

FACULDADE OU ESCOLA
PROGRAMA DE PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

GREICE PINHO DAL MOLIN

ANÁLISE MULTIMODAL EM BLOGS BRASILEIROS

Porto Alegre
2019

PÓS-GRADUAÇÃO - *STRICTO SENSU*



Pontifícia Universidade Católica
do Rio Grande do Sul

**PONTIFÍCIA UNIVERSIDADE CATÓLICA DO RIO GRANDE DO SUL
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO**

ANÁLISE MULTIMODAL EM BLOGS BRASILEIROS

GREICE PINHO DAL MOLIN

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre em Ciência da Computação na Pontifícia Universidade Católica do Rio Grande do Sul.

Orientador: Prof. Soraia Raupp Musse

**Porto Alegre
2019**

Ficha Catalográfica

D136a Dal Molin, Greice Pinho

Análise Multimodal em Blogs Brasileiros / Greice Pinho Dal Molin
. – 2019.

115.

Dissertação (Mestrado) – Programa de Pós-Graduação em
Ciência da Computação, PUCRS.

Orientadora: Profa. Dra. Soraia Raupp Musse.

1. cross-media blogset. 2. image sentiment analysis. 3. text sentiment
analysis. 4. lexicons. 5. corpus. I. Musse, Soraia Raupp. II. Título.

Elaborada pelo Sistema de Geração Automática de Ficha Catalográfica da PUCRS
com os dados fornecidos pelo(a) autor(a).

Bibliotecária responsável: Clarissa Jesinska Selbach CRB-10/2051

Greice Pinho Dal Molin

ANÁLISE MULTIMODAL EM BLOGS BRASILEIROS

Dissertação apresentada como requisito parcial para obtenção do grau de Mestra em Ciência da Computação do Programa de Pós-Graduação em Ciência da Computação, Escola Politécnica da Pontifícia Universidade Católica do Rio Grande do Sul.

Aprovado em 30 de Agosto de 2019.

BANCA EXAMINADORA:

Profa. Dra Carla Maria Dal Sasso Freitas (INF/UFRGS)

Profa. Dra. Renata Vieira (PPGCC/PUCRS)

Profa. Dra Soraia Raupp Musse Orientador(a) (PPGCC/PUCRS)

DEDICATÓRIA

Dedico este trabalho a meus pais.

“Quem conhece a sua ignorância revela a mais profunda sapiência. Quem ignora a sua ignorância vive na mais profunda ilusão.”

(Lao-Tsé)

AGRADECIMENTOS

A presente dissertação de mestrado não poderia chegar a bom porto sem o precioso apoio de várias pessoas.

Em primeiro lugar, não posso deixar de agradecer a minha orientadora, Professora Doutora Soraia Raup Musse, por toda a paciência, empenho e sentido prático com que sempre me orientou neste trabalho e em todos aqueles que realizei durante os seminários do mestrado. Muito obrigada por me ter corrigido quando necessário sem nunca me desmotivar.

Desejo igualmente agradecer a todos os meus colegas do Mestrado em Ciência da Computação, especialmente aos colegas do laboratório VHLAB. Agradeço aos funcionários da Secretaria PPGCC, que foram sempre prestativos.

Por último, quero agradecer à minha família pelo apoio incondicional que me deram ao longo da elaboração deste trabalho.

ANÁLISE MULTIMODAL EM BLOGS BRASILEIROS

RESUMO

O uso de mídias sociais está cada vez mais presente em nossas vidas. É através de imagens, textos e vídeos que os seres humanos tentam se comunicar nas redes sociais e expor suas opiniões diante dos acontecimentos cotidianos. Devido ao aumento do volume de dados transmitidos pela internet, torna-se difícil realizar uma análise humana da mídia sem o uso de recursos computacionais. As comunidades científicas, com diversas motivações, tais como: analisar sentimentos em texto, em imagens, detectar opiniões em blogs, dentre outras, sentem-se desafiadas a descobrirem características a serem extraídas desses conteúdos, sendo um exemplo a análise de emoções em blogs. Embora a área de classificação de sentimentos através de textos e imagens esteja em desenvolvimento, ainda existem vários desafios. O principal desafio é construir algoritmos e métodos que possam inferir sentimentos sutis e subjetivos como os humanos os percebem. Neste trabalho é apresentado o corpus *Cross-media Brazilian Blog*, um conjunto de dados que foi construído com base no *BlogSet-BR*. Além disso, construiu-se o *Ground Truth* desses dados (com base nas opiniões de sujeitos) sobre os sentimentos percebidos nos textos e nas imagens destes blogs, que neste trabalho se tornam disponíveis para uso. Algumas tecnologias utilizadas para prever o sentimento em textos e em imagens foram testadas no corpus *Cross-media Brazilian Blog* e comparadas com o *Ground Truth* e são apresentadas e discutidas neste trabalho. Em adição às análises realizadas sobre os textos, realizou-se uma pesquisa especificamente sobre posts contraditórios, ou seja, quando a imagem é positiva e o texto é negativo, ou vice-versa, quando presentes no mesmo blog. Resultados indicam que metodologias para detecção de sentimentos em *blogs* podem ser customizadas para detectar postagens contraditórias e serem capazes de melhor identificar sentimentos nas postagens de mídia social.

Palavras-Chave: cross-media blogset, análise de sentimentos em texto, análise de sentimentos em imagens, corpus, léxicos, contradição entre domínios, CNN.

MULTIMODAL ANALYSIS IN BRAZILIAN BLOGS

ABSTRACT

The use of social media is increasingly present in our lives. It is through images, texts and videos that humans try to communicate on social networks and expose their opinions in the face of everyday events. Due to the increased volume of data transmitted over the Internet, it is difficult to perform a human analysis of the media without the use of computer resources. Scientific communities, with various motivations, such as: analyzing feelings in text, in images, detecting opinions in blogs, among others, feel challenged to discover characteristics to be extracted from these contents, being an example of the analysis of emotions in blogs. Although the area of classification of feelings through texts and images is under development, there are still several challenges. The main challenge is to build algorithms and methods that can infer subtle and subjective feelings as humans perceive them. This paper presents the corpus Cross-media Brazilian Blog, a dataset that was built based on BlogSet-BR. In addition, it was built the Ground Truth of these data (based on the opinions of subjects) about the feelings perceived in the texts and images of these blogs, which in this work become available for use. Some technologies used to predict sentiment in text and images have been tested in the Cross-Media Brazilian Blog corpus and compared with Ground Truth. In addition to the analyzes performed on the texts, a research was conducted specifically on contradictory posts, i.e. when the image is positive and the text is negative, or vice versa, when present on the same blog. Results indicate that methodologies for detecting feelings in blogs can be customized to detect conflicting posts and be able to better identify feelings in social media posts.

Keywords: cross-media blogset, text sentiment analysis, image sentiment analysis, corpus, lexicons, domain contradiction, CNN.

LISTA DE FIGURAS

Figura 3.1 – Quantidade de textos e imagens com a polaridade positiva, neutra e negativa indicadas no corpus através do Léxico 3 e da Rede 3.	43
Figura 3.2 – Texto e imagem no mesmo <i>post</i> indicando a mesma polaridade que pode ser positiva ou negativa informada através da classificação do LIWC e da VGG para textos e imagens respectivamente.	44
Figura 3.3 – Quantidade de textos e imagens com a polaridade positiva, neutra e negativa indicadas no corpus através das anotações realizadas no Figure Eight.	45
Figura 3.4 – Texto e imagem no mesmo <i>post</i> indicando a mesma polaridade que pode ser positiva, neutra ou negativa informada no corpus através das anotações realizadas no <i>Figure Eight</i>	46
Figura 3.5 – Número de posts indicados pela polaridade dos domínios do texto e da imagem. A polaridade do texto está no eixo X e também indica se é um post contraditório ou não-contraditório. No eixo Y, há a quantidade de Posts. No eixo Z tem a polaridade da imagem. Os valores entre o cruzamento dos domínios estão disponíveis em percentual.	48
Figura 3.6 – Distribuição das porcentagens médias dos avaliadores para definição de polaridade em cada domínio nos posts contraditórios. As polaridades do domínio textual com o domínio da imagem são cruzadas, com todas as combinações possíveis de resultados.	49
Figura 3.7 – 29 posts considerados contraditórios no GT e distribuídos entre positivo, neutro e negativo, com predominância de sentimento neutro no domínio das imagens.	49
Figura 3.8 – 20 posts considerados contraditórios no GT e distribuídos principalmente em polaridade neutra, aparentemente indicando que são necessários mais elementos para definir a polaridade.	50
Figura 3.9 – Quando um dos domínios foi classificado com polaridade neutra, foi utilizada a polaridade do outro domínio, sendo denominada resultado da possível polaridade. Na legenda, Post GT corresponde ao resultado do GT e Polaridade possível implica predominância da polaridade em função de um dos domínios não ter polaridade neutra no Post.	51
Figura 3.10 – Distribuição de Posts de acordo com a porcentagem de anotadores que definem a polaridade dos domínios separadamente nos Posts contraditórios.	51

Figura 3.11 – Distribuição das porcentagens médias dos avaliadores para a definição de polaridade em cada domínio nos posts não contraditórios. As polaridades do domínio textual com o domínio da imagem são cruzadas, com todas as combinações possíveis de resultados.	52
Figura 3.12 – Os valores entre domínios estão disponíveis em percentuais médios dos anotadores para definir a polaridade do domínio. A polaridade do texto está no eixo X dos posts não contraditórios. No eixo Y, mostra a porcentagem. No eixo Z tem a polaridade da imagem.	52
Figura 3.13 – Os valores entre domínios estão disponíveis em percentuais médios de avaliadores para definir a polaridade do domínio. A polaridade do texto está no eixo X dos posts não contraditórios. No eixo Y, mostra a porcentagem. No eixo Z tem a polaridade da imagem.	53
Figura 3.14 – Desvio padrão da porcentagem do anotador para definir polaridades do domínio. Os domínios e a polaridade foram cruzados para ter todas as combinações possíveis, mostrando Posts contraditórios e Não-Contraditórios.	54
Figura 4.1 – Apenas a quantidade de imagens distribuídas pela polaridade positiva, neutra e negativa indicadas no corpus através das anotações realizadas no <i>Figure Eight</i> (GT) sendo classificadas pela rede SentiBank.	74
Figura 4.2 – Apenas quantidade de imagens cuja polaridade é positiva, neutra e negativa indicadas no GT Imagens através das anotações realizadas no <i>Figure Eight</i> e sendo classificadas pela DeepSentiBank.	75
Figura 4.3 – Quantidade de imagens com a polaridade positiva, neutra e negativa indicadas no dataset através dos critérios adotados.	77
Figura 4.4 – Imagens com polaridade positiva, neutra e negativa do <i>dataset</i> de Imagens do Google (IG), sendo verificadas se as polaridades classificadas nas Redes SentiBank, DeepSentiBank e VGG equivalem ao IG.	79
Figura 4.5 – Distribuição quantitativa de textos através da avaliação do OpLexicon e GT Texto.	81
Figura 4.6 – Distribuição quantitativa dos textos através da avaliação do SentiLex e GT Texto.	81
Figura 4.7 – Distribuição quantitativa de textos através da avaliação do LIWC e GT Texto.	82
Figura 4.8 – Distribuição quantitativa de textos através da avaliação do NLTK.	83
Figura 4.9 – 10 <i>post</i> não contraditórios representados por seus Números do <i>post</i> e com a quantificação de palavras de cada classe gramatical. Mais detalhes podem ser verificados nas Tabelas 4.9 a 4.18.	95

Figura 4.10 – 10 <i>posts</i> contraditórios com a quantificação dos dados de análise que podem ser visualizadas com mais detalhes nas Tabelas 4.20, 4.21, 4.22, 4.23, 4.24, 4.25, 4.26, 4.27, 4.28, 4.29.	96
Figura 4.11 – Média Aritmética do número de palavras das classes gramaticais detectadas por <i>post</i>	107
Figura 4.12 – Quantidade de <i>post</i> não-contraditórios (851 <i>posts</i>) do CBB distribuídos conforme o percentual de subjetividade à esquerda. À direita indica a quantidade de <i>post</i> contraditórios (29 <i>posts</i>) do CBB distribuídos conforme o percentual de subjetividade.	107

LISTA DE TABELAS

Tabela 3.1 – Imagens de exemplo processadas pela SentiBank, DeepSentiBank e VGG-T4SA, representados pelos números romanos I, II e III respectivamente.	37
Tabela 3.2 – Frase de exemplo processada com OpLexicon, SentiLex e LIWC . . .	41
Tabela 3.3 – Frase de exemplo processada com OpLexicon, SentiLex e LiWC em que as stopwords não foram removidas no pré-processamento para os Léxicos OpLexicon e SentiLex.	42
Tabela 3.4 – Quantidade de <i>posts</i> indicando contradições conforme as anotações realizadas no <i>Figure Eight</i>	45
Tabela 3.5 – Quantidade de <i>posts</i> identificados como contraditórios, havendo a definição da polaridade predominante conforme as anotações realizadas no Figure Eight.	45
Tabela 3.6 – Mediana da subjetividade dos textos considerando a classificação dos <i>posts</i>	46
Tabela 3.7 – Porcentagem média de anotadores que indicam se um Post é Contraditório ou Não-Contraditório.	47
Tabela 3.8 – Instruções	56
Tabela 3.9 – Example: As imagens podem ser classificadas como positiva, neutra ou negativa	56
Tabela 3.10 – Exemplo de questão para definir o sentimento na imagem.	57
Tabela 3.11 – Julgar o sentimento dominante em <i>posts</i> em português.	57
Tabela 3.12 – Exemplos de textos que podem ser classificados como positivos, neutros ou negativos.	58
Tabela 3.13 – Julgar o sentimento dominante em <i>posts</i>	59
Tabela 3.14 – Exemplos de <i>posts</i> classificados como positivos, neutro e negativo. .	60
Tabela 3.15 – Example: The pictures can be classified as positive, negative or neutral	61
Tabela 3.16 – Frase de exemplo pré-processada, traduzida e com características para detectar contradição. Esse <i>Post</i> foi definido como NÃO-contraditório no GT.	68
Tabela 3.17 – Frase de exemplo pré-processada, traduzida e características para detectar contradição. Esse <i>Post</i> foi definido como NÃO-contraditório no GT.	69
Tabela 3.18 – Frase de exemplo pré-processada, traduzida e características para detectar contradição. Esse <i>Post</i> foi definido como NÃO-contraditório no GT.	70

Tabela 3.19 – Frase de exemplo preprocessada, traduzida e características para detectar contradição. Esse <i>Post</i> foi definido como Contraditório e também indica Ironia.	71
Tabela 3.20 – Frase de exemplo preprocessada, traduzida e características para detectar contradição. Esse <i>Post</i> foi definido como Contraditório e também indica Ironia.	72
Tabela 4.1 – Comparando os resultados da classificação da SentiBank com o GT Imagens, resulta em 39,20% de acerto	73
Tabela 4.2 – Comparando os resultados da classificação da DeepSentiBank com o GT das imagens, resulta em 40,56% de acerto	75
Tabela 4.3 – Comparando os resultados da classificação da Rede VGG com o GT das imagens positivas e negativas apenas, resulta em 67,68% de acerto.	76
Tabela 4.4 – Comparando os resultados da classificação do Classificador SentiBank, e das Redes DeepSentiBank e VGG com o GT, resultando em predições em torno de 39,20%, 40,56% e 32,84% (considerando as neutras) e 67,68% (sem considerar as neutras) de acurácia em cada rede, respectivamente	76
Tabela 4.5 – Imagens de exemplo processadas pela SentiBank, DeepSentiBank e VGG, representadas pela numeração I, II e III respectivamente. A primeira linha indica uma imagem negativa, a segunda linha se trata de sentimento neutro e a terceira linha retrata uma imagem positiva, de acordo com as pesquisas realizadas no Google.	78
Tabela 4.6 – Mostrando os resultados da classificação da Rede SentiBank, DeepSentiBank e VGG em cada classe.	78
Tabela 4.7 – Comparando os resultados da classificação da Rede SentiBank, DeepSentiBank e VGG com o IG, resultando em predições em torno de 72,07%, 72,51% e 91,23% de acurácia em cada rede, respectivamente.	79
Tabela 4.8 – Comparando os resultados da classificação dos léxicos OpLexicon, Sentilex, LIWC e NLTK com o GT, resultando em predições em torno de 44,65%, 45,45%, 43,29% e 58,22% de acurácia em cada léxico, respectivamente.	83
Tabela 4.9 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Neutra, de acordo com o GT.	85
Tabela 4.10 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Positiva, de acordo com o GT.	86
Tabela 4.11 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Negativa, de acordo com o GT.	87

Tabela 4.12 – <i>Post</i> NÃO contraditório com emoção predominantemente Negativa, de acordo com o GT	88
Tabela 4.13 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Neutra, de acordo com o GT.	89
Tabela 4.14 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Neutra, de acordo com o GT.	90
Tabela 4.15 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Negativa, de acordo com o GT.	91
Tabela 4.16 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Negativa, de acordo com o GT.	92
Tabela 4.17 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Positiva, de acordo com o GT.	93
Tabela 4.18 – <i>Post</i> considerado NÃO-contraditório com emoção predominantemente Positiva, de acordo com o GT.	94
Tabela 4.19 – Médias de ocorrência nos 10 <i>posts</i> contraditórios e não-contraditórios analisados por classe gramatical.	96
Tabela 4.20 – <i>Post</i> considerado contraditório com emoção predominantemente Positiva, de acordo com o GT.	97
Tabela 4.21 – <i>Post</i> considerado contraditório com emoção predominantemente Negativa, de acordo com o GT.	98
Tabela 4.22 – <i>Post</i> considerado contraditório com emoção predominantemente Negativa, de acordo com o GT.	99
Tabela 4.23 – <i>Post</i> considerado contraditório com emoção predominantemente Positiva, de acordo com o GT.	100
Tabela 4.24 – <i>Post</i> considerado contraditório com emoção Positiva, de acordo com o GT.	101
Tabela 4.25 – <i>Post</i> contraditório com emoção predominantemente Negativa, de acordo com o GT.	102
Tabela 4.26 – <i>Post</i> considerado contraditório com emoção Negativa, de acordo com o GT.	103
Tabela 4.27 – <i>Post</i> contraditório com emoção Positiva, de acordo com o GT.	104
Tabela 4.28 – <i>Post</i> contraditório com emoção Positiva, de acordo com o GT.	105
Tabela 4.29 – <i>Post</i> considerado contraditório com emoção Positiva, de acordo com o GT.	106

