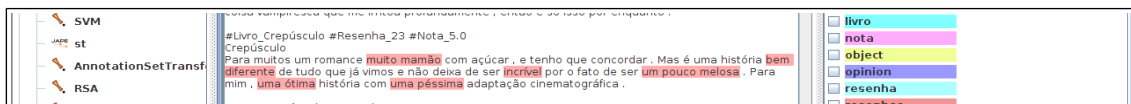


Figura 4.6: Grupos avaliativos

A figura 4.7 ilustra dois estados emocionais ocultos “APP” (atrativo) e “UAPP” (não atrativo) dos quais os grupos avaliativos “uma ótima” (AG1) e “com péssima” (AG2) tem probabilidade de emergir.

<sup>51</sup> O ideal teria sido identificar “muito mamão com açúcar”

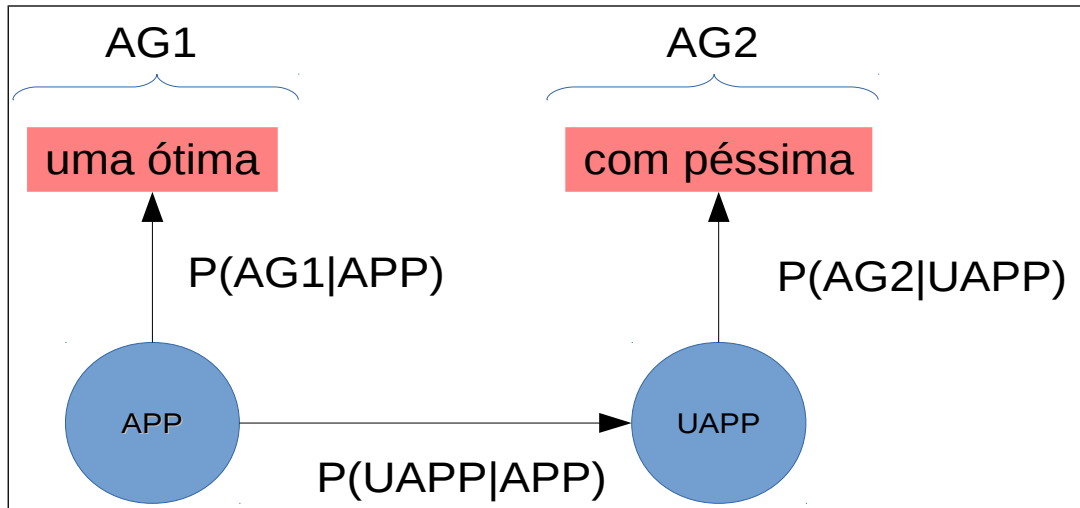


Figura 4.7: Exemplo de grupo avaliativo observado e estado emocional oculto

O conjunto de estados tratados nessa tese constituem um subconjunto das emoções previstas no modelo OCC (seção 3.6) e estão discriminados na seção 5.2. Para calcular a probabilidade de um estado emocional (oculto) gerar um grupo avaliativo (observado no texto) é necessário propor um alinhamento entre as teorias acima mencionadas. Essa proposta está descrita na seção 5.3. Com esse alinhamento se pode propor o modelo linguístico (MLE) (a verossimilhança na fórmula 2) cuja descrição está na seção 5.2. O modelo de emoção (ME) (a probabilidade a priori na fórmula 2) que consiste nos melhores atributos (calculados com as anotações das polaridades no corpus) para maximizar o desempenho de um classificador está na seção 5.1.

## **5 Os modelos propostos neste trabalho**

Nesse capítulo se descrevem os modelos e seus constituintes que suportarão as implementações necessárias à avaliação. Essa tese consiste em uma síntese de diversas teorias e esse capítulo tem como objetivo adicional descrever como elas se conectam. A seção 5.3 descreve a principal conexão que consiste no alinhamento entre duas teorias importantes nessa pesquisa que são a “Estrutura Cognitiva das Emoções”, descrita na seção 3.6, e a “Teoria de Avaliatividade em Linguagem”, descrita na seção 3.2.

### **5.1 Proposta do modelo de emoção (ME)**

A função do modelo ME é estabelecer uma probabilidade a priori (fórmulas 1 e 2) de uma sequência de estados emocionais comporem estados que (ORTONY; CLORE; COLLINS, 1988) chamaram de sentimento. Sentimento seria um estado emocional não diferenciado (de um dos 22 tipos que descrevem), mas que possui uma valência (positiva ou negativa). Os autores descrevem que o processo de uma reação com valência começa em um estado não emocional. Desse estado segue para um estado não diferenciado (sentimento positivo ou negativo), prosseguindo para um estado emocional diferenciado. Essas transições são simétricas, ou seja, de um estado diferenciado o processo pode seguir para um estado não diferenciado e desse para um estado não emocional. A composição de estados emocionais não diferenciados em estados emocionais diferenciados é discutida na seção 5.5.

O modelo ME, portanto, calculará a probabilidade a priori dos estados não diferenciados (sentimentos positivo e negativo) e estado não emocional.



Palavra	POS	Polaridade	Canônica	LLR
livro	N	positivo	livro	19.3672142371
bom	ADJ	positivo	bom	14.1707198101
!	!	positivo	!	14.116188284
muito	ADV	positivo	muito	13.9212843751
Recomendo	V	positivo	recomendo	13.748521946
leitura	N	positivo	leitura	13.3462865335
?	?	neutro	?	11.1546089178
Gostei	V	positivo	gostar	10.054500297
e	KC	positivo	e	9.1590389139
história	N	positivo	história	8.8958373565
Partido	NPROP	neutro	partir	8.8950113361
não	ADV	negativo	não	8.7734243609
melhores	N	positivo	bom	8.763609517
envolvente	ADJ	positivo	envolvente	8.4519539263
otimo	ADJ	positivo	otimo	8.16928461
adorei	V	positivo	adorar	8.0282781658
era	V	neutro	ser	7.8956287186
prende	V	positivo	prender	7.8065868176
vale	V	positivo	vale	7.7165556429
divertido	PCP	positivo	divertido	7.6880561349
ler	V	positivo	ler	7.6792074019
Amei	V	positivo	amar	7.4049819055
pena	N	positivo	pena	7.3804345017
lí	V	positivo	lí	7.3384418488
chato	ADJ	negativo	chato	7.1295178593

*Figura 5.1: Amostra dos 20 atributos com maior LLR*

O modelo emocional, portanto, consistiu nos termos que melhor qualificam uma sentença positiva, negativa ou neutra. Para a escolha desses termos foi utilizado o *LLR* conforme descrito no APÊNDICE J. Uma amostra com 20 termos com o maior escore está na figura 5.1. Esses serviram como atributos para o SVM (ver APÊNDICE H), classificador escolhido para implementar o modelo, pois foi o aquele que apresentou melhor desempenho nos experimentos (seção 6.4).

Consiste em um trabalho futuro alterar esse modelo para modelos de Markov. Para isso é necessário um corpus rotulado de acordo com os estados emocionais propostos e seus respectivos grupos avaliativos. Assim o modelo MLE rotularia a sequência de estados prováveis em uma sentença. O ME calcularia a probabilidade dessa sequência emergir de um modelo neutro, positivo ou negativo.

## 5.2 Proposta para o modelo linguístico emocional (MLE)

O modelo descrito nessa seção, consiste em uma síntese das teorias descritas nas seções 3.2 (avaliação em linguagem avaliativa) e 3.6. (estrutura cognitiva da s emoções). Nessa pesquisa utilizamos a camada mais abstrata do modelo OCC, ou seja, aquela que trata das variáveis globais: desejabilidade, louvabilidade e atratividade.

Era intenção trabalhar com todos os 22 tipos de emoção. Entretanto desenvolver ou adaptar os recursos necessários para o tratamento de todos os tipos se mostrou inviável dentro do tempo disponível para o desenvolvimento dessa tese. Por isso priorizamos os grupos que englobam os tipos de emoção com maior probabilidade de serem observadas no corpus que apoiou o experimento. Os grupos de emoção foram: bem-estar (na vertente da desejabilidade); atribuição (na vertente da louvabilidade) e atração (na vertente da atratividade) (ver figura 3.8).

Uma observação sobre a nomenclatura que segue. Nas funções  $i$  consiste em um termo e  $V$  no vocabulário de um corpus.  $i_{subscrito}$  consiste no termo  $i$  pertencendo à classe *subscrito*.

### 5.2.1 Desejabilidade

O grupo de emoção BEM-ESTAR engloba as emoções feliz e triste. Essas emergem da intensidade do desejo pelo resultado do evento. Assumindo que num texto o evento já aconteceu, portanto com prognóstico irrelevante, seus resultados possíveis são satisfação e insatisfação. A figura 5.2, extraída de (ORTONY; CLORE; COLLINS, 1988), contém um quadro resumo das especificações do tipo de emoção BEM-ESTAR e as tabelas 5.1 e 5.2 contém as especificações da emoção FELICIDADE e TRISTEZA respectivamente.

AVALIAÇÃO DE UM EVENTO	
DESEJÁVEL	INDESEJÁVEL
satisfeito com um evento desejável	insatisfeito com um evento indesejável

Figura 5.2: Especificação das emoções do grupo BEM-ESTAR

Tabela 5.1: Resumo do tipo de emoção FELICIDADE

EMOÇÃO FELICIDADE	
Palavras	contente, alegre, encantado, extasiado, eufórico, feliz
Variáveis que afetam a intensidade	1. O grau de desejabilidade do evento 2. Esforço investido para alcançar o resultado
Exemplo	A satisfação de uma pessoa ao saber que um parente querido vem visitá-lo.

Tabela 5.2: Resumo do tipo de emoção TRISTEZA

EMOÇÃO TRISTE	
Palavras	deprimido, insatisfeito, desconfortável, triste, miserável
Variáveis que afetam a intensidade	3. O grau de indesejabilidade do evento 4. Esforço investido para evitar o resultado
Exemplo	A insatisfação de um motorista quando seu carro enguiça.

O cálculo das variáveis locais será feito conforme especificado abaixo:

- Partindo do alinhamento descrito na seção 5.3.3, a **intensidade** é calculada como sendo a divergência KL simétrica entre a palavra encontrada no texto, e que seja um elemento do conjunto daquelas que constam nas tabelas 5.2 e 5.3 acrescidas das palavras listadas no apêndice C, e sua polaridade no corpus. Uma mesma palavra pode aparecer no corpus em sentenças positiva, negativas ou neutras. A polaridade da palavra no dicionário é preterida por está aqui calculada. A preferência é consequência de que a calculada considera o contexto (se está em uma sentença positiva, negativa ou neutra) enquanto a do dicionário independe do contexto.
- O **esforço** empreendido para alcançar ou prevenir o resultado de um evento. Será utilizada uma adaptação da proposta em (SHAIKH; PRENDINGER; ISHIZUKA, 2009) onde advérbios qualificando verbos servem como evidência de esforço. Ex: Ele torceu intensamente para seu time ganhar. Seu valor foi calculado como a distância KL (ver APÊNDICE I) onde um dicionário contendo os advérbios do ReLi que qualificam verbos constitui a classe objeto com a

frequência das demais palavras constituindo a única entrada na classe referência.

Na figura 5.3 está a Função de Desejabilidade. O AFETO vem do sistema de atitude da teoria de avaliatividade em linguagem. DESEJABILIDADE, portanto, consiste na variável central que caracteriza dois estados ocultos de onde o afeto emerge no texto através da Função de Desejabilidade. O alinhamento proposto entre as duas teorias está descrito na seção 5.3.




Figura 5.3: Função de Desejabilidade

Na figura 5.3 os estados DES e IDES derivam da seguinte regra:

$$\begin{aligned} DES, \text{ SE } \operatorname{argmax}(f_{Desejabilidade} > LIMIAR_{DES}) = POSITIVO \\ IDES, \text{ SE } \operatorname{argmax}(f_{Desejabilidade} > LIMIAR_{IDES}) = NEGATIVO \end{aligned}$$

A função  $f_{Desejabilidade}$  é definida como:

$$f_{Desejabilidade} = Intensidade * Esforço, \text{ onde:}$$

$$Intensidade = DKL(i_{atitude} || i_{polaridade});$$

$$Esforço = DKL(i_{esforço} || i_{-esforço}); \text{ e}$$

$$i \in V$$

### 5.2.2 Louvabilidade

O grupo de emoção ATRIBUIÇÃO engloba as emoções orgulho, vergonha, admiração e repreensão. Essas emergem da intensidade do julgamento de um agente ou de uma ação sua. Seus resultados possíveis são: aprovado e desaprovado. A figura 5.4, extraída de (ORTONY; CLORE; COLLINS, 1988), contém um quadro resumo das especificações do tipo de emoção ATRIBUIÇÃO e as tabelas 5.3, 5.4, 5.5 e 5.6 contém as especificações das emoções ORGULHO, VERGONHA, ADMIRAÇÃO e REPREENSÃO respectivamente.

AVALIAÇÃO DE UM EVENTO		
AGENTE	DESEJÁVEL	INDESEJÁVEL
PRÓPRIO	aprovar uma louvável ação própria	reprovar um culpável ação própria
TERCEIRO	aprovar uma louvável ação de terceiro	reprovar um culpável ação de terceiro

Figura 5.4: Especificação das emoções do grupo ATRIBUIÇÃO

Tabela 5.3: Resumo do tipo de emoção ORGULHO

EMOÇÃO ORGULHO	
Palavras	orgulho
Variáveis que afetam a intensidade	<ol style="list-style-type: none"> <li>1. O grau de louvabilidade da ação.</li> <li>2. A força da unidade cognitiva com o agente.</li> <li>3. Grau de desvio da ação esperada.</li> </ol>
Exemplo	O professor ficou orgulhoso com o prêmio conquistado

Tabela 5.4: Resumo do tipo de emoção VERGONHA

EMOÇÃO VERGONHA	
Palavras	Vergonha, culpa e condenação
Variáveis que afetam a intensidade	<ol style="list-style-type: none"> <li>1. O grau de culpabilidade da ação.</li> <li>2. A força da unidade cognitiva com o agente.</li> <li>3. Grau de desvio da ação esperada.</li> </ol>
Exemplo	O goleiro ficou envergonhado com o gol que levou.

Tabela 5.5: Resumo do tipo de emoção ADMIRAÇÃO

EMOÇÃO ADMIRAÇÃO	
Palavras	admiração, apreciação, estima e respeito
Variáveis que afetam a intensidade	<ol style="list-style-type: none"> <li>1. O grau de louvabilidade da ação.</li> <li>2. Grau de desvio da ação esperada.</li> </ol>
Exemplo	Os alunos admiram o conhecimento do professor.

Tabela 5.6: Resumo do tipo de emoção *REPREENSÃO*

EMOÇÃO <i>REPREENSÃO</i>	
Palavras	estarrecido, desprezo e indignação
Variáveis que afetam a intensidade	1. O grau de culpabilidade da ação. 2. Grau de desvio da ação esperada.
Exemplo	As pessoas ficaram indignadas com a ação do bandido.

A variável central louvabilidade agrupa emoções que emergem do julgamento ético de pessoas ou de suas ações. Geram dois estados “louvabilidade” (PRA) e “culpabilidade” (BLA).

As variáveis locais da função que modelam esses estados são:

- A **intensidade** da louvabilidade será medida com o conceito de informação mútua (MI) de cada palavra em sua classe (polaridade).
- O **desvio de expectativa**, que significa a diferença entre o que a pessoa esperava da ação de um indivíduo e o que esse indivíduo fez. Quando um avaliado for identificado, se a polaridade do avaliado for a mesma da atitude não haverá desvio de expectativa, i.e., desvio de expectativa igual a zero. Caso contrário o desvio de expectativa será igual a um.

Na figura 5.5 está a Função de Louvabilidade. O *JULGAMENTO* vem do sistema de atitude da teoria de avaliatividade em linguagem. *LOUVABILIDADE*, portanto, consiste na variável central que caracteriza dois estados ocultos de onde o *JULGAMENTO* emerge no texto através da Função de Louvabilidade. O alinhamento proposto entre as duas teorias está descrito na seção 5.3.




Figura 5.5: Função de Louvabilidade

Na figura 5.5 os estados PRA e BLA derivam da seguinte regra:

$$\begin{aligned} PRA, SE \quad & \operatorname{argmax}(f_{\text{Louvabilidade}} > \text{LIMIAR}_{PRA}) = \text{POSITIVO} \\ BLA, SE \quad & \operatorname{argmax}(f_{\text{Culpabilidade}} > \text{LIMIAR}_{BLA}) = \text{NEGATIVO} \end{aligned}$$

A função de louvabilidade  $f_{\text{Louvabilidade}}$  é definida como:

$$f_{\text{Louvabilidade}} = \text{Intensidade} * \text{Força} * \text{Desvio}, \text{ onde:}$$

$$\text{Intensidade} = \text{DKL}(i_{\text{atitude}} || i_{\text{polaridade}});$$

$$\text{Força} = \text{DKL}(i_{\text{força}} || i_{\neg \text{força}});$$

$$\text{Desvio} = \begin{cases} 0, & \text{se } \operatorname{argmax}(I_{Av}(i_{\text{atitude}}; i_{\text{polaridade}})) = \operatorname{argmax}(I_{Op}(i_{\text{atitude}}; i_{\text{polaridade}})) \\ 1, & \text{se } \operatorname{argmax}(I_{Av}(i_{\text{atitude}}; i_{\text{polaridade}})) \neq \operatorname{argmax}(I_{Op}(i_{\text{atitude}}; i_{\text{polaridade}})) \end{cases}$$

;e

$$i \in V.$$

### 5.2.3 Atratividade

O grupo de emoção ATRAÇÃO engloba as emoções gostar e desgostar. Essas emergem da atratividade de um objeto ou aspecto desse objeto. Seus resultados possíveis são: gosta e desgosta. A figura 5.6, extraída de (ORTONY; CLORE; COLLINS, 1988), contém um quadro resumo das especificações do tipo de emoção ATRAÇÃO e as tabelas 5.7 e 5.8 contém as especificações das emoções GOSTAR e DESGOSTAR respectivamente.

A variável central atratividade agrupa emoções que emergem da apreciação estética de um objeto ou de seus aspectos. Geram dois estados: atraente (APP)<sup>52</sup> e não atraente (UPP)<sup>53</sup>.

AVALIAÇÃO DE UM OBJETO	
ATRATIVO	DESATRATIVO
gosta de um objeto atrativo	desgosta de um objeto desatrativo

Figura 5.6: Especificações do grupo de emoções ATRAÇÃO

52 Do inglês “appeal”.

53 Do inglês “unappeal”

Tabela 5.7: Resumo do tipo de emoção GOSTAR

EMOÇÃO GOSTAR	
Palavras	gostar, adorar, amar e atrair
Variáveis que afetam a intensidade	1. O grau de atratividade do objeto. 2. Grau de familiaridade com o objeto.
Exemplo	O aluno gostou do livro.

Tabela 5.8: Resumo do tipo de emoção DESGOSTAR

EMOÇÃO DESGOSTAR	
Palavras	desgostar, detestar, odiar e repulsão
Variáveis que afetam a intensidade	1. O grau de desatratividade do objeto. 2. Grau de familiaridade com o objeto.
Exemplo	O aluno odiou o filme.

As variáveis locais da função que modelam esses estados são:

- A **intensidade** da atratividade será medida da mesma forma que em louvabilidade (ver seção 5.2.2); e
- A **familiaridade** será proporcional a frequência do objeto. Quanto mais comum maior deve ser a intensidade de atratividade para gerar uma reação com valência.

Na figura 5.7 está a Função de Atratividade. A ATRAÇÃO vem do sistema de atitude da teoria de avaliatividade em linguagem. ATRATIVIDADE, portanto, consiste na variável central que caracteriza dois estados ocultos de onde a ATRAÇÃO emerge no texto através da Função de Atratividade. O alinhamento proposto entre as duas teorias está descrito na seção 5.3.




Figura 5.7: Função de Atratividade



Na figura 5.7 os estados APP e UAPP derivam da seguinte regra:

$$\begin{aligned} APP, \quad SE \quad \text{argmax}(f_{Atratividade} > LIMIAR_{APP}) = POSITIVO \\ UAPP, \quad SE \quad \text{argmax}(f_{Atratividade} > LIMIAR_{UAPP}) = NEGATIVO \end{aligned}$$

A função de atratividade  $f_{Atratividade}$  é definida como:

$$f_{Atratividade} = Intensidade * Força * Familiaridade, \text{ onde:}$$

$$Intensidade = DKL(i_{atitude} || i_{polaridade});$$

$$Força = DKL(i_{força} || i_{\neg força});$$

$$Familiaridade = \frac{1}{tf}; \text{ e}$$

$$i \in V$$

Na função de Familiaridade  $tf$  consiste na frequência do termo.

### 5.3 O alinhamento entre as teorias de linguística e de emoção

Nesse trabalho foi utilizada uma versão simplificada do modelo OCC. A razão para isso, discutida em (STRAPPARAVA; MIHALCEA, 2007), reside em que quanto maior for a granularidade do afeto, maior a dificuldade para o próprio agente humano identificar a emoção. Considerando que os modelos são implementados com classificadores probabilísticos supervisionados<sup>54</sup>, o baixo desempenho humano atua como limite superior para o desempenho do agente artificial.

---

<sup>54</sup> Exceto no modelo MLE, baseado em HMM. Nesse foi utilizado treinamento não supervisionado por não existir um corpus rotulado de acordo com as emoções passíveis de serem reconhecidas pelo RS.

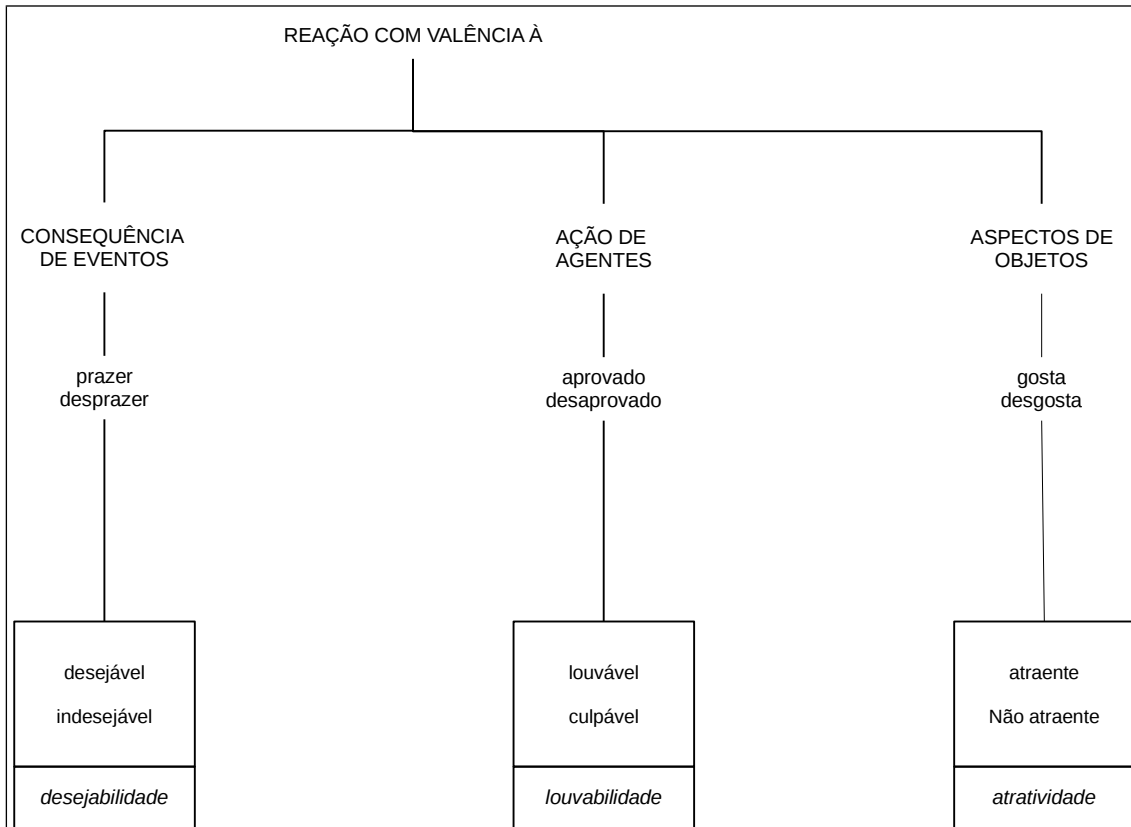


Figura 5.8: Modelo OCC simplificado, adaptado de (ORTONY; CLORE; COLLINS, 1988)

A simplificação ocorreu diminuindo a profundidade da árvore descrita na figura 3.8 e é apresentada na figura 5.8, onde as variáveis centrais de desejabilidade, louvabilidade e atratividade estão em itálico.

No escopo dessa pesquisa o alinhamento começa na organização dos eventos, agentes e objetos sujeitos a uma avaliação que ambas teorias fazem.

Na SFL o sistema de atitude, como visto na figura 3.3, envolve afeto, julgamento e apreciação. No modelo OCC o sistema de atitude consiste em uma reação com valência à consequência de um evento, à ação de um agente ou ao aspeto de um objeto. Nesse trabalho, tomando como base a descrição de ambos os modelos, decidiu-se ser adequado um alinhamento conforme a abaixo:

1. Alinhar o conceito de AFETO na teoria da avaliação em linguagem avaliativa com a variável central de DESEJABILIDADE no modelo OCC;
2. Alinhar o conceito de JULGAMENTO na teoria da avaliação em linguagem avaliativa com a variável central de LOUVABILIDADE no modelo OCC; e

3. Alinhar o conceito de ATRAÇÃO na teoria da avaliação em linguagem avaliativa com a variável central de DESEJABILIDADE no modelo OCC;

Essa proposta de alinhamento consiste no conteúdo da figura 5.9. A seguir são discutidos detalhadamente o alinhamento observado entre esses conceitos.

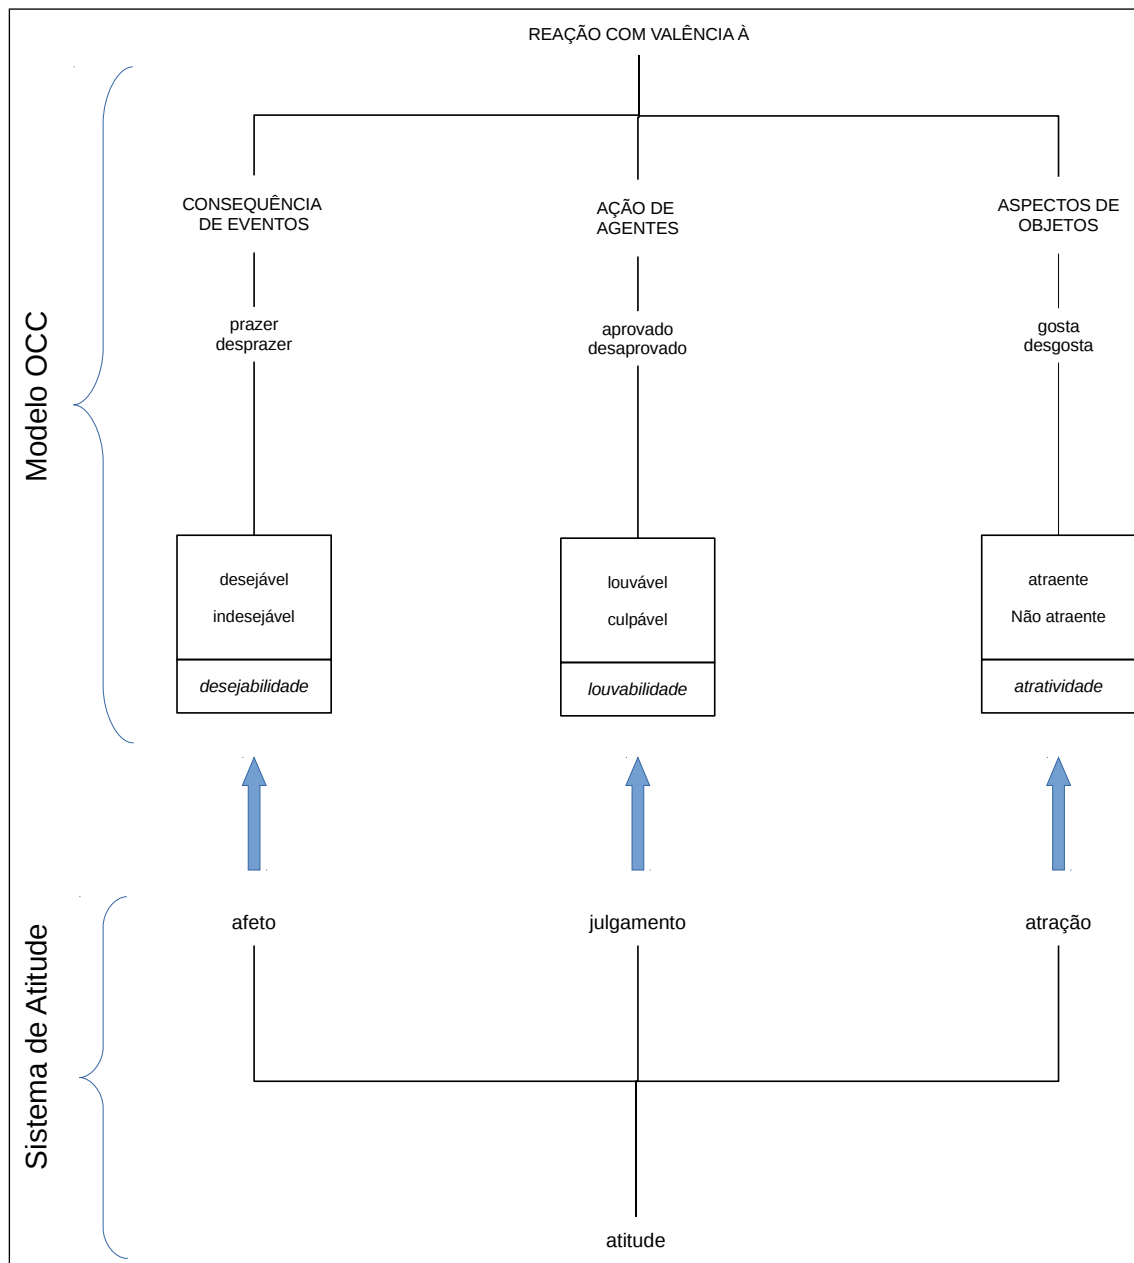


Figura 5.9: Proposta de alinhamento entre o modelo OCC e o sistema de atitude

### **5.3.1 O alinhamento entre julgamento e ação de agentes**

Julgamento, na teoria da avaliação em linguagem avaliativa (seção 3.2), é definido como a forma que o significado molda nossa avaliação ética em relação às pessoas ou em relação ao seu comportamento, ou seja, aspectos éticos. Na teoria esse subsistema de atitude é dividido em estima social e sanção social conforme exemplificado na figura 3.3. O julgamento de uma pessoa ou do seu comportamento (capaz, arrogante, sincero seriam exemplos) leva o avaliador a sentir o afeto admirar, louvar, culpar ou condenar.

No modelo OCC a variável que caracteriza a avaliação das ações de agentes é a louvabilidade, incluída nessa variável a culpabilidade, cujo valor é relativo a padrões sociais. Na figura 3.8 observam-se as emoções do tipo atribuição como orgulho, admiração, vergonha e reprovação.

Abaixo se listam três fatores de convergência entre as teorias:

- Possuem sistemas distintos dos demais para avaliar pessoas ou seus comportamentos;
- Essas avaliações são balizadas por padrões sociais; e
- As variáveis encontradas no modelo OCC de louvabilidade e culpabilidade são entendidas como julgamento na teoria da avaliação em linguagem avaliativa.