SUMÁRIO

1	INTRODUÇÃO	27
2	TRABALHOS RELACIONADOS	29
3	TECNOLOGIAS UTILIZADAS	35
3.1	TECNOLOGIAS USADAS PARA A DETECÇÃO DE EMOÇÕES EM IMAGENS .	35
3.1.1	SENTIBANK	35
3.1.2	DEEPSSENTIBANK	36
3.1.3	VGG-T4SA	37
3.2	TECNOLOGIAS USADAS PARA A DETECÇÃO DE EMOÇÕES EM TEXTOS .	38
3.3	CORPUS CROSS-MEDIA BRAZILIAN BLOG	42
3.3.1	UMA BREVE ANÁLISE DO CBB	47
3.3.2	PROCESSO DE ANOTAÇÕES COM FIGURE EIGHT	54
3.3.3	QUESTIONÁRIOS CRIADOS NO <i>FIGURE EIGHT</i> PARA A VALIDAÇÃO DO CORPUS	55
3.4	UMA ANÁLISE SOBRE CONTRADIÇÃO NO GROUND TRUTH	58
3.4.1	ANÁLISE DE CONTRADIÇÃO	58
3.4.2	TÉCNICAS USADAS PARA DETECÇÃO DE ELEMENTOS DE CONTRADI- ÇÃO NOS TEXTOS DO GT	65
3.4.3	EXEMPLOS DE TEXTOS EXTRAÍDOS DO CBB PARA USO DA TÉCNICA DE DETECÇÃO DE CONTRADIÇÃO	67
4	RESULTADOS DOS EXPERIMENTOS	73
4.1	RESULTADOS OBTIDOS COM CLASSIFICAÇÃO DAS IMAGENS	73
4.1.1	SENTIBANK	73
4.1.2	DEEPSSENTIBANK	74
4.1.3	VGG-T4SA	75
4.1.4	COMPARAÇÃO DO CLASSIFICADOR E DAS 2 REDES USADAS NA CLAS- SIFICAÇÃO DAS IMAGENS	76
4.1.5	COMPARANDO CBB E OUTRO <i>DATASET</i> - GOOGLE IMAGES	76
4.2	RESULTADOS OBTIDOS COM CLASSIFICAÇÃO DOS TEXTOS	80
4.2.1	OPLEXICON	80
4.2.2	SENTILEX	80

4.2.3	LIWC	82
4.2.4	NLTK	82
4.2.5	COMPARAÇÃO DOS 4 LÉXICOS USADOS NA CLASSIFICAÇÃO DOS TEXTOS EM RELAÇÃO AO GT	83
4.3	RESULTADOS DAS CONTRADIÇÕES NO GROUND TRUTH	84
4.3.1	RESULTADO DA ANÁLISE EM AMOSTRA DE 10 <i>POSTS</i> NÃO-CONTRADITÓRIOS	84
4.3.2	RESULTADO DA ANÁLISE EM AMOSTRA DE 10 <i>POST</i> CONTRADITÓRIOS .	95
4.3.3	ANÁLISE DO CBB BASEADO NA DETECÇÃO DE CONTRADIÇÃO	96
5	CONCLUSÃO	109
	REFERÊNCIAS	111

1. INTRODUÇÃO

A análise de sentimentos tem como objetivo automatizar técnicas de extração de informações como opiniões e sentimentos dos textos, imagens, vídeos, com o intuito de gerar dados estruturados que poderão ser utilizados em um sistema para tomada de decisão, como discute Soleymani et al. [SGJ⁺17]. Existem diversos estudos na área de classificação de sentimentos em textos que foram desenvolvidos e apresentados ao longo dos últimos anos no contexto de redes sociais. A classificação de sentimentos a partir de imagens ainda está em desenvolvimento porque, como demonstra Joshi et al. [JDF⁺11], envolve um alto nível de abstração e subjetividade no processo de reconhecimento pelo ser humano, englobando tarefas de reconhecimento visual dos mais variados, indicando que para uma aprendizagem supervisionada seriam necessários milhões de imagens rotuladas e diversificadas para cobrir os domínios pertinentes.

É indiscutível que as imagens transmitem emoções com muito mais facilidade do que os textos. Com base nisso, usamos muito mais imagens nas redes sociais para expressar sentimentos, hoje em dia, do que textos segundo Xu et al. [XCLL14]. Como as emoções são percebidas por cada indivíduo de maneira diferente, a subjetividade desempenha um papel intrínseco no processo de reconhecimento das emoções pelo ser humano. Acredita-se que esse seja um dos principais desafios nas investigações para indexar emoções em imagens conforme é tratado por Schmidt et al. [SS09]. Mesmo com limitações, analisar a emoção em imagens tem aplicabilidade em diversas áreas, tais como, indústria, economia, publicidade e saúde, pois a imagem apresenta expressividade. Inclusive, vem sendo objeto de desenvolvimento em grandes empresas e ocasionando o surgimento de muitas *start-ups*. Muitas tarefas na área de classificação de sentimentos em imagens e textos exigem que haja um corpus de treinamento e de teste para confirmar que a aplicação de técnicas no reconhecimento de padrões está sendo adequadamente realizada. Normalmente os conjuntos de dados usados para criação do *Ground Truth* tratam apenas de um domínio, sendo texto ou imagem. Por isso, o objetivo principal desta dissertação é estudar e utilizar tecnologias disponíveis para análise de emoções, em particular, comparando *blogs* com textos e imagens, que são classificadas separadamente para se obter o sentido do conteúdo separado, bem como do *blog* como um todo.

Para realizar a classificação de sentimentos em imagens, usamos o classificador VGG-T4SA, como proposto por Vadicamo et al. [VCC⁺17], no qual o treinamento é realizado usando um conjunto de dados em larga escala de *tweets* não rotulados (texto e imagens). Também utilizamos o SentiBank 1.1 [BCJC13], que é um classificador de emoções construído a partir da ontologia do sentimento visual e que foi baseado em um modelo psicológico de emoções conhecido como a Roda das Emoções de Plutchik [Plu80]. Por fim, foi utilizada a rede convolucional DeepSentiBank [CBDC14] porque é uma outra abordagem do

classificador SentiBank para classificação de sentimentos em imagens, e, de acordo com os autores, a acurácia melhorou 8% em relação a predição do SentiBank.

Para a predição textual, usamos os dicionários léxicos LIWC dictionary, OpLexicon e SentiLex que se utilizam de palavras em português para avaliação da polaridade. Também foi usado NLTK (Natural Language ToolKits) ¹ que é uma ferramenta conhecida na manipulação de textos e útil para análise de polaridade de palavras e subjetividade. Além da análise feita separadamente para textos e imagens, também analisamos os dois domínios pertencentes a um mesmo *blog*. Podemos resumir a contribuição deste trabalho da seguinte forma:

- Criação de um corpus de *blogs* em português chamado de *Cross-media Brazilian Blog*, denominado CBB, incluindo textos e imagens de *posts* criados por usuários;
- Classificação de emoções em imagens e textos, separados e juntos, no *blog* testado por sujeitos usando *Figure Eighth* ², uma plataforma de *crowdsourcing* para realizar tarefas de alto volume e repetitivas. Este processo culminou na geração do *Ground Truth* do corpus;
- Avaliação de tecnologias disponíveis em nosso conjunto de dados CBB, comparando os resultados com a verdade básica obtida no *Ground Truth*; e
- Discussão de *posts* contraditórios com o objetivo de encontrar métricas que possam ser usadas para melhorar os resultados automáticos.

Esta dissertação está organizada da seguinte forma: o Capítulo 2 apresenta vários trabalhos na área de análise de sentimentos em textos e imagens, assim como trata de diferentes técnicas para classificação de sentimentos e contradições entre domínios, um tema ainda bastante recente nessa área; o Capítulo 3 explica o método proposto para essa dissertação, informando como ocorreu a construção do corpus e o processo de anotações envolvido. É feita uma breve explicação sobre redes neurais e os modelos utilizados para a classificação de imagens. São descritos os léxicos textuais usados e as técnicas utilizadas para prever a polaridade nos textos. Também é feita uma explanação sobre análise de contradição e as técnicas a serem trabalhadas na análise dos textos, inclusive buscando a identificação manual da ironia; o Capítulo 4 apresenta alguns resultados do estudo proposto através de uma visão geral estatística do conteúdo dos dados coletados em textos e imagens. Além disso, é indicada uma visão geral sobre análise de contradições e descritos alguns casos com informações relevantes observadas. Por fim, o Capítulo 5 aborda algumas conclusões e sugestões para trabalhos futuros que ainda pretendemos realizar.

¹<https://www.nltk.org/>

²<https://figure-eight.com>

2. TRABALHOS RELACIONADOS

Muitos estudos na área de classificação de sentimentos por meio de textos e imagens foram propostos, no entanto dada a subjetividade do problema, o desafio continua posto nas pesquisas recentes. Sarlan et al. [SNB14] descrevem que as redes sociais são usadas por milhões de pessoas que escrevem de qualquer forma sobre os mais variados assuntos. Também indicam que as mídias sociais são uma oportunidade para os negócios, uma vez que podem conversar diretamente com clientes, anunciar produtos e serviços. Então, se uma empresa consegue saber o que o seu cliente deseja, ela consegue mudar o seu comportamento mais rapidamente e ter uma tomada de decisão para competir no mercado, conseguindo conquistar clientes. A grande dificuldade ainda se encontra na extração dos dados que pode influenciar, por exemplo, na análise de sentimentos em textos. O coloquialismo e as gírias em sistemas capazes de detectar sentimentos nem sempre são tratados, podendo prejudicar o processo de análise e tomada de decisão. Soleymani et al. [SGJ⁺17], discute a área de análise de sentimentos e suas recentes mudanças, porque os usuários de redes sociais não estão usando apenas recursos textuais, mas também áudio, vídeo e imagem. Em relação à análise de imagens, Joshi et al. [JDF⁺11] referem-se à classificação de sentimentos em imagens por envolver um alto nível de abstração e subjetividade no processo de reconhecimento humano, englobando tarefas de reconhecimento visual, como de objetos, cenas, ações e eventos. Isso indica que, para o aprendizado supervisionado, milhões de imagens rotuladas e altamente diversificadas são necessárias para cobrir os mais diversos domínios. Vadicamo et al. [VCC⁺17], propõem um classificador de sentimento em imagens que utiliza um grande conjunto de conteúdos gerados e não rotulados pelo usuário. Eles compararam estudos e avaliações para análise de sentimento visual e descobriram que os textos contêm muitos ruídos, tornando-se fracamente correlacionados com a imagem.

YOU et al. [YLJY15] compara os *tweets* com as imagens postadas em conjunto e tenta descobrir a emoção do tweet usando esses dois recursos. Eles usam uma Rede Neural Convolutiva (CNN) proposta pelos autores para análise de sentimentos em imagens usando Flickr e vídeos. Eles consideram as redes sociais uma fonte de informações sobre a vida das pessoas, porque os usuários adoram postar suas experiências e compartilhar suas opiniões sobre uma ampla gama de assuntos como tópicos de pesquisa utilizando eleições políticas, filmes e indicadores econômicos. Os autores usam uma estrutura para classificar recursos usando o trabalho de LeCun [LBD⁺08], que apresenta uma rede de retropropagação aplicando-a no reconhecimento de dígitos do código postal dos EUA, e de Ciresan [CMGS10], que usou retropropagação em uma rede perceptron multicamadas (MLP) - que é semelhante à perceptron, mas com mais de uma camada de neurônios em alimentação feedforward - e aplicou o dataset de dígitos manuscritos nela, obtendo uma baixa taxa de erro, entre outros. Os autores sugerem que o aprendizado profundo é muito eficaz

no aprendizado robusto de recursos para um ambiente supervisionado e não supervisionado. Jinda e Singh [JS15] propõem uma estrutura de predição de sentimento de imagem usando Redes Neurais Convolucionais (CNN) cuja estrutura é treinada em dados de grande escala para reconhecimento de objetos. Para construção do dataset de treino, foi conduzida uma pesquisa sobre o conjunto de dados de imagem do Flickr e rotulados manualmente. Joshi et al. [JDF⁺11] tentam verificar os principais aspectos da estética, emoções e problemas computacionais referentes a imagens. Fazem uma discussão em diversas áreas, tais como: psicologia, filosofia, artes visuais, entre outras. Propõem uma forma de discussão sobre os *datasets* disponíveis para o objetivo da pesquisa deles, apresentando uma análise dos dados e classificação. Dentre alguns questionamentos levantados nesse trabalho, está o entendimento social, cultural e a preferência individual em relação aos dados - ou seja, um julgamento em relação à estética e à emoção que pode ser afetado pelo conhecimento cultural e social.

O aprendizado de *cross-media* tem sido um assunto bem estudado recentemente. Chen et al. [CZYL17] comentam sobre métodos para classificar sentimentos em imagens confrontando domínios. O objetivo é trabalhar com discrepâncias entre domínios textuais e de imagem. A forma utilizada é através de amostras classificadas e altamente confiáveis para a redução de divergências entre domínios. O treinamento é feito com dois classificadores de sentimento, um de texto e outro de imagens. Com base nas classificações realizadas separadamente, é feito um cruzamento entre os domínios de origem e de destino para verificar similaridade, conforme definido no artigo. Wiesen e HaCohen-Kerner [WHK18] descrevem uma visão geral dos modelos de representação unimodais e multimodais para a tarefa de classificação. Os autores propõem classificar os *tweets* e o desafio a ser enfrentado na aprendizagem de múltiplas modalidades ao encontrar uma representação eficiente e a fusão de várias representações. Peng et al. [PHZ17] descrevem uma visão geral sobre consulta e resultado de *cross-media*, abordando um assunto novo, que ainda não tem muita clareza na literatura. Abordam conceitos, metodologias, desafios e questões que ainda estão em aberto com base na análise de 100 referências bibliográficas no assunto. Ainda, os autores constroem um novo *dataset* chamado de XMedia que contém texto, imagem, vídeo, áudio e modelo 3D para uso público a fim de novos pesquisadores poderem se concentrar na criação de algoritmos que auxiliem na recuperação de *cross-media*.

Yu et al [YLMZ16] investigam a análise de sentimentos baseada em conteúdo multimodal, a qual consideram uma tarefa desafiadora. Usam modelos de redes neurais profundas com o intuito de extrair tanto recursos visuais como textuais a fim de analisar os sentimentos de *microblogs* chineses. Indicam que o modelo proposto supera o estado da arte de modelos que fazem análise de sentimentos de apenas um dos domínios. No trabalho de Yan et al. [YNL⁺16] é proposto um algoritmo de aprendizado que usa *cross-media* para rotular imagens. Para isso, foram usadas imagens da internet que estão associadas a textos. Borth et al. [BCJC13] descrevem um classificador de sentimentos de imagem que

usa um modelo psicológico de emoções chamado Roda das Emoções de Plutchik [Plu80]. Inicialmente, eles trabalham com o processo de mineração de dados, usando as 24 emoções da teoria de Plutchik para encontrar imagens em um *tweet* e rotulá-las. Em seguida, a análise de texto e as ferramentas de análise de sentimento baseadas no léxico são aplicadas para detectar o sentimento polarizado (positivo, neutro ou negativo) dos rótulos criados. Em seguida, um treinamento de classificador usando aprendizado de máquina é feito para cada emoção rotulada nas imagens usadas nas etapas anteriores. Finalmente, os autores descrevem uma visão geral do modelo através de aplicações de visualização dos sentimentos negativos, neutros e positivos detectados em imagens, bem como os rótulos que foram criados.

Araújo et al. [AGBC13] indicam que muitos estudos relacionados às redes sociais trabalham com a identificação de polaridade em mensagens compartilhadas, estando ligadas ao humor e a emoções expressas pelos usuários. Mas, também comentam que os métodos para análise de sentimentos estão sendo muito usados em aplicações sem estudo prévio sobre suas vantagens e desvantagens. A proposta deles é usar os métodos existentes para análise de sentimento em mensagens curtas e em tempo real. Utilizaram 2 bases de dados diferentes advindas de redes sociais online e 8 métodos propostos na literatura. Com base nos estudos que fizeram, desenvolveram um método de análise de sentimentos que consistia em alcançar maior abrangência (a fração de mensagens capturadas por cada método) e concordância (identificação correta do sentimento por cada método). Na pesquisa de Chen et al. [CBDC14] é proposto um método de classificação de sentimento visual com base em redes neurais profundas (CNN). Consideram sentimentos visuais os pares de substantivos e adjetivos (ANPs), que são detectados nas *tags* das imagens na *web*. Informam também que essas *tags* podem ser utilizadas como pistas estatísticas para detectar a emoção indicada na imagem. Milhares de imagens do Flickr foram utilizadas para o treinamento, validação e teste do classificador de conceitos. O modelo é treinado no *Framework Caffe* [BRSS15]¹ e utilizam os pesos da rede ImageNet [DDS⁺09] a fim de poderem tratar os limites que existem nas imagens e para evitar o *overfitting* - termo usado em estatística para descrever quando um modelo estatístico se ajusta muito bem ao conjunto de dados anteriormente observado, mas se mostra ineficaz para prever novos resultados. Esse modelo é chamado de DeepSentiBank, que corresponderia ao SentiBank 2.0. Apresenta melhoria significativa tanto na precisão como no desempenho em relação ao modelo binário SentiBank 1.1.

A Análise de Sentimentos em textos é uma técnica que consiste em extrair informações de textos em linguagem natural. O objetivo dessa técnica é obter de forma automática a polaridade de um texto ou sentença. Por exemplo, dada uma sentença um computador classifica como positivo ou negativo essa sentença. Pode-se citar como léxicos bastante utilizados em pesquisas científicas os seguintes:

¹<https://caffe.berkeleyvision.org/>

- O método LIWC [BFPA13], é um recurso bem conhecido para analisar sentimentos em textos.
- O método OpLexicon [SV12] é um léxico de sentimento para a língua portuguesa, composto de 32.191 linha. Atualmente está na versão 3.0 que foi revisada por linguistas em relação a polaridade de alguns adjetivos.
- O método SentiLex [CS15] é um léxico de sentimentos para o português que é composto de aproximadamente 6.000 adjetivos e 25.000 formas flexionadas.

Existem poucos trabalhos publicados na área de análise de contradição em sentimentos, que consiste em uma incompatibilidade lógica entre dois ou mais domínios. Dentre eles, temos: Hillard et al. [HOS03] descrevem uma forma de detectar concordância ou discordância de gravações em áudio de reuniões que ocorrem nas organizações. O objetivo é detectar contradições nas interações entre as pessoas. Os rótulos de concordância e discordância são considerados como uma forma de categorização do ato de falar, usando recursos prosódicos e palavras. Nesse estudo, são exploradas técnicas de treinamento não supervisionadas através de um grande volume de dados não rotulados. A contribuição de Harabagiu et al. [HHL06] consiste em indicar um método para reconhecer contradições que se utiliza de uma estrutura que combina processamento e remoção de negação, usa a mineração do WordNet ² para a derivação de antonímia e trata do problema de classificação para reconhecer as relações de alinhamento textual.

Marneffe et al. [DMRM08] buscam definir contradição para tarefas de processamento de linguagem natural (PLN) e tipificar contradições juntamente com seu grau de complexidade. Informa aplicações das contradições, tais como: debates políticos, nos assuntos que os candidatos indicam opiniões divergentes; em relatórios de inteligência demonstrando quais informações podem precisar de verificação adicional; na bioinformática, onde a interação proteína-proteína é amplamente estudado, encontrando automaticamente fatos conflitantes sobre tais interações, dentre outros, esse método foca em tipos de contradição por negação e antônimo que são menos complexos de tratar.

Singh [Sin12] traz os conceitos de humor, ironia e sátira. Indica que há diferenças e semelhanças entre elas. Trata da ironia conceitualmente e define três tipos principais existentes na literatura: a verbal, a dramática e a situacional. Dias et al. [DB16] descrevem detecção de posicionamento em *tweets* com base em uma abordagem semi-supervisionada, pois necessita da entrada de um conjunto de palavras que representem, no domínio, alvos relacionados ou expressões que caracterizem apoio ou oposição. Para isso, usam detecção de polaridade, sendo o maior desafio descobrir o sentimento referente à temática. Criam um corpus para treinamento do trabalho através de rotulagem automática, usando *hashtags*. Nesse trabalho, consideram domínios distintos política, feminismo,

²<https://wordnet.princeton.edu/>

legalização do aborto, ateísmo e mudança do clima. Oliveira et al. [dFO14] analisam a polaridade nos *tweets* em função dos protestos que ocorreram no Brasil entre os meses de Junho e Agosto de 2013 a fim de verificar o apoio ou não em relação às manifestações através das opiniões. Criaram um corpus através da coleta de mensagens no período relevante de estudo, sendo de interesse dos autores a escrita em português brasileiro por haver poucos trabalhos nesse idioma. Hutto et al. [HG14] descrevem o desenvolvimento, validação e avaliação do *VADER* (*valence aware dictionary for sentiment reasoning*) que é baseado em léxicos de palavras relacionados ao sentimento com intensidade. Trabalham com várias combinações de métodos qualitativos e quantitativos para validação desse léxico que está relacionado a sentimentos e que usa um contexto muito parecido com *microblogs*. Também usam convenções gramaticais e sintáticas utilizados pelos seres humanos para se expressar ou intensificar um sentimento. Fazem descobertas heurísticas que melhoram a precisão do processo de análise de sentimentos em muitos domínios.

Neste trabalho, apresentamos nosso corpus CBB com textos em português e o GT, associado aos textos e imagens, para testar as tecnologias disponíveis. Pelo que sabemos, não há pesquisa anterior abordando um corpus em português que contenha informações sobre textos e imagens juntos, inclusive com dados para análise de contradição. Fizemos análise das postagens contraditórias para encontrar métricas que possam ser usadas para melhorar as classificações automáticas de emoção. No Capítulo 3, é apresentado o modelo de trabalho proposto.

3. TECNOLOGIAS UTILIZADAS

Conforme mencionado anteriormente, este trabalho visa criar um Corpus com *Ground Truth* e testar tecnologias disponíveis para detecção de sentimentos em imagens e textos. Este capítulo apresenta a metodologia proposta organizada em três etapas: primeiro, a descrição das tecnologias testadas para detecção de emoção em imagem e texto. Inicia-se apresentando as tecnologias utilizadas (Seções 3.1 e 3.2) para classificação de sentimentos em *posts*. As tecnologias são apresentadas anteriormente ao detalhamento do Corpus, pois duas delas foram usadas como ferramentas de pré-seleção de dados, na construção do Corpus, introduzido neste trabalho. A Seção 3.3 detalha o corpus *Cross-media Brazilian Blog* (CBB) e a metodologia proposta para sua criação. Por fim, na Seção 3.4.1 são descritos alguns aspectos sobre contradição no contexto dos textos analisados.

3.1 Tecnologias usadas para a detecção de emoções em imagens

Para realizar a classificação de sentimento em imagens do corpus são utilizados um classificador e duas redes no corpus, sendo uma a SentiBank [BCJC13], a outra a DeepSentiBank [CBDC14] e a última a VGG-T4SA [VCC⁺17] respectivamente. Importante salientar que neste trabalho os três recursos para classificação de sentimento são usados para estudos comparativos e avaliações no presente trabalho, ou seja, são efetuados apenas testes de classificação, não havendo retreino de quaisquer das tecnologias citadas. As próximas seções descrevem as referidas tecnologias.

3.1.1 SentiBank

Trata-se de um classificador de emoções construído a partir da ontologia de sentimento visual. Segundo o contexto da análise de sentimento em Kontopoulos et al. [KBDB13], as ontologias podem ser usadas para mapear o domínio da aplicação e também informar o grau de intensidade da emoção, sendo representada através de valor numérico. O Classificador SentiBank foi baseado em um modelo psicológico de emoções conhecido como a Roda das Emoções de Plutchik [Plu80]. Apesar da rede criada por Borth et al. [BCJC13] não classificar explicitamente a polaridade da imagem, ela indica um percentual de intensidade de emoções em seu resultado final. Por isso, utilizamos a classificação disponibilizada pelo SentiBank e trabalhamos com limites condicionais, que variam de $[-2; 2]$ no cálculo da média ponderada da intensidade das emoções, para fornecer a polaridade ternária (negativa, neutra e positiva) da imagem.

Para se manipular as intensidades de emoções, usou-se um conjunto de 1200 detectores de conceito ANP (*adjective noun pair*), que são pares de substantivos e adjetivos os quais possuem graus de intensidade de emoção normalizados, definidos por Borth et al. [BCJC13], sendo considerados para a classificação da polaridade. O ANP relaciona-se com *tags* textuais das imagens oriundas de *blogs* e redes sociais que foram usadas no treinamento da rede. Quando se testa uma nova imagem, a rede gera um arquivo que resulta em *tags*, valores que representam seus pesos na referida image, bem como um valor de ANP resultante no intervalo $[-2; 2]$. O sentimento negativo é definido quando o grau de intensidade do ANP é ≤ -1 , enquanto o sentimento positivo é representado pelo grau de ANP ≥ 1 . Os sentimentos neutros são representados por valores no intervalo de $(-1; 1)$. Para calcular a polaridade final da imagem, calculamos a média ponderada (usando os pesos resultantes) para o sentimento positivo, negativo e neutro separadamente. Depois comparamos os valores a fim de detectar o maior valor e assim definir a polaridade final da imagem.

3.1.2 DeepSentiBank

Trata-se de uma rede neural de emoções a partir da ontologia de sentimento visual. A arquitetura da rede DeepSentiBank [CBDC14] contém oito camadas principais. As cinco primeiras camadas de convolução e as outras três estão totalmente conectadas. A saída da última camada é totalmente conectada e é alimentada por uma função softmax que produz uma distribuição sobre os rótulos de 2089 classes. A rede maximiza a média entre instâncias de treinamento e a probabilidade de log da *tag* correta sob a previsão de distribuição por regressão logística multinomial. Os kernels da segunda, quarta e quinta camadas convolucionais são conectados apenas a metade dos mapas do kernel na camada anterior. Como a última camada dessa rede informa classes de emoções e não a polaridade da imagem, utiliza-se o arquivo de referência, como na rede SentiBank, com um conjunto de 4098 detectores ANP, conforme criado por Borth et al. [BCJC13].

O pós-processamento é feito de maneira equivalente a rede SentiBank, usando os mesmos limiares de valores e média ponderada pelos pesos das *tags* resultantes. Pega-se o arquivo `textit«.json»` gerado pelo DeepSentiBank ao classificar imagem e se calcula a média ponderada para o sentimento positivo, negativo e neutro separadamente. Depois são comparados os valores a fim de detectar o maior valor e poder definir a polaridade da imagem.

3.1.3 VGG-T4SA

No caso da classificação de emoções em imagens, utilizou-se a rede neural convolucional proposta por Vadicamo et al. [VCC⁺17] e treinada com o *dataset Twitter for Sentiment Analysis (T4SA)*, também proposto pelos autores. O T4SA é composto por cerca de 1 milhão de *tweets* para os quais os autores fornecem classificação de sentimento textual e imagens correspondentes a 1,4 milhão. Todos esses dados estão disponíveis publicamente na página do projeto T4SA ¹.

A rede neural VGG proposta por Simonyan et al [SZ14] é uma rede neural convolucional (CNN) de classificação de imagens. Dada uma imagem, a rede VGG produz probabilidades das diferentes classes às quais uma imagem pode pertencer. Por exemplo, em relação especificamente à presente pesquisa, a rede VGG pode indicar que uma imagem específica pode apresentar uma chance de 80% de confiança de apresentar uma emoção positiva, 10% de chance de apresentar emoções negativas, bem como 10% de uma emoção ser neutra.

A Tabela 3.1 apresenta 4 imagens-exemplo e suas análises conforme resultado de avaliação das três redes testadas.

Tabela 3.1 – Imagens de exemplo processadas pela SentiBank, DeepSentiBank e VGG-T4SA, representados pelos números romanos I, II e III respectivamente.

Imagem	Positivo	Neutro	Negativo
	-	I	II e III
	-	I e II	III
	I e II	-	III
	I e II	-	III

¹<http://www.t4sa.it/>

3.2 Tecnologias usadas para a detecção de emoções em textos

Devido ao crescente aumento de conteúdo gerado pelos usuários na internet, ocasionado principalmente pela popularização das redes sociais, a análise de sentimentos se tornou muito conhecida. Em relação ao domínio textual, as publicações sobre as opiniões das pessoas, mesmo em linguagem coloquial, são usadas como fonte de dados para as ferramentas de predição de emoção. É imprescindível existir exemplos rotulados, no entanto trata-se uma tarefa difícil e exaustiva que exige esforços humanos na maioria das aplicações.

Essa seção apresenta alguns léxicos usados no presente trabalho. O *dataset* utilizado para os resultados foi o CBB. As tecnologias utilizadas nessa atividade foram escolhidas por duas razões:

- Como os *posts* são escritos em português, era necessário escolher léxicos que tenham a classificação de polaridade em palavras da língua portuguesa;
- Foram detectados poucos léxicos de sentimento para a língua portuguesa, sendo os comumente citados nos estudos de análise de sentimento em texto: LIWC [BFPA13], SentiLex [CS15] e OpLexicon [SV12].
- Foi utilizada uma ferramenta muito usada na manipulação de textos, conhecida como NLTK [LB02] e que tem seu estudo bastante aprimorado para a língua inglesa. Então, houve uma curiosidade em constatar seu funcionamento, traduzindo os textos de português para inglês.

Os léxicos utilizados retornam a polaridade de palavras e a contagem das reconhecidas. Com o objetivo de classificar-se um determinado texto do blog como negativo, neutro ou positivo, seguimos a definição de subjetividade proposta por Moraes et al. [MSR⁺16] em que sentenças subjetivas são aquelas que indicam polaridade positiva ou negativa, por representarem uma opinião, sendo as sentenças restantes consideradas como objetivas por indicarem fatos. A proporção de palavras com subjetividade considera o número de tokens com polaridade em relação ao total de tokens do texto. A decisão sobre a subjetividade do texto é baseada em um limiar testado pelos autores, os quais definiram que pelo menos duas palavras com mesma polaridade definem a subjetividade do texto. As próximas seções descrevem brevemente os léxicos utilizados.

OpLexicon

O método OpLexicon [SV12], considerado a maior base de palavras, é um léxico de sentimento para a língua portuguesa, composto de 32.191 linhas. Atualmente, Oplexi-

con ² está na versão 3.0 que foi revisada por linguistas em relação a polaridade de alguns adjetivos.

SentiLex

O método SentiLex [CS15] é um léxico de sentimentos para o português que é composto de aproximadamente 6.000 adjetivos e 25.000 formas flexionadas. O SentiLex ³ foi construído a partir de um corpus composto de comentários sobre assuntos políticos em jornais. Ele contém, além das classes de palavras, a polaridade associada a cada item, podendo ser positiva, negativa ou neutra.

LIWC Dictionary

LIWC (Linguistic Inquiry and Word Count) ⁴ é um recurso previamente avaliado como bom para a análise de sentimentos em português [BFPA13]. Neste trabalho é utilizado para fins de classificação, visando informar a polaridade do texto (positivo, neutro ou negativo). É constituído por um dicionário de palavras que permite extrair características linguísticas, psicológicas e sociais nos textos. A versão do LIWC 2007 possui 4.542 fichas e a versão traduzida do LIWC 2007 em português possui 127.227 tokens. A versão em português é principalmente preenchida com conjugações verbais.

NLTK

O NLTK (Natural Language Toolkit) [LB02] contém muitos módulos de programas em código aberto sobre processamento de linguagem natural. Um dos módulos utilizado nesse estudo é o «Sentiment.vader» que é um modelo simples baseado em regras para análise geral de sentimentos. Foi utilizada a função que retorna a polaridade do texto e utiliza a métrica *compound*, que calcula o somatório das polaridades das palavras no léxico, sendo ajustado conforme as seguinte regras informadas ⁵:

- Para sentimento positivo, o compound é $\geq 0,05$;
- Para sentimento neutro, o compound está no intervalo $(-0,05; 0,05)$;
- Para sentimento negativo, o compound é $\leq 0,05$;

Para interpretação dos resultados de polaridade e subjetividade, também informada pela função «SentimentIntensityAnalyzer()», deve-se usar as seguintes regras:

²<http://ontolp.inf.pucrs.br/Recursos/downloads-OpLexicon.php>

³<http://xldb.fc.ul.pt/wiki/SentiLex-PT01>

⁴<http://143.107.183.175:21380/portlex/index.php/en/projetos/liwc>

⁵<https://github.com/cjhutto/vaderSentimentabout-the-scoring>

- *Polarity* - é um valor contínuo que varia de -1,0 a 1,0, sendo -1,0 referente a 100% negativo e 1,0 a 100% positivo.
- *Subjectivity* - que também é um valor contínuo que varia de 0,0 a 1,0, sendo 0,0 referente a 100% objetivo e 1,0 a 100% subjetivo.

O algoritmo utilizado para classificação da polaridade do texto nos léxicos em português é a seguir definido:

- Primeiramente é carregado o texto do *dataset* CBB que apresenta a opinião das pessoas sobre os diversos assuntos discutidos no *Blog*. Trata-se de 880 linhas com dados textuais;
- É feito um pré-processamento no texto, removendo *stopwords* - que são palavras que não precisam ser indexadas por possuírem pouco significado, podendo ser consideradas irrelevantes para o conjunto de resultados na construção do modelo;

Um exemplo é a entrada do texto "Eu não gosto do partido, e também não votaria novamente nesse governante!", resultando em "'não', 'gosto', 'partido', 'não', 'votaria', 'novamente', 'governante'".

- Remove-se sinais de pontuação, deixando apenas os sinais significativos, como exemplo: "'?', '!'",
- Reorganiza-se o texto em uma lista de palavras;
- Carregamos o arquivo com um dos dicionários léxicos citados;
- Uma comparação é feita entre as palavras relevantes do texto e o dicionário léxico para identificar a polaridade da palavra. A quantificação de palavras positivas, negativas e neutras é realizada;
- A saída desta análise compreende as seguintes informações: o número de identificação único do *blog*, o texto preprocessado, a quantidade de palavras analisadas e as medidas de polaridade, juntamente com a polaridade do texto completo.

Além dos três léxicos em português, foi utilizado o NLTK [LB02]. Primeiramente, o texto foi traduzido para o inglês usando a biblioteca «TextBlob»⁶ que também indica uma maneira conveniente de realizar várias tarefas de processamento de linguagem natural (PLN). A subjetividade e a métrica *compound* do texto foram analisadas conforme os passos a seguir:

- É carregado o texto do corpus;

⁶<https://textblob.readthedocs.io/en/dev/>

- É feito um pré-processamento no texto, removendo *stopwords*;
- Removemos sinais de pontuação, deixando apenas os sinais significativos, como exemplo: "'?', '!";
- É feita a tradução do texto do português para o inglês;
- A função `SentimentIntensityAnalyzer().polarity_scores()` é executada para resultar nos escores de polaridade, subjetividade e a métrica *compound*;
- A saída desta análise compreende as seguintes informações: o número de identificação único do blog, o texto pré-processado, a polaridade, subjetividade e métrica *compound* do texto completo.

Exemplo extraído do corpus e avaliado pelos léxicos

Utilizou-se um exemplo extraído do CBB. Tem-se o resultado da polaridade, conforme avaliação de cada léxico, informando a quantidade de palavras detectadas como sendo positivas, neutras e negativas, bem como a quantidade de palavras reconhecidas no texto.

"Sumi, eu sei que sumi! Mas estou de volta! O post de hoje vai falar sobre o lindo convite que recebi do Marcello Caridade, para fazer parte do elenco de "The Rocky Horror Show" que foi apresentado em fevereiro de 2014 no Teatro do Fashion Mall em São Conrado - RJ. O Elenco estava lindo, a galera realmente encarnou nos zumbis viciados em sexo! hahah Enfim, vou postar aqui umas fotos são para vocês ficarem ainda mais na vontade de ter assistido! Porquê eu sou dessas, malvada!!! Poliana Anderle Espero que tenham gostado!!! Beijos, Poliana Anderle" [dSWV18]

Tabela 3.2 – Frase de exemplo processada com OpLexicon, SentiLex e LIWC

Léxico	Positivo	Neutro	Negativo	Palavras Reconhecidas
OpLexicon	2	3	5	59
SentiLex	2	0	4	59
LIWC	6	0	2	97

A Tabela 3.2 apresenta divergências de palavras reconhecidas, porque na utilização dos léxicos OpLexicon e SentiLex houve a preocupação de retirar as *stopwords* do texto. Para esse exemplo, as *stopwords* envolvidas são as seguintes: eu, que, mas, estou, de, o, do, para, foi, em, estava, em, nos, a, são, vocês. Não estamos repetindo a quantidade de vezes que essas *stopwords* ocorreram. Se não fossem removidas as *stopwords* no pré-processamento do texto, o resultado para esse exemplo não mudaria, apenas alteraria a quantidade de palavras reconhecidas, como pode ser verificado na Tabela 3.3.

Tabela 3.3 – Frase de exemplo processada com OpLexicon, SentiLex e LiWC em que as stopwords não foram removidas no pré-processamento para os Léxicos OpLexicon e SentiLex.

Léxico	Positivo	Neutro	Negativo	Palavras Reconhecidas
OpLexicon	2	3	5	94
SentiLex	2	0	4	94
LiWC	6	0	2	97

Para o caso da técnica com o NLTK, foi feita a tradução do texto em português para o inglês, gerando o texto do exemplo como segue:

I disappeared, I know gone! but i'm back! today's post will talk about the beautiful invitation I received from marcello charity, to be part of the cast of "the rocky horror show" was presented in February 2014 at the fashion mall Teatro in Sao Conrado - RJ. the cast was beautiful, the guys really incarnated in the sex addicted zombies! hahah anyway, I'll post here some photos just to make you feel more like watching! because I'm such, mean! ! poliana anderle hope have enjoyed it! ! kisses, poliana anderle.

O resultado indica que a métrica compound gerou um escore de 98%, considerando o texto positivo. O escore indicativo de subjetividade foi de aproximadamente 58%, informando que se trata de um texto subjetivo.