Dados esses três fatores foram alinhados o subsistema de JULGAMENTO, na teoria da avaliação em linguagem avaliativa, com a vertente AÇÃO DAS PESSOAS no modelo OCC.

Com isso palavras encontradas no texto que caracterizam avaliação em relação ao comportamento de pessoas, segundo o dicionário seminal proposto por (MARTIN; WHITE, 2005), servirão de evidência de emoções ligadas à “ação de agentes” no modelo OCC. O referido dicionário encontra-se no apêndice A.

### **5.3.2 O alinhamento entre apreciação e aspectos dos objetos**

Apreciação, na teoria da avaliação em linguagem avaliativa (seção 3.2), envolve

o sistema de avaliação estética das coisas, definida como a forma que o significado molda nossa atitude como reação aos objetos, processos, comportamento de agentes ou fenômenos naturais. Na teoria esse subsistema de atitude é dividido em reação, composição e valoração como já discutido na seção 3.2.1. A caracterização do valor depende da forma como o objeto avaliado é percebido em um determinado campo. A apreciação de um objeto (cativante, bom, harmonioso e inovador seriam exemplos de adjetivos) leva o agente que avalia a sentir afeto caracterizado globalmente como positivo ou negativo, mas com graduação em intensidade (regular < bom < excelente).

No modelo OCC a variável que caracteriza a avaliação dos aspectos dos objetos é a atratividade, incluída sua contrapartida negativa), cujo valor é relativo à predisposição do agente que sente de gostar ou desgostar de objetos ou de seus aspectos. Essa predisposição resulta na valoração do grau de gostar ou não gostar Na figura 3.8 observam-se as emoções do tipo atração como amor e ódio.

Abaixo se listam três fatores de convergência entre as teorias:

- Possuem sistemas distintos dos demais, centrado na atitude, para avaliar objetos ou seus aspectos;
- Essas atitudes são balizadas por valor do objeto em uma área; e
- A variável encontrada no modelo OCC de atratividade é entendida como afeto positivo ou negativo na teoria da avaliação de afetividade.

Dados esses três fatores foram alinhados o sistema de ATRAÇÃO, na teoria da avaliação em linguagem avaliativa, com a vertente ASPECTOS DOS OBJETOS no modelo OCC.

Com isso palavras encontradas no texto que caracterizam atitude em relação a aspectos de objetos, segundo o dicionário seminal proposto por (MARTIN; WHITE, 2005), servirão de evidência de emoções ligadas a “aspectos dos objetos” no modelo OCC. O referido dicionário encontra-se no apêndice B.

### **5.3.3 O alinhamento entre afeto e consequência de evento**

A forma como evento é percebida no modelo OCC está embutida em julgamento e apreciação na teoria de avaliatividade em linguagem. Ambos (julgamento e apreciação) são definidos como “sentimentos institucionalizados”. Quando

retrabalhados no domínio ético, ou seja, como as pessoas devem se comportar, dadas as regras de comportamento, se passa do afeto (por exemplo admiração) para o sentimento institucionalizado (por exemplo: capaz).

De forma análoga quando o “amar” é retrabalhado no domínio estético, ou seja, como objetos, comportamento ou fenômenos naturais e são valorizados através de parâmetros de valor em um contexto, se passa desse afeto para o sentimento institucionalizado apreciação (por exemplo: encantador).

A figura 5.10 ilustra o processo descrito.

Uma vez que o mapeamento de afeto a pessoas ou seus comportamentos e o mapeamento de objetos e seus aspectos já foram relacionados a afetos, resta mapear os aspectos de evento relativo ao afeto.

Afeto possui cinco dimensões. As três primeiras são inespecíficas a eventos. A primeira trata da sua polaridade (positivo/negativo). A segunda envolve a emoção percebida através de uma manifestação (exemplo: sudorese) ou comportamento corporal (sorrir). A terceira relaciona-se a graduação (baixa, média. Alta).

A quarta alinha-se com a noção de evento cujo prognóstico é relevante ou irrelevante do modelo OCC. Essa dimensão caracteriza o afeto como sendo uma intenção (e não uma reação) a um estímulo real (prognóstico irrelevante) ou irreal (prognóstico relevante).

A quinta consiste em uma tipologia de afetos com três grupos. O tipo alegria abriga emoções “ligadas ao coração” como tristeza, ódio, alegria e amor. A segunda abriga emoções ligadas a segurança como ansiedade, medo e confiança. A terceira aglutina emoções do tipo satisfação como entusiasmado, envolvido e impressionado.

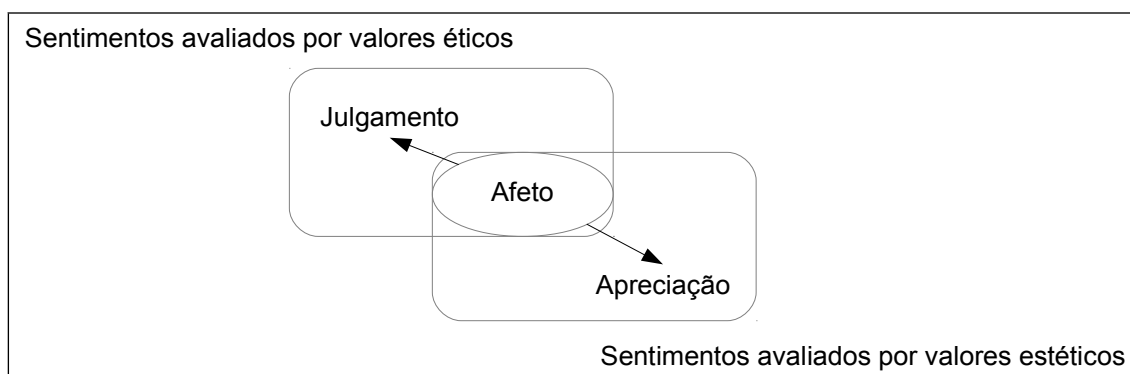


Figura 5.10: Julgamento e apreciação constituídos como afeto

O alinhamento com as 12 emoções do modelo OCC na vertente cuja variável é a desejabilidade, conforme figura 3.8 (excluindo as emoções compostas como: gratificação, remorso, agradecido e raiva), foi elaborado e implementado como os anteriores, ou seja, através de um dicionário. Apenas foram excluídas as palavras constantes nos dois dicionários anteriores (o dicionário de atração e o de julgamento).

#### 5.4 Quadro resumo do alinhamento

A figura 5.11 contém um resumo do alinhamento entre as duas teorias modelos: Estrutura cognitiva das emoções e teoria de avaliatividade em linguagem.

Avaliação Linguagem	OCC	Estados
<ul style="list-style-type: none"> <li>• Afeto</li> </ul>	<ul style="list-style-type: none"> <li>• Eventos: Consequências</li> <li>• Desejabilidade</li> </ul>	<ul style="list-style-type: none"> <li>• Desejável – DES</li> <li>• Indesejável - IDES</li> </ul>
<ul style="list-style-type: none"> <li>• Julgamento</li> </ul>	<ul style="list-style-type: none"> <li>• Agentes:</li> <li>• Aspectos éticos</li> <li>• Louvabilidade</li> </ul>	<ul style="list-style-type: none"> <li>• Louva – PRA</li> <li>• Culpa - BLA</li> </ul>
<ul style="list-style-type: none"> <li>• Apreciação</li> </ul>	<ul style="list-style-type: none"> <li>• Objetos:</li> <li>• Aspectos estéticos</li> <li>• Atratividade</li> </ul>	<ul style="list-style-type: none"> <li>• Atraente – APP</li> <li>• Repulsivo - UAPP</li> </ul>

Figura 5.11: Resumo do alinhamento entre modelo OCC e teoria de avaliatividade em linguagem

## 5.5 Composição de estados emocionais em sentimento

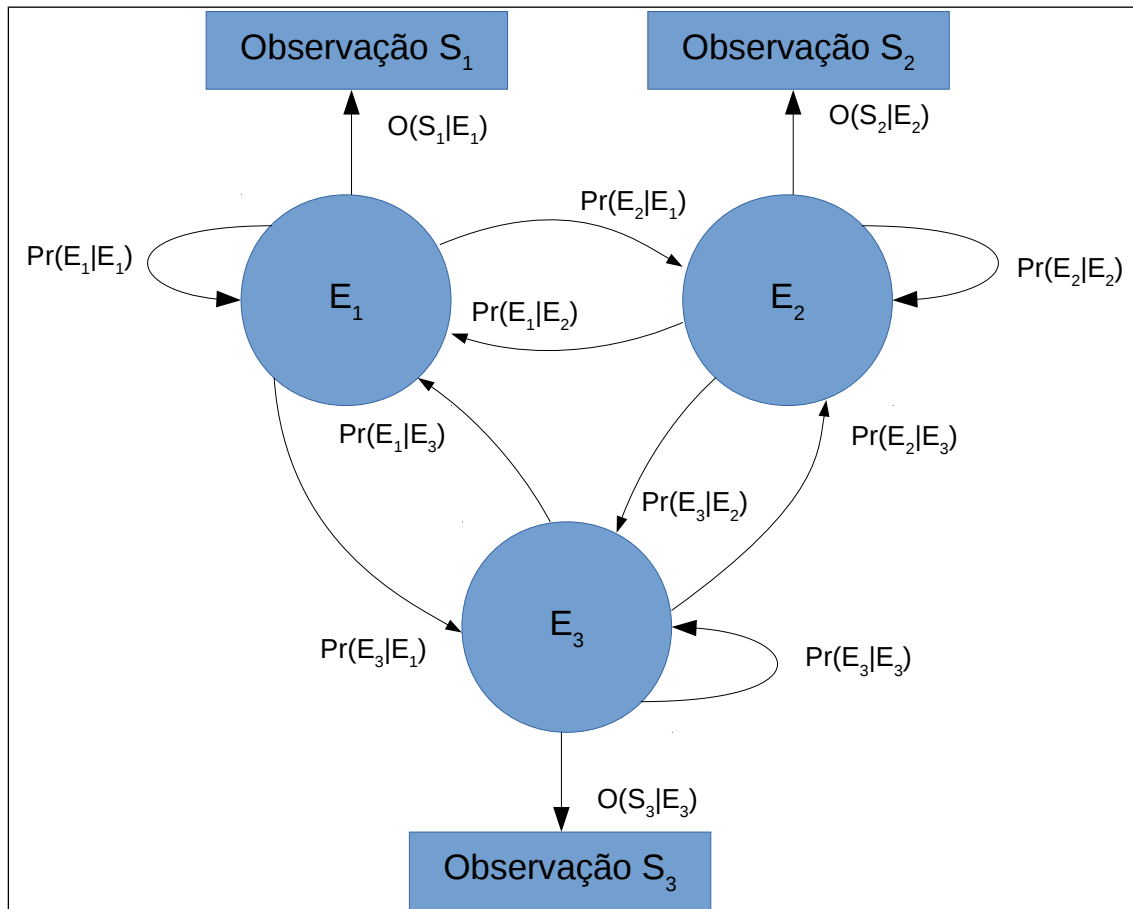


Figura 5.12: Composição de estados emocionais com HMM

Uma premissa deste trabalho consiste em que ao longo da escrita de um texto o autor pode passar por uma sequência de emoções. A figura 5.12, adaptada de (PICARD, 1995), mostra a topologia da HMM que modela essa sequência. No caso se optou por apresentar apenas três estados para simplificar a figura.

A figura 5.13 contempla um exemplo da mesma topologia aplicada à proposta desse trabalho.



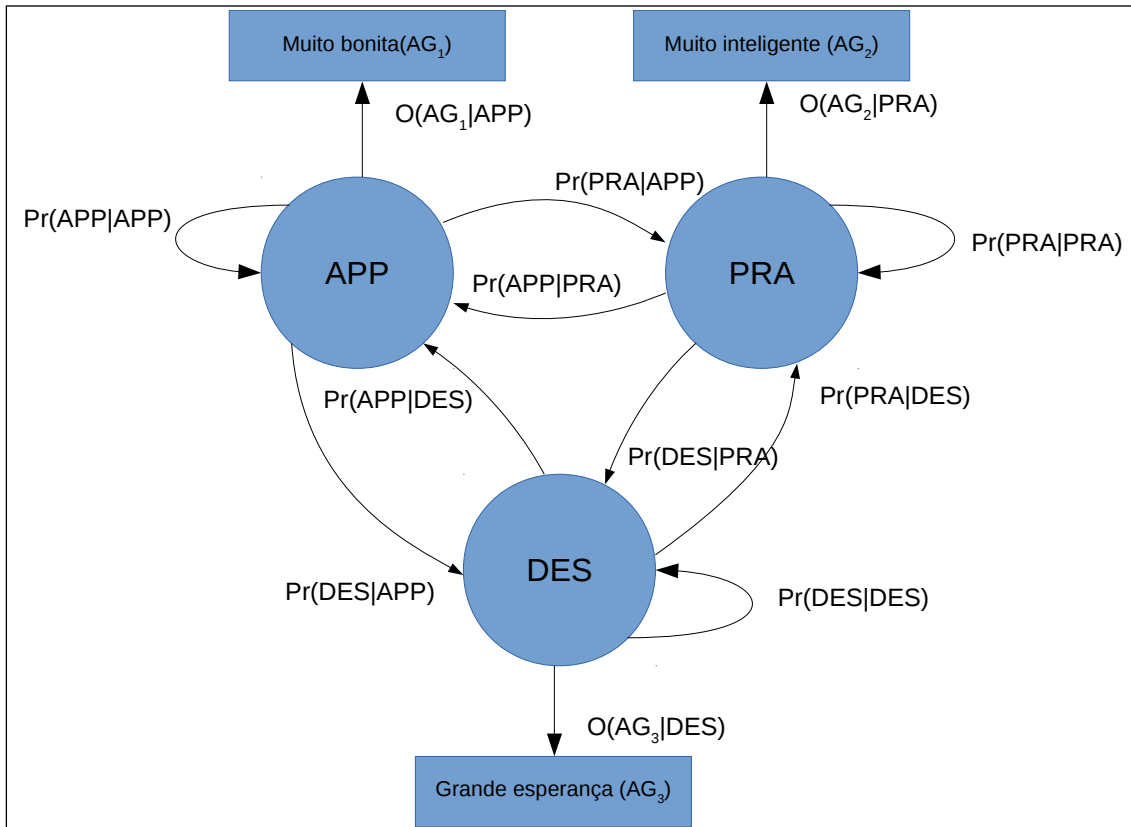


Figura 5.13: Exemplo da composição de estados emocionais com grupos avaliativos

Nela existem distribuições de probabilidade tanto para a transição de estados como para a emissão dos símbolos (os grupos avaliativos). Na figura 5.14 estão discriminados os parâmetros necessários para iniciar um HMM (ver APÊNDICE G) de acordo com os modelos propostos nesse trabalho.

▼ $Q = q_1, q_2, \dots, q_N$	▼ O conjunto de estados - OCC
▼ $A = a_{01}, a_{02}, \dots, a_{n1}, a_{n2}, \dots, a_{nn}$	▼ Matriz de transição de estados
▼ $O = o_1, o_2, \dots, o_N$	▼ Observações = $s_1, s_2, \dots, s_V$ , onde cada $s$ é um grupo avaliativo
▼ $B = b_i(s_t)$	▼ Probabilidade de emissão
▼ $Q_{início}, Q_{fim}$	▼ Estados inicial e final

Figura 5.14: Parâmetros de uma HMM para o modelo MLE

Os estados  $Q$  serão os seis estados discriminados na seção 5.2, ou seja, aqueles

sumarizados na figura 5.11. Como emoções são reações com valência, segundo o modelo OCC, será acrescentado um estado NEUTRO (NEU) para caracterizar a ausência da valência. As observações serão os grupos avaliativos descritos na seção 5.6 e seus atributos são extraídos conforme descritos na seção 5.7 e ilustrados na figura 5.17. A probabilidade de um grupo avaliativo emergir de uma emoção é calculada como gaussianas multivariadas, descrita na seção 6.6.2. Os estados inicial e final seguirão os delimitadores de sentença.

No modelo cognitivo a sequência de estados é definida começando por um estado não emocional ( $\tilde{N} Q$ ). Segue para um estado emocional não diferenciado que os autores chamam de sentimento, tendo esse sentimento uma polaridade positiva ou negativa. A sequência prossegue para qualquer um dos estados específicos ( $Q_0, \dots, Q_5$ ), podendo retornar ao sentimento. Esse mecanismo está descrito na figura 5.15 extraída de (ORTONY; CLORE; COLLINS, 1988).

Tanto a proposta de (PICARD, 1995) quanto a sequência de estados emocionais proposta por (ORTONY; CLORE; COLLINS, 1988) inspiraram a implementação do modelo MLE utilizando HMM.

Portanto o HMM não rotulará cada estado, inferindo sua sequência mais provável. O classificador calculará a probabilidade da sequência observada emergir do modelo treinado. Haverá um modelo, ou seja, um HMM para sequências não emocionais, que será chamado do modelo neutro. Dois modelos para sentimento, sendo um positivo e o outro negativo, constituirão os modelos de sentimento que resultarão de sequências de emoções observadas em cada sequência.

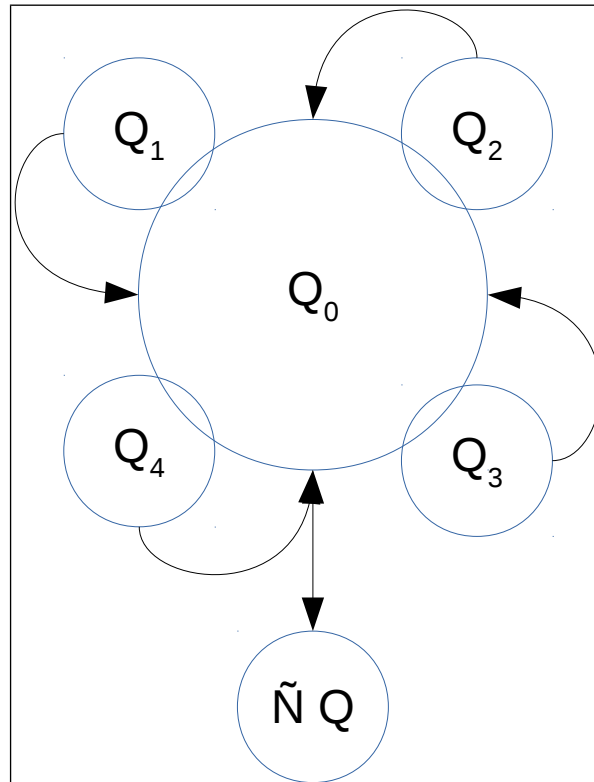


Figura 5.15: Relação entre estados emocionais, sentimento e estado neutro

## 5.6 Os grupos avaliativos

Na seção 4.5 foi descrito que um grupo avaliativo consiste na menor porção de texto possível de emergir de um estado emocional subjacente (oculto). Mais precisamente, um grupo avaliativo (WHITELAW; GARG; ARGAMON, 2005) consiste em uma unidade linguística elementar que liga um tipo de atitude (afeto, julgamento ou apreciação) a um alvo (no caso dessa pesquisa o evento, agente ou objeto avaliado) (BLOOM; GARG; ARGAMON, 2007)<sup>55</sup>. Em extração da informação os atributos dessa unidade linguística compõem o “cenário de extração” (ver seção 3.8). Esse cenário, ou grupo avaliativo, se encontra na figura 5.17. Podem ser de quatro tipos:

1. Grupo Avaliativo Adjetival: Consiste no grupo onde a atitude recai sobre o adjetivo. Exemplo: Uma mulher bonita.
2. Grupo Avaliativo Verbal: Consiste no grupo onde a atitude recai sobre o verbo. Exemplo: Gostei do livro.

<sup>55</sup> Chamou de expressão avaliativa

3. Grupo Avaliativo Adverbial<sup>56</sup>: Consiste no grupo onde a atitude recai sobre o advérbio. Exemplo: O piloto correu lentamente.
4. Grupo Avaliativo Nominal: Consiste no grupo onde a atitude recai sobre o substantivo, desde que consista em um atributo significativo para polaridade positiva ou negativa conforme o LLR. Exemplo: O livro é um lixo.

Neste trabalho optou-se por utilizar o advérbio com evidência do atributo esforço, seguindo a proposta de (SHAIKH; PRENDINGER; ISHIZUKA, 2009), e, portanto, serão tratados os grupos avaliativos adjetival, verbal e nominal. Os grupos avaliativos podem ter dois modificadores:

1. Modificador do tipo força: O livro é  **muito bom** . O grupo avaliativo adjetival é composto pelo bigrama “muito bom” onde o muito intensifica o adjetivo “bom”
2. Modificador do tipo negação: O livro  **não é muito bom** . O grupo avaliativo adjetival “muito bom” tem sua polaridade invertida pelo advérbio “não”.

Nessa figura os atributos foram agrupados por sua origem teórica. Os atributos empíricos foram introduzidos ao longo do experimento de forma a incrementar a acurácia do classificador.

A seguir definem-se os atributos:

- **Avaliado**: consiste em uma lista de substantivos e nomes próprios cujo score do teste de independência “*log likelihood ratio*” (DUNNING, 1993) foi maior do que um limiar, empiricamente encontrado para cada polaridade. A descrição e desempenho desse teste estão no APÊNDICE J. Para exemplificar na figura 5.16 encontram-se os dez maiores calculados para cada polaridade.
- **Polaridade do avaliado**: A polaridade do avaliado.
- **Tipo de atitude**: São aquelas descritas na seção 3.2.1, ou seja, afeto, julgamento e apreciação. A escolha do tipo de atitude será feita baseada na associação do termo central do grupo avaliativo (adjetivo, verbo ou substantivo) no dicionário de atitude. Como existe a ambiguidade uma função probabilística será utilizada para escolher a atitude mais provável.
- **Intensidade da atitude**: Consiste na Divergência Simétrica de Kullback–Leibler

---

<sup>56</sup> Na tese esse grupo foi desconsiderado pois advérbios são tratados como evidência de força ou esforço.

como uma medida de distância<sup>57</sup> entre o conjunto de palavras que caracterizam uma atitude, por exemplo julgamento, e aquelas que não a caracterizam conforme suas frequências no corpus. A descrição desse cálculo está na seção J.1 do APÊNDICE J.

- **Força:** Pode assumir dois valores (intensificador e atenuador) e consiste na lista de palavras que estão no dicionário do sistema de graduação conforme o APÊNDICE D.
- **Intensidade força:** Calculada de forma análoga a do cálculo da intensidade da atitude.
- **Negação:** Consiste na existência dos advérbios não e nada invertendo a polaridade de um grupo avaliativo. Exemplo: um livro nada bom.
- **Polaridade:** Positiva, negativa ou neutra. Consiste no argumento da função máximo entre as entropias mútuas entre a frequência da palavra no corpus e a respectiva polaridade. Sua descrição formal está na seção J.2 do APÊNDICE J.
- **Intensidade da emoção:** A definição dessa intensidade depende das variáveis desejabilidade, louvabilidade e atratividade e está definida na seção 5.2. Como dependem do tipo de atitude, segundo a alinhamento proposto nessa tese e, como já descrito para o atributo tipo de atitude, existe ambiguidade, o resultado dessa intensidade emerge de uma função probabilística.
- **Desvio de expectativa:** A definição do seu cálculo está na seção 5.2.2
- **Esforço:** A definição está na seção 3.6.3
- **Intensidade esforço:** A definição do seu cálculo está na seção 5.2.1
- **Familiaridade:** A definição está na seção 3.6.3 e o seu cálculo está na seção 5.2.1
- **LLR:** “*Log Likelihood Ratio*” e sua forma de cálculo está na seção J.1 do APÊNDICE J
- **I(N-grama; Polaridade):** Consiste na informação mútua entre o N-grama que compõe esse grupo e as polaridades. Consiste no valor da função máximo entre as entropias mútuas entre a frequência da palavra no corpus e a respectiva

---

<sup>57</sup> Divergência KL, mesmo a simétrica, não é uma medida de distância. O valor da simétrica entre duas variáveis aleatórias é a mesma independentemente da direção.

polaridade. Sua descrição formal está na seção J.2 do APÊNDICE J.

- **GA|Polaridade:** Consiste na probabilidade condicional do grupo avaliativo dada a polaridade.

Palavra	Polaridade	Palavra	Polaridade	Palavra	Polaridade
autora	negativo	livro	positivo	Edward	neutro
enredo	negativo	história	positivo	pessoas	neutro
confesso	negativo	leitura	positivo	filme	neutro
metade	negativo	romance	positivo	coisa	neutro
linguagem	negativo	personagens	positivo	mãe	neutro
pontos	negativo	vezes	positivo	Winston	neutro
partes	negativo	fim	positivo	pai	neutro
sucesso	negativo	final	positivo	irmão	neutro
lixo	negativo	Sidney	positivo	dia	neutro
impressão	negativo	Sheldon	positivo	mulher	neutro

Figura 5.16: Lista dos 10 substantivos com maior escore de cada polaridade

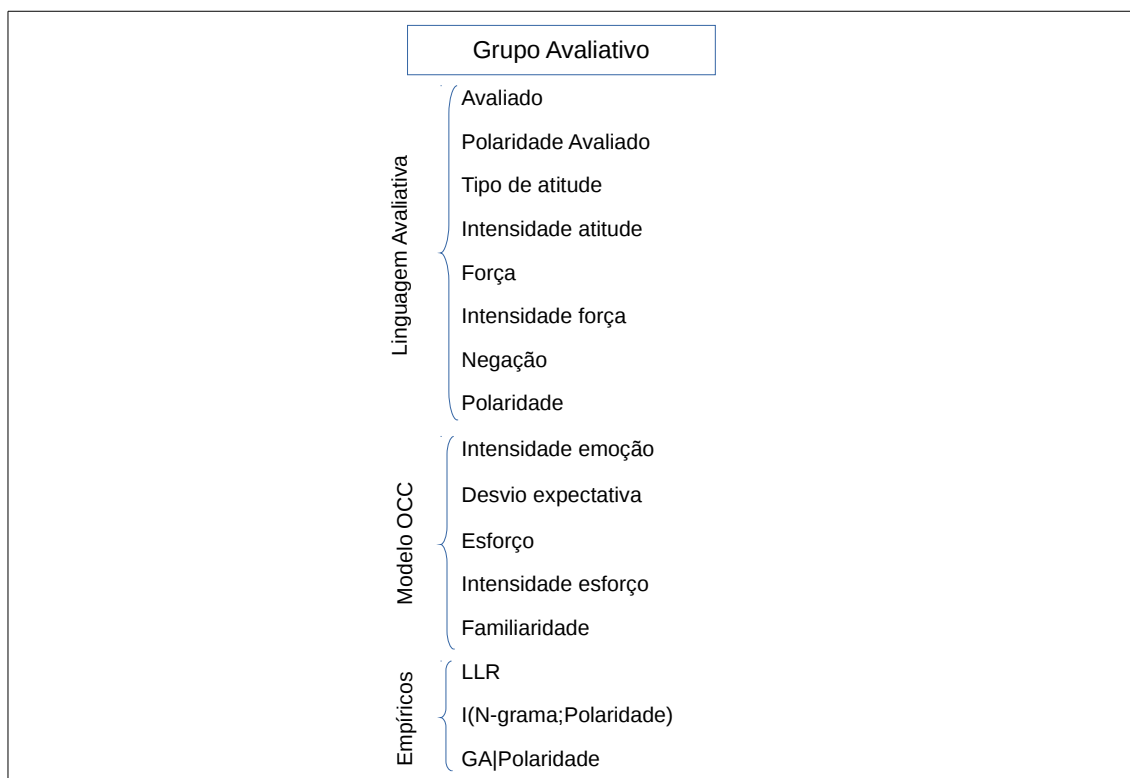


Figura 5.17: Atributos dos grupos avaliativos

## 5.7 A extração dos grupos avaliativos

Como descrito na seção 5.6 um grupo avaliativo é formado por um adjetivo, advérbio, verbo ou substantivo, podendo ser precedido ou sucedido de modificadores de

força ou negação. Para a produção das regras que permitiram a extração dos grupos avaliativos<sup>58</sup> (WHITELAW; GARG; ARGAMON, 2005) aproveitaram duas características da língua inglesa: na ordenação típica em inglês os modificadores precedem o adjetivo; e a lista de modificadores é composta por advérbios intercalados, ou não, por artigos.

Em português, particularmente no ReLi, os modificadores sucedem ou precedem as palavras com a atitude. Adicionalmente são intercaladas com artigos, verbos auxiliares e preposição. Exemplos são<sup>59</sup>:

1. O livro *não é de muito* **mau** gosto; e
2. O livro é **meloso** demais.

No primeiro exemplo a lista de modificadores precede a palavra com atitude (o adjetivo mau). No segundo exemplo a lista, constituída apenas do advérbio demais, sucede a palavra com atitude (o adjetivo meloso).

As regras para a extração dos grupos avaliativos foram desenvolvidas baseadas na frequência dos modificadores, sucedendo ou precedendo as palavras com atitude. Essas regras são constituídas de sequências rótulos, que são as classes gramaticais das palavras.

A figura 5.18 ilustra o processo de extração utilizando um cenário de extração simplificado da figura 5.17.

---

58 Os autores trabalharam somente com grupo avaliativo adjetival.

59 Em itálico os modificadores e em negrito a palavra com atitude.

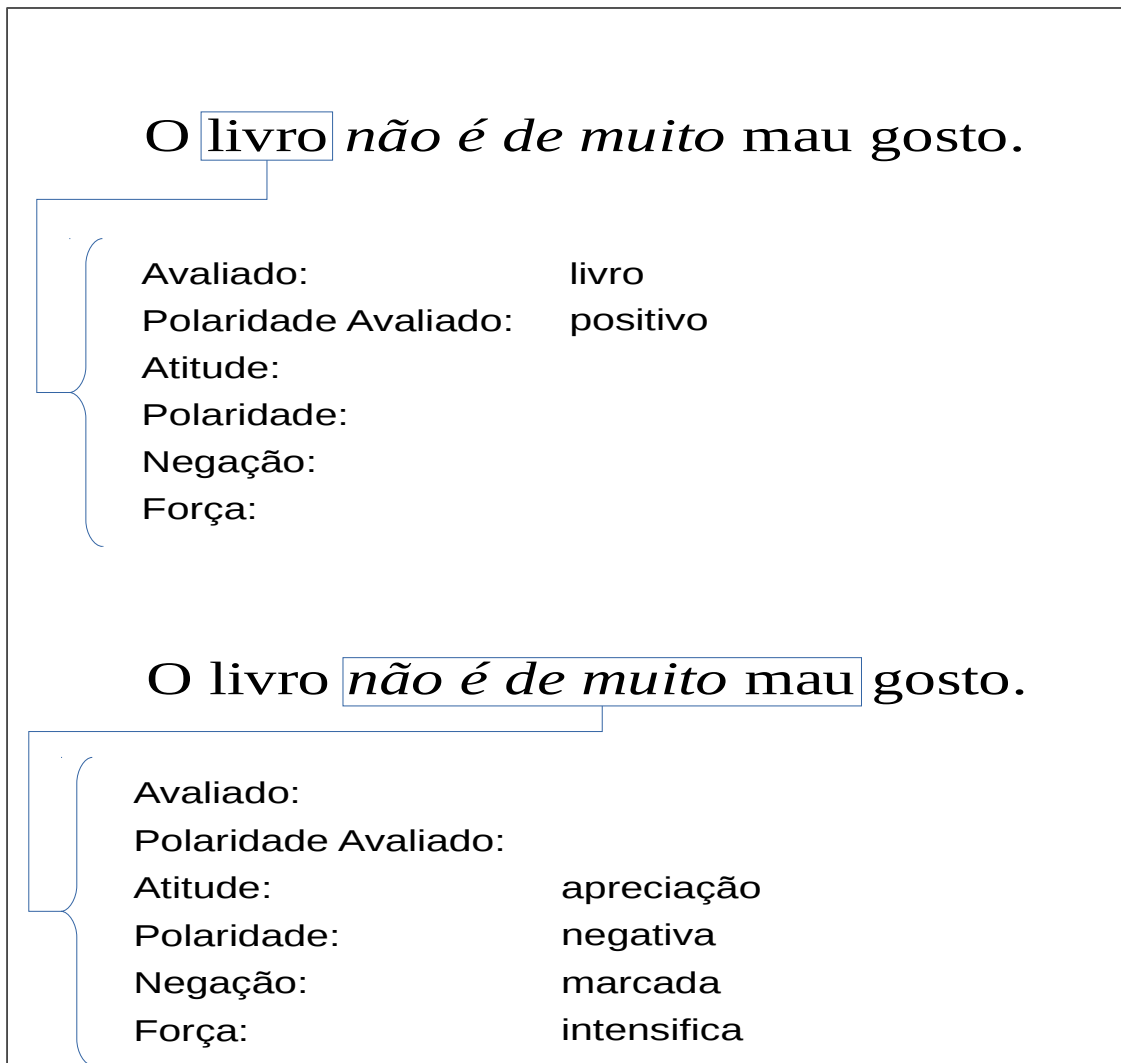


Figura 5.18: Exemplo de grupos avaliativos

O primeiro consiste em um grupo avaliativo por questão contextual. O teste de independência LLR para a palavra livro<sup>60</sup> identificou que essa palavra é um atributo importante para sentenças rotuladas como positiva. Por isso livro foi considerado um grupo avaliativo nominal.