3.3 Corpus Cross-media Brazilian Blog

Esse *dataset* foi construído baseado nos *posts* da plataforma *BlogSet-BR* [dSWV18] que inclui informações sobre *posts*, ids de usuários, datas, entre outras informações. Para o escopo dessa pesquisa, usou-se *posts* que contêm texto e apenas uma imagem associada, implicando seleção de 17.826 *posts* dentre os iniciais 7,4 milhões de *posts*. Em seguida, foi verificado se os *posts* e se os links de imagens ainda estavam disponíveis na rede social, resultando em um conjunto de dados de 5.649 *posts*. A partir desses 5.649 *posts*, foram feitas classificações iniciais de sentimentos dos textos e das imagens de forma independente. Nesse processo, foi usado o léxico LIWC 3.2 para a classificação de sentimentos em texto e foi usado o modelo VGG-T4SA ⁷ para a classificação de sentimentos em imagens. O principal objetivo foi usar estas tecnologias como maneira de selecionar posts para o corpus. Dos resultados obtidos pelo uso dos algoritmos LIWC e VGG-T4SA, foram adotadas as seguintes regras para restringir um pouco mais o corpus:

⁷<http://www.t4sa.it/>

- Foram escolhidos imagens e textos cujas polaridades são negativas ou positivas, descartando as polaridades neutras. Isto foi feito porque, o nosso objetivo era trabalhar com a polaridade binária, indicando apenas o grau de positividade e negatividade de um texto ou de uma imagem conforme é citado o conceito de força de sentimento por Reis et al. [dRdSdM⁺15];
- A probabilidade obtida da classificação das imagens com o VGG-T4SA, que define a polaridade 0 para negativo e 2 para positivo, deveria ser maior do que 40%. Esta métrica foi observada empiricamente como um ponto de corte aceitável para os resultados obtidos, uma vez que tentamos seguir a definição de subjetividade apresentada pelo autor Moraes et al. [MSR⁺16]; e
- Os textos classificados pelo LIWC devem conter um mínimo de 10 e um máximo de 500 palavras não repetidas.

O resultado do processo acima descrito foi a criação de um corpus com 1000 *blogs* onde as imagens e os textos foram processados respectivamente no VGG-T4SA e LIWC. A Figura 3.1 apresenta o resultado das classificações do VGG e do LIWC. Pode-se perceber a polaridade binária resultado do VGG. Em adição, a Figura 3.2 indica a classificação em comum, mesma polaridade e mesmo *post*, resultados das tecnologias testadas.




Figura 3.1 – Quantidade de textos e imagens com a polaridade positiva, neutra e negativa indicadas no corpus através do Léxico 3 e da Rede 3.

Destes mesmos 1000 *blogs*, 880 foram anotados pelos participantes do Figure Eight⁸ - plataforma de anotações, ou seja, 880 textos e 880 imagens que foram manual-

⁸<https://www.figure-eight.com/>




Figura 3.2 – Texto e imagem no mesmo *post* indicando a mesma polaridade que pode ser positiva ou negativa informada através da classificação do LIWC e da VGG para textos e imagens respectivamente.

mente e individualmente classificados como positivos, neutros e negativos, como mostra a Figura 3.3, dando origem ao *Ground truth* (GT). Os 120 *posts* restantes de 1000 não tiveram suas anotações consideradas porque só tivemos *feedback* de sentimento de imagem ou de texto, mas não de ambos. Conforme pode ser visto na Figura 3.3, mais textos foram classificados como positivos e mais imagens foram consideradas neutras, de acordo com as opiniões dos sujeitos, em comparação as tecnologias utilizadas. Além da análise anterior, também investigou-se a discrepância ou variação entre os sentimentos classificados entre texto e imagem do mesmo *post*. Essa análise é apresentada na Figura 3.4. A Figura 3.4 mostra que há mais *posts* positivos do que neutros e negativos através das anotações realizadas na plataforma *Figure Eight*. Como foi uma surpresa o surgimento do sentimento neutro com grande intensidade tanto em texto como em imagem nas anotações do *Figure Eight*, bem como detecção de divergências de polaridade entre texto e imagem no mesmo *post*, houve a necessidade de se fazer uma outra anotação. Nesse caso, a anotação se baseia em o usuário analisar os dois domínios juntos, ou seja, analisar o *post* completo que é composto de imagem e texto e verificar se há contradição ou não. Caso haja divergência de polaridade entre texto e imagem do *post*, o usuário deveria indicar o sentimento predominante no *post* sendo possíveis as opções positivo, neutro e negativo. O resultado sobre a quantidade de *posts* contraditórios pode ser visualizado na Tabela 3.4. Para os *posts* que foram identificados como contraditórios, é apresentado o sentimento predominante, sendo visualizado na Tabela 3.5.




Figura 3.3 – Quantidade de textos e imagens com a polaridade positiva, neutra e negativa indicadas no corpus através das anotações realizadas no Figure Eight.

Tabela 3.4 – Quantidade de *posts* indicando contradições conforme as anotações realizadas no *Figure Eight*.

Há contradição?	
Sim	29
Não	851

Tabela 3.5 – Quantidade de *posts* identificados como contraditórios, havendo a definição da polaridade predominante conforme as anotações realizadas no Figure Eight.

Polaridade predominante	
Positivo	11
Neutro	8
Negativo	10

Além de ser realizada essa segunda anotação, também se investigou a subjetividade dos textos contraditórios e não contraditórios. A metodologia escolhida foi utilizar a tecnologia NLTK, conforme já explicitado na Seção 3.2, cujo objetivo é indicar a polaridade e a subjetividade do texto. Calculou-se a mediana da subjetividade dos posts e o resultado pode ser visto na Tabela 3.6.

Frases subjetivas geralmente se referem à opinião pessoal, à emoção ou ao julgamento de algum assunto. Já a frase objetiva se refere à informação factual. Como a Tabela 3.6 indica uma mediana com percentual em torno de 50%, significa que os textos

Classificação de textos e de imagens em Posts

com o mesmo sentimento




Figura 3.4 – Texto e imagem no mesmo *post* indicando a mesma polaridade que pode ser positiva, neutra ou negativa informada no corpus através das anotações realizadas no *Figure Eight*.

Tabela 3.6 – Mediana da subjetividade dos textos considerando a classificação dos *posts*

Há contradição?	Mediana em % da Subjetividade
Sim	54%
Não	51%

nem apresentaram tanto a opinião pessoal de quem escreveu, nem fatos. Essa informação poderia ser um motivo para haver muitos textos com a classificação Neutra.

Para facilitar o entendimento ao longo do texto, denomina-se o corpus como GT, abreviatura de *Ground Truth*. Em alguns momentos, também se usa GT Texto para fazer referência somente aos textos do GT.

3.3.1 Uma breve análise do CBB

Houve necessidade de fazer uma análise exploratória nos dados do CBB. Portanto, alguns questionamentos foram feitos para tentar encontrar as respostas quando possível. A primeira observação é relacionada ao Post ser Contraditório ou Não-Contraditório em função do percentual de anotadores. Parece que é mais fácil identificar um Post Não-Contraditório, porque a porcentagem média de anotadores é de cerca de 96%, enquanto que para indicar se o Post é contraditório é em torno de 75%. A Tabela 3.7 mostra isso.

Tabela 3.7 – Porcentagem média de anotadores que indicam se um Post é Contraditório ou Não-Contraditório.

Contradição?	Média percentual de anotadores
Sim	75%
Não	96%

Outra observação é referente ao confronto dos domínios, tentando identificar qual prevalece e em quais situações. Para isso, foi verificada a quantidade de Posts, cruzando a polaridade da imagem e do texto em cada Post, comparando a avaliação separadamente e também levando em consideração se o Post era Contraditório ou Não-Contraditório. Foi analisado quando eles tinham a mesma polaridade e quando não tinham. A Figura 3.5 mostra o resultado encontrado em todo o GT.

Quando o Post é Não-Contraditório, para os casos em que o texto tem polaridade negativa ou neutra, e a imagem sendo classificada como neutra, indicam que os percentuais dos avaliadores foram mais altos. Somente quando o texto e a imagem indicam polaridade positiva é que prevaleceu o maior percentual dos avaliadores. Quando o Post é Contraditório, independente da polaridade do texto, a polaridade neutra da imagem prevalece, indicando os percentuais dos avaliadores mais altos. Outras observações surgiram após a Figura 3.5, tais como:

- Se as polaridades dos domínios são iguais e as porcentagens dos avaliadores também, qualquer um dos domínios é suficiente para definir a polaridade predominante do Post;
- Se as polaridades dos domínios forem iguais e os avaliadores indicarem que a porcentagem de polaridade da imagem é maior que o texto, a polaridade da imagem no Post pode ser predominante;
- Se as polaridades dos domínios forem iguais e os avaliadores indicarem que a porcentagem de polaridade do texto é maior que da imagem, a polaridade do texto no Post pode ser predominante;

Posts indicando se são Contraditórios ou Não-Contraditórios
e a Polaridade dos Domínios

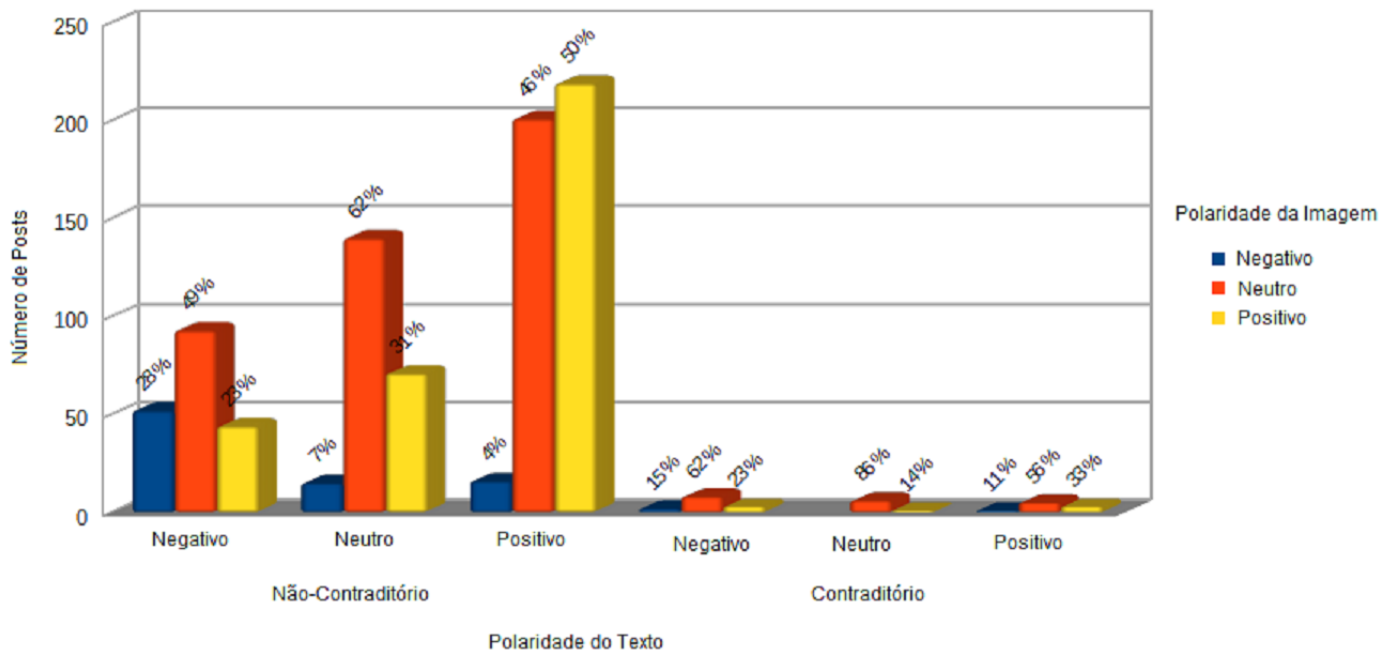


Figura 3.5 – Número de posts indicados pela polaridade dos domínios do texto e da imagem. A polaridade do texto está no eixo X e também indica se é um post contraditório ou não-contraditório. No eixo Y, há a quantidade de Posts. No eixo Z tem a polaridade da imagem. Os valores entre o cruzamento dos domínios estão disponíveis em percentual.

- Se as polaridades dos domínios são diferentes e as porcentagens dos avaliadores são iguais, aparentemente nada pode ser informado sobre o Post, porque as polaridades dos domínios são diferentes. Talvez o texto possa ser analisado para encontrar contrastes que na literatura indicam que o texto pode mudar de polaridade, como casos de negação, conjunções, ironia;
- Se as polaridades dos domínios são diferentes e os avaliadores indicam que a porcentagem de polaridade da imagem é maior que o texto, então a polaridade da imagem pode ser predominante no Post;
- Se as polaridades dos domínios forem diferentes e os avaliadores indicarem que a porcentagem da polaridade do texto é maior que a imagem, a polaridade do texto pode ser predominante no Post;
- A polaridade neutra está muito presente nos domínios textual e de imagem. Se um dos dois domínios for neutro e o outro não, a polaridade do Post poderá ser alterada. Existe um Post com polaridade neutra se um dos dois Posts tiver a mesma polaridade?

Com base nas informações da Tabela 3.7 e também da Figura 3.5 foi feita a distribuição média dos percentuais de anotadores para definir as polaridades nos domínios dos Posts contraditórios, conforme mostra a Figura 3.6. Curiosamente, não há informações entre texto com polaridade neutra e imagem com polaridade negativa para avaliação.

Post Contraditório	GT Texto	GT Imagens					
		Média GT Texto			Média GT Imagens		
		Negativo	Neutro	Positivo	Negativo	Neutro	Positivo
Sim	Negativo	83,21%	87,40%	87,83%	82,38%	83,95%	78,38%
	Neutro		78,00%	65,44%		94,67%	100,00%
	Positivo	100,00%	100,00%	89,65%	64,16%	67,01%	88,94%

Figura 3.6 – Distribuição das porcentagens médias dos avaliadores para definição de polaridade em cada domínio nos posts contraditórios. As polaridades do domínio textual com o domínio da imagem são cruzadas, com todas as combinações possíveis de resultados.

A Figura 3.6 aparentemente mostra que quando o texto é indicado com polaridade positiva existe predomínio do texto em relação à polaridade negativa e neutra da imagem. Quando o texto é indicado com polaridade neutra, o predomínio é da polaridade definida para a imagem. Quando o texto é definido com polaridade negativa, as médias dos avaliadores são muito próximas das médias para as polaridades indicadas para o domínio da imagem. Acredita-se que quando as polaridades do domínio são iguais, as porcentagens médias são altas e muito uniformes. Quando há divergências de polaridade entre domínios, não é possível identificar se o texto ou a imagem podem ser decisivos.




Figura 3.7 – 29 posts considerados contraditórios no GT e distribuídos entre positivo, neutro e negativo, com predominância de sentimento neutro no domínio das imagens.

Na Figura 3.7, ocorre o predomínio do sentimento neutro no domínio da imagem, pois 19 imagens de 29 foram detectadas com a polaridade neutra. No entanto, no domínio textual foram detectados 7 textos dos posts com sentimento neutro, sendo 1 texto considerado com polaridade neutra e a imagem com polaridade positiva.

Existem 6 casos em que o texto e a imagem indicam a mesma polaridade neutra e com o mesmo percentual de anotadores definindo as polaridades em cada domínio. Em 4 outros casos, a imagem tem uma classificação de 100% dos anotadores indicando polaridade neutra e o texto está abaixo de 70%. Nos outros 9 casos restantes das imagens, a predominância é da imagem indicando uma porcentagem de anotadores que relataram polaridade neutra acima de 70%, principalmente 100%.




Figura 3.8 – 20 posts considerados contraditórios no GT e distribuídos principalmente em polaridade neutra, aparentemente indicando que são necessários mais elementos para definir a polaridade.

Dos 29 Posts considerados contraditórios, 20 deles têm pelo menos um dos domínios classificados como neutros, como pode ser visto na Figura 3.8. Parece que isso indica que apenas um domínio não seria suficiente para indicar a polaridade predominante no Post. Supondo que se considerasse que a presença de um dos domínios com classificação neutra implicasse o Post receber polaridade do outro domínio que não é considerado neutro, a classificação predominante do Post corresponderia à do GT? Pelo que foi encontrado nos resultados do GT, não apresenta um bom resultado usar esse recurso, como mostra a Figura 3.9. Talvez, nesses casos, deva ser realizada uma análise para elementos irônicos ou mórficos contraditórios que possam alterar a polaridade do domínio textual.

A distribuição de Posts pela porcentagem de anotadores que definiram a polaridade do domínio quando avaliadas separadamente é mostrada na Figura 3.10. Pode-se




Figura 3.9 – Quando um dos domínios foi classificado com polaridade neutra, foi utilizada a polaridade do outro domínio, sendo denominada resultado da possível polaridade. Na legenda, Post GT corresponde ao resultado do GT e Polaridade possível implica predominância da polaridade em função de um dos domínios não ter polaridade neutra no Post.

Porcentagem de Anotadores que definem a Polaridade do Domínio em Posts Contraditórios




Figura 3.10 – Distribuição de Posts de acordo com a porcentagem de anotadores que definem a polaridade dos domínios separadamente nos Posts contraditórios.

verificar que o domínio do texto e o domínio da imagem estão distribuídos uniformemente,

por isso talvez seja difícil identificar nesse *dataset*, quando um Post é contraditório ou não-contraditório, a polaridade predominante no Post.

Para posts não contraditórios, temos a seguinte distribuição, como mostra a Figura 3.11.

Post Contraditório	GT Texto	GT Imagens					
		Média GT Texto			Média GT Imagens		
		Negativo	Neutro	Positivo	Negativo	Neutro	Positivo
Não	Negativo	82,69%	75,05%	73,11%	76,94%	84,53%	89,32%
	Neutro	78,98%	78,48%	74,60%	84,44%	86,28%	82,56%
	Positivo	87,73%	84,41%	85,60%	83,06%	82,97%	89,34%

Figura 3.11 – Distribuição das porcentagens médias dos avaliadores para a definição de polaridade em cada domínio nos posts não contraditórios. As polaridades do domínio textual com o domínio da imagem são cruzadas, com todas as combinações possíveis de resultados.

A Figura 3.11 mostra a combinação de polaridades em cada domínio, indicando a porcentagem média em cada interseção. Aparentemente, a combinação de polaridades para cada domínio mostra porcentagens médias muito uniformes, não sendo possível indicar o predomínio da polaridade indicada para texto ou para imagem.

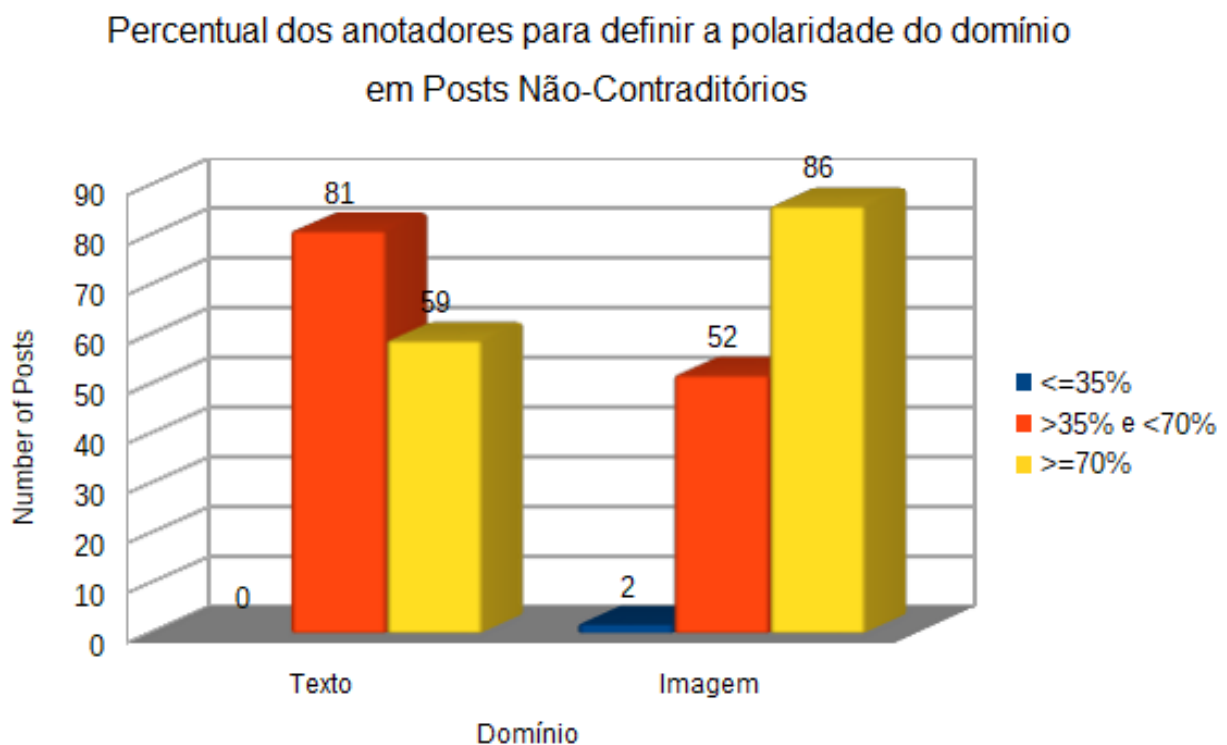


Figura 3.12 – Os valores entre domínios estão disponíveis em percentuais médios dos anotadores para definir a polaridade do domínio. A polaridade do texto está no eixo X dos posts não contraditórios. No eixo Y, mostra a porcentagem. No eixo Z tem a polaridade da imagem.

Dos 851 Posts Não-Contraditórios, 520 Posts têm um ou dois dos domínios classificados como neutros. 140 Posts indicam ambos os domínios com polaridade neutra e são distribuídos de acordo com o percentual dos anotadores, como mostra a Figura 3.12.




Figura 3.13 – Os valores entre domínios estão disponíveis em percentuais médios de avaliadores para definir a polaridade do domínio. A polaridade do texto está no eixo X dos posts não contraditórios. No eixo Y, mostra a porcentagem. No eixo Z tem a polaridade da imagem.

Existem 331 Posts que têm domínios com polaridades positivas e negativas distintas. 271 posts têm ambos os domínios com a mesma polaridade, deixando 60 Posts, dos quais apenas 13 Posts têm domínios classificados como 100% dos anotadores indicando polaridades opostas, ou seja, se um domínio é positivo, o outro é negativo, não podendo ser definida a predominância da polaridade do Post pelo percentual de anotadores. A Figura 3.13 mostra a distribuição da porcentagem de anotadores para definir cada polaridade e parece indicar que os domínios não apresentam diferenças que podem informar que um domínio se destaca sobre o outro e pode ser usado como postagem definidor de polaridade.

A Figura 3.14 mostra o desvio padrão da porcentagem de anotadores que definiram a polaridade para cada domínio do Post. Era necessário mostrar essa medida de dispersão em torno da média para que se pudesse mostrar que as porcentagens são bastante uniformes. Mesmo ao analisar postagens que refinam a busca pela polaridade do domínio e se a postagem é considerada contraditória ou não, os valores percentuais são muito próximos. Como o baixo desvio padrão indica que os pontos de dados tendem a estar próximos do valor médio ou esperado, é uma maneira de indicar que a Figura 3.14 está alinhada com as Figuras 3.6 e 3.11. Acredita-se que isso seja porque pelo menos um

		GT Imagens						Total DP	Total DP
		Desvio Padrão GT Texto			Desvio Padrão GT Imagens			GT Texto	GT Imagens
Post Contraditório	GT Texto	Negativo	Neutro	Positivo	Negativo	Neutro	Positivo		
Não	Negativo	18,99%	19,11%	20,01%	19,23%	18,54%	18,54%	19,65%	19,27%
	Neutro	19,07%	18,23%	18,92%	16,69%	17,90%	21,66%	18,60%	19,17%
	Positivo	16,01%	18,43%	18,22%	20,59%	18,27%	17,66%	18,26%	18,33%
Sim	Negativo	16,80%	16,31%	17,22%	17,62%	16,07%	30,58%	16,67%	20,68%
	Neutro		15,62%	0,00%		11,93%	0,00%	15,11%	11,20%
	Positivo	0,00%	0,00%	14,64%	0,00%	20,60%	15,65%	9,76%	20,73%

Figura 3.14 – Desvio padrão da porcentagem do anotador para definir polaridades do domínio. Os domínios e a polaridade foram cruzados para ter todas as combinações possíveis, mostrando Posts contraditórios e Não-Contraditórios.

dos domínios da publicação não esteja claramente definido como opinativo ou subjetivo, ou seja, talvez existam muitos textos e imagens definidos com polaridade neutra que possivelmente possam exigir mais recursos de outros domínios a fim de evitar a polaridade neutra. Outra possibilidade relevante pode ser as diferenças culturais, sociais e pessoais que fazem parte desses Posts.

3.3.2 Processo de Anotações com Figure Eight

Conforme citado anteriormente, para o processo de anotação, usamos a *Figure Eight*⁹, anteriormente conhecida como Dolores Lab, *CrowdFlower* - uma empresa de aprendizado de máquina e inteligência artificial humana. *Figure Eight* é uma plataforma de crowdsourcing para executar tarefas repetitivas e de alto volume de dados, sendo uma força de trabalho amplamente distribuída. porque usa a inteligência humana para executar tarefas simples, como transcrever texto ou fazer anotações em imagens para treinar algoritmos de aprendizado de máquina. Automatiza tarefas para algoritmos de aprendizado de máquina, que podem ser usados para melhorar os resultados da pesquisa de catálogos, aprovar fotos ou dar suporte a clientes e a tecnologia pode ser usada no desenvolvimento de carros autônomos, assistentes pessoais inteligentes e outras tecnologias que usa aprendizado de máquina.

Figure Eight possui suporte estatístico e qualidade controlada para produzir um trabalho escalável e confiável, podendo gerar um conjunto de tarefas diversificadas e poder ser respondido em tempo quase real. Contém layouts como sugestão e permite que a pessoa os defina através da *Figure Eight markup language*, que é uma linguagem que permite abstração em objetos *HTML*, permitindo a interação com a unidade de dados.

Depois que o trabalho é feito pelos anotadores, um relatório completo é disponibilizado para análise. O processo de avaliação usa votação por maioria que pode excluir respostas com base nas unidades de teste criadas.

⁹<https://figure-eight.com>

3.3.3 Questionários criados no *Figure Eight* para a validação do corpus

Inicialmente, gerou-se um questionário para cada domínio (imagem e texto), não havendo relação entre eles no momento de criação do questionário e de anotação pelas pessoas. O questionário visa conhecer a polaridade do domínio. O resultado indicou muito mais sentimentos neutros do que positivos e negativos, quando analisados os domínios separadamente. Também se percebeu que houve divergências de sentimentos entre texto e imagem que compõem o mesmo *post*.

Por haver divergências de sentimento entre texto e imagem, em um segundo momento, foi criado um outro questionário usando texto e imagem juntos a fim de indagar ao anotador se ele encontrava contradição entre os domínios quando analisados em conjunto. Para essa situação, era necessário que o anotador selecionasse sim ou não. Caso fosse detectada contradição, outro questionamento era feito. O anotador deveria indicar o sentimento predominante no *post*, que é a junção dos dois domínios, baseado na polaridade.

Apesar de nossa seleção de textos e imagens no *BlogSet* levar em consideração somente classificações positivas e negativas de acordo com as tecnologias testadas e informadas na Seção 3.3, os questionários foram gerados com a possibilidade de o anotador escolher entre negativos, neutros e positivos. Por isso, nos exemplos que foram criados para que o anotador pudesse compreender o que estava sendo proposto em todos os questionários, definiu-se cada sentimento como segue:

- Positivo significa que alguns aspectos da imagem/texto revelam um humor positivo, como elogios, recomendações ou resultados favoráveis.
- Neutro significa que a imagem/texto é apenas informativa na natureza e não fornece nenhuma indicação como humor.
- Negativo significa que alguns aspectos da imagem/texto revelam um clima negativo, como críticas, insultos ou uma comparação negativa.

A fim de detalhar os questionários as Tabelas de 3.7 a 3.13 ilustram perguntas e exemplos do GT. A Tabela 3.8 indica as regras para os avaliadores do *Figure Eighth* poderem responder a polaridade da imagem, podendo ser positiva, neutra ou negativa. A Tabela 3.9 mostra um exemplo de imagem para cada sentimento. Enquanto a Tabela 3.10 indica como é feito o questionamento aos avaliadores do *Figure Eighth* a fim de eles responderem a polaridade apenas das imagens. A Tabela 3.11 apresenta a visão geral do trabalho, os passos para a realização das anotações para a classificação da polaridade do texto. A Tabela 3.12 mostra alguns exemplos de textos de acordo com a polaridade. A Tabela 3.13 indica as regras para os avaliadores do *Figure Eighth* poderem responder se o *post*, composto de

Tabela 3.8 – Instruções

<p>Job Instructions</p> <p>Overview</p> <p>In this job, we present you some random images. Please, review the images to determine the sentiment so that we can have a greater understanding about the overall sentiment of the picture.</p>
<p>Steps</p> <p>Look the picture.</p> <p>Determine if the picture is positive, neutral, or negative.</p> <p>Rules & Tips</p> <p>The pictures can be classified as positive, negative or neutral:</p> <p>Positive means some aspects of the image uncover a positive mood, such as praise, recommendations or a favorable comparison.</p> <p>Neutral means that the image is only informative in nature and provides no hint as to the mood of the image.</p> <p>Negative means some aspects of the image uncover a negative mood such as, criticism, insults or a negative comparison.</p>
<p>Note:</p> <p>Pictures that are purely factual are not necessarily Neutral – consider whether the fact/news itself is Positive or Negative regarding the business and select one of those when possible.</p>

Tabela 3.9 – Example: As imagens podem ser classificadas como positiva, neutra ou negativa


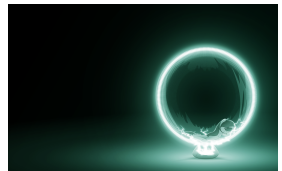


<p>Positive</p> <p>This example denotes a positive meaning and indicates a positive tone for the tweet.</p>	
<p>Neutral</p> <p>In this example the image is purely informative and offers no indication about the mood of the author.</p>	
<p>Negative</p> <p>In this example the negative mood is indicated by the use of the facial expression.</p>	

Tabela 3.10 – Exemplo de questão para definir o sentimento na imagem.



<http://4.bp.blogspot.com/-Kwc2Ng1gEh4/Tkg9cQuQoyI/AAAAAAAAAQ8/XvVkn5hpFUI/s1600/pai+filha.jpg>

What is the sentiment (feeling) of the image? (required)

Positive

Neutral

Negative

Image Error

REASON (Shown when contributor misses this question)

Tabela 3.11 – Julgar o sentimento dominante em *posts* em português.

Visão Geral

Neste trabalho você será apresentado a diversos textos. Analise os textos para determinar a polaridade que é um sentimento que pode ser transmitido como positivo, neutro ou negativo.

Passos

Leia o texto abaixo:

Quando todos estiverem chorando, tente você o primeiro sorriso! Talvez não na forma de lábios sorridentes, mas na de um coração que compreenda, de braços que confortem. Determine o sentimento do texto, ou seja: o sentimento do texto é positivo, é neutro ou é negativo.

Regras e Dicas

O texto pode ser classificado como positivo, neutro ou negativo:

Positivo significa que alguns aspectos do texto revelam um humor positivo, como elogios, recomendações ou uma comparação favorável.

Neutro significa que o texto é apenas de natureza informativa e não fornece nenhuma sugestão quanto ao humor do autor.

Negativo significa que alguns aspectos do texto revelam um clima negativo, como críticas, insultos ou uma comparação negativa.

Observação:

Para esse texto exemplificado a polaridade foi anotada como positiva.

Tabela 3.12 – Exemplos de textos que podem ser classificados como positivos, neutros ou negativos.

<p>Positivo Você não tem noção do que eu sou capaz, quando eu decido batalhar pelos meus ideais!</p>
<p>Neutro Me perguntaram: - o que é mais importante: amar ou ser amada? E eu respondi: para um pássaro, o que lhe é mais importante: a asa esquerda ou a direita?</p>
<p>Negativo Eu odeio explicar porque estou chorando, só quero chorar e pronto. via: gota d'água</p>

imagem e texto, indica contradição ou não. Caso seja considerado um *post* contraditório, o anotador deverá informar o sentimento predominante do *post*, podendo ser positivo, neutro ou negativo. A Tabela 3.14 indica exemplos de *posts*, informando a polaridade do texto e da imagem, bem como uma justificativa para a polaridade escolhida, de acordo com os sujeitos. A Tabela 3.15 indica exemplos de *posts*, informando se são contraditórios ou não-contraditórios, uma justificativa e em caso de contradição, polaridade predominante é indicada.

Na próxima seção será discutida análise de contradição e sua influência na análise de polaridade de textos.

3.4 Uma Análise sobre Contradição no Ground Truth

O objetivo dessa seção é analisar as contradições de polaridade detectadas no *Ground Truth* ao avaliar separadamente a imagem e o texto. Com base no conceito de contradição e seus tipos, os textos são reavaliados em busca de contradições que possam ter contribuído para que o resultado da polaridade seja invertido. Caso haja a possibilidade de troca, devido aos elementos detectados, o *post* pode sofrer alteração em sua polaridade.

3.4.1 Análise de contradição

A Análise de Contradição é uma área multidisciplinar e considerada bastante complexa. Facilmente pode-se produzir textos contraditórios por descuido, ou as vezes podendo ser percebida, outras vezes não. O computador pode ser muito útil para poder detectar as contradições em textos. Muitas definições foram criadas sobre esse tema, baseadas nos problemas que se pretende resolver. Por essa razão, algumas definições são apresentadas por terem contribuído para a análise nesse trabalho:

Tabela 3.13 – Julgar o sentimento dominante em *posts*.**Visão Geral**

Neste trabalho, você será apresentado aos *posts* que contém texto e imagem. Analise os *posts* para determinar se expressam contradição de sentimentos entre texto e imagem. A contradição de sentimentos é quando o texto tem um sentimento diferente do sentimento detectado na imagem, por exemplo: o texto pode ter um sentimento positivo e a imagem pode ter um sentimento negativo.

Steps

Leia o texto do post

Clique no link para visualizar a imagem que compõe o *post*. Determine se há contradição entre sentimento do texto e imagem, ou seja: que o sentimento do texto é diferente da imagem, ou se eles se complementam, que indica que possuem o mesmo sentimento, não existindo contradição no *post*. Determine se o *post* indica sentimento predominantemente positivo, neutro ou negativo, caso houver contradição (sentimentos diferentes) entre texto e imagem.

Regras e Dicas

O *post* pode ser classificado como positivo, neutro ou negativo:

Positivo significa que alguns aspectos do *post* revelam um humor positivo, como elogios, recomendações ou uma comparação favorável.

Neutro significa que o *post* é apenas de natureza informativa e não fornece nenhuma sugestão quanto ao humor do autor.

Negativo significa que alguns aspectos do *post* revelam um clima negativo, como críticas, insultos ou uma comparação negativa.


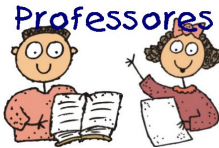
Observação:

Os posts, composto de texto e imagem, que foram extraídos do Brazilian Blog-Set não são necessariamente neutros - considere se o fato em si é positivo, neutro ou negativo em relação ao *post* e selecione um deles quando possível.

Tabela 3.14 – Exemplos de *posts* classificados como positivos, neutro e negativo.

<p>Positivo</p> <p>Neste exemplo, a emoção indicada pelo tema sorrir denota um significado positivo e indica um tom positivo para o total do <i>post</i>. Abrindo o link visualizar a imagem, também podemos determinar que o <i>post</i> é positivo, pois está se referindo a uma pessoa dançando e recebendo confete.</p> <p>Texto: Sorrir não mata , viver não dói , abraçar não arde , beijar não fere , rir não machuca. Você não tem motivos para não tentar ser feliz. =)</p>	
<p>Neutro</p> <p>Neste exemplo, o <i>post</i> é puramente informativo e não oferece nenhuma indicação quanto ao humor do autor. Este <i>post</i> também é relevante, pela imagem que a compõe.</p> <p>Texto: "Sabe por que a Lua é solitária? Nos começamos dos tempos, haviam dois espíritos que reinavam o cão noturno: a Lua e Coacuatchoo, e eles se amavam. Certo dia, um espírito trapaceiro enganou Coacuatchoo dizendo que ele deveria descer ao reino dos mortais para trazer rosas para a Lua. Certo de que faria sua amada feliz, assim ele o fez. Mas ao tentar retornar ao reino dos espíritos, Coacuatchoo percebeu que jamais poderia voltar. Assim, até hoje, nas noites que a Lua revela toda sua beleza, Coacuatchoo chora, gritando para o mundo o nome dela, sabendo que jamais por toda a eternidade poderá mais tocá-la".- Velha Lenda Nativo-Americana, retratada no filme X-Men Origine: Wolverine</p>	
<p>Negativo</p> <p>Neste exemplo, o clima negativo é indicado pela descrição feita da forma com que o homem trata a mulher, quanto pela imagem de solidão e indicativo de reflexão.</p> <p>Texto: Por que os homens são tão difíceis? Não aceitam nada, não aceitam sofrer, não aceitam, se entregar fácil, não aceitam ser "gente" e dizem que são solitários. Porra, mulheres se humilham, por causa deles, e eles? Dizem que amam, iludem, conseguem o que querem, e que se dane a gente! Dizem ainda que sabem o que é amar. Tá na hora deles, se assumirem, e dizerem que são "HOMENS".(tati)</p>	

Tabela 3.15 – Example: The pictures can be classified as positive, negative or neutral

<p>Contraditório</p> <p>Neste exemplo, o texto é positivo pela descrição das guloseimas feita da forma com que seja irresistível não comer. Já a imagem representa um sentimento negativo porque mostra uma pessoa além do peso, comendo descontroladamente. Através desse <i>post</i>, podemos indicá-lo com sentimento negativo.</p> <p>Texto: Eu só queria saber quem foi o indivíduo que inventou o chocolate? E também queria saber quem inventou a pizza, o pão de queijo, a pipoca, a coca-cola, o pastel, o Mc Donald's, a batata frita, o sorvete e o brownie. Mas o que eu mais queria saber é porque tudo que é bom engorda? p.s.: sim, eu queria todas essas guloseimas agora mesmo.</p>	
<p>Contraditório</p> <p>Neste exemplo, o texto é negativo pela descrição crítica sobre o professor. Já a imagem representa um sentimento positivo em relação ao professor. Através desse <i>post</i>, composto de texto e imagem, podemos indicar um sentimento negativo.</p> <p>Texto: O material escolar mais barato que existe na praça é o professor! É jovem, não tem experiência. É velho, está superado. Não tem automóvel, é um pobre coitado. Tem automóvel, chora de barriga cheia. Fala em voz alta, vive gritando. Fala em tom normal, ninguém escuta. Não falta ao colégio, é um caxias. Precisa faltar, é um turista. Conversa com os outros professores, está malhando os alunos. Não conversa, é um desligado. Daí muita matéria, não tem dó do aluno. Daí pouca matéria, não prepara os alunos. Brinca com a turma, é metido a engraçado. Não brinca com a turma, é um chato. Chama a atenção, é um grosso. Não chama a atenção, não sabe se impor. A prova é longa, não dá tempo. A prova é curta, tira as chances do aluno. Escreve muito, não explica. Explica muito, o caderno não tem nada. Fala corretamente, ninguém entende. Fala a língua do aluno, não tem vocabulário. Exige, é rude. Elogia, é debochado. O aluno é reprovado, é perseguição. O aluno é aprovado, é mole.</p>	

Harabagiu et al. [HHL06] indica uma definição para contradição sendo a incompatibilidade entre dois textos diferentes. Essas incompatibilidades podem ser apresentadas de várias formas, tais como: negação (através do advérbio de modo 'não', por exemplo), antonímia ou contraste (usando palavras de sentidos opostos) mas com informação semântica e pragmática, ou seja, quando o texto tem que seguir uma linha de sentido ou uma sequência de atos.