Já o segundo grupo foi considerado um grupo avaliativo adjetival pois o adjetivo mau está na lista de palavras do sistema de apreciação (ver seção 5.3.2). Sua polaridade é negativa.

O atributo negação foi marcado, pois o advérbio, não, consta do sistema de negação (ver definição do atributo negação na seção 5.6).

O atributo força foi marcado como intensifica, pois o advérbio muito consta na

<sup>60</sup> O resultado desse teste é dependente de corpus.



lista de palavras do sistema da graduação (ver definição do atributo força na seção 5.6) como intensificador de uma atitude.

## 6 O experimento, resultados e avaliação

O experimento foi constituído de quatro etapas:

1. Estabelecer uma referência para comparação de desempenho do modelo proposto nessa pesquisa.
2. Determinar o conjunto de atributos linguísticos que melhor descrevem os sentimentos positivo, negativo e neutro para o modelo ME.
3. Determinar os melhores parâmetros para cada um dos três modelos linguístico emocional, sendo um modelo para sentimento positivo, outro negativo e o terceiro para o neutro.
4. Encontrar a melhor combinação de parâmetros para a composição dos modelos ME e MLE que maximizam o desempenho do canal de ruído.

### 6.1 Metodologia

Foi desenvolvido um analisador que converteu o ReLi de seu formato original em arquivos xml, onde os rótulos eram as próprias anotações. O resultado desse analisador gerou duas bases. A primeira, chamada de base de desenvolvimento, contém 90% das resenhas aleatoriamente selecionadas. As restantes 10% constituíram a base de teste.

Os experimentos, portanto, foram efetuados na base de desenvolvimento utilizando o método validação cruzada “*10-fold*”, cujo objetivo é verificar a capacidade de generalização do modelo. Se seguiu os passos a seguir conforme descritos em (MANNING; SCHUETZE, 1999):

1. Se dividiu a base em 10 partes;
2. Uma parte é escolhida para teste, variando-a em cada rodada. Treino ocorre nas demais.
3. Desempenho medido sobre a parte de teste.
4. Reportada a média das 10 rodadas.

Na figura 6.1 se encontra um desenho (com “5-fold”) descrevendo o processo.



Figura 6.1: Desenho esquemático de teste de validação cruzada "5-fold"

Terminada a fase de desenvolvimento, os classificadores foram aplicados na base de teste e o resultado final anotado.

## 6.2 Corpus anotado

Muito se tem pesquisado para o tratamento de sentimento em texto. A maior parte dos esforços visam a língua inglesa. Um objetivo importante dessa tese foi desenvolvê-la prioritariamente para o português, língua na qual foram encontrados somente dois corpora anotados.

O SentiCorpus-PT (CARVALHO et al., 2011) consiste em um corpus rotulado de “tweets” sobre políticos portugueses. Priorizamos o ReLi (seção 6.2.1) sobre esse corpus por duas razões:

1. O SentiCorpus-PT aborda somente políticos. Contém aspectos éticos e, em

escala menor, estéticos de pessoas não ofertando uma riqueza de emoções mais alinhada com os objetivos dessa tese; e

2. O SentiCorpus-PT é uma base pequena com aproximadamente 2.800 entradas.

Todavia tratá-la com a proposta dessa pesquisa será fruto de trabalho futuro. Uma diferença interessante desse corpus para o ReLi é que a foi atribuída a polaridade negativa para a maioria das sentenças.

### **6.2.1 O ReLi**

O corpus que apoiou o experimento dessa tese foi o ReLi – Resenha de Livros (FREITAS et al., 2012). Embora seja constituído por 13 livros de 7 autores, a versão disponibilizada não continha resenhas para “Capitães de Areia” de Jorge Amado.

O ReLi consiste em um corpus anotado com a polaridade em nível de sentença e de sintagma (a opinião). Os alvos da opinião, chamados de objetos pelos autores, também estão anotados. Uma anotação adicional consiste na ligação da opinião com seu objeto.

Os autores reportam resenhas de três tipos:

1. Aquelas que contém apenas resumo do livro;
2. Resenhas que misturam opinião com resumo;
3. Resenhas cujo conjunto de objetos opinados incluem outros elementos além do livro resenhado.

Depois de conversar com a curadora do corpus resolveu-se excluir as resenhas do primeiro grupo. Na figura 6.2 consta um quadro com o resumo do corpus original e daquele que apoiou o experimento da tese. A exclusão do primeiro grupo deveu-se a diminuir o impacto do desequilíbrio entre o número de sentenças positivas, negativas e neutras. Um classificador tendencioso para classificar sentenças como neutras teria desempenho satisfatório, mesmo errando a classificação das sentenças negativas e positivas. Adicionalmente a intenção consiste em tratar textos opinativos e não resumo de livros, caracterizados apenas por conterem sentenças neutras.

Autor	Título	Resenhas		Frases		Palavras	
		Original	Experimento	Original	Experimento	Original	Experimento
Stephenie Meyer	Crepúsculo	409	357	3.266	2.883	62.628	56.744
Thalita Rebouças	Fala sério, amiga!; Fala sério, amor!; Fala sério, mãe!; Fala sério, pai!; Fala sério, professor!	161	139	910	762	16.864	14.846
Sidney Sheldon	O Outro lado da meia noite; O Reverso da Medalha; Se houver Amanhã	230	205	1.569	1.394	31.712	29.697
George Orwell	1984	202	159	2.228	1.718	51.320	39.107
José Saramago	Ensaio sobre a Cegueira	271	199	1.991	1.389	42.152	28.492
J. D. Salinger	O Apanhador nos Campos de Centeio	140	116	1.158	972	23.725	20.569
Total		1.413	1.175	11.122	9.118	228.401	189.455

Figura 6.2: Resumo do Corpus ReLi Original e do Experimento

Esse foi o caso do classificador Rede Bayesiana Ingênua (NB)<sup>61</sup>. Em um experimento para verificar esse impacto o classificador NB não acertou a polaridade de nenhuma sentença positiva e negativa<sup>62</sup>. Mesmo assim obteve acurácia de 74% no corpus original contra 70% no corpus sem as resenhas do tipo 1. Mesmo sem essas resenhas o número de sentenças neutras predominou como mostra a figura 6.3.

Autor	Título	Sentenças			Total
		Neutras	Negativas	Positivas	
Stephenie Meyer	Crepúsculo	2.063	278	542	2.883
Thalita Rebouças	Fala sério, amiga!; Fala sério, amor!; Fala sério, mãe!; Fala sério, pai!; Fala sério, professor!	492	39	231	762
Sidney Sheldon	O Outro lado da meia noite; O Reverso da Medalha; Se houver Amanhã	891	41	462	1.394
George Orwell	1984	1.277	30	411	1.718
José Saramago	Ensaio sobre a Cegueira	1.001	28	360	1.389
J. D. Salinger	O Apanhador nos Campos de Centeio	704	87	181	972
Total		6.428	503	2.187	9.118
%		70%	6%	24%	

Figura 6.3: Percentual da polaridade das sentenças

Como visto a exclusão das resenhas tipo 1 atenua o impacto do número de sentenças neutras, sem eliminar o desafio de identificá-las.

O desafio emerge de algumas decisões tomadas pelos autores do corpus de forma a contornar a dificuldade inerente ao processo de identificação e classificação de

61 Do inglês “Naive Bayes”

62 Os atributos foram todas as palavras do corpus de treino.

opinião para o próprio ser humano. Se destacam:

1. Uma opinião recebeu o rótulo positivo ou negativo somente se os anotadores puderam responder à pergunta “gostou do livro/dessa parte do livro?”;
2. Descrição do livro ou de personagem não foram anotadas. Por exemplo “final triste” foi interpretado como descrição de uma parte do livro, enquanto “final louco” foi interpretado como opinião sobre a parte final do livro.
3. Uma opinião não relativa ao livro (por exemplo uma opinião relativa ao filme derivado de um livro) não foi anotada.
4. A dificuldade de se distinguir declarações factuais (“vampiro charmoso”) das declarações opinativas (“vilã fascinante”).

Exemplos das dificuldades inerentes do processo de anotação são ilustradas nas figuras 6.4 e 6.5. Elas mostram o mesmo trecho (retângulo vermelho na figura) de duas resenhas<sup>63</sup> distintas: “ele é lindo, perfeito, misterioso”. Na primeira resenha “lindo”, “perfeito” e “misterioso” foram considerados texto opinativo (sombreados em azul) enquanto na segunda resenha a mesma sequência de palavras não foi. O anotador da figura 6.4 considerou a palavra “temperado” (retângulo verde) como opinião enquanto o anotador da figura 6.5 desconsiderou,

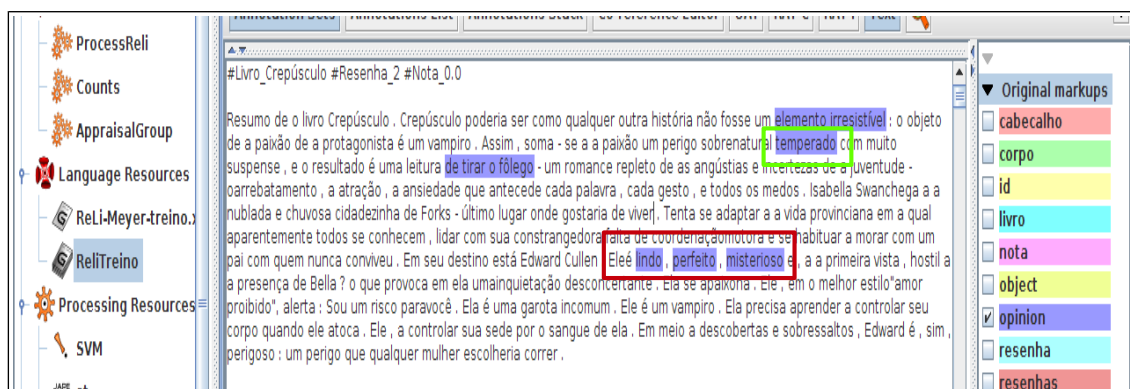


Figura 6.4: Sentença descritiva anotada.

63 Resenhas escolhidas por suas semelhanças, porém anotadas distintamente.

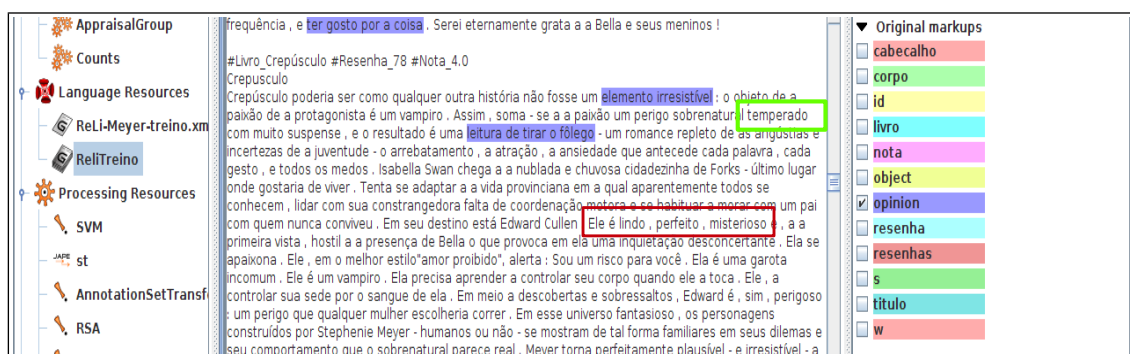


Figura 6.5: Sentença descritiva não anotada.

Nas figuras também estão ilustradas as concordâncias entre os anotadores. Ambos consideraram “elemento irresistível” e “de tirar o fôlego” como opiniões positivas.

Identificação		Anotadores			Média
		A B	A C	B C	
	Frase	85.00	81.90	78.50	81.80
	Objeto	71.10	75.30	71.30	72.57
	Opinião	78.50	71.30	79.80	76.53
Polaridade	Frase	98.10	98.40	98.40	98.30
	Sintagma	99.90	99.60	100.00	99.83

Figura 6.6: Concordância entre os anotadores do ReLi

No geral FREITAS et al. (2012) mostram um bom nível de concordância entre os três anotadores do corpus. O resumo se encontra na figura 6.6, onde A, B e C são identificadores atribuídos aos anotadores.

FREITAS et al. (2012) argumentam que o uso de linguagem avaliativa (“vampiro charmoso”) não é suficiente para caracterizar uma opinião. O contexto é importante nessa caracterização e foi considerado para atribuição ou não de polaridade.

É importante para essa pesquisa que o agente artificial “aprenda” a atitude neutra da palavra charmoso no ReLi, embora seja caracterizada na teoria da avaliação em linguagem avaliativa como atração no sistema de atitude (polaridade positiva).

Na figura 6.7 está a polaridade aprendida, utilizando a distância KL na dimensão avaliação do modelo EPA. Nessa figura as demais palavras que compõe a distribuição de probabilidades foi escondida. O propósito da figura é destacar que foi atribuída a polaridade neutra para “charmoso” e “filme”.

	Filme	Charmoso	REFERENCE
NEU	154	4	0
NEG	2	0	0
POS	35	1	0
REF	0	0	1

	Filme	Charmoso	REFERENCE
NEU	0.0799169694	0.0020757654	0
NEG	0.0058479532	0	0
POS	0.0210084034	0.0006002401	0
REF	0	0	1

DKL(NEU  REF)			
EPSILON	0.0005		
LAMBDA	0.9945		
	Filme	Charmoso	REFERENCE
REF	0.0005	0.0005	0.9945
NEU	0.0799169694	0.0020757654	0
DKL(NEU  REF)	0.5813663627	0.0032360603	0
DKL(NEU  REF)	0.0641674794	0.0003571755	0

DKL(NEG  REF)			
EPSILON	0.0005		
LAMBDA	0.9945		
	Filme	Charmoso	REFERENCE
REF	0.0005	0.0005	0.9945
NEG	0.0058157895	0.0005	0.005
DKL(NEG  REF)	0.0188177621	0	7.5557225216
DKL(NEG  REF)	0.0011493959	0	0.4615063431

DKL(POS  REF)			
EPSILON	0.0005		
LAMBDA	0.9945		
	Filme	Charmoso	REFERENCE
REF	0.0005	0.0005	0.9945
POS	0.0208928571	0.0005969388	0.0045
DKL(NEG  REF)	0.1098142692	2.47829E-005	7.7100235338
DKL(NEG  REF)	0.0065901877	1.48727E-006	0.462694899

	Filme	Charmoso
NEU	1	1
NEG	0	0
POS	0	0

*Figura 6.7: DKL no ReLi para filme e charmoso*

Durante a revisão bibliográfica constatou-se que diferentes autores deram definições distintas para o conceito de neutralidade.

O paradigma introduzido por (HATZIVASSILOGLOU; WIEBE, 2000) que correlacionaram a existência de opinião a textos subjetivos, e esses dependentes da existência de adjetivos em uma sentença, ficando a neutralidade associada a textos objetivos, foi importante para melhorar a performance dos classificadores (PANG; LEE, 2004).

Grau de positividade, ou seja, a intensidade de positivo ou negativo, adicionando ao problema de classificação o problema de regressão, foi proposto por (WILSON; WIEBE; HWA, 2004). Nesse paradigma os autores classificam como neutros textos posicionados no meio da escala.

Talvez (KOPPEL; SCHLER, 2006) tenham sido os primeiros a levantarem a importância de tratar a neutralidade como uma classe distinta, ampliando o problema da análise de sentimento de polar (positivo/negativo) para várias classes. Trabalhando em



duas bases distintas de opiniões (uma sobre programas de TV e a outra sobre produtos eletrônicos) os autores concluíram que enquanto na primeira a associação polar estava ligada a subjetividade, na segunda estava associada a existência de opiniões com polaridades diferentes em um mesmo texto.

Vale destacar o trabalho de (CABRAL; HORTAÇSU, 2006) onde os autores verificam que avaliações neutras são percebidas em alguns casos como negativas.<sup>64</sup>

Como trabalhos futuros traduziremos, desenvolveremos ou adaptaremos vários dos artefatos utilizados nessa pesquisa para o inglês. Com isso será possível verificar a eficácia da proposta desenvolvida nessa pesquisa em (WIEBE; WILSON; CARDIE, 2006), (TABOADA et al., 2011) e (READ; CARROLL, 2012).

### **6.3 Referência para a comparação do desempenho do modelo**

Até o momento em que se concluiu as atividades de pesquisa e desenvolvimento dessa tese havia apenas uma publicação (BALAGE FILHO; ALEXANDRE SALGUEIRO PARDO; M. ALUÍSIO, 2013) descrevendo o desempenho de classificação das polaridades das sentenças e opiniões sobre o ReLi. No artigo os autores utilizam o método proposto em (TABOADA et al., 2011), chamado “*Semantic Orientation Calculator – (SO-Cal)*”, que consiste em atribuir pesos, extraídos de dicionários, às palavras positivas e negativas (com sinal invertido), sendo a polaridade resultante o sinal da soma dos pesos atribuídos. O objetivo era comparar o desempenho do dicionário LWIC<sup>65</sup>, desenvolvido a partir do trabalho de (PENNEBAKER, 2011). A comparação é realizada com dois outros dicionários: o “SentiLex” (SILVA; CARVALHO; SARMENTO, 2012) e o “Opinion Lexicon” (SOUZA et al., 2011). Os autores concluem que tanto em nível de opinião como em nível de sentença o resultado alcançado com o “*SO-Cal*” utilizando o “*LWIC*” foi o melhor para a polaridade positiva (medida F1 de 70,37% em opiniões e medida F1 de 74,48% em sentenças) enquanto o SentiLex foi o melhor para a polaridade negativa (medida F1 de 60,25% em opiniões e medida F1 de 47,28% em sentenças). Os autores consideraram as sentenças neutras no cálculo, entretanto omitiram<sup>66</sup> seu desempenho nos resultados. Não obstante calcularam a acurácia do classificador para opinião e sentença conforme discriminadas nas tabelas 6.1 e 6.2 respectivamente.

64 Fornecedores do eBay com avaliação neutra.

65 <http://www.liwc.net/>

66 Palavra utilizada pelos autores no artigo.

Tabela 6.1: Acurácia do LIWC em nível de opinião

Léxico	Acurácia
LIWC	52,02%
Opinion Lexicon	50,53%
SentiLex	53,35%

Tabela 6.2: Acurácia do LIWC em nível de sentença

Léxico	Acurácia
LIWC	57,33%
Opinion Lexicon	47,42%
SentiLex	44,17%

Esse trabalho serve parcialmente como referência para comparação por três razões. A primeira consiste no fato da omissão das sentenças neutras que constituem 70% do corpus. A segunda decorre do objetivo dos autores que consistia em medir o desempenho do LIWC em português, objetivo diferente do proposto nessa pesquisa, que consiste em uma estratégia de classificação. Terceira razão consiste na metodologia, pois como não há aprendizado de máquina (os três dicionários são dados) os autores não precisaram construir um modelo que generalizasse independentemente da base de desenvolvimento.

#### 6.4 O classificador de referência

O ReLi foi submetido a cinco classificadores. Foram eles o SVM com “kernel” linear e quadrático, rede Bayesiana ingênua (NB), perceptron e árvore de decisão C4.5. Como atributos foram utilizadas as frequências para todas as palavras - “*bag of words (BoW)*”. Cada sentença foi vetorizada conforme a tupla  $\langle BoW, Polaridade \rangle$ , sendo a polaridade aquela anotada no ReLi. Na figura 6.8 estão os resultados obtidos.

Características dos Dados Classificados		Características dos Algoritmos		Característica dos Resultados			
Escritor	Polaridade	Tipo	Kernel	P	R	F	Acurácia
Todos	positivo	SVM	Linear	0,7066	0,4937	0,5813	
Todos	negativo	SVM	Linear	0,5000	0,0270	0,0513	
Todos	neutro	SVM	Linear	0,8080	0,9372	0,8678	
<b>Todos</b>	<b>Total</b>			<b>0,7894</b>	<b>0,7894</b>	<b>0,7894</b>	<b>0,7894</b>
Todos	positivo	NB		0,0000	0,0000	0,0000	
Todos	negativo	NB		0,0000	0,0000	0,0000	
Todos	neutro	NB		0,7079	1,0000	0,8290	
<b>Todos</b>	<b>Total</b>			<b>0,7079</b>	<b>0,7079</b>	<b>0,7079</b>	<b>0,7079</b>
Todos	positivo	Perceptron		0,5181	0,7782	0,6221	
Todos	negativo	Perceptron		0,5000	0,0270	0,0513	
Todos	neutro	Perceptron		0,8818	0,7698	0,8220	
<b>Todos</b>	<b>Total</b>			<b>0,7429</b>	<b>0,7429</b>	<b>0,7429</b>	<b>0,7429</b>
Todos	positivo	C45		0,0000	0,0000	0,0000	
Todos	negativo	C45		0,0000	0,0000	0,0000	
Todos	neutro	C45		0,7079	1,0000	0,8290	
<b>Todos</b>	<b>Total</b>			<b>0,7079</b>	<b>0,7079</b>	<b>0,7079</b>	<b>0,7079</b>
Todos	positivo	SVM	Quadrático	0,6462	0,5272	0,5806	
Todos	negativo	SVM	Quadrático	0,4286	0,0811	0,1364	
Todos	neutro	SVM	Quadrático	0,8210	0,9118	0,8640	
<b>Todos</b>	<b>Total</b>			<b>0,7820</b>	<b>0,7820</b>	<b>0,7820</b>	<b>0,7820</b>

Figura 6.8: Resultados para classificação de referência

Nesse experimento a validação cruzada “10-fold” foi efetuada em todo o corpus, diferentemente dos demais experimentos, onde não foi reservado um subconjunto somente para o teste. Essa decisão foi tomada, pois se procurava por uma referência para toda a base.

A razão pela qual a precisão, cobertura e acurácia total dos cinco classificadores serem iguais consiste no fato de todas as sentenças do corpus terem sido encontradas e rotuladas.

Analisando os resultados da figura 6.8 observa-se que os classificadores rede Bayesiana ingênua (NB) e árvore de decisão C4.5 (C45) classificaram todas as sentenças como neutras e por isso foram descartados. O classificador perceptron obteve a melhor medida F1 para as sentenças positivas (0,6221). O SVM com “kernel” quadrático obteve o melhor desempenho na polaridade negativa (F1 = 0,1364) e o SVM com “kernel” linear obteve o melhor desempenho nas sentenças neutras (F1 = 0,8678). Por modelar melhor as características do ReLi, conclusão apenas baseada na maior acurácia (0,7894), foi escolhido o SVM com “kernel” linear como referência para o desempenho da proposta dessa tese.

## 6.5 Desempenho do modelo de emoção

Como visto na seção 5.1 o modelo de emoção será constituído das melhores

palavras que caracterizam as sentenças positivas, negativas e neutras. A proposta da tese é caracterizar as melhores palavras como aquelas que maximizem o desempenho do classificador. Seguindo (MANNING; SCHUETZE, 1999) serão escolhidas aquelas com maior valor do LLR.

Enquanto em (DUNNING, 1993) há a comparação do LLR com o  $X^2$ , comprovando o ganho de desempenho do LLR em matrizes esparsas, resolveu-se adicionar a medida de informação mútua  $I(X; Y)$ , outro teste de independência utilizado em linguística computacional (MANNING; SCHUETZE, 1999).

O experimento consistiu em calcular os escore LLR,  $X^2$  e  $I$  para verificar a dependência entre polaridade e palavras. Os resultados, que estão na mesma escala ( $-2 \log \lambda$ ), foram ordenados de forma decrescente em três listas, uma para cada polaridade. O número de atributos passados para o modelo de emoção (SVM) consistiu em um percentual do número de palavras destas listas. O gráfico da figura 6.9 mostra a medida F1 do desempenho do modelo na base de teste, variando de acordo com o percentual de palavras passadas para compô-lo. Tanto as palavras que compõem as listas como o próprio treinamento do classificador ocorreu na base de desenvolvimento.

A conclusão de (DUNNING, 1993) é válida no ReLi. O LLR tem desempenho melhor do que o  $X^2$ . Entretanto o teste de informação mutua teve desempenho equivalente, embora menor do que o LLR a partir dos 22%. Por essa razão foi escolhida a lista de palavras geradas pelo LLR para compor o modelo de emoção.

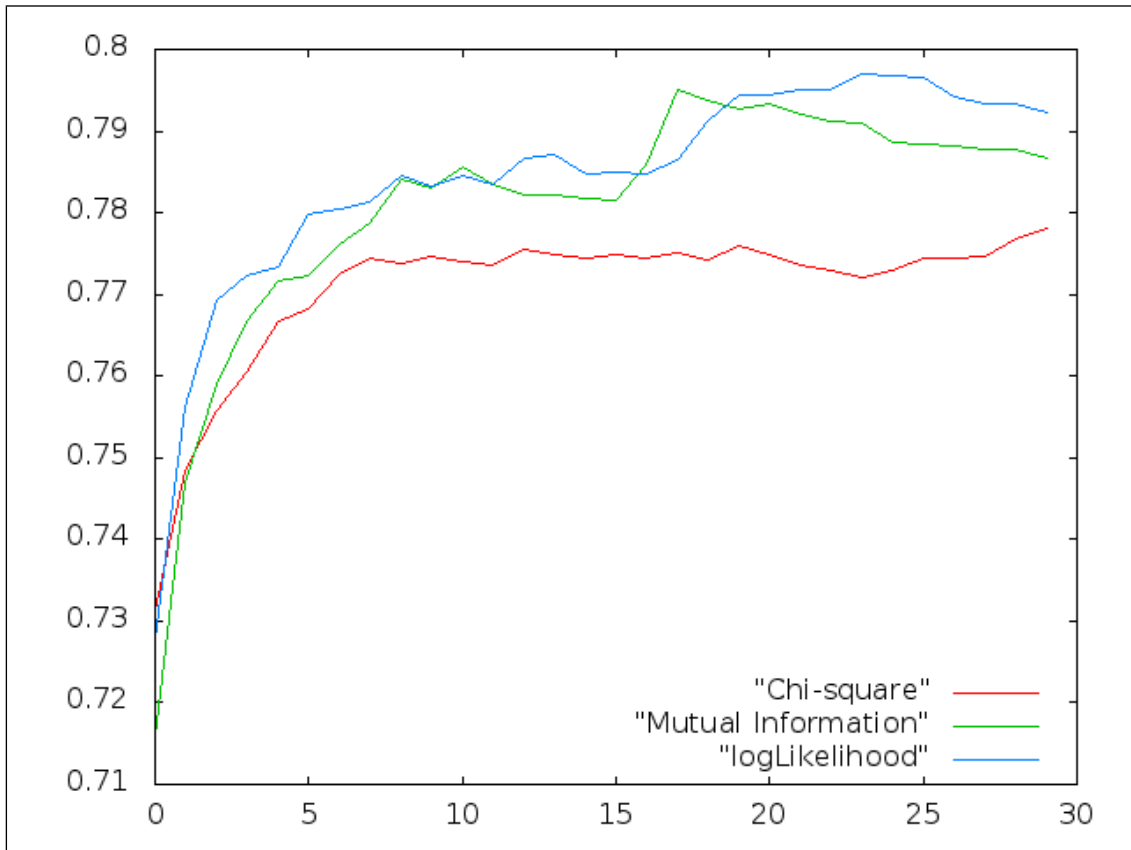


Figura 6.9: Comparação do desempenho do modelo de emoção de acordo com teste de independência

Com os resultados descritos acima o modelo de emoção ficou constituído de 2.586 palavras (algumas listadas na figura 5.1) de um total aproximado de 15.000 no ReLi, aumentando o desempenho do classificador e diminuindo o tempo de treinamento e classificação.

A atualização dos valores encontrados no experimento descrito na seção 6.4 depois de selecionados os atributos com o LLR estão na figura 6.10 (base de desenvolvimento) e na figura 6.11 (base de teste).

Características dos Dados Classificados		Características dos Algoritmos		Característica dos Resultados			
Escritor	Polaridade	Tipo	Kernel	P	R	F	Acurácia
Todos	positivo	SVM	Linear	0,6609	0,5869	0,6211	
Todos	negativo	SVM	Linear	0,6891	0,3308	0,4433	
Todos	neutro	SVM	Linear	0,8380	0,9017	0,8687	
<b>Todos</b>	<b>Total</b>			<b>0,7959</b>	<b>0,7959</b>	<b>0,7959</b>	<b>0,7959</b>

Figura 6.10: Resultados do ME com atributos selecionados pelo LLR

Esse modelo consiste em uma evolução de desempenho relativo ao modelo de

referência. Com as palavras que melhor classificam as sentenças por polaridade o modelo de emoção alcança uma acurácia de 0,7959 contra a acurácia 0,7894 do SVM com BoW. A medida F1 também aumenta para todas as polaridades.

No APÊNDICE L encontra-se o desempenho desse modelo discriminado por autor.

Entretanto, segundo a metodologia descrita na seção 6.1, os resultados válidos para o experimento são aqueles obtidos na base de teste. Esses se encontram na figura 6.11.

Características dos Dados Classificados		Características dos Algoritmos		Característica dos Resultados			
Escritor	Polaridade	Tipo	Kernel	P	R	F	Acurácia
Todos	positivo	SVM	Linear	0,7133	0,5602	0,6276	
Todos	negativo	SVM	Linear	0,4545	0,1163	0,1852	
Todos	neutro	SVM	Linear	0,8043	0,9256	0,8607	
<b>Todos</b>	<b>Total</b>			<b>0,7799</b>	<b>0,7799</b>	<b>0,7799</b>	<b>0,7799</b>

Figura 6.11: Resultado do ME

A queda observada na acurácia, de 0,7959 (base de desenvolvimento) para 0,7799 (base de teste) era esperada. Observa-se, no entanto, um inesperado aumento da medida F1 para sentenças positivas (de 0,6211 em desenvolvimento para 0,6276 em teste). Atribuiu-se esse fato a uma particularidade dessa base de teste, cujas sentenças foram selecionadas aleatoriamente. Em outra seleção esse fato pode não se repetir, enquanto o comportamento da acurácia deve permanecer inalterado.