Marneffe et al. [DMRM08] utilizam a definição lógica de contradição em que duas sentenças A e B são contraditórias quando não existe a possibilidade de ambas sentenças serem verdadeiras. Tentam expressar essa definição de forma mais intuitiva, definindo contradição como contrastes que são extremamente difíceis de ocorrerem concomitantemente. E, informam que para os textos serem contraditórios, é necessário referir-se ao mesmo evento. Vejamos exemplos:

- A polícia especializada em bombas desarmou os explosivos. Por volta de 100 pessoas estavam trabalhando na fábrica.
- 100 pessoas ficaram feridas.

Trata-se do mesmo evento, sendo que na frase 1 é informado que os explosivos foram desarmados, implicando ninguém ficar ferido. Já na 2 há uma contradição porque ele indica que houve feridos.

Tsytsarau et al. [TPD11] definem a contradição em uma base de pares de documentos, em que é avaliada a discordância entre eles. Nesse caso, a semelhança de informações dentro de cada documento serve como um ponto de referência. Os autores consideram que essa definição pode levar a diferentes implementações, e que cada uma delas poderá ter uma interpretação um pouco diferente da ideia de contradição.

Para esse trabalho, usou-se a definição que é caracterizada pelo uso da polaridade de Harabagiu [HHL06]. Verificou-se separadamente a classificação da imagem e do texto, que compõem o blog do *Ground Truth*. O resultado desses dois domínios determina se existe ou não uma contradição.

Segundo Marneffe [DMRM08], os tipos de contradição estão divididos em duas categorias, sendo uma de fácil detecção e outra mais complexa:

1. Categoria Fácil

- (a) Antonímia: Uma forma de detectar contradição é através de sincronia dos antônimos. Verifica-se se um par de palavras alinhadas na lista, assim como a prefixação de antônimos. A polaridade do contexto é usada para determinar se os antônimos criam uma contradição. A seguir são apresentados dois exemplos de antonímia que geram contradições:

- A pena de morte é um catalisador para mais crimes.

- A pena de morte é um impedimento ao crime.
- (b) Negação: São termos ou frases de negação que podem alterar a polaridade da sentença. Algumas palavras que têm essa característica são ‘não’, ‘sem’, ‘quase’. Cada um deles é capaz de inverter a polaridade da sentença ou afirmação. Seguem exemplos de negação que são contraditórios entre si:
- A Suprema Corte, muito dividida, disse que o júri e não os juízes devem impor uma sentença de morte.
 - A Suprema Corte decidiu que apenas juízes podem impor a sentença de morte.
- (c) Numérico: Havendo no texto informações numéricas, de data ou de tempo, a incompatibilidade dessas informações com as sentenças do contexto pode indicar a existência de uma contradição. Seguem exemplos de contradição:
- A tragédia da explosão em Qana, que matou mais de 50 civis, representou Israel com sua alma.
 - Uma investigação sobre a greve em Qana encontrou 28 confirmados mortos até agora.

2. Categoria Complexa

- (a) Factível: O contexto no qual uma frase verbal é inserida pode dar origem a contradição. A negação pode influenciar nesse processo. Seguem exemplos sobre a categoria factível:
- O primeiro-ministro John Howard diz que não será influenciado por ouvir os ataques de maior terrorismo da Austrália a menos que retire suas tropas do Iraque.
 - Austrália se retira do Iraque.
- (b) Estrutural: É analisada a estrutura sintática e determinado o papel de cada palavra dentro das sentenças para indicar se existe uma contradição. Seguem exemplos de Categoria Estrutural:
- O Canal da Mancha se estende da Inglaterra para a França. É o segundo túnel ferroviário mais longo do mundo, sendo o mais longo um túnel no Japão.
 - O Canal da Mancha liga a França e o Japão.
- (c) Lexical: Detectar contradição lexicográfica e de conhecimento de mundo tem uma grande complexidade, já que exigem muitas inferências. Seguem exemplos:
- A Comissão de Ética do parlamento canadense disse que a ex-ministra da Imigração, Judy Sgro, não fez nada errado e sua equipe a colocou em um conflito de interesses.
 - A Comissão de Ética do parlamento canadense acusa Judy Sgro.

A Categoria dita Fácil é vista assim pelos autores porque a detecção de contradição pode ser automatizada através do computador uma vez que não há necessidade de compreensão da sentença inteira. Da mesma forma, a Categoria dita Complexa contém tipos de contradição que não apresentam fácil detecção, porque a estrutura sintática dificulta garantir diferença estrutural no texto, tornando-se complexo inferir contradição.

A dita Categoria Fácil foi escolhida neste trabalho porque a detecção de antônimos e negação são exemplos de recursos que são facilmente automatizados através do computador, já que não há necessidade de entender a frase inteira. Ainda o estudo de Vargas [Var16] indica a relação de contraste entre duas sentenças quando as situações apresentadas são iguais ou diferentes em alguns aspectos. Esses marcadores discursivos são representados pelas classes sintáticas de conjunções e advérbios. As conjunções são consideradas uma das classes mais interessantes para identificar a polaridade. Os advérbios, de acordo com Marneffe [DMRM08], são um dos passos para descobrir a relação contrastante entre as palavras, além de citar os advérbios negativos fortes como um dos processos de identificação de negação.

Assim, nesta pesquisa incluímos advérbios com todas as suas divisões, incluindo advérbios de negação como mencionado na categoria fácil. Ainda Torres [dAT25] menciona que a pontuação indica, por escrito, as pausas que devem ser observadas pelo falante ou leitor. O uso do ponto de exclamação (!) se encaixa nessa definição porque pode aumentar a magnitude da intensidade sem alterar a orientação semântica. O uso do ponto-e-vírgula (;) normalmente substitui as conjunções de coordenação. Assim, neste trabalho, também consideramos o uso da pontuação no texto como um assunto para análise.

A ironia como contraste entre realidade e aparência

O processo de identificação de ironia em redes sociais tem chamado atenção de diversas áreas, tais como na computação. Para o ser humano é fácil a detecção da ironia devido à vários fatores, entre eles podemos destacar os gestuais e os fatores de entonação. Entretanto, detectar esses recursos nos meios de comunicação da Web, já é bastante desafiador.

Singh [Sin12] comenta que uma das características da ironia é a inversão da polaridade sobre o que se quer dizer que ocorrem através de vários recursos linguísticos. Então, conseguir reconhecer os elementos dessa mudança de polaridade, pode ajudar na detecção mais adequada de sentimentos sobre os dados disponíveis na Web. Existem três tipos de ironia definidas pelo autor:

- Ironia Verbal: Trata-se do contraste entre o que é dito e o que de fato significa. Um exemplo é o sarcasmo. As influências léxicas podem contribuir na percepção do sarcasmo conforme indica Kreuz et al. [KC07].

- **Ironia Dramática:** Trata-se do contraste entre o que o personagem pensa ser verdade e o que nós (o leitor) sabemos ser verdadeiro. Às vezes, quando lemos, somos colocados na posição de saber mais do que um personagem sabe. Porque sabemos algo que o personagem não sabe, lemos para descobrir como o personagem reagirá quando ele ou ela souber a verdade da situação.
- **Ironia Situacional:** Esta é a mais comum na literatura. É o contraste entre o que acontece e o que é esperado (ou o que parece apropriado). Por emergir dos eventos e circunstâncias de uma história, ela é freqüentemente mais sutil e efetiva do que a ironia verbal ou dramática.

Para esse trabalho, foram utilizados os três tipos de ironias classificados por Singh [Sin12] de forma empírica. Na próxima seção são apresentadas técnicas para detecção dos elementos de contradição usados neste trabalho.

3.4.2 Técnicas usadas para detecção de elementos de contradição nos Textos do GT

Para detecção de contradição no texto, foi usada a biblioteca NLTK (Natural Language ToolKits) ¹⁰. Dentre as bibliotecas disponíveis, usamos «nltk.synset» e «Spacy» que auxiliam na detecção de similaridades entre palavras, sentenças e fornecem a análise das classes gramaticais. A biblioteca «Spacy» foi utilizada com o texto em português para informar a classe gramatical de cada palavra. Dessa forma, foi possível identificar as conjunções, os advérbios, as palavras negativas, as pontuações do texto e quantificar cada classe.

A tarefa de processamento bruto é bastante desafiadora, porque as palavras comumente podem ter significados próximos ou mesmo diferentes se a ordem delas na frase for alterada. Para resolver alguns problemas a partir de dados brutos, é melhor o uso do conhecimento linguístico para que se tenha informações úteis. Para isso, são utilizadas as seguintes anotações linguísticas disponíveis para descobrir padrões de contradição no texto:

- Um modificador adverbial de uma palavra é um advérbio ou frase adverbial que serve para modificar o significado da palavra;
- O modificador de negação é a relação entre uma palavra de negação e a palavra que ela modifica. É usado tanto para negação de predicado quanto para negação nominal. Os elementos usados são os seguintes: nem, nunca e não;
- Um modificador adjetivo nominal é qualquer adjetivo ou frase adjetiva que serve para modificar o significado. Isso inclui modificadores, tais como: "sempre" ou "às vezes";

¹⁰<https://www.nltk.org/>

- O modificador conjuntivo que serve para modificar a polaridade da frase anterior está relacionado a conjunções coordenativas adversativas e conjunções subortivas concessivas
- A pontuação pode aumentar a magnitude da intensidade sem modificar a orientação semântica. Por exemplo, “A comida aqui é boa!” tem mais intensidade do que “A comida aqui é boa”.

Os recursos que utilizamos para a detecção de ironia são os indicados por Gonçalves et al. [GDR⁺15] baseadas em características linguísticas do conteúdo:

- O uso acentuado da terceira pessoa, pelo menos duas vezes mais do que os textos que não são irônicos;
- Utilizam mais expressões como “Er”, “hm” e “umm”;
- O conteúdo textual deve ser fundamentado no conhecimento sobre o assunto abordado.

A detecção de ironia é um assunto bastante complexo, inclusive de elaborar um programa para sua busca a fim de automatizar o processo. Por isso, a ironia será avaliada sem qualquer recurso tecnológico, apenas humano, nas amostras citadas nesse trabalho, ou seja, o uso será de forma empírica.

O objetivo das técnicas utilizadas nesse trabalho é obter de forma automática alguns elementos da classe gramatical que podem sinalizar contradição no texto e que possibilitam a alteração da polaridade do texto preprocessado. Por exemplo, dada uma sentença, o algoritmo busca advérbios, antônimos, negação e pontuação. Seguem os passos para esse processo:

- O texto é carregado do *dataset Cross-media Brazilian Blog*, conforme explicado na Seção 3.3, que apresenta a opinião das pessoas sobre os diversos assuntos discutidos no *Blog*. Trata-se de 880 linhas com dados textuais.
- É feito um preprocessamento no texto, sem remover *stopwords*, porque podem ser consideradas relevantes para o conjunto de resultados na construção desse modelo.
- O texto é analisado gramaticalmente e detecções de similaridade entre palavras são feitas.
- Listas de advérbios, de palavras e locuções de negação, conjunções relacionadas à contradição são criadas para comparar as análises gramaticas detectadas. A quantificação de palavras em cada elemento de estudo referenciado na Seção 3.4 é realizada.

- Em seguida é calculada a métrica *compound* para indicar a intensidade do sentimento analisado conforme explica Rieis et al. [dRdSdM⁺15] ao tratar de a força do sentimento, sendo um percentual que indica se o sentimento é positivo, neutro ou negativo no texto.
- Calcula-se também a subjetividade do texto a fim de reafirmar o exposto por Moraes et al. [MSR⁺16].
- Um *dataframe* é criado com o número de identificação único do *blog*, a quantidade de palavras com sua classe gramatical detectada, a subjetividade e a métrica *compound* que indica a intensidade da polaridade ternária do texto preprocessado.
- É gerado um arquivo para posterior análise dos resultados.

3.4.3 Exemplos de Textos extraídos do CBB para uso da Técnica de detecção de contradição

Seguem exemplos de textos extraídos do corpus para avaliação realizada em cada etapa informada nessa Seção a respeito das técnicas trabalhadas para detecção de contradição nas Tabelas 3.16 a 3.20. Lembrando que os textos do GT serão representados por GT Texto para melhor entendimento do que se refere e facilidade de escrita.

Na próxima seção serão apresentados os resultados obtidos através da metodologia proposta.

Tabela 3.16 – Frase de exemplo preprocessada, traduzida e com características para detectar contradição. Esse *Post* foi definido como NÃO-contraditório no GT.

Etapa	–
Preprocessamento	"Para estar diante de você, para poder te tocar, e sentir a sua respiração que fecho os olhos te trago pro meu mundo, e tudo ganha cor, posso finalmente ficar em teus braços e olhando em seus olhos dizer EU te AMO, MINHA VIDA SE RESUME EM você E O quê EU SINTO NUNCA ACABARÁ Mais então, você se afasta, e a cada segundo esta mais distante de mim, e então desperto para a realidade, e percebo que foi apenas mais um sonho, mais um maravilhoso sonho com você! Meu sentimento não é de tristeza por não te ter ao meu lado, e sim felicidade pois tenho você em minha vida, e é apenas questão de tempo para que eu finalmente possa te abraçar e ficar ao seu lado até o final! s2 "
Características	<ul style="list-style-type: none"> • Advérbios: 10 • Antônimo: 0 • Conjunção: 1 • Negação: 0 • Pontuação: 6
Tradução	"To be before you, to be able to touch you, and feel your breath that I close my eyes bring you to my world, and everything gets color, I can finally stay in your arms and look in your eyes say I LOVE YOU, MY LIFE IF SUMMARY ON YOU AND WHAT I FEEL WILL NEVER END More then, you move away, and every second you are farther from me, and then awake to reality, and realize it was just another dream, another wonderful dream with you! My feeling is not sadness for not having you by my side, but happiness because I have you in my life, and it's only a matter of time before I can finally hug you and stay by your side until the end! s2"
Características	<ul style="list-style-type: none"> • <i>Compound</i>: 96% de intensidade de sentimentos, indicando que a polaridade do texto é Positiva. O GT Texto também indica a mesma polaridade. • Subjetividade: 56% de acordo com as análises feitas usando o NLTK, indicando que o texto é considerado subjetivo

Tabela 3.17 – Frase de exemplo preprocessada, traduzida e características para detectar contradição. Esse *Post* foi definido como NÃO-contraditório no GT.

Etapa	–
Preprocessamento	"eu odeio explicar porquê estou chorando , só quero chorar e pronto . via : gota d'agua"
Características	<ul style="list-style-type: none"> • Advérbios: 1 • Antônimo: 0 • Conjunção: 0 • Negação: 0 • Pontuação: 4
Tradução	"I hate to explain why I'm crying, I just wanna cry and that's it. via: gotad'agua"
Características	<ul style="list-style-type: none"> • Compound: -87% de intensidade de sentimento, indicando que a polaridade do texto é Negativa. O GT Texto indica a mesma polaridade. • Subjetividade: 65% de acordo com as análises feitas usando o NLTK, indicando que o texto é considerado subjetivo.

Tabela 3.18 – Frase de exemplo preprocessada, traduzida e características para detectar contradição. Esse *Post* foi definido como NÃO-contraditório no GT.

Etapa	–
Preprocessamento	"bom dia instaladores da adobe , hoje mostrarei como resolver o erro de instalação do pacote adobe . É só mover a pasta de instalação pra raiz , ou seja , pra sua unidade c :/ por exemplo . e instalar a partir dessa pasta localizada na raiz . por hoje é só pessoal , gambiarrista"
Características	<ul style="list-style-type: none"> • Advérbios: 4 • Antônimo: 0 • Conjunção: 0 • Negação: 0 • Pontuação: 5
Tradução	"good morning adobe installers, today i will show you how to fix the adobe package installation error. Just move the installation folder to root, ie to your c:/ drive for example. and install from that folder located at the root. for today it's just folks, gambiarrista"
Características	<ul style="list-style-type: none"> • Compound: -35% de intensidade de sentimento, indicando que a polaridade do texto é Negativa. O GT Texto indica a mesma polaridade. • Subjetividade: 11% de acordo com as análises feitas usando o NLTK, indicando que o texto é considerado objetivo

Tabela 3.19 – Frase de exemplo preprocessada, traduzida e características para detectar contradição. Esse *Post* foi definido como Contraditório e também indica Ironia.

Etapa	–
Preprocessamento	"fora de mim , dentão de você , com saudade , verdade . mar , ar , respirar , amar estar ao lado , ficar distante . o amor é contraditório , talvez seja a explicação para tamanha confusão . eu sou contraditória , e é por isso que digo que não me importo com você , estou falando inverdades lembre-se disso , sempre que querer e achar que seja necessário . agora mesmo : eu não gosto de você , eu não sinto sua falta , não te preciso aqui entenda!"
Características	<ul style="list-style-type: none"> • Advérbios: 6 • Antônimo: 0 • Conjunção: 0 • Negação: 4 • Pontuação: 6 <p>Esse texto demonstra ironia verbal, ou seja, quando há contraste entre o que é dito e o que de fato significa.</p>
Tradução	"outside of me, big tooth of you, longing, truth. sea, air, breathe, love being by the side, staying away. Love is contradictory, perhaps the explanation for such confusion. I am contradictory, which is why I say that I do not care about you, I am speaking untruths remember this whenever you want and find it necessary. right now: I don't like you, I don't miss you, I don't need you here understand!"
Características	<ul style="list-style-type: none"> • Compound: 55% de intensidade de sentimento, indicando que a polaridade do texto é Positiva. O GT Texto indica que a polaridade é Neutra. • Subjetividade: 64% de acordo com as análises feitas usando o NLTK, indicando que o texto é considerado subjetivo.

Tabela 3.20 – Frase de exemplo preprocessada, traduzida e características para detectar contradição. Esse *Post* foi definido como Contraditório e também indica Ironia.

Etapa	–
Preprocessamento	"ah não sei porquê hoje eu acordei com uma sensação boa estranha diferente eu nem mesmo sei explicar aí certo como estou me sentindo mais digo uma coisa : - cuidado . hoje eu tô pro crime!"
Características	<ul style="list-style-type: none"> • Advérbios: 8 • Antônimo: 0 • Conjunção: 0 • Negação: 1 • Pontuação: 5 <p>A ironia, nessa situação, poderia ser classificada como verbal, porque se trata do contraste entre o que é dito e o que de fato significa. Nesse caso, poderíamos alterar a polaridade do texto de positiva para negativa.</p>
Tradução	"oh I don't know why today I woke up with a different weird good feeling I don't even know how to explain right how I'm feeling anymore I say one thing: - watch out. today i'm for crime!"
Características	<ul style="list-style-type: none"> • Compound: 53% de intensidade de sentimento indicando que a polaridade do texto é Positiva. O GT Texto indica o mesmo. • Subjetividade: 49% de acordo com as análises feitas usando o NLTK, indicando que o texto é considerado objetivo.

4. RESULTADOS DOS EXPERIMENTOS

Neste capítulo são apresentados os resultados da metodologia empregada nesse trabalho. Foram organizados em quatro etapas principais: primeiro, os resultados da análise realizada na classificação de imagens através das redes; segundo, apresentados os resultados da análise feita com a classificação dos textos através dos léxicos; e por fim a análise de contradição nos *posts*.

4.1 Resultados Obtidos com Classificação das Imagens

Nessa Seção é apresentado o resultado da classificação das 880 imagens do Corpus pelas redes SentiBank, DeepSentiBank e VGG-T4SA.

4.1.1 SentiBank

Foi feita a classificação da polaridade através da rede SentiBank e comparada com a quantidade de imagens do GT. A surpresa, nesse caso, é a rede não conseguir classificar 22 imagens. Esse erro de classificação ocorre por indicar um problema nos canais de cores do classificador.

A Figura 4.1 indica que a SentiBank detectou muitas imagens com polaridade neutra, inclusive ultrapassando 29% da quantidade definida no GT Imagens. Também pode-se observar que a quantidade de imagens classificadas como positivas chegou muito próximo do GT Imagens, havendo uma diferença de 0,5% a mais de classificação nesta polaridade. Em relação a polaridade negativa, a rede classificou 51,19% a mais, havendo muita divergência entre esta e o GT Imagens. A Tabela 4.1 indica que a SentiBank detectou apenas 150 imagens para classe positiva, 174 para neutra e 21 para negativa, tendo a mesma polaridade do GT Imagem. A rede SentiBank apresentou um total de acerto em relação ao Corpus completo de 39,20%.

Tabela 4.1 – Comparando os resultados da classificação da SentiBank com o GT Imagens, resulta em 39,20% de acerto

Polaridade	SentiBank	GT Imagens	Polaridade Igual
Positivo	339	341	150
Neutro	351	453	174
Negativo	168	86	21




Figura 4.1 – Apenas a quantidade de imagens distribuídas pela polaridade positiva, neutra e negativa indicadas no corpus através das anotações realizadas no *Figure Eight* (GT) sendo classificadas pela rede SentiBank.

A fim de avaliarmos essa baixa acurácia, testamos uma outra rede existente conforme descrita na Seção 3.1.2.

4.1.2 DeepSentiBank

Foi feita a classificação da polaridade através da rede DeepSentiBank e comparada com a quantidade de imagens do GT Image. O resultado é apresentado na Figura 4.2, a qual indica que a rede detectou poucas imagens com polaridade neutra, em torno de 36% do total de imagens do GT Imagens. No entanto, detectou muito mais imagens positivas e negativas que o próprio GT Imagens, sendo em torno de 75% e 35%, respectivamente. Observou-se que das 880 imagens do GT Imagens a rede conseguiu classificar 872 imagens que é a soma de 460 imagens classificadas como positivas, 163 como neutras e 249 como negativas. Logo, a rede não classificou 8 imagens porque apresentou erro nos canais RGB.

Foi comparada a polaridade do GT Imagem com a polaridade detectada no classificador da DeepSentiBank nos mesmos posts. A Tabela 4.2 indica que a rede DeepSentiBank detectou 65% de imagens com polaridade positiva e com a mesma classificação do GT. Também foi verificado que 20% de imagens com classificação neutra tinham a mesma classificação do GT e 50% de imagens com classificação negativa tinham a mesma classi-

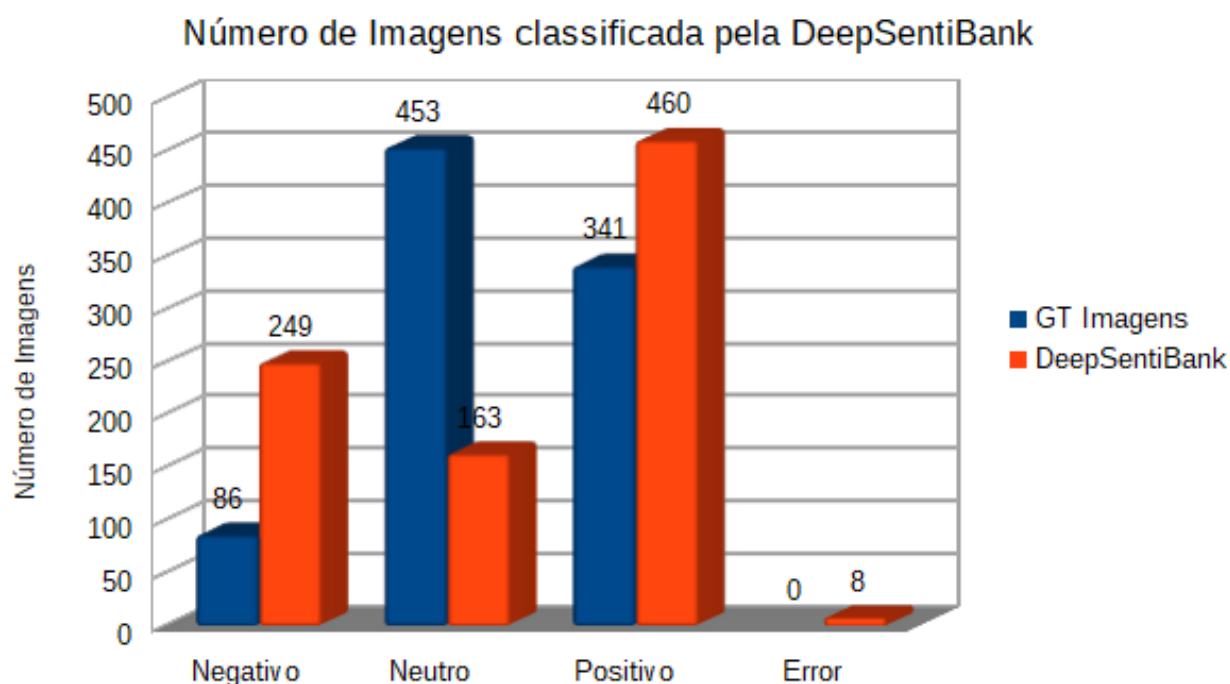


Figura 4.2 – Apenas quantidade de imagens cuja polaridade é positiva, neutra e negativa indicadas no GT Imagens através das anotações realizadas no *Figure Eight* e sendo classificadas pela DeepSentiBank.

ficação do GT. No total 40,56% das imagens foram corretamente classificadas pela DeepSentiBank.

Tabela 4.2 – Comparando os resultados da classificação da DeepSentiBank com o GT das imagens, resulta em 40,56% de acerto

Polaridade	DeepSentiBank	GT Imagem	Polaridade Igual
Positive	460	341	222
Neutral	163	453	92
Negative	249	86	43

4.1.3 VGG-T4SA

A classificação da polaridade através da Rede VGG foi citada no processo de criação do corpus na Seção 3.3. Foram selecionadas apenas imagens que contivessem classificação binária, ou seja, positiva ou negativa para posterior seleção de *posts* a serem usados no *Figure Eight*. Portanto, das 880 imagens do Corpus, conforme Tabela 4.3, 490 imagens foram classificadas como positivas e 390 como negativas pela rede VGG.

Conforme a Tabela 4.3, foram detectadas 58 imagens com polaridade negativa que se equivalem ao GT Imagem, correspondendo a um percentual em torno de 69%. Também

foram classificadas 231 imagens com polaridade positiva igual ao GT Image, implicando em percentual em torno de 67%. Como a classificação foi somente binária, o percentual de acerto total baixa para 32,84% se consideradas as imagens neutras no total, e fica em 67,68%, sendo consideradas somente as imagens positivas e negativas do GT.

Tabela 4.3 – Comparando os resultados da classificação da Rede VGG com o GT das imagens positivas e negativas apenas, resulta em 67,68% de acerto.

Polaridade	VGG	GT Imagens	Polaridade Igual
Positivo	490	341	231
Neutro	0	453	0
Negativo	390	86	58

4.1.4 Comparação do Classificador e das 2 Redes Usadas na Classificação das Imagens

Apesar da rede VGG apresentar classificação binária (pois foi usada no processo de pré-seleção de imagens do CBB), a Tabela 4.4 visa resumir as classificações obtidas com as três redes testadas no presente trabalho.

Tabela 4.4 – Comparando os resultados da classificação do Classificador SentiBank, e das Redes DeepSentiBank e VGG com o GT, resultando em predições em torno de 39,20%, 40,56% e 32,84% (considerando as neutras) e 67,68% (sem considerar as neutras) de acurácia em cada rede, respectivamente

Polaridade	SentiBank e GT	DeepSentiBank e GT	VGG e GT
Positivo	150	222	231
Neutro	174	92	0
Negativo	21	43	58
Totais	345	357	289
% de acerto	39,20	40,56	32,84-67,68

Uma vez que as redes testadas apresentaram baixa acurácia com o corpus CBB, foi criado um outro *dataset* para verificação, conforme apresentado na próxima seção.

4.1.5 Comparando CBB e outro *Dataset* - Google Images

Enquanto o CBB, que compreende *blogs* reais e espontâneos, apresentou baixa acurácia nas redes testadas, decidimos buscar outras imagens mais explícitas das emo-

ções referidas (positiva, neutra e negativa) para que pudessem ser testadas. Assim criamos outro *dataset* com base nas imagens disponíveis através do mecanismo de buscas Google ¹. Para a escolha das palavras-chave usadas na busca de imagens com emoções bem definidas, usou-se o estudo de Robert Plutick [Plu80], cujo trabalho originou a roda de emoções composta por 8 emoções básicas e que unidas podem gerar outras emoções. Assim, utilizou-se as seguintes palavras-chave:

- Para a emoção positiva usou-se as palavras Felicidade e Diversão, retornando em torno de 1600 imagens;
- Para a emoção neutra usou-se as palavras Serenidade e Aceitação retornando em torno de 800 imagens;
- Para a emoção negativa usou-se as palavras Raiva e Ódio, retornando em torno de 1400 imagens;

Por fim, descartou-se imagens que contivessem textos. Como resultado desse processo criamos um *dataset* com 924 imagens, sendo 400 imagens positivas, 150 neutras e 374 negativas. A Figura 4.3 mostra a distribuição de imagens entre as classes positivas, neutras e negativas. A classificação oriunda da pesquisa da Google foi considerada como sendo o *Ground truth* deste *dataset* e denominado de IG. O *dataset* IG foi testado com as







Figura 4.3 – Quantidade de imagens com a polaridade positiva, neutra e negativa indicadas no dataset através dos critérios adotados.

¹<https://www.google.com.br/>

tecnologias pesquisadas no presente trabalho (SentiBank, DeepSentiBank e VGG-T4SA) e resultaram na classificação de polaridade das imagens. Três imagens são ilustradas na Tabela 4.5 a fim de apresentar exemplos qualitativos.

Tabela 4.5 – Imagens de exemplo processadas pela SentiBank, DeepSentiBank e VGG, representadas pela numeração I, II e III respectivamente. A primeira linha indica uma imagem negativa, a segunda linha se trata de sentimento neutro e a terceira linha retrata uma imagem positiva, de acordo com as pesquisas realizadas no Google.

Imagem	Positivo	Neutro	Negativo
	-	-	I, II e III
	-	I, II e III	-
	II e III	-	I

O resultado das polaridades das imagens do *dataset* IG é apresentado na Figura 4.4 e na Tabela 4.6. Ainda a Tabela 4.7 apresenta as quantidades de imagens em que as polaridades foram equivalentes quando comparadas as redes com o *Ground truth* (IG). Para fins de comparação com o GT, as duas últimas linhas da tabela reapresentam os dados obtidos.

Tabela 4.6 – Mostrando os resultados da classificação da Rede SentiBank, DeepSentiBank e VGG em cada classe.

Polaridade	SentiBank	DeepSentiBank	VGG	IG
Positivo	414	429	404	400
Neutro	231	213	182	150
Negativo	279	282	338	374

O resultado apresentado na Tabela 4.7 indica claramente a baixa acurácia das redes nas avaliações do CBB quando comparadas às classificações obtidas nas imagens do Google. Se por um lado o *Ground truth* do CBB foi criado pela participação de sujeitos usando o Figure Eight, a pesquisa do Google com palavras-chave foi considerada como *Ground truth*. Enquanto a diferença na origem da "verdade" sobre as imagens dos dois *datasets* possa ser uma variável no resultado obtido, acreditamos que um outro aspecto deva ser considerado. Nossa hipótese é que o CBB, por ser espontâneo (*wild*) seja composto por imagens cuja emoção não é tão bem definida em comparação as imagens do Google e portanto possa ocasionar maiores divergências na classificação. Ainda, para as redes




Figura 4.4 – Imagens com polaridade positiva, neutra e negativa do *dataset* de Imagens do Google (IG), sendo verificadas se as polaridades classificadas nas Redes SentiBank, DeepSentiBank e VGG equivalem ao IG.

Tabela 4.7 – Comparando os resultados da classificação da Rede SentiBank, DeepSentiBank e VGG com o IG, resultando em previsões em torno de 72,07%, 72,51% e 91,23% de acurácia em cada rede, respectivamente.

Polaridade	SentiBank e IG	DeepSentiBank e IG	VGG e IG
Positivo	308	316	375
Neutro	123	117	139
Negativo	235	237	329
Totais	666/924	670/924	843/924
% de acerto	72,07	72,51	91,23
	SentiBank e GT	DeepSentiBank e GT	VGG e GT
Totais	345/880	357/880	289/880
% de acerto	39,20	40,56	32,84-67,68

SentiBank e DeepSentiBank o *dataset* para treinar os conceitos de sentimento visual envolve milhares de categorias, que são substantivos e adjetivos detectados nas *tags* das imagens retiradas da *web*. Esse *dataset* consiste em cerca de um milhão de imagens baixadas do Flickr. Na rede VGG-T4SA foram exploradas imagens dos tweets, rotulados de acordo com a polaridade do sentimento do texto associado. Foram coletados e analisados mais de 3 milhões de *tweets* para construir o *dataset Twitter for Sentiment Analysis (T4SA)*.

T4SA é composto de cerca de 1 milhão de *tweets* de alta confiança para os quais foram classificados o sentimento textual.

Aparentemente, pode-se dizer que para garantir boa acurácia na classificação de polaridade de imagens *wild* é importante utilizar rótulos que identifiquem as possíveis emoções de uma imagem em seu *dataset* de treino. Datta et al. [DLW08], abordam o estudo da estética algorítmica em imagens genéricas buscando atributos estéticos para serem usados como uma medida consensual de um grupo, sendo a predição da emoção um problema de categorização de múltiplas classes e portanto um desafio nessa área.

4.2 Resultados Obtidos com Classificação dos textos

O primeiro passo para o processamento dos 880 textos do CBB é a análise de sentimentos de cada palavra para descobrir a sua polaridade predominante, conforme explicitadas as técnicas dos Léxicos na Seção 3.2. Neste trabalho, foram usados quatro léxicos: OpLexicon, SentiLex, LIWC e a biblioteca NLTK, sendo que os três primeiros trabalham com palavras em português enquanto o NLTK exigiu que os textos fossem traduzidos para o inglês. Nas próximas seções serão apresentados dados obtidos com as avaliações.

4.2.1 OpLexicon

Foi feita a classificação da polaridade através do léxico Oplexicon e comparada com a quantidade de textos do GT. A Figura 4.5 ilustra estes resultados. Ao confrontar o resultado de classificação do GT Texto com o OpLexicon, verificamos que 52,58% das classificações Positivas realizadas estão de acordo com o GT Texto. Em relação às classes neutras, o OpLexicon concordou em 50,21% com o GT Texto, e, para a classe negativa essa avaliação ficou em torno de 20,79%. Estes valores somam um total de 41,19% dos textos presentes nos 880 blogs do CBB.

4.2.2 SentiLex

Foi feita a classificação da polaridade através do SentiLex e comparada com a quantidade de textos do GT. A Figura 4.6 ilustra estes resultados. Ao confrontar o resultado de classificação do GT Texto com o SentiLex, verificamos que 50,56% das classificações positivas realizadas estão de acordo com o GT Texto. Em relação às classes neutras, o SentiLex concordou em 44,20% com o GT Texto, e, para a classe negativa essa avaliação




Figura 4.5 – Distribuição quantitativa de textos através da avaliação do OpLexicon e GT Texto.

ficou em torno de 35,64%. Estes valores somam um total de 43,46% dos textos presentes nos 880 blogs do CBB.




Figura 4.6 – Distribuição quantitativa dos textos através da avaliação do SentiLex e GT Texto.

4.2.3 LIWC

Foi feita a classificação da polaridade através do LIWC e comparada com a quantidade de textos do GT. A Figura 4.7 ilustra estes resultados. Ao confrontar o resultado de classificação do GT Texto com o LIWC, obtivemos 45,39% das classificações positivas realizadas estão de acordo com o GT Texto. Em relação às classes neutras, o LIWC concordou em 66,09% com o GT Texto, e, para a classe negativa essa avaliação ficou bastante baixa em torno de 12,37%. Estes valores somam um total de 41,28% dos textos presentes nos 880 blogs do CBB.