## 6.6 Desempenho do modelo linguístico emocional (MLE)

A extração da informação consiste em uma série de tarefas (ver seção 3.8) implementadas como uma sequência de transdutores conforme mostra a figura 1.1. Nessa seção serão tratados os transdutores “extração de padrão”, que nessa tese consiste no extrator dos grupos avaliativos. Esse processo está ilustrado na figura 6.12. A atividade “Treino dos Modelos” foi desmembrada na sequência de atividades, que começa com “Encontrar Clusters” e termina com “HMM por polaridade” (sequência inferior na figura), retornando então à tarefa desmembrada. Essa segue para a tarefa “Aplicação base de teste” que conclui o processo.

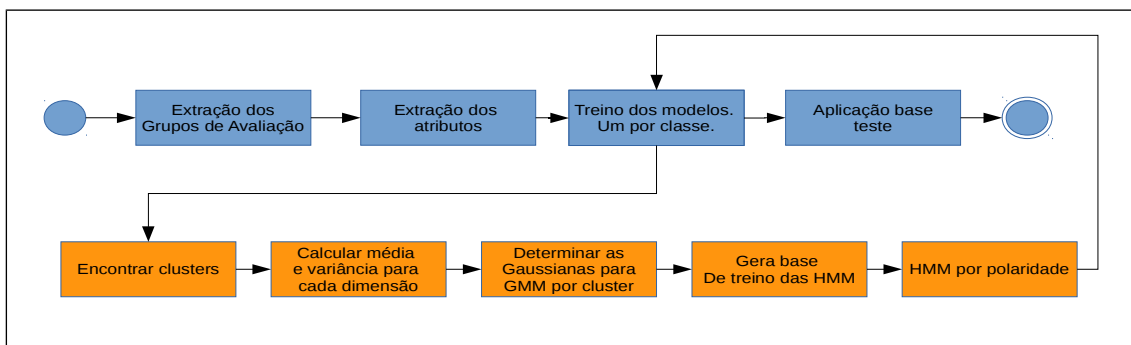


Figura 6.12: Processo para a extração dos grupos avaliativos

### 6.6.1 A extração dos grupos avaliativos

Na figura 6.13 as tarefas de extração dos grupos avaliativos e de seus atributos são ilustradas, utilizando uma abstração que permite melhor compreensão das entradas e saídas de cada etapa. Parte da camada “texto” até chegar nos atributos do grupo avaliativo que são os símbolos emitidos pelos estados ocultos da HMM.

Muitos dos preprocessamentos necessários à extração dos grupos avaliativos já estão anotados no ReLi e foram aproveitados no experimento. São eles:

- Tokenização: consiste na divisão do texto em sua menor unidade que são os “tokens”. Esses na sua maioria são palavras, mas também datas, números e URIs;

- Segmentação de sentenças: consiste na identificação do início e do fim de uma sentença;
- Rotulação da classe gramatical das palavras (POS)<sup>67</sup>: consiste em associar a cada palavra um rótulo com sua classe gramatical.

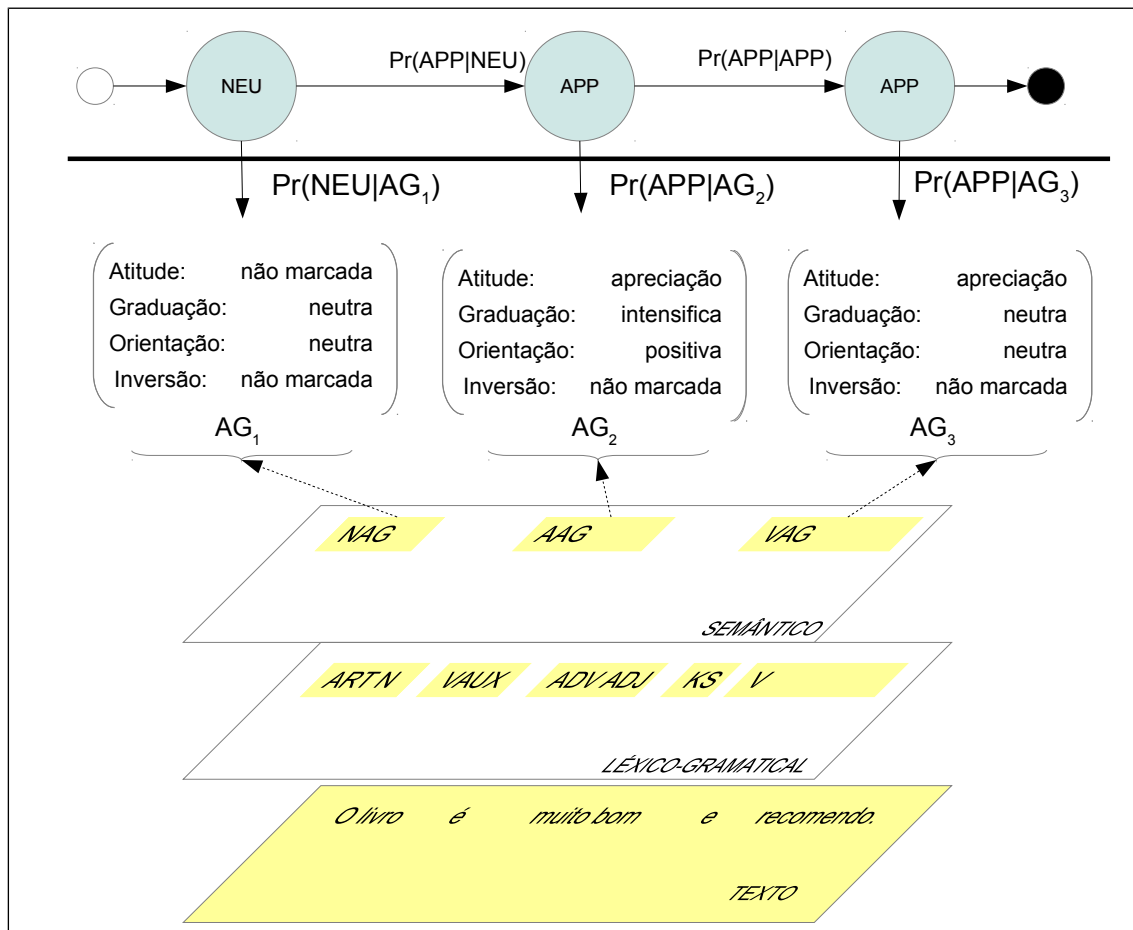


Figura 6.13: Entradas e saídas do processo de extração de grupos avaliativos.

Por essa razão não foi necessário desenvolver e avaliar esses transdutores.

Partindo do texto, já dividido em “tokens” e segmentado em sentenças (camada inferior da figura 6.13), segue-se para a camada léxico gramatical. Nessa camada, com as classes gramaticais já atribuídas no ReLi, há um agrupamento de sequência das palavras conforme a definição de grupos avaliativos (ver seção 5.6). Esse agrupamento é chamado a “Grupo Avaliativo Candidato”. No exemplo da figura “O livro”, “muito bom” e “recomendo” são grupos avaliativos candidatos.

<sup>67</sup> Acrônimo para “Part of Speech”



Essas regras foram extraídas observando as sequências de classes gramaticais das opiniões anotadas no ReLi, em adição à definição de grupos avaliativos, dadas as diversas escolhas utilizadas na produção de texto avaliativo em português, e descritas utilizando o formalismo JAPE do GATE. Tanto o GATE quanto JAPE estão descritos no apêndice E<sup>68</sup>. Essas regras estão listadas no apêndice F.

Um grupo avaliativo candidato é rotulado como grupo avaliativo se, pelo menos, um dos atributos do conjunto “Linguagem Avaliativa” ou “Modelo OCC” (ver na figura 5.17) não estiver vazio ou que a maior informação mútua entre I(Palavra;Positivo), I(Palavra;Negativo), I(Palavra;Neutro) não seja a neutra. Na figura 6.14 estão os grupos avaliativos candidatos anotados (em azul) e na figura 6.15 estão os grupos avaliativos resultantes (em vermelho). As duas figuras foram extraídas do corpus de desenvolvimento do GATE<sup>69</sup>.

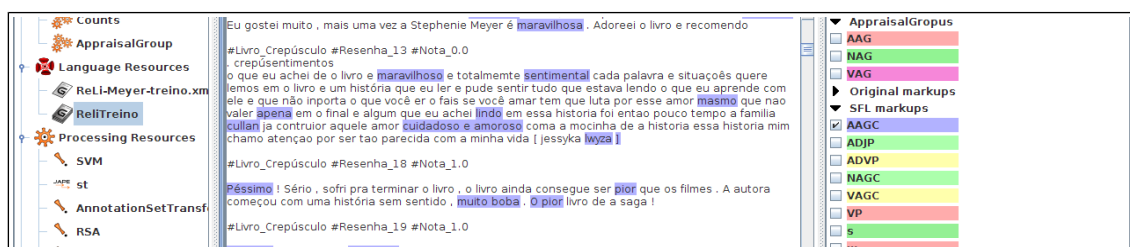


Figura 6.14: Grupos avaliativos candidatos anotados

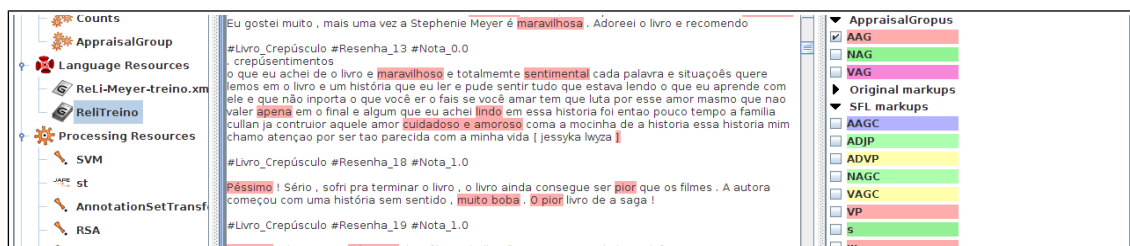


Figura 6.15: Grupos avaliativos anotados.

Nesse momento o processo está na camada semântica e os atributos dos grupos avaliativos calculados. Cada conjunto de atributos atua como manifestação observável de um estado emocional oculto (na figura 6.15 esses estados são “NEU” e “APP”).

Na fase de desenvolvimento dos modelos esses atributos treinam o classificador HMM, cuja descrição está no apêndice G<sup>70</sup>, e na fase de teste funcionam para o HMM calcular a probabilidade dessa sequência de observação emergir de um modelo de

68 O Gate foi utilizado em minha dissertação de mestrado e o texto desse apêndice foi dela extraído.

69 Nas figuras se observa à esquerda o recurso linguístico “ReLiTreino” destacado.

70 HMM foi vista na tese de mestrado e o texto do apêndice foi dela extraído.

polaridade positiva, negativa ou neutra.

Na figura 6.16 contém um exemplo dos atributos de um grupo avaliativo candidato que não foi considerado grupo avaliativo e na figura 6.17 de outro que foi.

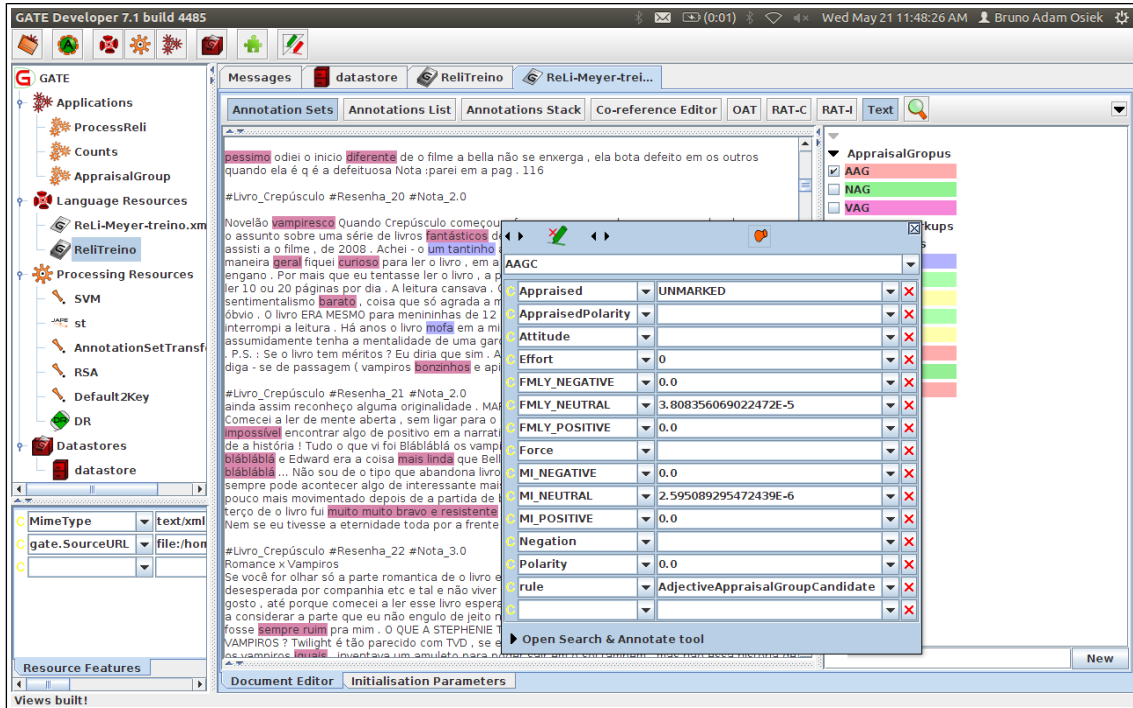


Figura 6.16: Atributos de um grupo avaliativo candidato não considerado grupo avaliativo.

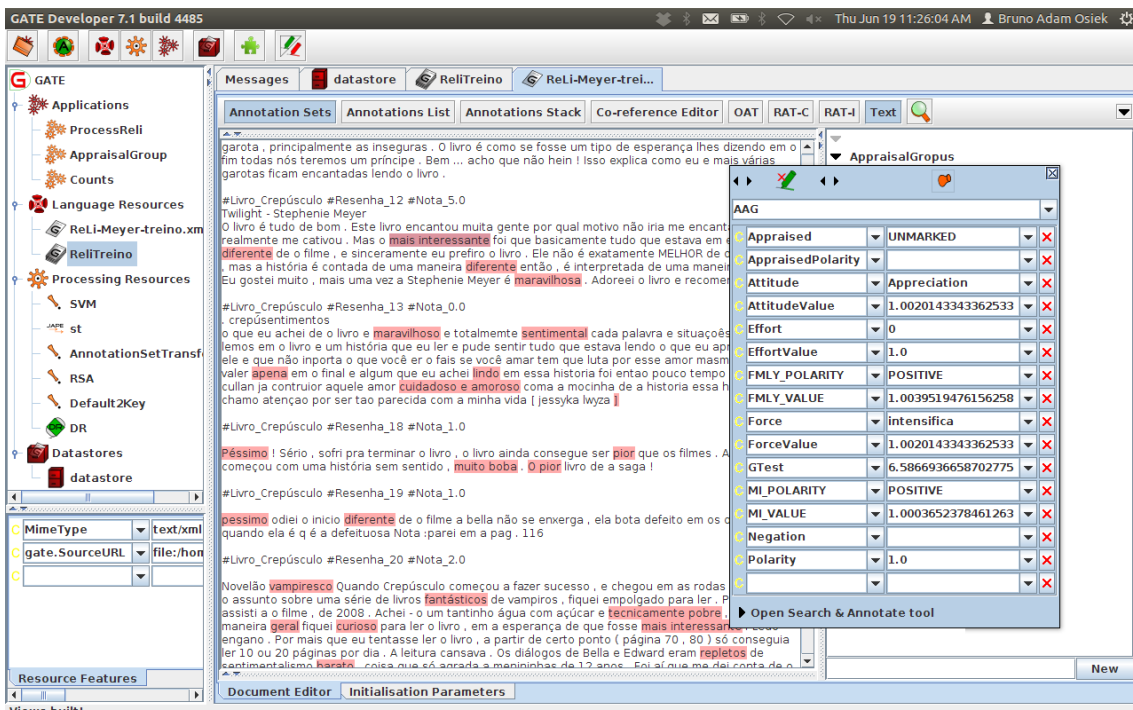


Figura 6.17: Atributos do grupo avaliativo "mais interessante"

## 6.6.2 Treino do Modelo Linguístico Emocional

O desafio para treinar o modelo linguístico emocional consistiu na inexistência de um corpus de desenvolvimento anotado com os estados emocionais propostos a luz do alinhamento entre as teorias de avaliação linguagem avaliativa e o modelo OCC proposto nessa tese.

Dada a dificuldade para o próprio agente humano em identificar e anotar a emoção sentida por uma pessoa tendo como evidência o texto (STRAPPARAVA; MIHALCEA, 2007) e, adicionalmente, o próprio custo de treinar pessoas para atuarem como anotadores, foi descartada essa atividade.

A solução foi adaptar a proposta utilizada para o reconhecimento de fala<sup>71</sup> descrita em (JURAFSKY; MARTIN, 2008) que utiliza HMM para o modelo acústico. A adaptação consiste na substituição do vetor de atributos “Mel Frequency Cepstral Coefficients” (MFCC) pela vetorização dos atributos dos grupos avaliativos (seção 5.7).

No reconhecimento de fala cada palavra consiste em um HMM. No modelo linguístico emocional cada polaridade constituirá um HMM.

O algoritmo de treino do HMM consiste no mesmo Baum & Welch (descrito no apêndice G), substituindo a função de emissão de símbolos por uma função de gaussianas multivariadas. Assim a probabilidade  $\bar{b}_{s_i s_j k_m}$  passa para:

$$b_j(k_m) = \prod_{d=1}^D \frac{1}{\sqrt{2\pi}\sigma_{jd}} \exp\left(-\frac{1}{2} \left[ \frac{(o_{md} - \mu_{jd})^2}{\sigma_{jd}^2} \right]\right)$$

Nessa equação  $\sigma_{jd}^2$  e  $\mu_{jd}$  são respectivamente a variância e a média de cada atributo do grupo avaliativo  $d$  para o estado emocional  $j$ .  $D$  Consiste no número de dimensões do grupo avaliativo.

A média é dada por:

---

71 Do inglês “Speech Recognition”

$$\hat{\mu}_j = \frac{\sum_{t=1}^T a_{s_{jt}} o_t}{\sum_{t=1}^T a_{s_{jt}}}$$

Nessa equação  $a_{s_{jt}}$  consiste na probabilidade de se estar no estado emocional  $j$  no momento  $t$ , que é a posição do grupo avaliativo na sequência.

A variância é dada por:

$$\hat{\sigma}_j^2 = \frac{\sum_{t=1}^T a_{s_{jt}} (o_t - \mu_j)(o_t - \mu_j)^T}{\sum_{t=1}^T a_{s_{jt}}}$$

Para iniciar o modelo assumiu-se uma distribuição uniforme entre o estado inicial  $\pi$  e os estados emocionais. Também assumiu-se uma distribuição uniforme para inicializar a matriz de transição de estados  $A$ .

Ao se implementar a função de emissão de símbolos como uma função de gaussianas multivariadas o resultado da probabilidade de uma observação (apêndice G.2.2) não é uma probabilidade, mas uma pdf<sup>72</sup> em  $\mathcal{R}$ .

A probabilidade de uma sequência de observações foi calculada normalizando-se a pdf resultante de cada modelo.

### 6.6.2.1 Normalização

Antes de qualquer processamento foi necessário normalizar cada vetor dos grupos avaliativos. Essa normalização é necessária, pois os atributos têm escalas distintas. Foram testadas a norma euclidiana e a norma Manhattan (norma  $L_1$ ). A última acabou sendo aquela que apresentou o melhor resultado e por isso a utilizada. Essa é definida como:

$$\|\vec{x}\|_1 = \sum_i |x_i|$$

---

<sup>72</sup> “Probability Density Function” (PDF)

### 6.6.2.2 Inicialização da matriz de emissão de símbolo $B$

Cada polaridade tem um HMM. Cada grupo avaliativo tem seus atributos. Cada sentença é representada por uma sequência de grupos de atributos. No corpus de desenvolvimento essas sequências foram agrupadas de acordo com a polaridade anotada, resultando em três conjuntos. Cada conjunto serviu para treinar os três modelos.

Cada conjunto, por sua vez, foi agrupado em 7 subconjuntos utilizando o algoritmo *K-Means* (distância Euclidiana), onde cada um desses sete subconjuntos representam os estados emocionais propostos (seis) mais o estado neutro. Uma vez agrupados foram encontrados o vetor média e a matriz de covariância para cada um desses subconjuntos. Esses, vetor e matriz, foram utilizados para iniciar a matriz de emissão de símbolos  $B$ .

### 6.6.2.3 Os resultados do MLE

Para a implementação do MLE com HMM foram utilizadas as bibliotecas JAHMM<sup>73</sup>. Com essas bibliotecas não foi possível iniciar os modelos com mais do que três estados, pois apresentavam erro<sup>74</sup>. Contactando o grupo de discussão que suporta a utilização dessas bibliotecas duas razões foram apontadas. A primeira consistia em uma base pequena para o número de estados e número de atributos do vetor. A segunda razão consistiu em utilizar vetores não normalizados.

Por não ser possível aumentar o corpus a alternativa foi diminuir o número de atributos ou o número de estados.

Optou-se pela redução do número de estados, pois, baseado na própria definição no modelo OCC, sentimento consiste em um estado emocional não diferenciado.

Cada sentença foi submetida aos três modelos. A probabilidade de cada modelo foi computada utilizando o algoritmo progressivo (ver apêndice G). Foi atribuída a polaridade do HMM com maior probabilidade.

A matriz de confusão desse classificador na base de teste encontra-se na figura 6.18.

---

<sup>73</sup> <https://code.google.com/p/jahmm/wiki/Overview>

<sup>74</sup> Matriz de covariância tinha autovalores iguais ou menor do que zero.

	Modelo MLE		
	Positivo	Negativo	Neutro
Positivo	140	15	36
Negativo	13	28	2
Neutro	110	39	335

Figura 6.18: Matriz de confusão do MLE

Seu desempenho utilizando precisão, cobertura, Medida F1 e acurácia está na figura 6.19

Características dos Dados Classificados		Características dos Algoritmos		Característica dos Resultados			
Escritor	Polaridade	Tipo	Kernel	P	R	F	Acurácia
Todos	positivo	HMM		0,5551	0,7644	0,6432	
Todos	negativo	HMM		0,3415	0,6512	0,4480	
Todos	neutro	HMM		0,8981	0,6921	0,7818	
<b>Todos</b>	<b>Total</b>			<b>0,7006</b>	<b>0,7006</b>	<b>0,7006</b>	<b>0,7006</b>

Figura 6.19: Resultado do MLE

## 6.7 O desempenho do reconhecedor de emoção

O cálculo da emoção está descrito na fórmula 2. Para cada sentença os modelos ME e MLE computaram a probabilidade de cada polaridade. No reconhecedor essas probabilidades foram multiplicadas e a polaridade da sentença foi aquela cujo argumento da multiplicação foi o maior.

O modelo MLE resulta da multiplicação de uma sequência de estados derivados de um vetor com baixa probabilidade de ser repetido. Entretanto o número de estados foi reduzido. O resultado disso é que a diferença entre a maior probabilidade e a menor é pequena. Na figura 6.20 se observa que a média das máximas, ou seja, a polaridade considerada correta pelo modelo, é de 0,3610 enquanto a mínima é de 0,3092. No modelo ME as respectivas médias são 0,9013 e 0,1021. Por isso a “certeza” do modelo ME, mesmo quando erra, é grande. Já a certeza do modelo MLE, mesmo quando acerta, é pequena. Essas “certezas” são relativas às demais probabilidades. Adicionalmente a isso, dada as diferenças entre as máximas, a probabilidade do modelo ME domina o canal, diminuindo o efeito do modelo MLE (verossimilhança).

	ME		MLE
	Média	$\lambda=0.1$	Média
Máxima	0.9013	0.9897	0.3610
Não máxima	0.5835	0.9476	0.3286
Não máxima	0.1021	0.7960	0.3092

Figura 6.20: Distribuição das probabilidades das polaridades dos modelos ME e MLE

Para atenuar esse efeito, adaptou-se a proposta de (JURAFSKY; MARTIN, 2008), onde se equilibram essas probabilidades atribuindo um peso  $\lambda$  à probabilidade do modelo a priori. Os autores por terem as probabilidades do modelo de verossimilhança subestimadas procuraram diminuir a probabilidade do modelo a priori. Assim variaram o atenuador no intervalo  $\lambda \geq 1$ . Aqui procurou-se equilibrar a certeza dos modelos. Para isso o atenuador variou no intervalo  $0 < \lambda < 1$ .

Assim a fórmula 2 é reescrita como:

$$E' = \underset{E \in \epsilon}{\operatorname{argmax}} \underbrace{P(M'|E)}_{MLE} \times \underbrace{P(E)^\lambda}_{ME}$$

Equação 6.1: Reconhecedor de ruído com ME atenuado

O valor de  $\lambda=0,1$  foi calculado variando-o conforme o gráfico na figura 6.21, e calculando a maior medida F1 do RS, levando às médias do modelo ME descritas na figura 6.20. Com essa adaptação se diminuiu o efeito da dominância do modelo ME sobre o modelo MLE.

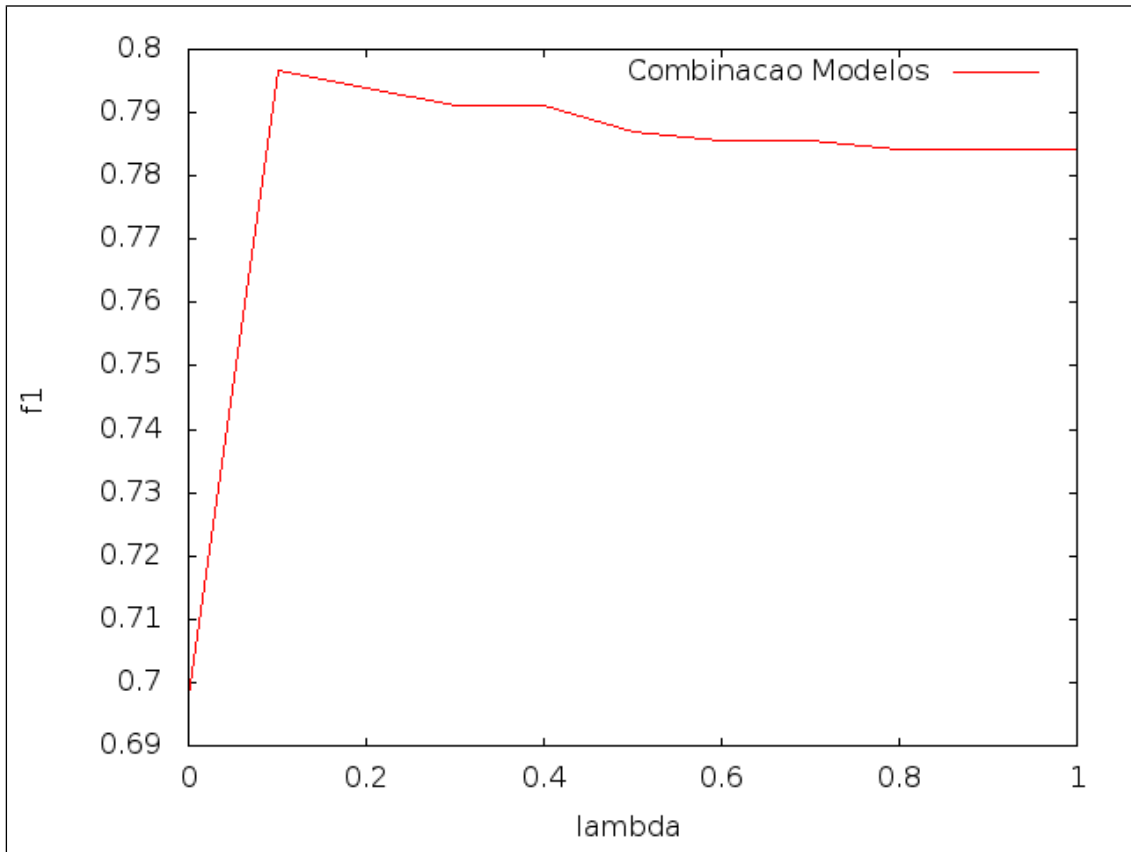


Figura 6.21: Desempenho do reconhecedor de emoção variando lambda

A matriz de confusão na base de teste do reconhecedor de sentimento encontra-se na figura 6.22.

	Reconhecedor de Sentimento		
	Positivo	Negativo	Neutro
Positivo	122	3	66
Negativo	9	19	15
Neutro	44	9	431

Figura 6.22: Matriz de confusão para o reconhecedor de sentimento

O desempenho final do RS se encontra na figura 6.23.



Características dos Dados Classificados		Características dos Algoritmos		Característica dos Resultados			
Escritor	Polaridade	Tipo	Kernel	P	R	F	Acurácia
Todos	positivo	HMM x SVM		0,6971	0,6387	0,6667	
Todos	negativo	HMM x SVM		0,6129	0,4419	0,5135	
Todos	neutro	HMM x SVM		0,8418	0,8905	0,8655	
<b>Todos</b>	<b>Total</b>			<b>0,7967</b>	<b>0,7967</b>	<b>0,7967</b>	<b>0,7967</b>

Figura 6.23: Desempenho do RE

## 6.8 Avaliação

Na figura 6.24 se ilustra o desempenho do reconhecedor de sentimento.

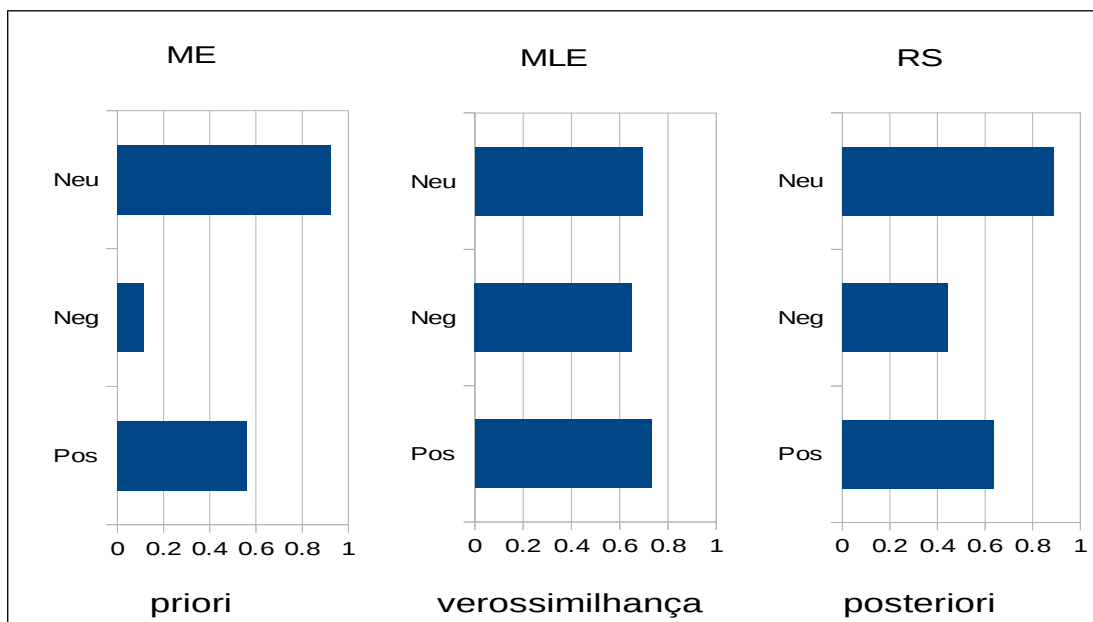


Figura 6.24: Efeito do MLE sobre o ME na classificação

Comparando a classificação a priori com a posteriori pode se perceber o efeito desejado do MLE na classificação das classes positiva e negativa. A variação percentual está na figura 6.25.

	ME	MLE	RS	Varição
Positiva	107	140	122	1,14
Negativa	5	28	19	3,80
Neutra	448	335	431	0,96

Figura 6.25: Variação entre os modelos ME e RS

O desempenho da função de agregação (função de máximo) foi positivo para as classes positiva e negativa enquanto gerou um pequeno decréscimo na classe neutra. O incremento total na acurácia entre o ME e o RS foi de 1,6%.

Em termos de medida F1 e acurácia o reconhecedor de sentimento tem seu desempenho resumido na figura 6.26.

	MEDIDA F1		
	ME	MLE	RS
Positiva	0,6276	0,6432	0,6667
Negativa	0,1852	0,4480	0,5135
Neutra	0,8607	0,7818	0,8655
<b>Acurácia</b>	<b>0,7799</b>	<b>0,7006</b>	<b>0,7967</b>

Figura 6.26: Resumo desempenho de acurácia e medida F1

	Características dos Dados Classificados		Características dos Algoritmos		Característica dos Resultados			
	Escritor	Polaridade	Tipo	Kernel	P	R	F	Acurácia
LIWC	Todos	positivo	SO-Cal		0,8642	0,6543	<b>0,7448</b>	
	Todos	negativo	SO-Cal		0,4006	0,2266	0,2895	
	Todos	neutro			N/A	N/A	N/A	
	<b>Todos</b>	<b>Total</b>			N/A	N/A	N/A	<b>0,5733</b>
RS	Todos	positivo	HMM x SVM		0,6971	0,6387	0,6667	
	Todos	negativo	HMM x SVM		0,6129	0,4419	<b>0,5135</b>	
	Todos	neutro	HMM x SVM		0,8418	0,8905	<b>0,8655</b>	
	<b>Todos</b>	<b>Total</b>			<b>0,7967</b>	<b>0,7967</b>	<b>0,7967</b>	<b>0,7967</b>

Figura 6.27: Comparação LIWC/SO-Cal com RS

Na figura 6.27 está uma comparação entre o desempenho reportado em (BALAGE FILHO; ALEXANDRE SALGUEIRO PARDO; M. ALUÍSIO, 2013) sobre o ReLi e o alcançado pelo RS. Enquanto o RS tem melhor desempenho em sentenças neutras e negativas e na acurácia total o reportado tem o mérito de apresentar melhor desempenho em sentenças positivas. Entretanto o RS consiste em um classificador probabilístico cujo desempenho aumenta com a quantidade de entradas na base de desenvolvimento. No RS se observa que a medida F1 cresce na medida em que o número de observações aumenta ( $F1(\text{negativa}) < F1(\text{positiva}) < F1(\text{neutra})$ ).

Existem espaços para aprimoramentos e a função de agregação entre os modelos ME e MLE consiste em um. O primeiro tem desempenho melhor nas sentenças neutras enquanto o segundo tem desempenho melhor em sentenças com polaridade.

Seja pelo tamanho da base ou por ineficiência das bibliotecas utilizadas para implementar o modelo MLE, não foi possível implementar os seis estados emocionais previstos. Chegar a essa granularidade consiste em outra melhoria. Na figura 6.28 observa-se o aumento do desempenho do RS com o aumento do número de estados no modelo MLE.




Figura 6.28: Comparação de desempenho variando o número de estados do modelo MLE

Uma comparação do desempenho do modelo MLE com 2 e 3 estados encontra-se na figura 6.29.

		Características dos Dados Classificados		Características dos Algoritmos		Característica dos Resultados			
		Escritor	Polaridade	Tipo	Kernel	P	R	F	Acurácia
2 ESTADOS	Todos	positivo		HMM		0,5552	0,8429	0,6694	
	Todos	negativo		HMM		0,4127	0,6047	0,4906	
	Todos	neutro		HMM		0,9178	0,6921	0,7892	
	<b>Todos</b>	<b>Total</b>				<b>0,7270</b>	<b>0,7270</b>	<b>0,7270</b>	<b>0,7270</b>
3 ESTADOS	Todos	positivo		HMM		0,5551	0,7644	0,6432	
	Todos	negativo		HMM		0,3415	0,6512	0,4480	
	Todos	neutro		HMM		0,8981	0,6921	0,7818	
	<b>Todos</b>	<b>Total</b>				<b>0,7006</b>	<b>0,7006</b>	<b>0,7006</b>	<b>0,7006</b>

Figura 6.29: Comparação do desempenho do modelo MLE com 2 e 3 estados

O atributo “intensidade da emoção” (ver seção 5.17) consiste no resultado das funções de desejabilidade (seção 5.2.1) ou de louvabilidade (seção 5.2.2) ou de atratividade (seção 5.2.3). Esse atributo, conforme definido, consistiu em uma combinação linear de suas respectivas parcelas. Portanto o modelo MLE foi implementado sem esse atributo. Essas funções foram inspiradas naquelas propostas no modelo OCC. Consiste em um trabalho futuro verificar como essas funções podem agregar no reconhecimento de emoções.

## 7 Conclusão e trabalhos futuros

Nessa tese foi proposta, implementada e avaliada uma nova abordagem para a análise de sentimento em texto. Reconhecimento de sentimento foi a expressão utilizada para referenciar essa nova abordagem, por entender que o processo de externalização de uma emoção sofre ruído ao ser modulado pelo autor em função do seu objetivo, do público-alvo e do canal de comunicação da mensagem.

O reconhecimento de sentimento é resolvido, adaptando o canal de ruído proposto por (SHANNON, 2001) para a transmissão de mensagens. Para isso foram desenvolvidos dois modelos.

O primeiro consiste no linguístico emocional (chamado de MLE), apoiado em (ORTONY; CLORE; COLLINS, 1988) e (MARTIN; WHITE, 2005) que calcula a verossimilhança de um texto (diretamente observado) dada a emoção subjacente (oculta). Esse modelo foi implementado utilizando HMM.

O segundo (modelo de emoção – ME) calcula a probabilidade a priori de uma emoção no texto, probabilidades computadas de um corpus anotado – o ReLi (FREITAS et al., 2012). O sentimento consiste no argumento da função de máximo, considerando três polaridades (positiva, negativa e neutra), entre a multiplicação das probabilidades dos dois modelos.

Os resultados alcançados (medidas F1 e acurácia 0,7966 contra a acurácia de 0,5733 obtida por (BALAGE FILHO; ALEXANDRE SALGUEIRO PARDO; M. ALUÍSIO, 2013) no mesmo corpus) mostram a eficiência dessa abordagem enquanto apontam novos caminhos para sua evolução como a implementação das funções de deseabilidade, louvabilidade e atratividade de outra forma que não a da função Gaussiana multivariada. Outra melhoria está na função de agregação entre os modelos de forma a ampliar o impacto do modelo MLE no reconhecedor de sentimento.

## 7.1 Resumo das contribuições originais

São nove o número de contribuições originais dessa pesquisa. Abaixo elas são discriminadas.

1. O modelo de externalização de sentimento através da linguagem (seção 4.2) e sua adaptação (seção 4.3) para que sua manifestação e comunicação em texto seja feita através do canal de ruído. Na literatura revisada o ruído e suas fontes geradoras são tratados no processo e meios de comunicação. Na psicologia, relevando a discussão de que não há consenso sobre o que seja uma emoção, essa foi tratada como uma reação com valência a um estímulo. Na teoria da avaliação em linguagem avaliativa, e na gramática sistêmica funcional da qual é derivada, viu-se que a produção de um discurso considera o seu contexto, agentes envolvidos e meio de troca da mensagem. Entretanto existe essa lacuna, ou seja, um modelo que trate a comunicação da emoção desde o momento em que é identificada pelo agente que a sentiu até o momento em que o agente alvo da comunicação a interpreta no texto para inferir a emoção original.
2. Com a contribuição anterior foi possível modelar a emoção a posteriori utilizando o canal de ruído de SHANNON (2001) como o argumento máximo da multiplicação de dois modelos. Um consiste na verosimilhança de um texto dado uma emoção, ou seja, um alinhamento entre texto e emoção subjacente. O outro consiste na emoção a priori, computada com o texto anotado. Essa contribuição está descrita na seção 4.3 e constitui-se na principal contribuição desse trabalho. Ou seja, considerar que a emoção sofre ruído ao seguir pelo canal de comunicação e que o tratamento desse ruído contribui para melhorar a classificação de textos avaliativos. Na literatura, independentemente de área de aplicação, as abordagens consistem em:
  - Uso de dicionários com polaridade das palavras normalmente associados a uma forma de calcular a polaridade composta;
  - Elaborar dicionários automaticamente de acordo com o contexto;
  - Escolha de atributos para treinar classificadores (os trabalhos se diferenciam na escolha dos atributos e dos classificadores); e

- Estratégia de classificação, sendo a mais comum dividi-la em duas: classificação de textos subjetivos (apoiada na existência de adjetivos); e nos textos subjetivos efetuar a classificação polar.
3. O uso da distância simétrica de “Kullback-Leibler” como métrica do modelo EPA (seção 3.3 e apêndice I.1) para a elaboração dos dicionários semânticos, ou seja, os dicionários que caracterizam polaridade e os sistemas de escolha. Essa distância é utilizada como atributo dos grupos avaliativos. A distância KL é utilizada na literatura como atributo em substituição, por exemplo, ao tf-idf. A originalidade foi estabelecer uma referência, ou origem<sup>75</sup>, da qual quanto mais afastada uma palavra estiver maior ou menor será seu significado semântico.
  4. O uso da métrica LLR para descobrir os atributos do modelo de emoção (ME) (seção 5.1). Na literatura o teste mais comum é o de Pearson ( $X^2$ ). Porém se observou que o LLR, como proposto por (DUNNING, 1993), apresentou melhor desempenho como mostra a seção 6.5. Na pesquisa realizada encontrou-se esse escore utilizado para a análise de sentimento em substituição ao tf-idf no modelo vetorial. Dado o tempo e a simplicidade do teste, causou surpresa não ter sido utilizado e explicitado na literatura anteriormente<sup>76</sup>.
  5. O modelo linguístico emocional (MLE) para traduzir a avaliação dos grupos avaliativos em estados emocionais (seção 5.2). Essa consiste na segunda principal contribuição desse trabalho. Nesse modelo foram combinadas técnicas de aprendizado de máquina com uma teoria cognitiva e outra linguística para o tratamento de avaliação, atribuindo a esse trabalho o atributo necessário para aproximá-lo do paradigma da computação afetiva. Uma abordagem diferente, porém que utilizou um modelo psicológico foi apresentada em (CAMBRIA; HUSSAIN, 2012), sendo que uma discussão do trabalho desses autores é apresentada na seção 3.5.1;
  6. Os atributos dos grupos avaliativos (seção 5.6). A originalidade está em duas dimensões: uma está na junção dos atributos propostos por (MARTIN; WHITE, 2005) com os atributos do modelo OCC conforme descritos na seção 5.7; e a segunda está no uso da distância KL como medida do atributo em detrimento de frequência das palavras no copus como em (WHITELAW; GARG; ARGAMON,

---

75 No sentido da mecânica newtoniana.

76 Não se descarta a hipótese de ter sido referenciado, mas as pesquisas efetuadas não trouxeram documentos com o LLR utilizado para esse fim em análise de sentimento.

2005) e (BLOOM; GARG; ARGAMON, 2007).

7. A probabilidade de um estado emocional emitir um grupo avaliativo implementada como uma função de gaussianas multivariadas (seção 6.6.2). No modelo OCC as funções de desejabilidade, louvabilidade e atratividade são resultantes da combinação de duas funções: uma que trata das variáveis globais e outra das variáveis locais. Entretanto o modelo não propõe a forma de agregar as duas. Os resultados alcançados pelo modelo MLE mostram a eficácia dessa proposta.
8. A utilização de HMM para a composição da sequência de estados emocionais foi proposta por (PICARD, 1995). O foco da autora era o desenvolvimento de agentes artificiais capazes de perceber ou simular emoções. Entretanto não foi encontrada na literatura uma proposta para o reconhecimento de sentimento, como um estado não diferenciado de emoção pelo modelo OCC, utilizando HMM.
9. O alinhamento entre a teoria de (MARTIN; WHITE, 2007) com a de (ORTONY; CLORE; COLLINS, 1988). Esse alinhamento proposto na seção 5.2 constitui no alicerce teórico para o modelo MLE. Ainda há poucos estudos publicados para o tratamento de texto considerando o modelos emocionais, em particular o OCC (HUANGFU et al., 2013) e esse alinhamento consiste em um esforço para ajudar a preencher essa lacuna.

## **7.2 Trabalhos futuros**

Uma evolução desse trabalho está na modificação do classificador que suporta o modelo ME. Em vez de utilizar o SVM a ideia consiste em processá-lo utilizando uma máquina de estado probabilística (por exemplo modelos de Markov). Para isso é necessário um corpus rotulado de acordo com os estados emocionais propostos e seus respectivos grupos avaliativos.

Com isso o modelo MLE rotularia a sequência de estados prováveis em uma sentença, através do algoritmo de Viterbi (seção G.2.3) (a verosimilhança) em vez de calcular a probabilidade de uma sequência de estados emergir de um modelo. O ME calcularia a probabilidade dessa sequência de estados emergir de um modelo neutro, positivo ou negativo (a probabilidade a priori).



O segundo trabalho futuro consiste em aplicar o reconhecedor de sentimento em outras bases. Os resultados alcançados foram sobre um corpus com número de sentenças neutras predominando sobre as demais. Interessante será constatar o desempenho da proposta dessa tese em bases equilibradas, ou seja, com número de entradas positivas, negativas e neutras parecidas ou desequilibradas em direção à polaridade positiva ou negativa. Esse seria o caso do corpus originado do trabalho de (CARVALHO et al., 2011). Em adição será interessante aplicar o RS em corpus com conteúdo em outros idiomas.

Um terceiro trabalho consiste em aumentar a granularidade das emoções hoje tratadas pelo reconhecedor de sentimento. O objetivo consiste em alcançar as 22 propostas no modelo OCC. Os trabalhos nessa área utilizam recursos de processamento natural não utilizados nessa tese, tais como: analisador sintático de texto e ConceptNet (LIU; SINGH, 2004). Tratar as 22 emoções requer, por exemplo, identificar se um evento já aconteceu ou se ainda está para concluir. Isso permitirá tratar emoções do tipo esperança. O tratamento de emoções compostas pelas vertentes “eventos” e “reação a agentes” como a emoção “agradecido” exigirá recursos como reconhecedor de entidades nomeadas e resolver um problema de sistemas de EI como “Detecção e Reconhecimento de Relação” visto na seção 3.8.

Um quarto trabalho consiste na utilização dos grupos avaliativos para a identificação da opinião e sua polaridade no texto. Delimitar com precisão onde começa e termina um texto com opinião consiste em um problema aberto. Nessa tese começou-se experimentos nesse sentido. A ideia consistiu em adaptar o uso de modelos de linguagem para encontrar tópicos novos<sup>77</sup> ao problema de identificar opinião. Por exemplo era esperado que sequências de palavras descrevendo opiniões positivas fossem diferentes daquelas que não as descrevem. Variando o número de palavras na sequência, chegou-se a uma alta cobertura (acima de 90%), entretanto com baixa precisão (em torno de 18%). Embora esses números não estejam muito desalinhados com o observado na literatura (WIEBE; WILSON; BELL, 2001), (KIM; HOVY, 2006) e (BLOOM, 2011) há espaço para evolução.

Uma quinta evolução consiste na identificação do avaliador. Exemplificando, essa pode ser do autor do texto ou de uma terceira pessoa que o autor referencia. Essa evolução passa pelo reconhecimento de entidades nomeadas e a elaboração ou utilização

---

<sup>77</sup> Tradução livre de “*trending topics*”

de alguma ontologia existente que descreva, por exemplo, um livro e seus constituintes. Entretanto observou-se que o LLR encontrou escore alto para objetos alvos da avaliação de um livro. Palavras como: livro, história e, personagem estão nesse conjunto, incluindo atribuições polares a elas. A palavra livro, por aparecer relativamente mais em contexto positivo do que negativo e neutro, constituiu num dos atributos do modelo ME. Substituindo a palavra livro por um produto pode-se atribuir uma opinião geral ao objeto avaliado.

Um sexto trabalho, de certa forma dependente dos dois anteriores, consiste na ligação de uma opinião ao seu alvo. Isso também está alinhado com a tarefa “Detecção e Reconhecimento de Relação” visto na seção 3.8.

Um sétimo trabalho consiste na utilização de gramáticas locais, como a descrita em (HUNSTON, 2012), para encontrar padrões que ocorrem com frequência em texto atribuindo a esses um papel semântico. Um exemplo seria padrão de comparação “A é melhor do que B”. Gramática local foi utilizada em (BLOOM, 2011) com resultados interessantes.

Um oitavo trabalho consiste na investigação do desempenho de um comitê de classificadores de forma a encontrar uma combinação entre os modelos ME e MLE que maximize seus respectivos desempenhos.

Em resumo, esse trabalho consiste no começo de um caminho e não no seu fim. Trata-se de um trabalho multidisciplinar envolvendo aprendizado de máquina, linguística e psicologia. O modelo linguístico emocional resulta do encontro dessas áreas. Sua evolução passa pela aproximação com pesquisas desenvolvidas nas disciplinas mencionadas<sup>78</sup>. Essa tese abre caminho para essa aproximação.

---

<sup>78</sup> Dada as evoluções em neurociência essa também deve ser foco de aproximação.

## 8 Referências Bibliográficas

- AIDS.gov Communication Strategy Internal Working Plan.** Disponível em: <[www.aids.gov/pdf/aidsgov-communication-plan-jan-2011.pdf](http://www.aids.gov/pdf/aidsgov-communication-plan-jan-2011.pdf)>. Acesso em: 17 jul. 2011.
- ALM, C. O.; ROTH, D.; SPROAT, R. **Emotions from Text: Machine Learning for Text-based Emotion Prediction** Proceedings of the Conference on Human Language Technology and Empirical Methods in Natural Language Processing. **Anais...**: HLT '05. Stroudsburg, PA, USA: Association for Computational Linguistics, 2005 Disponível em: <<http://dx.doi.org/10.3115/1220575.1220648>>. Acesso em: 30 abr. 2014
- ANACLETO, J. et al. Can Common Sense uncover cultural differences in computer applications? In: BRAMER, M. (Ed.). **Artificial Intelligence in Theory and Practice.** IFIP International Federation for Information Processing. [s.l.] Springer US, 2006. p. 1–10.
- AZEVEDO, F. **A comunicação do Governo Lula – o caso do Programa de Aceleração do Crescimento** Comunicação e Cidadania. **Anais...** In: ACTAS DO 50 CONGRESSO DA ASSOCIAÇÃO PORTUGUESA DE CIÊNCIAS DA COMUNICAÇÃO. Braga: Centro de Estudos de Comunicação e Sociedade (Universidade do Minho): Moisés de Lemos Martins & Manuel Pinto (Orgs.), Setembro 2007
- BAILLIE, P. **The synthesis of emotions in artificial intelligences: an affective agent architecture for intuitive reasoning in artificial intelligences.** Thesis (\_PhD/Research). Disponível em: <<http://eprints.usq.edu.au/1408/>>. Acesso em: 23 maio. 2011.
- BALAGE FILHO, P.; ALEXANDRE SALGUEIRO PARDO, T.; M. ALUÍSIO, S. **An Evaluation of the Brazilian Portuguese LIWC Dictionary for Sentiment Analysis** Proceedings of the 9th Brazilian Symposium in Information and Human Language Technology. **Anais...** 2013 Disponível em: <<http://aclweb.org/anthology/W13-4829>>
- BALAHUR, R.; MONTOTOYO, A. Applying a culture dependent emotion triggers database for text valence and emotion classification,” *Procesamiento del lenguaje natural*. p. 107–114, 2008.
- BANSAL, M.; CARDIE, C.; LEE, L. **The power of negative thinking: Exploiting label disagreement in the min-cut classification framework.** Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.147.1132>>. Acesso em: 15 set. 2011.
- BARBARA PFETSCH. Government news management strategic communication in comparative perspective. **WZB Publications**, 1999.
- BELLEGARDA, J. R. **Emotion analysis using latent affective folding and embedding** Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text. **Anais...**: CAAGET '10. Stroudsburg, PA, USA: Association for Computational Linguistics, 2010 Disponível em: <<http://dx.doi.org/10.3115/1220575.1220648>>. Acesso em: 30 abr. 2014

em: <<http://dl.acm.org/citation.cfm?id=1860631.1860632>>

BLEI, D. M.; NG, A. Y.; JORDAN, M. I. Latent dirichlet allocation. **J. Mach. Learn. Res.**, v. 3, p. 993–1022, mar. 2003.

BLOOM, K. **Sentiment analysis based on appraisal theory and functional local grammars**. annotated edition ed. [s.l.] ProQuest, UMI Dissertation Publishing, 2011.

BLOOM, K.; GARG, N.; ARGAMON, S. **Extracting Appraisal Expressions**. In: HUMAN LANGUAGE TECHNOLOGIES 2007: THE CONFERENCE OF THE NORTH AMERICAN CHAPTER OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS; PROCEEDINGS OF THE MAIN CONFERENCE. Association for Computational Linguistics, 2007Disponível em: <<http://www.aclweb.org/anthology/N/N07/N07-1039.pdf>>. Acesso em: 2 jun. 2013

CABRAL, L.; HORTAÇSU, A. **The Dynamics of Seller Reputation: Theory and Evidence from eBay**. [s.l.: s.n.]. Disponível em: <[http://pages.stern.nyu.edu/lcabral/workingpapers/CabralHortacsu\\_Mar06.pdf](http://pages.stern.nyu.edu/lcabral/workingpapers/CabralHortacsu_Mar06.pdf)>.

CAMBRIA, E. et al. Sentic Computing for social media marketing. **Multimedia Tools and Applications**, maio 2011.

CAMBRIA, E. et al. New Avenues in Opinion Mining and Sentiment Analysis. **IEEE Intelligent Systems**, v. 28, n. 2, p. 15–21, mar. 2013.

CAMBRIA, E.; HUSSAIN, A. **Sentic Computing: Techniques, Tools, and Applications**. 2012 edition ed. Dordrecht ; New York: Springer, 2012.

CAMBRIA, E.; LIVINGSTONE, A.; HUSSAIN, A. **The Hourglass of Emotions**Proceedings of the 2011 International Conference on Cognitive Behavioural Systems. **Anais...: COST'11**.Berlin, Heidelberg: Springer-Verlag, 2012Disponível em: <[http://dx.doi.org/10.1007/978-3-642-34584-5\\_11](http://dx.doi.org/10.1007/978-3-642-34584-5_11)>. Acesso em: 24 abr. 2014

CARDIE, C. et al. Combining Low-Level and Summary Representations of Opinions for Multi-Perspective Question Answering. **IN WORKING NOTES - NEW DIRECTIONS IN QUESTION ANSWERING (AAAI SPRING SYMPOSIUM SERIES)**, p. 20–27, 2003.

CARVALHO, P. et al. **Liars and Saviors in a Sentiment Annotated Corpus of Comments to Political Debates**Proceedings of the 49th Annual Meeting of the Association for Computational Linguistics: Human Language Technologies: Short Papers - Volume 2. **Anais...: HLT '11**.Stroudsburg, PA, USA: Association for Computational Linguistics, 2011Disponível em: <<http://dl.acm.org/citation.cfm?id=2002736.2002847>>. Acesso em: 28 abr. 2014

**CGI.br - Comitê Gestor da Internet no Brasil**. Disponível em: <<http://www.cgi.br/noticia/tic-domicilios-indica-que-31-da-populacao-brasileira-usa-internet-pelo-telefone-celular/10044>>. Acesso em: 7 jul. 2014.

CHEN, W. **Dimensions of Subjectivity in Natural Language**Proceedings of ACL-08: HLT, Short Papers. **Anais...**Association for Computational Linguistics, 2008Disponível em: <<http://www.aclweb.org/anthology-new/P/P08/P08-2004.bib>>. Acesso em: 20 set.

2011

CLYNES, M. **Sentics: the touch of emotions**. [s.l.] Anchor Press, 1977.

COMSCORE; THE KELSEY GROUP. **Online Consumer-Generated Reviews Have Significant Impact on Offline Purchase Behavior**. Press Release. Disponível em: <[http://www.comscore.com/Press\\_Events/Press\\_Releases/2007/11/Online\\_Consumer\\_Reviews\\_Impact\\_Offline\\_Purchasing\\_Behavior](http://www.comscore.com/Press_Events/Press_Releases/2007/11/Online_Consumer_Reviews_Impact_Offline_Purchasing_Behavior)>.

CONRAD, J. G.; SCHILDER, F. Opinion mining in legal blogs. **IN PROCEEDINGS OF THE 11TH INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND LAW (ICAIL07)**, p. 231–236, 2007.

CUNNINGHAM, H. et al. **Text Processing with GATE (Version 6)**. [s.l.: s.n.]. Disponível em: <<http://tinyurl.com/gatebook>>.

DAMASIO, A. **Descartes' Error: Emotion, Reason, and the Human Brain**. Reprint edition ed. London: Penguin Books, 2005.

DANISMAN, T.; ALPKOCAK, A. **Feeler: Emotion Classification of Text Using Vector Space Model** AISB 2008 Convention, Communication, Interaction and Social Intelligence. **Anais...** In: AISB. 2008

DAVE, K.; LAWRENCE, S.; PENNOCK, D. M. **Mining the peanut gallery** ACM Press, 2003 Disponível em: <<http://dl.acm.org/citation.cfm?id=775226>>. Acesso em: 13 set. 2011

DE SOUSA, R. **Emotion** (E. N. Zalta, Ed.), 2014. Disponível em: <<http://plato.stanford.edu/archives/spr2014/entries/emotion/>>

DEVITO, J. A. **Human Communication: The Basic Course, Books a la Carte Edition**. 12 edition ed. [s.l.] Pearson, 2011.

DINI, L.; MAZZINI, G. Opinion classification through information extraction. **IN INTL. CONF. ON DATA MINING METHODS AND DATABASES FOR ENGINEERING, FINANCE AND OTHER FIELDS**, v. 2002, p. 299–310, 2002.

DUNNING, T. Accurate methods for the statistics of surprise and coincidence. **Comput. Linguist.**, v. 19, n. 1, p. 61–74, mar. 1993.

EFRON, M. Cultural orientation: Classifying subjective documents by cocitation analysis. p. 41–48, 2004.

EGGINS, S. **An introduction to systemic functional linguistics**. [s.l.] Continuum International Publishing Group, 2004.

EKMAN, P. Facial expression and emotion. **The American Psychologist**, v. 48, n. 4, p. 384–392, abr. 1993.

FAHRNI, A.; KLENNER, M. **Old Wine or Warm Beer: Target-Specific Sentiment Analysis of Adjectives** Proc. of the Symposium on Affective Language in Human and Machine. **Anais...** In: PROC. OF THE SYMPOSIUM ON AFFECTIVE LANGUAGE IN HUMAN AND MACHINE, 2008 Disponível em:

- <<http://www.aisb.org.uk/convention/aisb08/proc/proceedings/02%20Affective%20Language/11.pdf>>. Acesso em: 30 set. 2011
- FELDMAN, R. Techniques and Applications for Sentiment Analysis. **Commun. ACM**, v. 56, n. 4, p. 82–89, abr. 2013.
- FRANCISCO DA SILVA BORBA. **Dicionário UNESP do português contemporâneo**. São Paulo: Editora UNESP, 2004.
- FREITAS, C. et al. **Vampiro que brilha... rá! Desafios na anotação de opinião em um corpus de resenhas de livros** Encontro de Linguística de Corpus (ELC 2012). **Anais...** In: ELC 2012. São Paulo, Brasil: 2012
- GOLDBERG, A. B. Dissimilarity in graph-based semisupervised classification. **ELEVENTH INTERNATIONAL CONFERENCE ON ARTIFICIAL INTELLIGENCE AND STATISTICS (AISTATS, 2007**.
- GOLDEN, P. **Write here, write now**. Disponível em: <<http://www.research-live.com/features/write-here-write-now/4005303.article>>.
- GRASSI, M. et al. Sentic Web: A New Paradigm for Managing Social Media Affective Information. **Cognitive Computation**, maio 2011.
- GRATCH, J. Editorial. **IEEE Transactions on Affective Computing**, v. 1, n. 1, p. 1–10, 2010.
- GRIMES, S. **Sentiment Analysis: Opportunities and Challenges**. Disponível em: <<http://www.b-eye-network.com/view/6744>>.
- HARRIS, Z. S. Distributional Structure. In: HIŽ, H. (Ed.). **Papers on Syntax**. Synthese Language Library. [s.l.] Springer Netherlands, 1981. p. 3–22.
- HARTNETT, C. The Encyclopedia of Democracy : Edited by Seymour Martin Lipset, Washington, DC: Congressional Quarterly, 1995. 4 v. ISBN 0-87187-675-2 (set). LCCN 95-34217. \$395.00. **Journal of Government Information**, v. 23, n. 4, p. 523–524, July.
- HATZIVASSILOGLOU, V.; WIEBE, J. M. **Effects of adjective orientation and gradability on sentence subjectivity** Association for Computational Linguistics, 2000 Disponível em: <<http://dl.acm.org/citation.cfm?id=990864>>. Acesso em: 21 set. 2011
- HEARST, M. Direction-Based Text Interpretation as an Information Access Refinement. In: (ED.), P. J. (Ed.). **Text-Based Intelligent Systems**. [s.l.] Lawrence Erlbaum Associates, 1992. p. 257–274.
- HEISE, D. R. **The semantic differential and attitude research**. Disponível em: <<http://www.indiana.edu/~socpsy/papers/AttMeasure/attitude..htm>>.
- HUNSTON, S. Pattern Grammar. In: **The Encyclopedia of Applied Linguistics**. [s.l.] Blackwell Publishing Ltd, 2012.
- HUNSTON, S.; THOMPSON, G. **Evaluation in text: authorial stance and the construction of discourse**. [s.l.] Oxford University Press US, 2001.

- JIN, X. et al. **Sensitive webpage classification for content advertising** ACM Press, 2007 Disponível em: <<http://dl.acm.org/citation.cfm?id=1348604>>. Acesso em: 15 set. 2011
- JURAFSKY, D.; MARTIN, J. H. **Speech and Language Processing, 2nd Edition**. 2nd edition ed. Upper Saddle River, N.J: Prentice Hall, 2008.
- KAPPAGODA, A. K. et al. The use of systemic-functional linguistics in automated text mining. 2009.
- KATZ, E.; LAZARSELD, P. F. **Personal influence: the part played by people in the flow of mass communications**. [s.l.] Transaction Publishers, 2006.
- KIM, S.-M.; HOVY, E. **Extracting opinions, opinion holders, and topics expressed in online news media text** Proceedings of the Workshop on Sentiment and Subjectivity in Text. **Anais...** Sydney, Australia: Association for Computational Linguistics, 2006 Disponível em: <<http://portal.acm.org/citation.cfm?id=1654642&dl=GUIDE,>>. Acesso em: 9 ago. 2010
- KIM, S. M.; VALITUTTI, A.; CALVO, R. A. **Evaluation of unsupervised emotion models to textual affect recognition** Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text. **Anais...**: CAAGET '10. Stroudsburg, PA, USA: Association for Computational Linguistics, 2010 Disponível em: <<http://dl.acm.org/citation.cfm?id=1860631.1860639>>
- KWON, N.; SHULMAN, S. W.; HOVY, E. **Multidimensional text analysis for eRulemaking** ACM Press, 2006 Disponível em: <<http://dl.acm.org/citation.cfm?id=1146649>>. Acesso em: 15 set. 2011
- LANDAUER, T.; FOLTZ, P.; LAHAM, D. An Introduction to Latent Semantic Analysis. **Discourse Processes**, n. 25, p. 259–284, 1998.
- LAVER, M.; BENOIT, K.; COLLEGE, T. Extracting Policy Positions from Political Texts Using Words as Data. **AMERICAN POLITICAL SCIENCE REVIEW**, p. 311–331, 2003.
- LISCOMBE, J.; AL., ET. Using Context to Improve Emotion Detection in Spoken Dialog Systems. **IN PROCEEDINGS OF INTERSPEECH**, v. 1845, p. 1845–1848, 2005.
- LITA, L. V. et al. Qualitative dimensions in question answering: Extending the definitional qa task. **IN AAAI-2005**, 2005.
- LIU, B. Sentiment Analysis and Subjectivity. **Handbook of Natural Language Processing**, n. 1, p. 1–38, 2010.
- LIU, H.; LIEBERMAN, H.; SELKER, T. A Model of Textual Affect Sensing Using Real-World Knowledge. p. 125–132, 2003.
- LIU, H.; SINGH, P. ConceptNet &mdash; A Practical Commonsense Reasoning Tool-Kit. **BT Technology Journal**, v. 22, n. 4, p. 211–226, out. 2004.
- LOPES, R. E. DE L.; VIAN JR, O. The Language of Evaluation: appraisal in English.

**DELTA: Documentação de Estudos em Lingüística Teórica e Aplicada**, v. 23, n. 2, p. 371–381, jan. 2007.

LUTFI, S. L. et al. **Template-driven Emotions Generation in Malay Text-to-Speech: A Preliminary Experiment**. (N. Kulathuramaiyer et al., Eds.)CITA. **Anais...032005 2007**Disponível em: <<http://dblp.uni-trier.de/db/conf/cita/cita2005.html#LutfiAMD05>>. Acesso em: 30 maio. 2014

MANNING, C. D.; SCHUETZE, H. **Foundations of Statistical Natural Language Processing**. 1. ed. [s.l.] The MIT Press, 1999.

MARTIN, J. R.; WHITE, P. R. R. **Language of Evaluation: Appraisal in English**. [s.l.] Palgrave Macmillan, 2005.

MEJOVA, Y.; SRINIVASAN, P.; BOYNTON, B. **GOP primary season on twitter: “popular” political sentiment in social media**Proceedings of the sixth ACM international conference on Web search and data mining. **Anais...: WSDM '13**.New York, NY, USA: ACM, 2013Disponível em: <<http://doi.acm.org/10.1145/2433396.2433463>>. Acesso em: 18 jun. 2013

MIHALCEA, R.; BANEA, C. Learning Multilingual Subjective Language via Cross-Lingual Projections. **PROCEEDINGS OF THE 45TH ANNUAL MEETING OF THE ASSOCIATION OF COMPUTATIONAL LINGUISTICS**, 2007.

MILLER, G. A. WordNet: A Lexical Database for English. **Commun. ACM**, v. 38, n. 11, p. 39–41, nov. 1995.

**Minsky’s Frame System Theory**. Proceedings of the 1975 Workshop on Theoretical Issues in Natural Language Processing. **Anais...: TINLAP '75**.Stroudsburg, PA, USA: Association for Computational Linguistics, 1975Disponível em: <<http://dx.doi.org/10.3115/980190.980222>>. Acesso em: 7 jul. 2014

MITROVIĆ, M.; PALTOGLOU, G.; TADIĆ, B. Quantitative Analysis of Bloggers Collective Behavior Powered by Emotions. **1011.6268**, 29 nov. 2010.

MORINAGA, S. et al. **Mining product reputations on the Web**Proceedings of the eighth ACM SIGKDD international conference on Knowledge discovery and data mining - KDD '02. **Anais... In: THE EIGHTH ACM SIGKDD INTERNATIONAL CONFERENCE**. Edmonton, Alberta, Canada: 2002Disponível em: <<http://dl.acm.org/citation.cfm?id=775098>>. Acesso em: 21 ago. 2011

MULLEN, T.; MALOUF, R. A preliminary investigation into sentiment analysis of informal political discourse. **AAAI SYMPOSIUM ON COMPUTATIONAL APPROACHES TO ANALYSING BLOGS (AAAI-CAAW**, p. 159–162, 2006.

NASUKAWA, T.; YI, J. **Sentiment analysis: capturing favorability using natural language processing**Proceedings of the 2nd international conference on Knowledge capture. **Anais...Sanibel Island, FL, USA: ACM**, 2003Disponível em: <<http://portal.acm.org/citation.cfm?id=945658>>. Acesso em: 6 set. 2010

NICOLOV, N.; SALVETTI, F.; IVANOVA, S. Sentiment Analysis: Does Coreference Matter. **IN AISB 2008 CONVENTION COMMUNICATION, INTERACTION**



**AND SOCIAL INTELLIGENCE**, 2008.

NOVIELLI, N. HMM modeling of user engagement in advice-giving dialogues. **Journal on Multimodal User Interfaces**, v. 3, n. 1-2, p. 131–140, dez. 2009.

NUNES, P.; BREENE, T. **Jumping the S-Curve How to beat the growth cycle, get on top, and stay there**. [s.l.] Accenture Institute for High Performance, 2011.

Disponível em:

<[http://www.accenture.com/SiteCollectionDocuments/PDF/Accenture\\_Jumping\\_the\\_S\\_Curve.pdf](http://www.accenture.com/SiteCollectionDocuments/PDF/Accenture_Jumping_the_S_Curve.pdf)>.

O'DONNELL, M.; BATEMAN, J. SFL in Computational Contexts: a Contemporary History. 2005.

OLSON, P. **Inside The Facebook-WhatsApp Megadeal: The Courtship, The Secret Meetings, The \$19 Billion Poker Game**. Disponível em:

<<http://www.forbes.com/sites/parmyolson/2014/03/04/inside-the-facebook-whatsapp-megadeal-the-courtship-the-secret-meetings-the-19-billion-poker-game/>>. Acesso em: 28 abr. 2014.

ORTONY, A.; CLORE, G.; COLLINS, A. **The Cognitive Structure of Emotions**. [s.l.] {Cambridge University Press}, 1988.

OSHERENKO, A. Towards Semantic Affect Sensing in Sentences. In: **AISB 2008**. [s.l.: s.n.]. p. 1–4.

PANG, B.; LEE, L. **A Sentimental Education: Sentiment Analysis Using Subjectivity Summarization Based on Minimum Cuts**. Disponível em:

<<http://adsabs.harvard.edu/abs/2004cs.....9058P>>. Acesso em: 24 maio. 2010.

PANG, B.; LEE, L. Opinion Mining and Sentiment Analysis. **Found. Trends Inf. Retr.**, v. 2, n. 1-2, p. 1–135, 2008.

PANG, B.; LEE, L.; VAITHYANATHAN, S. **Thumbs up?: sentiment classification using machine learning techniques** Proceedings of the ACL-02 conference on Empirical methods in natural language processing - Volume 10. **Anais...Association for Computational Linguistics**, 2002 Disponível em: <[http://portal.acm.org/citation.cfm?id=1118704&dl=GUIDE\)7](http://portal.acm.org/citation.cfm?id=1118704&dl=GUIDE)7)>. Acesso em: 24 maio. 2010

PENNEBAKER, J. W. **The Secret Life of Pronouns: What Our Words Say About Us**. 1 edition ed. [s.l.] Bloomsbury Press, 2011.

PENNEBAKER, J. W.; FRANCIS, M. E. **Linguistic Inquiry and Word Count**. [s.l.] Lawrence Erlbaum Associates, Incorporated, 1999.

PIAO, S. S. et al. Mining Opinion Polarity Relations of Citations. 2006.

PICARD, R. W. **Affective Computing**: Media Laboratory Perceptual Computing Section. [s.l.] M.I.T, 1995. Disponível em:

<<http://citeseer.ist.psu.edu/viewdoc/summary?doi=10.1.1.153.8488>>.

PICARD, R. W. Affective computing: challenges. **International Journal of Human-Computer Studies**, v. 59, n. 1-2, p. 55–64, 2003.

- RAINIE, L. **25th Web Anniversary Pew Research Center's Internet & American Life Project**, 27 fev. 2014. Disponível em: <<http://www.pewinternet.org/2014/02/27/the-web-at-25-in-the-u-s/>>. Acesso em: 8 abr. 2014
- REISENZEIN, R. et al. Computational Modeling of Emotion: Toward Improving the Inter- and Intradisciplinary Exchange. **IEEE Transactions on Affective Computing**, v. 4, n. 3, p. 246–266, jul. 2013.
- RILOFF, E. Exploiting subjectivity classification to improve information extraction. **IN AAAI-2005**, 2005.
- RITCHIE, G. et al. **Evaluating humorous properties of texts** AISB 2008 Convention Communication, Interaction and Social Intelligence. **Anais...** In: AISB. 2008 Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.158.3276>>
- RUMBELL, T. et al. **Affect in Metaphor: Developments with WordNet** Convention Communication, Interaction and Social Intelligence. **Anais...** In: AISB. 2008 Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.157.2266>>
- RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 1st. ed. [s.l.] Prentice Hall, 1995.
- SARACEVIC, T. **Relevance reconsidered** Proceedings of the Second Conference on Conceptions of Library and Information Science (CoLIS 2). **Anais...** In: INFORMATION SCIENCE: INTEGRATION IN PERSPECTIVES. Copenhagen (Denmark): out. 1996
- SCHERER, K. **Appraisal Processes in Emotion: Theory, Methods, Research (Series in Affective Science)**. [s.l.] {Oxford University Press, USA}, 2001.
- SHAIKH, M. A. M.; PRENDINGER, H.; ISHIZUKA, M. A Linguistic Interpretation of the OCC Emotion Model for Affect Sensing from Text. In: TAO, D. J.; MSC, P. T. T. BS. (Eds.). **Affective Information Processing**. [s.l.] Springer London, 2009. p. 45–73.
- SHANNON, C. E. A Mathematical Theory of Communication. **SIGMOBILE Mob. Comput. Commun. Rev.**, v. 5, n. 1, p. 3–55, jan. 2001.
- SHULMAN, S. et al. **Language processing technologies for electronic rulemaking: a project highlight** Proceedings of the 2005 national conference on Digital government research. **Anais...**: dg.o '05. Digital Government Society of North America, 2005 Disponível em: <<http://dl.acm.org/citation.cfm?id=1065226.1065248>>
- SHULMAN, S. eRulemaking: Issues in Current Research and Practice. **eRulemaking Research Group**, 1 jan. 2005.
- SILVA, M. J.; CARVALHO, P.; SARMENTO, L. **Building a sentiment lexicon for social judgement mining** Proceedings of the 10th international conference on Computational Processing of the Portuguese Language. **Anais...**: PROPOR'12. Berlin, Heidelberg: Springer-Verlag, 2012 Disponível em: <[http://dx.doi.org/10.1007/978-3-642-28885-2\\_25](http://dx.doi.org/10.1007/978-3-642-28885-2_25)>. Acesso em: 9 maio. 2013

- SINGH, P. *The Public Acquisition of Commonsense Knowledge*. 2001.
- SMITH, A. **The Internet and Campaign 2010**. Disponível em: <<http://www.pewinternet.org/Reports/2011/The-Internet-and-Campaign-2010/Summary.aspx>>. Acesso em: 17 jul. 2011.
- Social Media Monitoring Tools and Services - 2nd. Edition.** : Ideya Market Report. [s.l.] Ideya Ltd., de maio 2011.
- SOKOLOVA, M.; LAPALME, G. **Verbs as the most affective words** Proceedings of the International Symposium on Affective Language in Human and Machine. **Anais...**UK, Scotland, Aberdeen: 2008 Disponível em: <<http://rali.iro.umontreal.ca/Publications/files/VerbsAffect2.pdf>>
- SOMASUNDARAN, S. et al. QA with attitude: Exploiting opinion type analysis for improving question answering in on-line discussions and the news. **IN INTL. CONFERENCE ON BLOGS AND SOCIAL, 2007.**
- SOUZA, M. et al. **Construction of a Portuguese Opinion Lexicon from multiple resources**In 8th Brazilian Symposium in Information and Human Language Technology - STIL, Mato Grosso. **Anais...**2011
- SPERTUS, E. Smokey: Automatic Recognition of Hostile Messages. **IN PROC. IAAI**, p. 1058–1065, 1997.
- STOYANOV, V.; CARDIE, C.; WIEBE, J. Multi-Perspective Question Answering Using the OpQA Corpus. **Symposium A Quarterly Journal In Modern Foreign Literatures**, n. October, p. 923–930, 2005.
- STRAPPARAVA, C.; MIHALCEA, R. **SemEval-2007 Task 14: Affective Text** Proceedings of the 4th International Workshop on Semantic Evaluations. **Anais...** SemEval '07. Stroudsburg, PA, USA: Association for Computational Linguistics, 2007 Disponível em: <<http://dl.acm.org/citation.cfm?id=1621474.1621487>>. Acesso em: 17 abr. 2014
- STRAPPARAVA, C.; VALITUTTI, A.; STOCK, O. The affective weight of lexicon. In: **Computer**. [s.l.: s.n.]. v. 19p. 423–426.
- SUBASIC, P.; HUETTNER, A. Affect analysis of text using fuzzy semantic typing. **IEEE Transactions on Fuzzy Systems**, v. 9, n. 4, p. 483–496, ago. 2001.
- TABOADA, M. et al. Lexicon-Based Methods for Sentiment Analysis. **Computational Linguistics**, v. 37, n. 2, p. 267–307, 5 abr. 2011.
- TABOADA, M.; GILLIES, M. A.; MCFETRIDGE, P. Sentiment classification techniques for tracking literary reputation. **IN PROCEEDINGS OF LREC WORKSHOP, &quot;TOWARDS COMPUTATIONAL MODELS OF LITERARY ANALYSIS**, p. 36–43, 2006.
- TATEMURA, J. **Virtual reviewers for collaborative exploration of movie reviews** ACM Press, 2000 Disponível em: <<http://dl.acm.org/citation.cfm?id=325870>>. Acesso em: 15 set. 2011

TERVEEN, L. et al. PHOAKS a system for sharing recommendations. **COMMUNICATIONS OF THE ACM**, v. 40, p. 59–62, 1997.

THOMAS HOFFMAN. **Online reputation management is hot -- but is it ethical? - Computerworld**. Disponível em: <[http://www.computerworld.com/s/article/9060960/Online\\_reputation\\_management\\_is\\_hot\\_but\\_is\\_it\\_ethical\\_?taxonomyId=16&pageNumber=3](http://www.computerworld.com/s/article/9060960/Online_reputation_management_is_hot_but_is_it_ethical_?taxonomyId=16&pageNumber=3)>. Acesso em: 9 jul. 2011.

THOMAS, M.; PANG, B.; LEE, L. Get out the vote: Determining support or opposition from Congressional floor-debate transcripts. **IN PROCEEDINGS OF EMNLP**, p. 327–335, 2006.

TOKUHISA, R.; TERASHIMA, R. **Relationship between Utterances and “Enthusiasm” in Non-task-oriented Conversational Dialogue** Proceedings of the 7th SIGdial Workshop on Discourse and Dialogue. **Anais...** Sydney, Australia: Association for Computational Linguistics, jul. 2006 Disponível em: <<http://www.aclweb.org/anthology/W/W06/W06-1323>>

TURMO, J.; AGENO, A.; CATALÀ, N. Adaptive information extraction. **ACM Comput. Surv.**, v. 38, n. 2, p. 4, 2006.

TURNERY, P. D. **Thumbs up or thumbs down?** Proceedings of the 40th Annual Meeting on Association for Computational Linguistics - ACL '02. **Anais...** In: THE 40TH ANNUAL MEETING. Philadelphia, Pennsylvania: 2001 Disponível em: <<http://dl.acm.org/citation.cfm?id=1073153>>. Acesso em: 21 ago. 2011

USPENSKY, B. **A Poetics of Composition**. Berkeley, CA: University of California Press, 1973.

VAN DER SLUIS, I.; MELLISH, C. Towards affective natural language generation: Empirical investigations. **PROCEEDINGS OF THE SYMPOSIUM ON AFFECTIVE LANGUAGE IN HUMAN AND MACHINE, AISB 2008, SOCIETY FOR THE STUDY OF ARTIFICIAL INTELLIGENCE AND SIMULATION OF BEHAVIOUR (2008) 9–16**, 2008.

VIAN JR., O. Appraisal System in Brazilian Portuguese: Resources for Graduation. **Odense Working Papers in Language and Communication**, v. 29, 2008.

WARNER, W.; HIRSCHBERG, J. **Detecting Hate Speech on the World Wide Web** Proceedings of the Second Workshop on Language in Social Media. **Anais...**: LSM '12. Stroudsburg, PA, USA: Association for Computational Linguistics, 2012 Disponível em: <<http://dl.acm.org/citation.cfm?id=2390374.2390377>>. Acesso em: 30 maio. 2014

WHITE, B.; CAMBRIA, E. Jumping NLP Curves: A Review of Natural Language Processing Research. **IEEE Computational Intelligence Magazine**, v. 9, p. 2, 2014.

WHITEHEAD, S.; CAVEDON, L. **Generating shifting sentiment for a conversational agent** Proceedings of the NAACL HLT 2010 Workshop on Computational Approaches to Analysis and Generation of Emotion in Text. **Anais...**: CAAGET '10. Stroudsburg, PA, USA: Association for Computational Linguistics, 2010 Disponível em: <<http://dl.acm.org/citation.cfm?id=1860631.1860642>>

WHITELAW, C.; GARG, N.; ARGAMON, S. **Using appraisal groups for sentiment analysis** Proceedings of the 14th ACM international conference on Information and knowledge management. **Anais...**: CIKM '05. New York, NY, USA: ACM, 2005

WHITELAW, C.; PATRICK, J.; HERKE-COUCHMAN, M. Identifying Interpersonal Distance using Systemic Features. In: SHANAHAN, J. et al. (Eds.). **Computing Attitude and Affect in Text: Theory and Applications**. The Information Retrieval Series. [s.l.] Springer Netherlands, 2006. v. 20p. 199–214.

WIEBE, J. et al. Recognizing and organizing opinions expressed in the world press. **IN WORKING NOTES - NEW DIRECTIONS IN QUESTION ANSWERING (AAAI SPRING SYMPOSIUM SERIES)**, p. 24–26, 2003.

WIEBE, J.; BRUCE, R. **Probabilistic classifiers for tracking point of view** Proceedings of the AAI Spring Symposium on Empirical Methods in Discourse Interpretation and Generation. **Anais...**1995

WIEBE, J. M. **Identifying subjective characters in narrative** Proceedings of the 13th conference on Computational linguistics -. **Anais...** In: THE 13TH CONFERENCE. Helsinki, Finland: 1990 Disponível em: <<http://dl.acm.org/citation.cfm?id=998008>>. Acesso em: 21 ago. 2011

WIEBE, J. M. Tracking point of view in narrative. **Computational Linguistics**, v. 20, n. 2, p. 233–287, 1994.

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 on Computational Linguistics -. **Anais...** In: THE 37TH ANNUAL MEETING OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS. College Park, Maryland: 1999 Disponível em: <<http://dl.acm.org/citation.cfm?id=1034721>>. Acesso em: 21 ago. 2011

WIEBE, J. M.; RAPAPORT, W. J. **A computational theory of perspective and reference in narrative** Proceedings of the 26th annual meeting on Association for Computational Linguistics -. **Anais...** In: THE 26TH ANNUAL MEETING. Buffalo, New York: 1988 Disponível em: <<http://dl.acm.org/citation.cfm?id=982039>>. Acesso em: 21 ago. 2011

WIEBE, J.; WILSON, T.; BELL, M. Identifying Collocations for Recognizing Opinions. **IN PROC. ACL-01 WORKSHOP ON COLLOCATION: COMPUTATIONAL EXTRACTION, ANALYSIS, AND EXPLOITATION**, p. 24–31, 2001.

WIEBE, J.; WILSON, T.; CARDIE, C. Annotating Expressions of Opinions and Emotions in Language. **Language Resources and Evaluation**, v. 39, n. 2-3, p. 165–210, fev. 2006.

WILKS, Y.; BIEN, J. **Beliefs, points of view and multiple environments** Proceedings of the international NATO symposium on artificial and human intelligence. **Anais...** Elsevier North-Holland, Inc., 1984

WILLIAMS, R.; POWER, R.; PIWEK, P. Simulating emotional reactions in medical

dramas. AISB 2008 Convention, Communication, Interaction and Social Intelligence. 2008.

WRIGHT, A. Mining the Web for Feelings, Not Facts. **The New York Times**, 24 ago. 2009.

YU, H.; HATZIVASSILOGLU, V. **Towards answering opinion questions** Proceedings of the 2003 conference on Empirical methods in natural language processing - **Anais...** In: THE 2003 CONFERENCE. Not Known: 2003 Disponível em: <<http://dl.acm.org/citation.cfm?id=1119372>>. Acesso em: 21 ago. 2011

ZABIN, J.; JEFFERIES, A. **Social Media Monitoring and Analysis: Generating Consumer Insights from Online Conversation**. [s.l.] Aberdeen Group Benchmark Report, 2008. Disponível em: <<http://www.bibsonomy.org/bibtex/201eea07cdc25584f76b4260a16ae8d4f/om>>.

ZHANG, M.; YE, X. **A generation model to unify topic relevance and lexicon-based sentiment for opinion retrieval** Proceedings of the 31st annual international ACM SIGIR conference on Research and development in information retrieval. **Anais...** Singapore, Singapore: ACM, 2008 Disponível em: <<http://portal.acm.org/citation.cfm?id=1390334.1390405>>. Acesso em: 9 ago. 2010

## APÊNDICE A

### A.1 Palavras do sistema de julgamento

Palavra	Polaridade	Palavra	Polaridade	Palavra	Polaridade
sortudo	positivo	próspero	positivo	impetuoso	negativo
afortunado	positivo	forte	positivo	apressado	negativo
charmoso	positivo	produtivo	positivo	distráido	negativo
normal	positivo	modesto	positivo	dependente	negativo
natural	positivo	fraco	negativo	incerto	negativo
familiar	positivo	insano	negativo	infiel	negativo
legal	positivo	burro	negativo	inconstante	negativo
estável	positivo	doente	negativo	teimoso	negativo
previsível	positivo	aleijado	negativo	obstinado	negativo
elegante	positivo	imaturo	negativo	voluntarioso	negativo
avançado	positivo	criança	negativo	verdadeiro	positivo
celebrado	positivo	desamparado	negativo	honesto	positivo
azarado	negativo	sério	negativo	confiável	positivo
infeliz	negativo	lento	negativo	correto	positivo
malfadado	negativo	grosso	negativo	franco	positivo
estranho	negativo	neurótico	negativo	sincero	positivo
peculiar	negativo	ingênuo	negativo	direto	positivo
excêntrico	negativo	inexperiente	negativo	discreto	positivo
errático	negativo	bobo	negativo	desonesto	negativo
imprevisível	negativo	iletrado	negativo	enganador	negativo
ultrapassado	negativo	ignorante	negativo	mentiroso	negativo
retrógrado	negativo	incompetente	negativo	enganador	negativo
obsuro	negativo	imbecil	negativo	manipulador	negativo
poderoso	positivo	idiota	negativo	corrupto	negativo
vigoroso	positivo	improdutivo	negativo	ladrão	negativo
robusto	positivo	valente	positivo	bom	positivo
são	positivo	bravo	positivo	moral	positivo
saudável	positivo	herói	positivo	ético	positivo
forma	positivo	cauteloso	positivo	justo	positivo
adulto	positivo	paciente	positivo	claro	positivo
maduro	positivo	cuidadoso	positivo	bondoso	positivo
experiente	positivo	minucioso	positivo	gentil	positivo
espiritoso	positivo	meticuloso	positivo	modesto	positivo
esperto	positivo	incansável	positivo	singelo	positivo
engraçado	positivo	perseverante	positivo	humilde	positivo
divertido	positivo	decidido	positivo	educado	positivo
perspicaz	positivo	firme	positivo	polido	positivo
inteligente	positivo	confiável	positivo	respeitável	positivo
dotado	positivo	seguro	positivo	respeitoso	positivo
equilibrado	positivo	fiel	positivo	reverente	positivo
inteligente	positivo	leal	positivo	altruísta	positivo
sensato	positivo	assíduo	positivo	generoso	positivo
sensível	positivo	flexível	positivo	caridoso	positivo
rápido	positivo	adaptável	positivo	ruim	negativo
sagaz	positivo	tímido	negativo	imoral	negativo
letrado	positivo	covarde	negativo	mal	negativo
instruído	positivo	precipitado	negativo	injusto	negativo
sábio	positivo	imprudente	negativo	insensível	negativo
competente	positivo	impaciente	negativo	malvado	negativo
realizado	positivo	indeciso	negativo	mesquinho	negativo
irreverente	negativo	arrogante	negativo	cruel	negativo
ganancioso	negativo	rude	negativo	vaidoso	negativo
avaro	negativo	egoísta	negativo		
boçal	negativo	esnobe	negativo		

## APÊNDICE B

### B.1 Palavras do sistema de atração

Palavra	Polaridade	Palavra	Polaridade	Palavra	Polaridade
prender	positivo	unificado	positivo	superficial	negativo
cativar	positivo	proporcional	positivo	fundo	positivo
cansar	positivo	considerado	positivo	raso	negativo
engajar	positivo	lógico	positivo	inovador	positivo
fascinar	positivo	simétrico	positivo	original	positivo
excitar	positivo	curvilíneo	positivo	criativo	positivo
animar	positivo	balanceado	positivo	oportuno	positivo
dramático	positivo	organizado	positivo	conveniente	positivo
intenso	positivo	desproporcional	negativo	esperado	positivo
notável	positivo	discordante	negativo	marco	positivo
sensacional	positivo	contraditório	negativo	inimitável	positivo
convidativo	positivo	irregular	negativo	excepcional	positivo
imprevisível	positivo	desigual	negativo	único	positivo
aborrecido	negativo	assimétrico	negativo	autêntico	positivo
chato	negativo	falho	negativo	real	positivo
entediante	negativo	contraditório	negativo	genuíno	positivo
seco	negativo	desorganizado	negativo	valioso	positivo
ascético	negativo	disforme	negativo	impagável	positivo
monótono	negativo	amorfo	negativo	inestimável	positivo
previsível	negativo	distorcido	negativo	apropriado	positivo
prosaico	negativo	deformado	negativo	efetivo	positivo
okay	positivo	simples	positivo	eficiente	positivo
fino	positivo	puro	positivo	eficaz	positivo
bom	positivo	elegante	positivo	significante	positivo
ótimo	positivo	lúcido	positivo	útil	positivo
encantador	positivo	claro	positivo	raso	negativo
bonito	positivo	objetivo	positivo	reducionista	negativo
esplêndido	positivo	preciso	positivo	insignificante	negativo
atraente	positivo	complexo	positivo	derivado	negativo
encantador	positivo	rico	positivo	convencional	negativo
acolhedor	positivo	detalhado	positivo	prosaico	negativo
mau	negativo	ornamentado	negativo	banal	negativo
péssimo	negativo	enfeitado	negativo	vulgar	negativo
desagradável	negativo	extravagante	negativo	datado	negativo
nojento	negativo	bizantino	negativo	velho	negativo
raso	negativo	misterioso	negativo	atrasado	negativo
feio	negativo	secreto	negativo	intempestivo	negativo
grotesco	negativo	lanoso	negativo	inoportuno	negativo
repulsivo	negativo	monilítico	negativo	comum	negativo
revoltante	negativo	simplicista	negativo	falsificação	negativo
balanceado	positivo	penetrante	positivo	falso	negativo
harmonioso	positivo	profundo	positivo	adulterado	negativo
fictício	negativo	inútil	negativo	salgado	negativo
tapeação	negativo	desprezível	negativo	amargo	negativo
chamativo	negativo	indigno	negativo		



## APÊNDICE C

### C.1 Palavras do sistema de afeto

Palavra	Polaridade	Palavra	Polaridade
descaso	positivo	ansioso	negativo
almejar	positivo	aflito	negativo
ansiar	positivo	apavorado	negativo
animado	positivo	assustado	negativo
alegre	positivo	surpreso	negativo
jubilante	positivo	atônito	negativo
gostar	positivo	envolvido	positivo
adorar	positivo	absorvido	positivo
amar	positivo	satisfeito	positivo
cauteloso	negativo	contente	positivo
temeroso	negativo	impressionado	positivo
aterrorizado	negativo	encantado	positivo
triste	negativo	emocionado	positivo
feliz	positivo	cansado	negativo
melancolia	negativo	raiva	negativo
desanimado	negativo	irritado	negativo
animado	positivo	furioso	negativo
inconsolável	negativo	entediado	negativo
abatido	negativo	aprovou	positivo
pesaroso	negativo	recomendar	positivo
aflito	negativo		
abatido	negativo		
deprimido	negativo		
infeliz	negativo		
sombrio	negativo		
junto	positivo		
confiante	positivo		
certo	positivo		
seguro	positivo		
confortável	positivo		
confiar	positivo		
desconfortável	negativo		

## APÊNDICE D

### D.1 Palavras do sistema de força

Palavra	Força	Palavra	Força
pouco	atenua	menos	atenua
muito	intensifica	muito	intensifica
bastante	intensifica	fortemente	intensifica
demais	intensifica	totalmente	intensifica
tanto	intensifica	fracamente	atenua
todo	intensifica	deve	intensifica
minúsculo	atenua	precisa	intensifica
pequeno	atenua	extremamente	intensifica
grande	intensifica	precisamente	intensifica
enorme	intensifica	perfeitamente	intensifica
gigante	intensifica	possivelmente	atenua
recente	intensifica	talvez	atenua
antigo	atenua	provavelmente	atenua
perto	atenua	certamente	intensifica
longe	intensifica	exatamente	intensifica
longo	intensifica	somente	intensifica
curto	intensifica	só	intensifica
durador	intensifica	tudo	intensifica
curto	atenua	nada	atenua
espalhado	intensifica	algum	atenua
estreito	atenua	nunca	atenua
largo	intensifica	sempre	intensifica
mais	intensifica	já	intensifica

## APÊNDICE E

### E.1 GATE

O GATE (General Architecture for Text Engineering) consiste em uma arquitetura para o processamento de texto. É composta de três objetos principais cujos nomes são:

- Language Resource (LR), em português recurso linguístico, ao qual estão associados conceitos como dicionário, corpora e ontologia;
- Processing Resource(PR), em português recurso de processamento, representam entidades cuja principal natureza seja algorítmica como etiquetadores de classe de palavras, analisadores sintáticos, resolução de correferência e reconhecimento de entidades nomeadas; e
- Visual Resource (VR), em português recurso visual, que são componentes de visualização ou edição dos LR e PR.

Estes objetos recebem o nome genérico de CREOLE (Collection of Reusable Objects for Language Engineering), tendo seus atributos descritivos registrados em arquivos XML.

Podem residir em servidores ou em máquinas dos usuários. Uma aplicação no GATE consiste num conjunto de PR, processados em série, chamado de “pipeline”, sobre um conjunto de LR, tendo ou não VR.

A principal vantagem desta arquitetura é que, uma vez separada a parte algorítmica de uma aplicação da sua parte linguística, seu desenvolvimento pode ser feito de forma independente pelas pessoas com competência nas respectivas partes.

O GATE suporta documentos em vários formatos, incluindo texto puro, HTML, XML, RTF e SGML. A adoção destes padrões simplifica a comunicação com outras plataformas de processamento de linguagem.

Uma vez aberto, o documento é analisado e convertido para um modelo interno de anotações onde é registrado o processamento de todos os PR, incluindo sua formatação original. As anotações são organizadas em um ou mais níveis de grafos ancorados no conteúdo do documento por ofsete, no caso de texto, ou por milissegundo, no caso de audiovisual. Cada anotação tem um identificador, nós inicial e final e conjunto de atributos.

JAPE (Java Annotations Pattern Engine) consiste numa máquina de estados finitos baseada em expressões regulares processada sobre as anotações. Sua gramática consiste num conjunto de regras, agrupadas em fases, que contém o padrão a ser comparado e a ação a ser aplicada sobre a anotação.

As fases são processadas sequencialmente como uma cascata de transformadores de estados finitos sobre as anotações. Não é permitida a recursão, mas regras de uma fase podem ser aplicadas sobre anotações geradas na fase anterior.

Uma regra tem dois lados (direito e esquerdo). No lado esquerdo está o padrão a ser encontrado e no lado direito está um conjunto de declarações (Java ou JAPE) que constituem a ação. Um rótulo é associado a cada anotação casada com o padrão e funciona como um sinalizador para o lado direito sobre quais anotações a ação deve ser aplicada. Na Figura abaixo está descrita uma regra em JAPE que identifica endereço IP. O símbolo “-->” separa o lado esquerdo do direito.

O padrão a ser encontrado constitui numa sequência de 7 anotações do tipo “*Token*”, cujos atributos tratados são o “*kind*” e o “*string*”. O atributo “*kind*” pode assumir somente o valor “*number*”. Já o atributo “*string*” somente pode assumir o caractere “.”. Este conjunto, quando encontrado, é rotulado como “*ipAddress*”.

A ação consiste em criar uma nova anotação do tipo “*Address*”, inserindo nela o atributo “*kind*” com o valor “*ipAddress*” uma vez encontrado o padrão. Esta nova anotação tem como nó inicial o nó inicial do primeiro “*token*” e como nó final o último token.

```
Rule: IPAddress
(
  {Token.kind == number}
  {Token.string == "."}
  {Token.kind == number}
  {Token.string == "."}
  {Token.kind == number}
  {Token.string == "."}
  {Token.kind == number}
)
:ipAddress -->
  :ipAddress.Address = {kind = "ipAddress"}
```

*Uma anotação no formato JAPE para identificar endereço IP*

Um valioso atributo do GATE está no reaproveitamento dos recursos desenvolvidos. Um exemplo consiste no conjunto de PR, os recursos de processamento, normalmente utilizados em aplicações de EI foram empacotados e disponibilizados com a plataforma. Este pacote é chamado de ANNIE e consiste dos seguintes elementos: tokenizador, separador de sentenças, etiquetador de palavras, gazeteers, etiquetador de entidades nomeadas, identificador de relações entre entidades nomeadas e identificador de sintagmas nominais.

Foi dada ênfase nos recursos e funcionalidades do GATE utilizados nesta dissertação. A plataforma, porém, oferece outros recursos que merecem uma menção. Um é a integração com aprendizado de máquina. Os atributos de um conjunto de anotações são estruturados na forma de vetores que, por sua vez, podem alimentar qualquer base de treinamento.

Existe um modelo de dados para ontologias com suporte para hierarquia de classes, hierarquia de relações e indivíduos. Este modelo, implementado na forma de API, isola o PR das várias implementações de ontologias existentes.

Um sistema de avaliação de desempenho facilita a avaliação dos recursos desenvolvidos. Funciona comparando as anotações feitas manualmente com as automáticas, fornecendo as métricas comuns de cobertura e precisão.

## APÊNDICE F

### F.1 Regras em JAPE para identificação dos grupos avaliativos

```
Phase:AdjectiveAppraisalGroupCandidate
Input: w NP ADJP ADVP
Options: control = appelt

Rule: AdjectiveAppraisalGroupCandidate
(
    ({ADVP})* {ADJP}
):label
-->
{
    gate.AnnotationSet label = (gate.AnnotationSet)bindings.get("label");
    Iterator labelIt = label.iterator();
    gate.FeatureMap features = Factory.newFeatureMap();
    features.put("rule", "AdjectiveAppraisalGroupCandidate");
    outputAS.add(label.firstNode(), label.lastNode(), "AAGC", features);
}
```

*Regra para identificar candidato a grupo avaliativo adjetival*

```
Phase:NominalAppraisalGroupCandidate
Input: w
Options: control = appelt

Rule: NominalAppraisalGroupCandidate
(
    (({w.pos == "PROSUB"})? ({w.pos == "PREP"})? ({w.pos == "ART"})? {w.pos == "N"} |
    ({w.pos == "PROADJ"})? ({w.pos == "ART"})? {w.pos == "N"} |
    (({w.pos == "PREP"})? ({w.pos == "ART"})? {w.pos == "NPROP"})+
):label
-->
{
    gate.AnnotationSet label = (gate.AnnotationSet)bindings.get("label");
    gate.Annotation labelAnn = (gate.Annotation)label.iterator().next();
    gate.FeatureMap features = Factory.newFeatureMap();
    features.put("rule", "NominalAppraisalGroupCandidate");
    outputAS.add(label.firstNode(), label.lastNode(), "NAGC", features);
}
```

*Regra para identificar candidato a grupo avaliativo adjetival.*

Phase:VerbalAppraisalGroupCandidate  
Input: w AAGC ADVP VP ADJP  
Options: control = appelt

Rule: VerbalAppraisalGroupCandidate

```
(  
    {{ADVP}}* {VP} {{ADVP}}*  
):label  
-->  
{  
gate.AnnotationSet label = (gate.AnnotationSet)bindings.get("label");  
Iterator labelIt = label.iterator();  
gate.FeatureMap features = Factory.newFeatureMap();  
features.put("rule", "VerbalAppraisalGroupCandidate");  
outputAS.add(label.firstNode(), label.lastNode(), "VAGC", features);  
}
```

*Regra para identificar candidato a grupo avaliativo verbal.*

Phase:adjectivephrase  
Input: w  
Options: control = appelt

Rule: adjectivephrase

```
(  
    (({w.pos == "ART"})? ({w.pos == "ADJ"}) (({w.token == "e"}) ({w.pos == "ART"})? {w.pos == "ADJ"})?)  
):label  
-->  
{  
gate.AnnotationSet label = (gate.AnnotationSet)bindings.get("label");  
gate.Annotation labelAnn = (gate.Annotation)label.iterator().next();  
gate.FeatureMap features = Factory.newFeatureMap();  
features.put("rule", "adjectivephrase");  
outputAS.add(label.firstNode(), label.lastNode(), "ADJP", features);  
}
```

*Regra para grupo adjetival*

Phase:nounphrase  
Input: w  
Options: control = appelt

Rule: nounphrase

```
(  
  (({w.pos == "PROSUB"})? ({w.pos == "PREP"})? ({w.pos == "ART"})? {w.pos == "N"} |  
  ({w.pos == "PROADJ"})? ({w.pos == "ART"})? {w.pos == "N"} |  
  ({w.pos == "NPROP"})+)+
```

):label

-->

```
{  
gate.AnnotationSet label = (gate.AnnotationSet)bindings.get("label");  
gate.Annotation labelAnn = (gate.Annotation)label.iterator().next();  
gate.FeatureMap features = Factory.newFeatureMap();  
features.put("rule", "nounphrase");  
outputAS.add(label.firstChild(), label.lastNode(), "NP", features);  
}
```

*Regra para grupo nominal*

Phase:verbalphrase

Input: w  
Options: control = appelt

Rule: verbalphrase

```
(  
  (({w.pos == "PROPESS"})? ({w.pos == "V"})+ |  
  ({w.pos == "VAUX"}) ({w.pos == "PROPESS"} | {w.pos == "PREP"})? ({w.pos == "V"} | {w.pos == "PCP"}))  
 |  
  (({w.pos == "V"})? {w.pos == "PCP"})
```

):label

-->

```
{  
gate.AnnotationSet label = (gate.AnnotationSet)bindings.get("label");  
gate.Annotation labelAnn = (gate.Annotation)label.iterator().next();  
gate.FeatureMap features = Factory.newFeatureMap();  
features.put("rule", "verbalphrase");  
outputAS.add(label.firstChild(), label.lastNode(), "VP", features);  
}
```

*Regra para grupo verbal*



## APÊNDICE G

### G.1 Modelos de Markov

Um processo é dito markoviano caso a probabilidade de transitar para um próximo estado seja condicionalmente independente dos estados anteriores, dado o estado atual.

Seja  $X = (X_1, \dots, X_T)$  uma sequência de variáveis aleatórias observadas e seja  $S = \{s_1, \dots, s_N\}$  um conjunto de estados finitos onde  $X_t = s_n, 1 \leq t \leq T, 1 \leq n \leq N$ .

Sejam, também, 2 propriedades (chamadas de propriedade de Markov) definidas na.

- *Propriedades de uma cadeia de Markov*

(1)	$P(X_{t+1} = s_n   X_1, \dots, X_t) = P(X_{t+1} = s_n   X_t)$	Horizonte limitado
(2)	$P(X_{t+1} = s_n   X_t, \forall t)$	Invariância temporal

Se as propriedades números (1) e (2) da forem verificadas em  $X$ , esta é denominada de Processo ou Cadeia de Markov.

Podemos descrever esta cadeia através de uma matriz de transição estocástica  $A$ , onde  $A = \{a_{ij}\}$  e  $a_{ij} = P(X_{t+1} = s_j | X_t = s_i)$ , sendo  $a_{ij} \geq 0 (\forall i, j)$ ,  $\sum_{j=1}^N a_{ij} = 1 (\forall i)$  e  $s_i, s_j \in S$ .

Para completar o modelo precisamos de um vetor com as probabilidades iniciais dos estados contidos em  $S$ . Este vetor, referenciado com a letra  $\Pi$ , onde  $\Pi = \{\pi_i\}$ ,

$$\pi_i = P(X_1 = s_i), \sum_{i=1}^N \pi_i = 1 \text{ e } s_i \in S.$$

Um modelo de Markov é, portanto, um conjunto de parâmetros  $\lambda = \{S, \Pi, A\}$  e a probabilidade  $P(X_1, \dots, X_T | \lambda) = P(X | \lambda)$  é dada pela equação a seguir:

$$P(X | \lambda) = \pi_{X_1} \prod_{t=1}^{T-1} a_{X_t X_{t+1}}$$

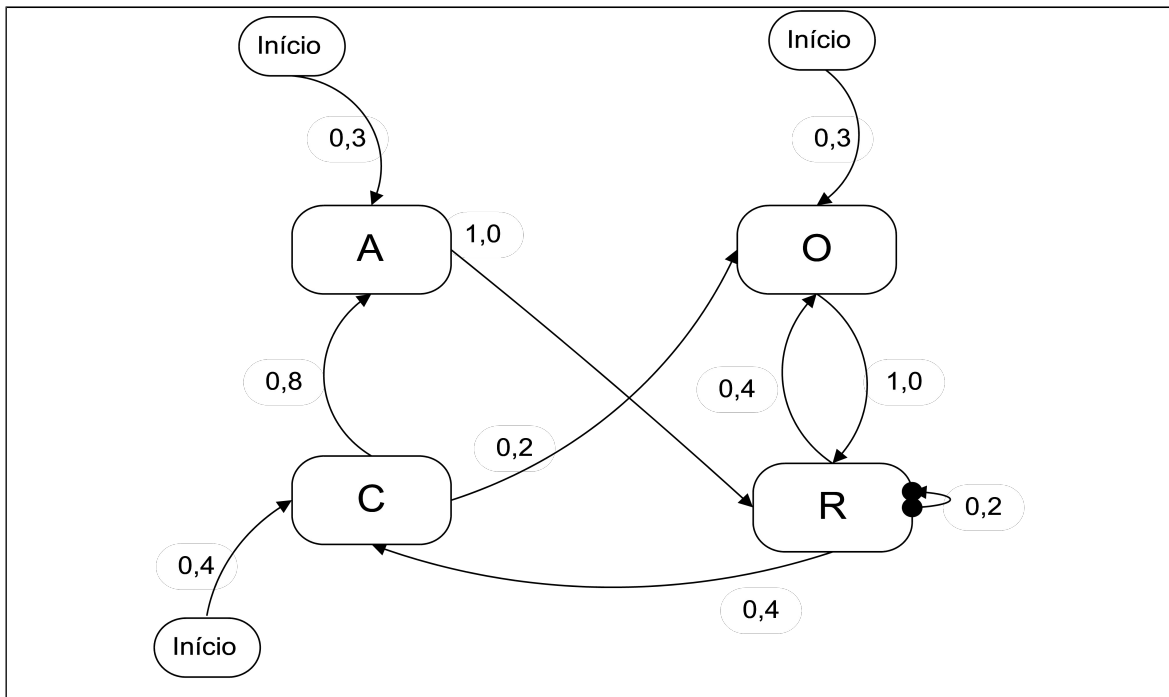
#### G.1.1 Um exemplo de modelos de Markov

Na representamos uma cadeia de Markov através de um diagrama de estado. Trata-se de um pequeno alfabeto cujas letras representam os estados. A probabilidade de transição entre os estados está associada ao arco que os conecta. A cadeia pode ser iniciada pelos estados A, C, O. Formalmente temos:

- Conjunto de estados  $S = \{A, C, O, R\}$
- Vetor de inicialização  $\Pi = (0,3 \quad 0,4 \quad 0,3 \quad 0,0)$
- Matriz de Transição de Estados  $A = \begin{bmatrix} & A & C & O & R \\ A & 0,0 & 0,0 & 0,0 & 1,0 \\ C & 0,8 & 0,0 & 0,2 & 0,0 \\ O & 0,0 & 0,0 & 0,0 & 1,0 \\ R & 0,0 & 0,4 & 0,4 & 0,2 \end{bmatrix}$

Dado o modelo, qual a probabilidade de observarmos as sequências CARRO e ORAR? Com a equação (3.1) calcula-se:

- $P(\text{CARRO}) = \pi_C * a_{CA} * a_{AR} * a_{RR} * a_{RO} = 0,4 * 0,8 * 1,0 * 0,2 * 0,4 = 0,256$  ; e
- $P(\text{ORAR}) = \pi_O * a_{OR} * a_{RA} * a_{AR} = 0,3 * 1,0 * 0,0 * 1,0 = 0,0$



- Modelo de Estado de uma Cadeia de Markov

Concluimos que a observação da sequência CARRO, dado o modelo, é possível e de que a sequência ORAR não é.

## G.2 Modelo oculto de Markov – HMM

Quando os estados não são diretamente observáveis, mas sim uma sequência de sinais resultantes de um conjunto de processos estocásticos que produzem a sequência observada se tem um modelo oculto de Markov - em inglês chama-se “Hidden Markov Model”, cujo acrônimo é HMM e através do qual passaremos a referenciar esta tecnologia.

Um HMM consiste, portanto, de dois processos estocásticos, sendo um subjacente e não observável (oculto), mas que pode ser percebido através do segundo que produz a sequência de observações visíveis (RABINER, 1989).

HMM são úteis quando desejamos modelar processo que percebemos indiretamente através de uma sequência de observações, ou símbolos. Um exemplo seria o reconhecimento de voz (RABINER, 1989) onde percebemos os sons emitidos pelas cordas vocais, mas não observamos diretamente os seus estados. Outro seria a rotulação (ou classificação) das palavras segundo sua função gramatical (MANNING, 1999) onde imaginamos uma cadeia de Markov oculta cujos estados são as classes das palavras (em inglês “Parts of Speech” ou POS) dos quais as palavras lidas emergem. LUGER (2002) afirma que “as cadeias de Markov oferecem uma ferramenta poderosa para capturar os padrões da linguagem e o relacionamento entre estes e o mundo que descrevem”.

Para que tenhamos um HMM precisamos adicionar dois parâmetros ao modelo ( $\lambda$ ) da seção anterior. O primeiro deles é o conjunto de símbolos  $K$ , cujos elementos correspondem às observações do sistema que queremos modelar. Formalmente:  $K = \{k_1, \dots, k_M\}$ , onde  $M$  consiste no número de elementos distintos. O segundo é a matriz de emissão de símbolos ( $B$ ) onde modelamos a função estocástica de um símbolo emergir de um estado. Formalmente seja  $O = \{o_1, \dots, o_T\}$  a sequência observada com  $o_t \in K$  e  $1 \leq t \leq T$ , temos:  $B = \{b_{s_i s_j k_m}\}$  e  $b_{s_i s_j k_m} = P(O_t = k_m | X_t = s_i, X_{t+1} = s_j)$ , onde  $s_i, s_j \in S, k_m \in K$ . O modelo passa a ter 5 parâmetros:  $\lambda = \{S, K, \Pi, A, B\}$  e a probabilidade  $P(O | \lambda)$  é dada pela equação a seguir.

$$P(X | \lambda) = \pi_{x_1} \prod_{t=1}^{T-1} a_{x_t x_{t+1}} \quad (3.2)$$

Uma aplicação com base em HMM precisa responder a uma das três perguntas abaixo para que seja útil na solução de problemas no mundo real:

- Problema 1: Dada uma sequência de observações  $O$  e um modelo  $\lambda$ , como podemos computar eficientemente  $P(O | \lambda)$ ? O aspecto prático deste problema é decidir dentre 2 ou mais modelos qual aquele que melhor descreve a sequência observada;
- Problema 2: Dada uma sequência de observações  $O$  e um modelo  $\lambda$ , como nós escolhemos a sequência de estados  $X$  que melhor explica  $O$ ? Seu aspecto prático é classificar cada elemento observado; e
- Problema 3: Como ajustar os parâmetros  $\Pi$ ,  $A$  e  $B$  para maximizar  $P(O | \lambda)$ ? Seu aspecto prático é definir os parâmetros do modelo quando estes são desconhecidos.

### G.2.1 Um exemplo de HMM

No diagrama de estados da figura 3.2 representamos uma cadeia onde os estados constituem num pequeno alfabeto de apenas 3 letras e os símbolos num conjunto com apenas 4 palavras. Define-se então:  $S = \{A \ N \ R\}$  e  $K = \{Associação, Nacional, Racionalista, Behaviorista\}$ . O objetivo consiste em calcular a probabilidade das sequências de observações “Associação Nacional Racionalista” e “Associação Nacional Behaviorista” emergirem da cadeia  $X = (A \ N \ R)$ , sabendo que um estado  $s_n \in S$  emite um símbolo  $k_n \in K$ , sendo  $l_1$  a primeira letra de  $o_t$ , através da seguinte função:

- $f_{emissão} \begin{cases} 0 & s_n \neq l_1(o_t) \\ 1 & s_n = l_1(o_t) \end{cases}$ ;
- O vetor de inicialização é  $\Pi = \begin{pmatrix} A & N & R \\ 1,0 & 0,0 & 0,0 \end{pmatrix}$ ;
- A matriz de transição de estados é  $A = \begin{bmatrix} & A & N & R \\ A & 0,0 & 1,0 & 0,0 \\ N & 0,0 & 0,0 & 1,0 \\ R & 0,0 & 0,0 & 0,0 \end{bmatrix}$ ;
- A matriz de emissão de símbolos é  $B = \begin{bmatrix} & Associação & Nacional & Racionalista & Behaviorista \\ A & 1,0 & 0,0 & 0,0 & 0,0 \\ N & 0,0 & 1,0 & 0,0 & 0,0 \\ R & 0,0 & 0,0 & 1,0 & 0,0 \end{bmatrix}$

Utilizando a fórmula da equação 3.2 calculam-se nos quadros a seguir as probabilidades das observações  $O_1=(\text{Associação Nacional Racionalista})$  e  $O_2=(\text{Associação Nacional Behaviorista})$ .

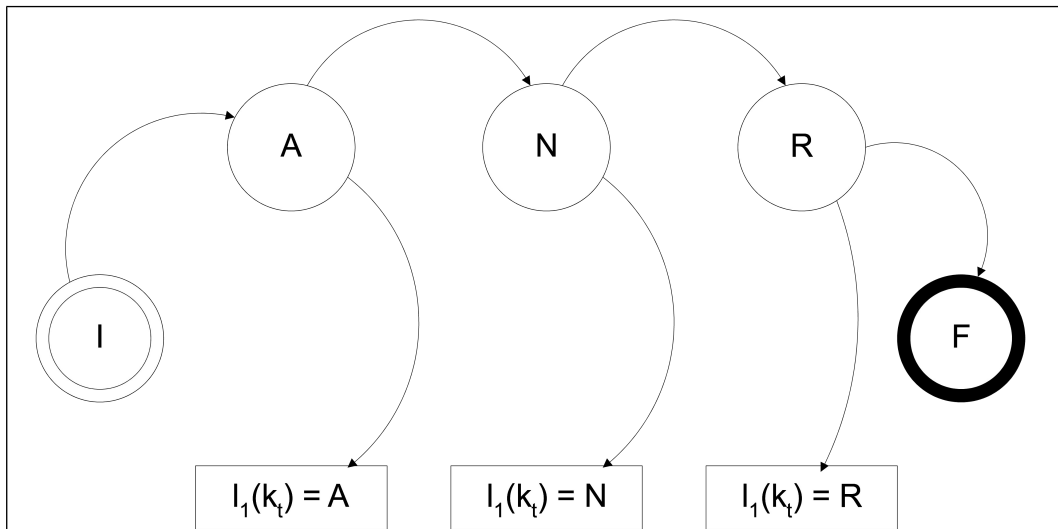
$O_1=(\text{Associação Nacional Racionalista})$

$$P = \pi_A * a_{an} * b_{a,n,Associação} * a_{nr} b_{nrNacional} * a_{rf} b_{rfRacionalista} = 1,0 * 1,0 * 1,0 * 1,0 * 1,0 = 1,0$$

$O_2=(\text{Associação Nacional Behaviorista})$

$$P = \pi_A * a_{an} * b_{a,n,Associação} * a_{nr} b_{nrNacional} * a_{rf} b_{rfBehaviorista} = 1,0 * 1,0 * 1,0 * 1,0 * 0,0 = 0,0$$

Neste exemplo o cálculo da probabilidade foi simplificado por existir apenas um caminho possível de se percorrer a cadeia. A complexidade do algoritmo para o cálculo da probabilidade descrita na equação 3.2 é  $O((2T+1) \cdot |S|^T)$  onde  $T$  é o número de palavras observadas e  $|S|$  é o número de estados. Os algoritmos (descritos nas seções G.2.2, G.2.3), baseados em programação dinâmica, para resolver os problemas apresentados na seção anterior reduzem esta complexidade para  $2T \cdot N^2$ .



- Diagrama de estados e símbolos de um HMM

## G.2.2 Probabilidade de uma observação dado um modelo

A probabilidade é computada através do algoritmo progressivo (do inglês forward procedure), tradução encontrada em KEPLER (2005), descrito a seguir:

Seja a matriz de propagação progressiva, cujas linhas referenciam cada elemento de  $S$  e as colunas cada elemento de  $O$ ,  $A = \alpha_{s_i}(t)$ , onde  $\alpha_{s_i}(t) = P(o_1, \dots, o_{t-1}, X_t = s_i | \lambda)$  e é calculado recursivamente em 3 etapas:

Seja a probabilidade de se observar  $O(o_1, \dots, o_{t-1})$  e de se chegar ao estado  $s_i$  em tempo  $t$ , calculamos:

- Inicialização:  $\alpha_{s_i}(1) = \pi_{s_i}$ ,  $1 \leq i \leq N$ ;
- Indução:  $\alpha_{s_j}(t+1) = \sum_{i=1}^N \alpha_{s_i}(t) a_{s_i s_j} b_{s_i s_j o_t}$ ,  $1 \leq t \leq T, 1 \leq j \leq N$ ; e
- Finalização:  $P(O | \lambda) = \sum_{i=1}^N \alpha_i(T+1)$ .

O algoritmo regressivo (do inglês backward procedure) não é necessário para o cálculo desta probabilidade, mas será descrito aqui e utilizado nas duas próximas seções.

Seja  $\beta_i(t) = P(o_t, \dots, o_T | X_t = s_i, \lambda)$  cada elemento da matriz de propagação regressiva  $B(s_i, t)$ , este algoritmo também se divide em 3 fases:

- Inicialização:  $\beta_{s_i}(T+1) = 1$ ,  $1 \leq i \leq N$ ;
- Indução:  $\beta_{s_j}(t) = \sum_{i=1}^N \beta_{s_i}(t+1) a_{s_i s_j} b_{s_i s_j o_t}$ ,  $1 \leq t \leq T, 1 \leq i \leq N$ ; e
- Finalização:  $P(O | \lambda) = \sum_{i=1}^N \pi_i \beta_i(1)$ .

Para finalizar para qualquer tempo:  $P(O | \lambda) = \alpha_{s_i}(t) \beta_{s_i}(t)$ ,  $1 \leq t \leq T+1$

## G.2.3 Definição da sequência de estados percorridos

A melhor sequência de estados ocultos é encontrada através do algoritmo de Viterbi, descrito a seguir.

Seja  $\Delta(s_j, t)$  a matriz que acumula a máxima probabilidade de estar no estado  $s_j$  em  $t$ , onde calculamos  $\delta_{s_j}(t) = \max_{X_1, \dots, X_{t-1}} P(X_1, \dots, X_{t-1}, o_1, \dots, o_{t-1}, X_t = s_j | \lambda)$ , e seja também a matriz  $\Psi(s_j, t)$  onde é armazenado o argumento, que neste caso é um estado, referente

a máxima probabilidade de  $\delta_{s_i}(t)$ , o algoritmo recursivo segue em 3 fases:

- Inicialização:  $\delta_{s_j}(1) = \pi_{s_j}, 1 \leq j \leq N$ ;
- Indução:  $\delta_{s_j}(t+1) = \max_{1 \leq i \leq N} \delta_{s_i}(t) a_{s_i s_j} b_{s_i s_j o_t}, 1 \leq j \leq N$  e  $\psi_{s_j}(t+1) = \arg \max_{1 \leq i \leq N} \delta_{s_i}(t) a_{s_i s_j} b_{s_i s_j o_t}, 1 \leq j \leq N$ ; e

Finalização, onde a sequência de estados é lida da direita para a esquerda:

$$\bar{x}_{T+1} = \arg \max_{1 \leq i \leq N} \delta_{s_i}(T+1) \text{ e } \bar{X}_t = \psi_{\bar{X}_{t+1}}(t+1).$$

## G.2.4 Maximização dos parâmetros do modelo

Ajustamos os parâmetros através do algoritmo de Baum & Welch, ou algoritmo progressivo regressivo, que funciona como descrito a seguir:

Dado um modelo  $\lambda = \{S, K, \Pi, A, B\}$ , inicializado baseado em heurísticas ou randomicamente, procura-se encontrar um novo que melhor explique as observações encontradas. Ou seja, queremos encontrar  $\{\bar{\Pi} \quad \bar{A} \quad \bar{B}\}$  maximizado por  $O$ .

Duas matrizes são necessárias:  $P_t = \{p_t(s_i, s_j)\}$  que contém a probabilidade de passar  $s_i \rightarrow s_j$  em qualquer momento  $t$ ; e a matriz  $H_{s_i} = \{\gamma_{s_i}(t)\}$  que contém o número de vezes em que o estado de origem foi  $s_i$  em  $o_t$ .

Calculam-se:

- $$p_t(s_i, s_j) = \frac{\alpha_{s_i}(t) a_{s_i s_j} b_{s_i s_j o_t} \beta_{s_j}(t+1)}{\sum_{y=1}^N \sum_{z=1}^N \alpha_y(t) a_{s_y s_z} b_{s_y s_z o_t} \beta_z(t+1)} ; \text{ e}$$
- $$\gamma_{s_i}(t) = \sum_{j=1}^N p_t(s_i, s_j).$$

Os novos parâmetros são então processados como descrito a seguir:

- $\bar{\pi}_{s_i} = \gamma_{s_i}(1);$
- $$\bar{a}_{s_i s_j} = \frac{\sum_{t=1}^T p_t(s_i, s_j)}{\sum_{t=1}^T \gamma_{s_i}(t)} ;$$
- $$\bar{b}_{s_i s_j k m} = \frac{\sum_{t: o_t=k, 1 \leq t \leq T, 1 \leq m \leq M} p_t(s_i, s_j)}{\sum_{t=1}^T p_t(s_i, s_j)}$$

## APÊNDICE H

### H.1 Support Vector Machine – SVM

Existem problemas em processamento de linguagem natural e extração da informação que podem ser representados como um problema de classificação. Exemplos são: classificar morfologicamente uma palavra, classificar com valor monetário um número, classificar como sintagma nominal um conjunto de palavras entre outros. Classificadores, como o SVM, baseados nos vetores de suporte definem um hiperplano que separa os pontos em exemplos positivos e negativos do conceito que se deseja classificar.

Alguns exemplos de como métodos de “*kernel*” (como SVM) são utilizados em extração de informação são encontrados em: (ROTH; WEN-TAU, 2001), (ZELENKO; AONE; RICHARDELLA, 2003) e (ZHAO; GRISHMAN, 2005) que utilizam o SVM para extração de atributos e relacionamento entre conceitos. Já (CHIEU; NG; LEE, 2003) propõe um analisador sintático baseado em classificação estatística.

O objetivo do SVM, como dos demais classificadores, consiste em produzir um modelo que permita associar um dado (conjunto de atributos) a uma classe. Esses dados são divididos em:

- Treinamento, onde o rótulo de cada dado é fornecido, permitindo o classificador construir o modelo; e
- Teste, onde o classificador infere o rótulo, ou seja, o classifica.



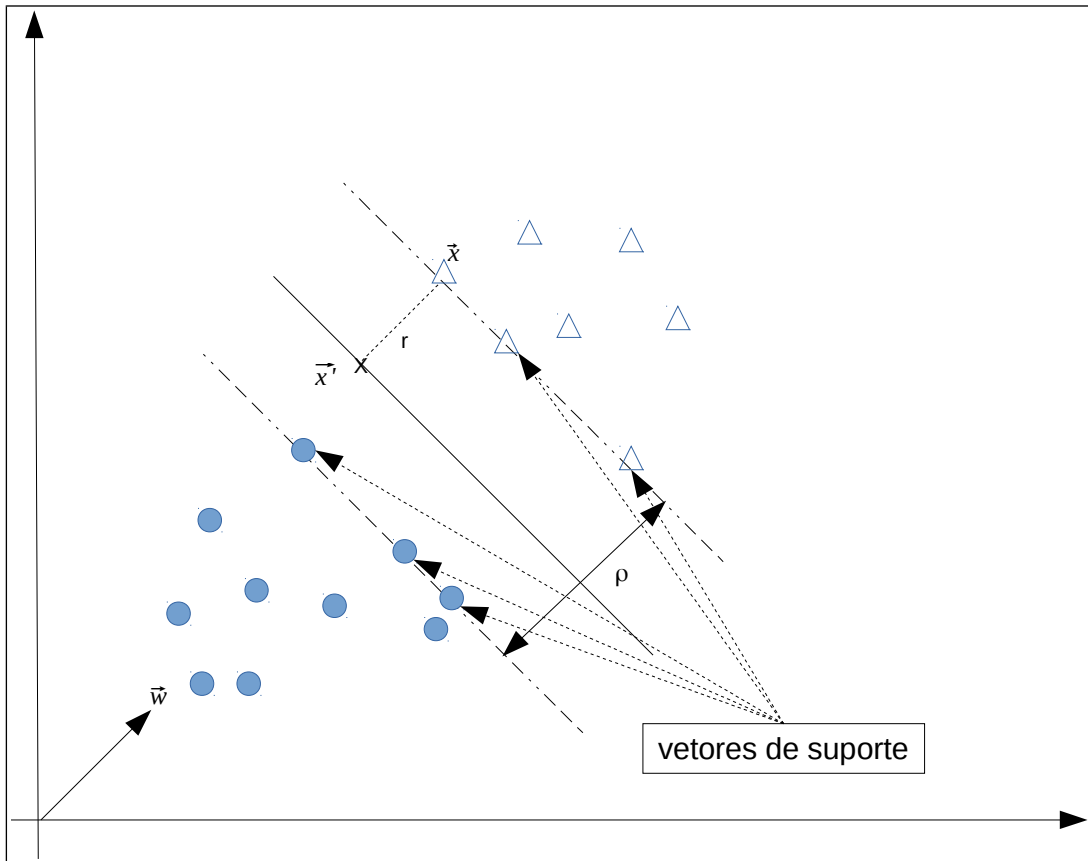


Figura H.1: Representação do SVM

O SVM calcula a maior distância  $\rho$  (figura H.1), também chamada de margem geométrica, de um hiperplano que separa os dados de duas classes. Supondo que:

- $f(\vec{x}) = \text{sign}(\vec{w}^T \vec{x} + b)$  um classificador linear com imagem  $[-1, 1]$ ;
- $\vec{x}'$  seja um ponto sobre a fronteira onde fica o hiperplano;
- $r$  seja a distância euclidiana entre  $\vec{x}$  e  $\vec{x}'$ ;
- $\vec{w}$ , também chamado de vetor peso<sup>79</sup>, seja perpendicular ao hiperplano e portanto paralelo a  $r$ ;
- Que o vetor unitário dessa direção é dado por  $\vec{w}/|\vec{w}|$ ;
- E a linha pontilhada é dada por  $r \vec{w}/|\vec{w}|$ .

Então:

$$\vec{x}' = \vec{x} - yr \frac{\vec{w}}{|\vec{w}|}$$

<sup>79</sup> Do inglês “weight vector”

Onde o  $y$  somente altera o sinal dos dois casos de  $\vec{x}$ , um para cada lado do hiperplano. Como  $\vec{x}'$  está sobre o hiperplano, atende a equação  $\vec{w}^T \vec{x}' + b = 0$ . Assim

$$\vec{w}^T \left( \vec{x} - yr \frac{\vec{w}}{|\vec{w}|} \right) + b = 0$$

Resolvendo para  $r$  se tem:

$$r = y \frac{(\vec{w}^T \vec{x} + b)}{|\vec{w}|}$$

E os pontos mais perto do hiperplano são chamados de vetores de suporte. Quando  $|\vec{w}|=1$  a margem geométrica é chamada de margem funcional. Assumindo que a margem funcional para todos os pontos é no mínimo 1 e que é igual a 1 para pelo menos 1 vetor  $\vec{x}$ , temos que para todos os pontos a seguinte desigualdade:

$$y_i (\vec{w}^T \vec{x} + b) \geq 1$$

Um vetor de suporte a desigualdade acima consiste na igualdade. Com a distância para todos os pontos do hiperplano é dada por:

$$r_i = y \frac{(\vec{w}^T \vec{x}_i + b)}{|\vec{w}|}$$

E como  $\rho = 2r$  e para os vetores de suporte  $r = \frac{1}{|\vec{w}|}$ , tem-se que  $\rho = \frac{2}{|\vec{w}|}$ , que consiste na equação a ser maximizada. Isso equivale a minimizar  $\rho = \frac{|\vec{w}|}{2}$ , levando a formulação padrão do SVM como um problema de minimização onde deseje-se encontrar  $\vec{w}$  e  $b$  de forma que:

- $\frac{1}{2} \vec{w}^T \vec{w}$  é minimizada; e
- $\forall \{(\vec{x}_i, y_i)\}$ ,  $y_i (\vec{w}^T \vec{x} + b) \geq 1$ .

Um problema com alta dimensionalidade, como é o caso de classificação de texto, dificilmente as classes são linearmente separáveis. Para contornar esse problema se introduz uma variável de negligência  $\xi$ , que também deve ser encontrada. Com ela as fórmulas acima são ajustadas para:

- $\frac{1}{2} \vec{w}^T \vec{w} + C \sum_i \xi_i$  ; e
- $\forall \{(\vec{x}_i, y_i)\} , y_i(\vec{w}^T \vec{x} + b) \geq 1 - \xi_i$  .

$C$  é um parâmetro de penalização do erro. Essa minimização consiste na otimização de uma função quadrática sujeita a restrições lineares. Embora a descrição desse processo de otimização transcenda o escopo dessa seção uma parte central consiste na escolha da função de decisão  $D(x)$  que enquanto devem ser lineares em seus parâmetros, não estão restritas a dependência linear de  $\vec{x}$  .

(BOSER; GUYON; VAPNIK, 1992) definem essa função em notação de espaço direto como:

$$\dots$$

Onde  $\varphi(\vec{x})$  consiste no produto vetorial dos componentes de  $\vec{x}$  . Em espaço dual a definem em espaço dual como:

$$\dots$$

Onde  $\alpha_k$  consiste em um parâmetro a ser ajustado e  $\vec{x}_k$  no padrão de treino. Já a função  $K(\vec{x}_k, \vec{x})$  é chamada de função de “kernel” e definida como:

$$\dots$$

Os autores em (HSU; CHANG; LIN, 2010) enquanto mencionam o recente desenvolvimento de novas funções de “kernel”, enumeram as mais comuns:

- Linear:  $K(\vec{x}_i, \vec{x}_j) = \vec{x}_i^T \vec{x}_j$  ;
- Polinomial:  $K(\vec{x}_i, \vec{x}_j) = (\gamma \vec{x}_i^T \vec{x}_j + f)^d$ ,  $\gamma > 0$  ;
- Função básica radial (RBF):  $K(\vec{x}_i, \vec{x}_j) = \exp(-\gamma \|\vec{x}_i - \vec{x}_j\|^2)$   $\gamma > 0$  ; e
- Sigmoide:  $K(\vec{x}_i, \vec{x}_j) = (\gamma \vec{x}_i^T \vec{x}_j + f)$ ,  $\gamma > 0$

Onde  $f$ ,  $\gamma$  e  $d$  são parâmetros a serem estimados.

## APÊNDICE I

### I.1 Distância simétrica de Kullback-Leibler (DKL)

Na seção 3.3 se apresentou a definição e o emprego da semântica diferencial na avaliação de conceitos. Essa semântica divide o espaço em três dimensões (o modelo EPA) onde cada uma das dimensões consiste na média dos seus atributos polares.

Nessa seção é descrita a técnica utilizada nessa pesquisa para atribuir valor a alguns dos atributos do modelo MLE.

A divergência KL, também conhecida como entropia cruzada ou entropia relativa, consiste em uma medida, sobre o mesmo espaço amostral, de quanto duas distribuições de probabilidade  $P$  e  $Q$  são diferentes. Essa divergência também pode ser compreendida como o número médio perdido de bits ao codificar eventos de uma distribuição  $P$  baseada na distribuição de outra distribuição  $Q$ . Essa divergência é dada pela fórmula:

$$D(P\|Q) = \sum_{x \in X} P(x) \log \frac{P(x)}{Q(x)}$$

*Fórmula 3: Divergência KL*

Essa divergência não é simétrica. Ou seja,  $D(P\|Q) \neq D(Q\|P)$ . Para transformar essa divergência em uma medida de distância somam-se  $D(P\|Q) + D(Q\|P)$ , chegando a seguinte equação:

$$D(P\|Q) = \sum_{x \in X} ((P(x) - Q(x)) \log \frac{P(x)}{Q(x)})$$

*Fórmula 4: Distância KL*

Na categorização de texto o modelo proposto assume que cada documento é representado por um vetor de pesos atribuídos a cada termo. Os termos pertencem a um vocabulário  $V$ .

A ideia aqui é mais simples. Se deseja apenas conhecer a distância entre a distribuição de probabilidade de duas classes, sendo uma delas chamada de classe de referência  $c_r$ . No modelo ETA seria a classe associada ao valor zero. Se chama a outra classe de classe objeto  $c_o$ .

A classe de referência contém apenas um termo. A frequência deste termo

consiste na frequência de todas as palavras de um determinado corpus menos a frequência de todas as palavras da classe  $c_o$ .

Como o número de termos do vetor que representa as classes envolvidas é o mesmo precisa-se de uma técnica de suavização<sup>80</sup> que garanta duas distribuições de probabilidades. A técnica, aqui descrita, consiste naquela proposta por (BIGI, 2003) onde o problema era a categorização de texto.

A probabilidade suavizada  $P'(t, c)$  do termo  $t$  na classe  $c$  é dada por:

$$P'(t_i|c_j) = \begin{cases} \gamma P(t_i|c_j) & , \text{ se } t_i \text{ ocorre em } c_j \\ \varepsilon & , \text{ caso contrário} \end{cases}$$

*Fórmula 5: Cálculo da probabilidade suavizada para encontrar DKL*

com:

$$P(t_i|c_j) = \frac{tf(t_i, c_j)}{\sum_{x \in c_j} tf(t_x, c_j)}$$

*Fórmula 6: Probabilidade de um termo*

onde:

- $P(t_i|c_j)$  é a probabilidade do termo  $t_i$  na classe  $c_j$  com  $\sum_{x \in c_j} tf(t_x, c_j) = 1$  ;
- $\gamma$  é o coeficiente de normalização; e
- $\varepsilon$  é uma probabilidade para todos os termos que não estão na classe  $c_j$

Os coeficientes  $\varepsilon$  e  $\gamma$  precisam ser escolhidos de forma a garantir que as probabilidades correspondentes somem 1.

Para isso a seguinte restrição precisa ser atendida:

$$\sum_{i \in c_j} \gamma P(t_i|c_j) + \sum_{i \notin c_j} \varepsilon = 1$$

*Fórmula 7: Restrição para encontrar o coeficiente de suavização*

onde  $\gamma$  é o coeficiente de normalização calculado por:

---

<sup>80</sup> Tradução livre do inglês “*smoothing*”

$$\gamma = 1 - \sum_{i \notin c_j} \varepsilon$$

*Fórmula 8: Cálculo do coeficiente de suavização.*

onde  $\varepsilon$  é um número positivo menor do que a menor das probabilidades dos termos que ocorrem em  $c_r$  e  $c_o$ .

Na sequência de figuras a seguir exemplifica-se os cálculos descritos acima.

	Filme	Livro	Gostei	Recomendo	Lixo	Péssimo	Ruim	Bom	Excelente	Casa	História	REFERENCIA
NEU	154	1115	39	15	1	4	21	108	11	50	416	0
NEG	2	189	17	10	7	6	21	15	0	2	73	0
POS	35	936	92	104	0	0	9	192	30	3	294	0
REF	0	0	0	0	0	0	0	0	0	0	0	1

*Figura I.1: Frequência das palavras em um corpus*

Na figura I.1 encontram-se as frequências das palavras do vocabulário  $V$  por classe objeto. Nesse caso as classes objeto são as polaridades. A classe referência “REF” consiste na quarta e contém apenas uma palavra (“REFERÊNCIA”) que não aparece nas demais<sup>81</sup>.

Na figura I.2 estão as probabilidades, antes da suavização, calculadas conforme a fórmula 3.

	Filme	Livro	Gostei	Recomendo	Lixo	Péssimo	Ruim	Bom	Excelente	Casa	História	REFERENCIA
NEU	0.0796277146	0.5765253361	0.0201654602	0.0077559462	0.0005170631	0.0020682523	0.0108583247	0.0558428128	0.0056876939	0.0258531541	0.215098242	0
NEG	0.0058479532	0.5526315789	0.0497076023	0.0292397661	0.0204678363	0.0175438596	0.0614035088	0.0438596491	0	0.0058479532	0.2134502924	0
POS	0.0206489676	0.5522123894	0.0542772861	0.0613569322	0	0	0.0053097345	0.1132743363	0.017699115	0.0017699115	0.1734513274	0
REF	0	0	0	0	0	0	0	0	0	0	0	1

*Figura I.2: Probabilidade das palavras por classe.*

A menor probabilidade nas distribuições da figura acima é  $p(\text{ruim}, \text{pos})=0,0053$ . Se atribuiu  $\varepsilon=0,0005$  e, pela fórmula 3  $\gamma=0,9945$ . Com isso podemos calcular a distância de cada uma das palavras nas respectivas classes para a classe de referência. Nas figuras I.3, I.4 e I.5 se encontram as distâncias das probabilidades suavizadas calculadas pela fórmula 6 e a distância KL calculada conforme a fórmula 4.

<sup>81</sup> As frequências das palavras por classe foram extraídas do corpus ReLi.

DKL(NEU REF)													
EPSILON	0.0005												
LAMBDA	0.9945												
	Filme	Livro	Gostei	Recomendo	Lixo	Péssimo	Ruim	Bom	Excelente	Casa	História	REFERENCE	
REF	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.9945
NEU	0.0796277146	0.5765253361	0.0201654602	0.0077559462	0.0005170631	0.0020682523	0.0108583247	0.0558428128	0.0056876939	0.0258531541	0.215098242		0
DKL(NEU REF)	0.5788349585	5.8588920547	0.1048919152	0.0286994644	8.26061E-007	0.0032124272	0.0459985195	0.3765137423	0.01819762	0.1443169577	1.8774882421		0

Figura I.3: DKL entre neutro e a referência

DKL(NEG REF)													
EPSILON	0.0005												
LAMBDA	0.9945												
	Filme	Livro	Gostei	Recomendo	Lixo	Péssimo	Ruim	Bom	Excelente	Casa	História	REFERENCE	
REF	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.9945
NEG	0.0058157895	0.5495921053	0.0494342105	0.0290789474	0.0203552632	0.0174473684	0.0610657895	0.0436184211	0.0005	0.0058157895	0.2122763158		0.005
DKL(NEG REF)	0.0188177621	5.5470478585	0.3243084408	0.1675270213	0.1061726437	0.0868542047	0.4198597662	0.2779786672		0.0188177621	1.8487647979		7.5557225216

Figura I.4: DKL entre negativo e a referência

DKL(POS REF)													
EPSILON	0.0005												
LAMBDA	0.9945												
	Filme	Livro	Gostei	Recomendo	Lixo	Péssimo	Ruim	Bom	Excelente	Casa	História	REFERENCE	
REF	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.0005	0.9945
POS	0.0205353982	0.5491752212	0.0539787611	0.061019469	0.0005	0.0005	0.005280531	0.1126513274	0.0176017699	0.001760177	0.1724973451		0.0045
DKL(POS REF)	0.1073905564	5.5422357445	0.3612126632	0.4194724058		0	0.0162570704	0.8765434293	0.0878628842	0.0022881292	1.4500116381		7.7100235338

Figura I.5: DKL entre positivo e a referência.

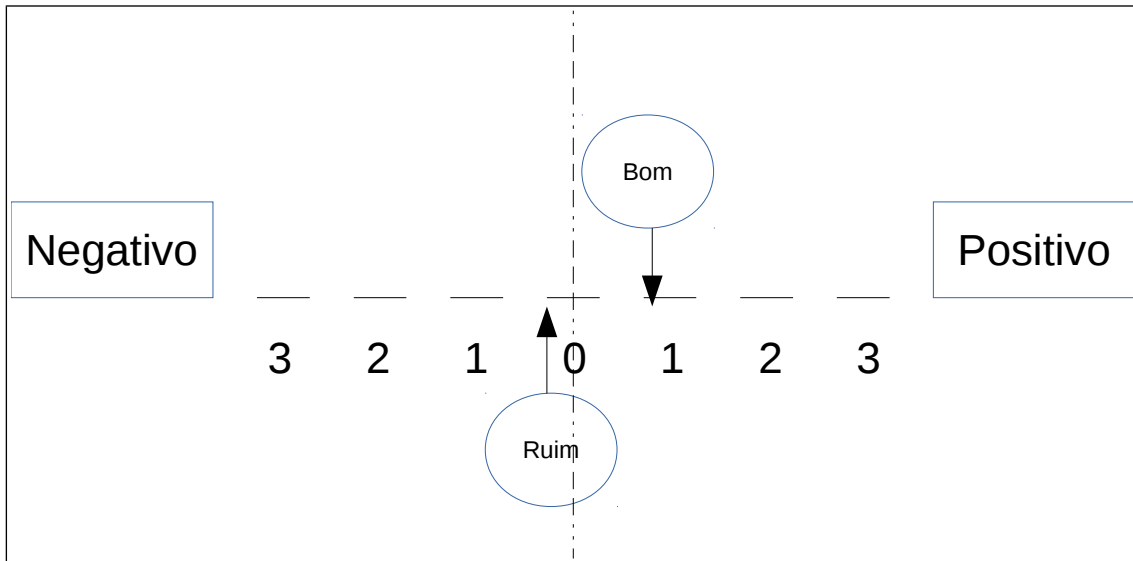
Uma aplicação dessa distância seria encontrar a polaridade de cada uma dessas palavras em relação à referência. Nessa aplicação a polaridade de uma palavra será aquela cuja distância KL para a referência seja a maior. O resultado se encontra na figura I.6. A maior distância é apontada com o inteiro 1.

	Filme	Livro	Gostei	Recomendo	Lixo	Péssimo	Ruim	Bom	Excelente	Casa	História	
NEU	1	1	0	0	0	0	0	0	0	1	1	
NEG	0	0	0	0	1	1	1	0	0	0	0	
POS	0	0	1	1	0	0	0	1	1	0	0	

Figura I.6: A polaridade de uma palavra segundo a maior DKL

Pela figura as palavras “Filme”, “Livro”, “Casa” e “História” são classificadas como neutras. As palavras “Lixo”, “Péssimo” e “Ruim” são classificadas como negativas. As palavras “Gostei”, “Recomendo”, “Bom” e “Excelente” são classificadas como positivas.





*Figura I.7: A inserção da DKL no modelo EPA*

Na figura I.7 se ilustra como a distância KL foi utilizada como medida para inserir uma palavra na dimensão E (avaliação) do modelo EPA.

## APÊNDICE J

### J.1 Teste de independência entre as sentenças – Log Likelihood Ratio

Nessa seção se descreve o “log likelihood ratio” (LLR) e os dois momentos onde foram aplicados na tese.

Dada as características do ReLi (ver seção 6.2.1) foi importante verificar a independência estatística entre os conjuntos de sentenças positivas, negativas e neutras. A ideia subjacente ao experimento é a de que existem três funções distintas que distribuem as palavras entre esses conjuntos. Se a distinção inexistisse, ou seja, a função de distribuição das palavras entre os conjuntos fosse a mesma, seria esperada uma degradação no desempenho de qualquer classificador probabilístico, incluindo os utilizados nessa pesquisa.

Seguindo as sugestões de (MANNING; SCHUETZE, 1999), quando verificam se n-gramas são colocações ou não, foram utilizados dois testes:  $X^2$  e LLR. A vantagem do segundo sobre o primeiro reside em sua resiliência em matrizes esparsas. Essa resiliência é consequência de esse teste não assumir que as variáveis aleatórias (palavras nesse caso) das amostras são normalmente distribuídas, fenômeno que acontece no teste de Pearson ( $X^2$ ) (DUNNING, 1993).

Os resultados estão na tabela J.1, onde cada célula consiste no menor *p-valor* para qual a hipótese nula (as duas distribuições são dependentes) pode ser rejeitada.

Tabela J.1: Teste de independência entre sentenças positivas, negativas e neutras

$X^2$				Log Likelihood Ratio			
	NEU	NEG	POS		NEU	NEG	POS
NEU	1	0	0	NEU	1	0,99	0
NEG		1	0	NEG		1	0
POS			1	POS			1

Na prática rejeitam-se hipóteses nulas para  $p < 0,05$ . Retornando à tabela J.1, pelo teste de Pearson, a hipótese nula deveria ser rejeitada para qualquer par de conjunto de sentenças (excluindo os pares compostos pelo mesmo conjunto – diagonal das matrizes). O mesmo não acontece com o teste de LLR onde não se pode rejeitar a dependência entre sentenças neutras e negativas.

Como já discutido há um desequilíbrio entre o número de elementos dos distintos conjuntos. Uma característica dessa base consiste no grande número de sentenças neutras (70%), pequeno conjunto de sentenças positivas (24%) e, comparativamente, insignificante número de sentenças negativas (6%).

Na implementação desse teste foi utilizada a biblioteca “Apache Commons Maths”<sup>82</sup>. Nela o teste LLR é calculado partindo da matriz K descrita na figura J.1, conforme (DUNNING, 2008).

	Palavra A	¬Palavra A
Classe B	A ^ B	¬A ^ B
Classe ¬B	A ^ ¬B	¬A ^ ¬B

Figura J.1: Matriz para o cálculo de LLR

Aplicando a fórmula:

$$\lambda = 2 * \sum_k (H(k) - H(\text{somaLinha}(k)) - H(\text{somaColuna}(k)))$$
 , onde

$$H \text{ é a entropia calculada } \sum k_{ij} / \text{soma}(k) * \log(k_{ij} / \text{soma}(k))$$
 .

Evento A consistiu em uma palavra do corpus e Evento B em uma classe (neutra, negativa e positiva). Sendo  $\lambda$  uma razão de verossimilhança de uma forma particular então a quantidade  $-2 \log \lambda$  tende assintoticamente à distribuição  $X^2$  (MANNING; SCHUETZE, 1999) APUD (MOOD; GRAYBILL; BOES, 1974). Assim se pode utilizar o valor de  $-2 \log \lambda$  para testar a dependência da palavra A e a classe B. Na prática se escolhem as palavras com maior valor (MANNING; SCHUETZE, 1999).

## J.2 Entropia mútua

A entropia mútua  $I$  entre duas variáveis aleatórias  $X$  e  $Y$  é dada, conforme

(MANNING; SCHUETZE, 1999) por: 
$$\sum_{x,y} p(x,y) \log p \frac{(x,y)}{p(x)p(y)}$$

<sup>82</sup> <http://commons.apache.org/proper/commons-math/>

## APÊNDICE K

### K.1 Arquitetura de um sistema de extração da informação

A discussão da arquitetura pode ser feita de diversas formas. Uma abordagem seria ver o que em comum tem entre aquelas intrinsecamente utilizadas nos diversos artigos sobre análise de sentimento, metodologia utilizada por (TURMO; AGENO; CATALÀ, 2006). (PANG; LEE, 2008), (TANG; TAN; CHENG, 2009) e (FELDMAN, 2013), três influentes revisões nessa área, não propuseram arquiteturas que melhor processassem textos opinativos.

Já autores como (SLOMAN; CHRISLEY; SCHEUTZ, 2005) e (GRATCH; MARSELLA, 2004) propõe arcabouços teóricos para o desenvolvimento de arquiteturas para agentes que simularão emoções, sendo que o segundo o faz sob o paradigma cognitivista. Em (BAILLIE, 2002) e (REISENZEIN et al., 2013) são listadas arquiteturas para desenvolvimento de agentes.

Entretanto todas essas arquiteturas têm como objetivo primário o desenvolvimento de agentes que simularão emoções de forma a melhorar a interação homem-máquina e tornar mais crível o comportamento de um personagem em um jogo.

Se concluiu que o trabalho desenvolvido nessa tese está mais aderente ao paradigma da extração de informação do que os almejados pelos autores acima referenciados.

Segundo (HOBBS, 1993) “a arquitetura de um sistema de extração de informação consiste numa cascata de transformadores ou módulos que a cada passo adicionam estrutura e frequentemente perdem informação, esperançosamente irrelevante, aplicando regras que são adquiridas manualmente e/ou automaticamente”. Dessa forma se optou por uma adaptação daquela proposta em (TURMO; AGENO; CATALÀ, 2006) cujo resultado encontra-se na figura K.1.

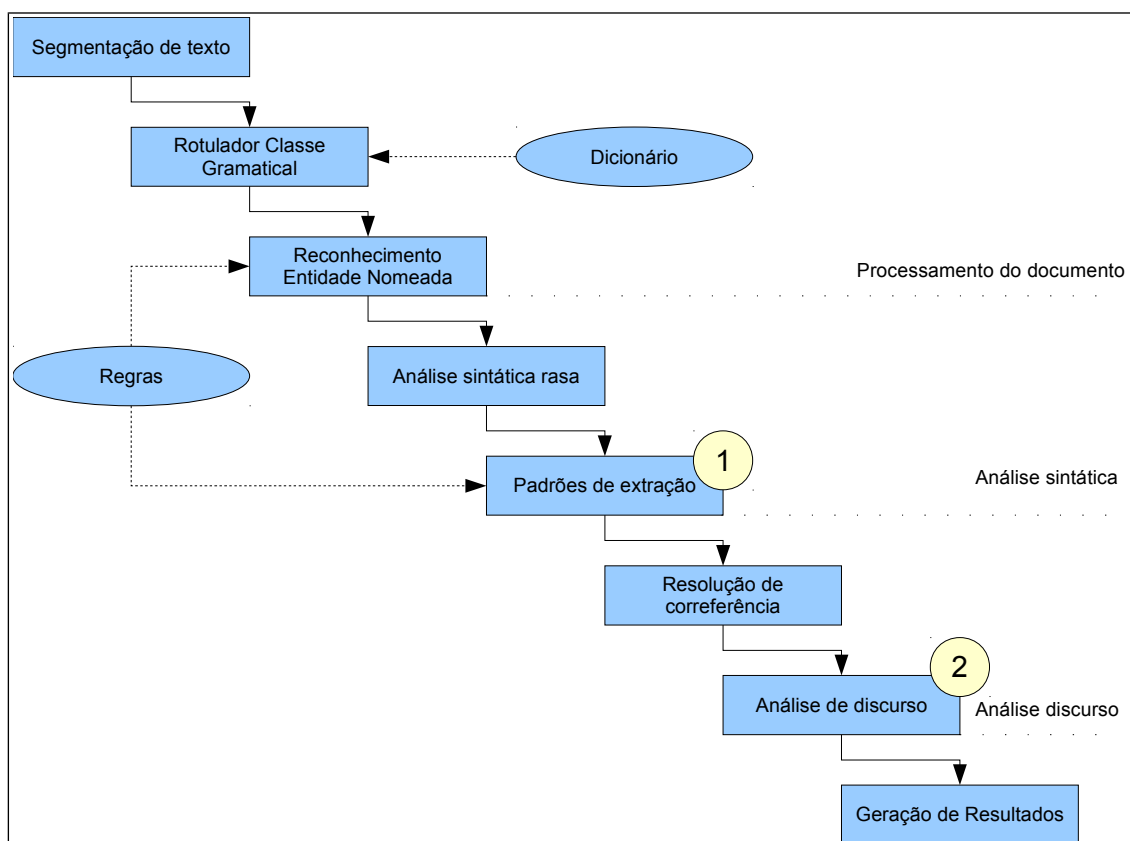


Figura K.1: Arquitetura de sistema de EI extraída de (TURMO; AGENO; CATALÀ, 2006)

No módulo de “Estruturação do Texto” o documento é preparado para o processo de extração. Esta preparação consiste na conversão do tipo do documento (o formato de destino é normalmente o tipo texto), sua segmentação em sentenças e estas desmembradas em seus “tokens” (uma sequência de caracteres entre espaços) constituintes.

O objetivo do transformador “Etiquetador Classe Gramatical” é classificar ou rotular cada “token” de acordo com a sua função gramatical na sentença. Esta classificação é feita através da consulta a dicionários e da aplicação de regras, que levam em consideração o seu contexto, para a desambiguação. Não constando no dicionário o analisador morfológico “adivinha” a classe através da extração do radical (na literatura a função de extração do radical é conhecida como “stemmer”) da palavra e da aplicação de regras gramaticais.

Nomes de empresas, de organizações, de unidades geográficas, de cargos e de pessoas devem ser classificados como nomes próprios, mas não constam de dicionários. O módulo de “Reconhecimento de entidades nomeadas” tem como objetivo reconhecer

e, muitas vezes, classificá-las quanto ao seu tipo.

No transformador “Análise sintática parcial” é feita a rotulação dos sintagmas existentes em uma sentença.

No módulo de “Extração” é preenchido o valor dos elementos que compõe o padrão de extração na medida em que são encontrados no texto.

No transformador de “Resolução de correferência” são resolvidas, normalmente, as anáforas encontradas.

No módulo de “Análise do discurso” os elementos encontrados são agrupados de acordo com o cenário de extração.

No transformador “Geração de resultado” elementos (como data, hora e número de telefone) tem seu formato normalizado.

Nessa pesquisa se aproveitou as anotações do corpus ReLi (seção 6.2.1). Com isso foi necessário implantar os transdutores números 1 e 2 (nos círculos amarelos) na figura K.1. Os padrões de extração consistem naqueles necessários à identificação dos grupos avaliativos e a “análise do discurso” consiste no âmago dessa tese.

## APÊNDICE L

### L.1 Desempenho modelo ME por autor

Sheldon							
ME							
	Positivo	Negativo	Neutro	P	R	F1	Acurácia
Positivo	34	1	13	0.7727	0.7083	0.7391	
Negativo	0	1	1	0.5000	0.5000	0.5000	
Neutro	10	0	73	0.8391	0.8795	0.8588	
Total				0.8120	0.8120	0.8120	

Reboucas							
ME							
	Positivo	Negativo	Neutro	P	R	F1	Acurácia
Positivo	12	1	7	0.2727	0.2500	0.2609	
Negativo	1	1	1	0.5000	0.3333	0.4000	
Neutro	2	0	34	0.8095	0.9444	0.8718	
Total				0.7966	0.7966	0.7966	

Saramago							
ME							
	Positivo	Negativo	Neutro	P	R	F1	Acurácia
Positivo	22	0	18	0.5000	0.4583	0.4783	
Negativo	0	1	0	0.5000	1.0000	0.6667	
Neutro	10	1	117	0.8667	0.9141	0.8897	
Total				0.8284	0.8284	0.8284	

Salinger							
ME							
	Positivo	Negativo	Neutro	P	R	F1	Acurácia
Positivo	14	0	10	0.3182	0.2917	0.3043	
Negativo	0	2	1	1.0000	0.6667	0.8000	
Neutro	3	0	76	0.8736	0.9620	0.9157	
Total				0.8679	0.8679	0.8679	

Orwell							
ME							
	Positivo	Negativo	Neutro	P	R	F1	Acurácia
Positivo	18	0	26	0.4091	0.3750	0.3913	
Negativo	1	0	4	0.0000	0.0000	#DIV/0!	
Neutro	5	0	160	0.8421	0.9697	0.9014	
Total				0.8318	0.8318	0.8318	

Meyer							
ME							
	Positivo	Negativo	Neutro	P	R	F1	Acurácia
Positivo	37	0	26	0.8409	0.7708	0.8043	
Negativo	7	1	14	0.5000	0.0455	0.0833	
Neutro	11	1	165	0.8049	0.9322	0.8639	
Total				0.7748	0.7748	0.7748	

Figura L.1: Desempenho do modelo ME base de desenvolvimento