Figura 4.7 – Distribuição quantitativa de textos através da avaliação do LIWC e GT Texto.

4.2.4 NLTK

Da mesma forma que computado para os léxicos apresentados anteriormente, foi feita a classificação da polaridade através do NLTK e comparada com a quantidade de textos do GT. A Figura 4.7 ilustra estes resultados. Ao confrontar o resultado de classificação do GT Texto com o NLTK, obtemos 92,13% das classificações positivas realizadas estão de acordo com o GT Texto. Em relação às classes neutras, o NLTK concordou em 13,30% com o GT Texto, e, para a classe negativa essa avaliação foi de 36,63%. Estes valores somam um total de 47,35% dos textos presentes nos 880 blogs do CBB.




Figura 4.8 – Distribuição quantitativa de textos através da avaliação do NLTK.

4.2.5 Comparação dos 4 Léxicos Usados na Classificação dos textos em Relação ao GT

O resultado apresentado na Tabela 4.8 indica uma baixa acurácia dos léxicos nas avaliações do CBB quando comparado ao GT. Conforme já discutido na análise das imagens, o *Ground truth* do CBB foi criado pela participação de sujeitos usando o Figure Eight e assumimos neste trabalho que esta é a verdade sobre os sentimentos atribuídos aos textos. Possíveis explicações para a baixa acurácia das classificações pode ser alta subjetividade dos textos, contradições, ironia e presença de muitos emoticons ou expressões usadas comumente, de maneira espontânea, que foram ignoradas na fase de pré-processamento dos textos.

Tabela 4.8 – Comparando os resultados da classificação dos léxicos OpLexicon, SentiLex, LIWC e NLTK com o GT, resultando em predições em torno de 44,65%, 45,45%, 43,29% e 58,22% de acurácia em cada léxico, respectivamente.

Polaridade	OpLexicon e GT	SentiLex e GT	LIWC e GT	NLTK e GT
Positivo	234	225	202	410
Neutro	117	103	154	31
Negativo	42	72	25	74
Totais	393/880	400/880	381/880	515/880
% de acerto	44,65	45,45	43,29	58,22

4.3 Resultados das Contradições no Ground Truth

Durante a anotação do Corpus CBB, foram detectados 29 *post* definidos manualmente como contraditórios, conforme explicitado na Seção 3.4. Em 7 desses 29 não houve dúvidas por parte dos avaliadores de que tratava-se de *posts* contraditórios, porque 100% dos avaliadores concordaram quanto a esta classificação. Nos demais *posts*, a indicação foi em torno de 65% dos avaliadores considerando-os contraditórios, ou seja ainda um valor alto. Assim, o objetivo desta seção é avaliar qualitativamente e quantitativamente os *posts* com relação a sua natureza contraditória.

Primeiramente, a fim de prover uma avaliação mais individual, optou-se por selecionar randomicamente 10 dos 29 *posts* ditos contraditórios e 10 dos 851 considerados não contraditórios. O resultado desta análise pode ser visualizado nas Seções 4.3.1 e 4.3.2 e Figuras 4.9 e 4.10.

4.3.1 Resultado da análise em amostra de 10 *posts* NÃO-contraditórios

Esta seção apresenta uma amostra de 10 *posts* não-contraditórios com dados quantificados em relação às classes gramaticais escolhidas para análise de contradição. Cada *post* foi representado pelo seu identificador no eixo X da Figura 4.9. O eixo Y indica a quantidade de palavras pertencente a cada referida classe gramatical.

Pode-se verificar que a maioria das classes gramaticais estão abaixo de 5 palavras para cada classe. Aquelas que indicam uma quantidade mais elevada de palavras pode ter relação com a quantidade de palavras totais no *post*, ou seja, o texto é maior. Em 6 *posts* houve a indicação do uso da classe adverbial com mais de 5 palavras. A classe dos antônimos aparecem em 3 *posts* sendo dois *post* com no máximo duas palavras e um *post* contendo no máximo 5. Somente 3 *post* indicaram a presença de uma conjunção. Os elementos de negação em apenas 3 *post* indicam mais de 5 palavras e não passam de 7. A maioria dos *post* que tem classes gramaticais negativas ficam em torno de 2 palavras. Nestes casos, o somatório de palavras das classes gramaticais ficou abaixo de 5 palavras em sua maioria e também dificilmente todas as classes estavam presentes no texto, indicando que textos não-contraditórios dificilmente terão classes como antônimos e conjunções, por exemplo. As ocorrências médias das classes gramaticas nestes 10 *post* ditos contraditórios e não-contraditórios são apresentadas na Tabela 4.19.

Tabela 4.9 – *Post* considerado NÃO-contraditório com emoção predominantemente Neutra, de acordo com o GT.


Imagem	Texto 1755476207				
	<p>Sumi, eu sei que sumi! Mas estou de volta! O <i>post</i> de hoje vai falar sobre o lindo convite que recebi do Marcello Caridade, para fazer parte do elenco de "The Rocky Horror Show" que foi apresentado em fevereiro de 2014 no Teatro do Fashion Mall em São Conrado - RJ. O Elenco estava lindo, a galera realmente encarnou nos zumbis viciados em sexo! hahah Enfim, vou postar aqui umas fotos só para vocês ficarem ainda mais na vontade de ter assistido! Porque eu sou dessas, malvada!!! Poliana Anderle Espero que tenham gostado!!! Beijinhos, Poliana Anderle</p>				
<p>O <i>post</i> foi indicado como sendo 100% NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 100% positivo • Imagem: 100% negativo • Post: 100% neutro <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Texto</th> <th style="text-align: left;">Imagem</th> </tr> </thead> <tbody> <tr> <td> <ul style="list-style-type: none"> • OpLexicon: negativo • SentiLex: neutro • LIWC: neutro • NLTK: positivo </td> <td> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo </td> </tr> </tbody> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 96 palavras e sinais de pontuação, sendo Pontuação: 6, Advérbios modificadores: 10, Conjunção: 1, Negação: 0 e Antônimos: 0.</p> <p>O somatório de palavras das classes é 17 e corresponde a aproximadamente 18% do total de palavras do <i>post</i>. O texto indica 54% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 96% de intensidade para sentimentos extremamente positivos. Pela análise manual, parece não indicar ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como NÃO-contraditório porque não houve a detecção de ironia.</p>		Texto	Imagem	<ul style="list-style-type: none"> • OpLexicon: negativo • SentiLex: neutro • LIWC: neutro • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo
Texto	Imagem				
<ul style="list-style-type: none"> • OpLexicon: negativo • SentiLex: neutro • LIWC: neutro • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo 				

Tabela 4.10 – *Post* considerado NÃO-contraditório com emoção predominantemente Positiva, de acordo com o GT.


<p>Imagem</p> 	<p>Texto 1755476210</p> <p>"Não, não, o mundo não me agrada. A maioria das pessoas estão mortas e não sabem, ou estão vivas com charlatanismo. E o amor, em vez de dar, exige. E quem gosta de nós quer que sejamos alguma coisa de que eles precisam. Mentir dá remorso. E não mentir ? um dom que o mundo não merece..."</p> <p>Clarice Lispector</p>		
<p>O <i>post</i> foi indicado como sendo 100% NÃO contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto - 100% negativo • Imagem - 73% positivo • Post - 85% positivo <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="vertical-align: top; width: 50%;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: negativo • SentiLex: negativo • LIWC: positivo • NLTK: positivo </td> <td style="vertical-align: top; width: 50%;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: positivo • VGG-T4SA: negativo </td> </tr> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 57 palavras e sinais de pontuação, sendo Pontuação: 4, Advérbios modificadores: 1, Conjunção: 0, Negação: 6 e Antônimos: 2.</p> <p>O somatório de palavras das classes é 17 e corresponde a aproximadamente 24% do total de palavras do <i>post</i>. O texto indica 47% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de -35% de intensidade para sentimentos negativos. Pela análise manual. Aparentemente não há indícios de ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como NÃO-contraditório porque não houve a detecção de ironia.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: negativo • SentiLex: negativo • LIWC: positivo • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: positivo • VGG-T4SA: negativo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: negativo • SentiLex: negativo • LIWC: positivo • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: positivo • VGG-T4SA: negativo 		

Tabela 4.11 – *Post* considerado NÃO-contraditório com emoção predominantemente Negativa, de acordo com o GT.


Imagem	Texto 1755476214				
	<p>Cultura ? o termo genérico usado para significar duas acepções diferentes. De um lado, o conjunto de costumes, civilização e realizações de uma época ou povo, e, de outro lado, artes, erudição e demais manifestações mais sofisticadas do intelecto e da sensibilidade humana, consideradas coletivamente. A cultura organizacional nada tem a ver com isto. No estudo das organizações, a cultura equivale ao modo de vida da organização em todos os seus aspectos, como idéias, crenças, costumes, regras, técnicas, etc. Neste sentido, todos os seres humanos são dotados de cultura, pois fazem parte de algum sistema cultural. Em função disso, toda pessoa tende a ver e julgar as outras culturas a partir do ponto de vista de sua própria cultura. Daí o relativismo: as crenças e comportamentos só podem ser compreendidos em relação ao seu contexto cultural. Cada organização cultiva e mantém a sua própria cultura. É por este motivo que algumas empresas são conhecidas por algumas peculiaridades próprias. Os administradores da Procter Gamble fazem memorandos que não ultrapassam uma página. Todas as reuniões da Du Pont começam com um comentário obrigatório sobre segurança. O pessoal da Toyota está concentrado em perfeição. A cultura representa o universo simbólico da organização e proporciona um referencial de padrões de desempenho entre de padrões de desempenho, entre os funcionários, influenciando a pontualidade, a produtividade e a preocupação com qualidade e serviço ao cliente. A cultura exprime a identidade da organização. ...</p>				
<p>O <i>post</i> foi indicado como sendo 85% NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>: o texto foi considerado neutro com 66%; a imagem foi considerada negativa com 100% e o <i>post</i> foi considerado negativo com 83%.</p> <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" data-bbox="172 1377 1326 1579"> <thead> <tr> <th data-bbox="172 1377 245 1406">Texto</th> <th data-bbox="815 1377 932 1406">Imagem</th> </tr> </thead> <tbody> <tr> <td data-bbox="220 1422 528 1579"> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: positivo • NLTK: positivo </td> <td data-bbox="863 1422 1246 1579"> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo </td> </tr> </tbody> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 385 palavras e sinais de pontuação, sendo Pontuação igual a 5 palavras, Advérbios modificadores igual a 28, para Conjunção não houve detecção, negação igual a 2 e antônimos igual a 5 palavras.</p> <p>O somatório de palavras das classes é 40 e corresponde a aproximadamente 10% do total de palavras do <i>post</i>. O texto indica 41% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 98% de intensidade para sentimentos extremamente positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como NÃO-contraditório porque não houve a detecção de ironia.</p>		Texto	Imagem	<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: positivo • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo
Texto	Imagem				
<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: positivo • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo 				

Tabela 4.12 – *Post* NÃO contraditório com emoção predominantemente Negativa, de acordo com o GT


<p>Imagem</p> 	<p>Texto 1755476239</p> <p>Se eu pedir com toda a minha fé pra Deus ele me trará você de volta? não posso sofrer. ao teu lado eu encontrei a felicidade. ao teu lado eu aprendi a sorrir. você sempre foi o elo que me ligava a realidade, e de repente isso se quebrou em mil pedaços, como um espelho que cai na ponta de alguma coisa afiada. Volta! Por favor, eu não vou conseguir sofrer de novo, não mesmo.</p>		
<p>O <i>post</i> foi indicado como sendo 100% NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 100% negativo • Imagem: 100% negativo • Post: 100% negativo <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="vertical-align: top;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: neutro • LIWC: neutro • NLTK: positivo </td> <td style="vertical-align: top;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo </td> </tr> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 75 palavras e sinais de pontuação, sendo Pontuação: 4, Advérbios modificadores: 5, Conjunção: 0, Negação: 3 e Antônimos: 0. O somatório de palavras das classes é 12 e corresponde a aproximadamente 16% do total de palavras do <i>post</i>. O texto indica 36% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 96% de intensidade para sentimentos extremamente positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como NÃO-contraditório porque não houve a detecção de ironia.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: neutro • LIWC: neutro • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: neutro • LIWC: neutro • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo 		

Tabela 4.13 – *Post* considerado NÃO-contraditório com emoção predominantemente Neutra, de acordo com o GT.


<p>Imagem</p> 	<p>Texto 1755476241</p> <p>Quando todos estiverem chorando, tente você o primeiro sorriso! Talvez não na forma de lábios sorridentes, mas na de um coração que compreenda, de braços que confortem.</p>				
<p>O <i>post</i> foi indicado com 100% como NÃO contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 100% positivo • Imagem: 100% negativo • Post: 100% neutro <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Texto</th> <th style="text-align: left;">Imagem</th> </tr> </thead> <tbody> <tr> <td> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: neutro • NLTK: neutro </td> <td> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo </td> </tr> </tbody> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 27 palavras e sinais de pontuação, sendo Pontuação: 4, Advérbios modificadores: 4, Conjunção: 1, Negação: 1 e Antônimos: 0. O somatório de palavras das classes é 10 e corresponde a aproximadamente 37% do total de palavras do <i>post</i>. O texto indica 34% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 45% de intensidade para sentimentos positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como NÃO-contraditório porque não houve a detecção de ironia.</p>		Texto	Imagem	<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: neutro • NLTK: neutro 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo
Texto	Imagem				
<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: neutro • NLTK: neutro 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: negativo 				

Tabela 4.14 – *Post* considerado NÃO-contraditório com emoção predominantemente Neutra, de acordo com o GT.


<p>Imagem</p> 	<p>Texto 1755476237</p> <p>Ah... não sei porquê?? hoje eu acordei com uma sensação boa... estranha... diferente... eu nem mesmo sei explicar ao certo como estou me sentindo... mais digo uma coisa: - Cuidado. Hoje eu tô pro crime!</p>		
<p>O <i>post</i> foi indicado como 100% NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 69% positivo • Imagem: 65% negativo • Post: 100% neutro <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="vertical-align: top;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: positivo </td> <td style="vertical-align: top;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: neutro • VGG-T4SA: positivo </td> </tr> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 34 palavras e sinais de pontuação, sendo Pontuação: 5, Advérbios modificadores: 8, Conjunção: 0, Negação: 1 e Antônimos: 0. O somatório de palavras das classes é 14 e corresponde a aproximadamente 41% do total de palavras do <i>post</i>. O texto indica 52% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 48% de intensidade para sentimentos positivos. Pela análise manual, parece tratar-se de ironia verbal, ou seja, quando o que acontece no texto contrasta entre o que é dito e o que de fato significa. Assim, após análise desse <i>post</i> esse texto seria classificado como Negativo porque houve a detecção de ironia. Dessa forma, o <i>post</i> poderia ser classificado como negativo, sendo NÃO-contraditório.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: neutro • VGG-T4SA: positivo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: neutro • VGG-T4SA: positivo 		

Tabela 4.15 – *Post* considerado NÃO-contraditório com emoção predominantemente Negativa, de acordo com o GT.


<p>Imagem</p> 	<p>Texto 1755476276</p> <p>Dir-se-ia teu olhar coberto de uma bruma; Teu olhar misterioso (azul, verde ou se esfuma?) às vezes terno e sonhador, às vezes cruel, Reflete a palidez e a indolência do céu. Lembras os dias brancos, mornos e velados, que em prantos corações enfeitados, quando, desperto por torço desconhecida, Os nervos tensos zombam da alma adormecida. não raro imitas essas cores vaporosas que fulguram aos são das estações brumosas... Como resplendes, horizonte assim molhado quando a flama do sol e o céu nublado! ?? mulher perigosa, aos climas sedutores! Hei de adorar a tua neve e os teus rigores E como arrancarei do inverno em que me enterro Mais agudo prazer que os do gelo e do ferro? Charles Pierre Baudelaire</p>		
<p>O <i>post</i> foi indicado como 100% NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 66% positivo • Imagem: 34% negativo • Post: 100% negativo <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="width: 50%; vertical-align: top;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: neutro • SentiLex: neutro • LIWC: negativo • NLTK: neutro </td> <td style="width: 50%; vertical-align: top;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: negativo • VGG-T4SA: negativo </td> </tr> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 119 palavras e sinais de pontuação, sendo Pontuação: 8, Advérbios modificadores: 19, Conjunção: 0, Negação: 1 e Antônimos: 1. O somatório de palavras das classes é 29 e corresponde a aproximadamente 24% do total de palavras do <i>post</i>. O texto indica 54% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de -37% de intensidade para sentimentos negativos. Pela análise manual, parece tratar-se de ironia dramática, ou seja, quando o que acontece no texto contrasta entre o que o personagem pensa ser verdade e o que o leitor sabe ser verdadeiro. Assim, após análise desse <i>post</i> esse texto seria classificado como negativo porque houve a detecção de ironia. Dessa forma, o <i>post</i> seria classificado como negativo, sendo Não-contraditório.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: neutro • SentiLex: neutro • LIWC: negativo • NLTK: neutro 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: negativo • VGG-T4SA: negativo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: neutro • SentiLex: neutro • LIWC: negativo • NLTK: neutro 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: negativo • VGG-T4SA: negativo 		

Tabela 4.16 – *Post* considerado NÃO-contraditório com emoção predominantemente Negativa, de acordo com o GT.


<p>Imagem</p> 	<p>Texto 1755476277</p> <p>Vejo tudo rodar e a dor não para... Sem entender porquê??a vida é assim me vejo seguindo o mesmo caminho... não olho em outra direção, minha visão está presa, presa a mundo de ilusão... Caminho para te encontrar, mas sei que??vc não vai estar lá... entÃo o que me resta são lagrimas de sangue, e em cada gota derramada um pedaço de minha alma se vai... quando o ultimo pedaço se for, o que restar? de mim serão suas simples lembranças daqueles belos momentos em que vivemos. não derramais uma gota de lagrima por minha alma que se foi, pois ela não foi amada, não como te amou...</p>		
<p>O <i>post</i> foi indicado com 100% como NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 100% negativo • Imagem: 100% negativo • Post: 100% negativo <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="vertical-align: top;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: negativo </td> <td style="vertical-align: top;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: negativo • VGG-T4SA: negativo </td> </tr> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 107 palavras e sinais de pontuação, sendo Pontuação: 3, Advérbios modificadores: 9, Conjunção: 1, Negação: 6 e Antônimos: 0. O somatório de palavras das classes é 19 e corresponde a aproximadamente 17% do total de palavras do <i>post</i>. O texto indica 37% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de -87% de intensidade para sentimentos extremamente negativos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como NÃO-contraditório porque não houve a detecção de ironia.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: negativo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: negativo • VGG-T4SA: negativo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: negativo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: negativo • VGG-T4SA: negativo 		

Tabela 4.17 – *Post* considerado NÃO-contraditório com emoção predominantemente Positiva, de acordo com o GT.



<p>Imagem</p> 	<p>Texto 1755476292</p> <p>Galera eu tava em uma viagem muito otima eu estava em Goiania lá tava tudo perfeito passei o carnaval otima! quanto no orkut quanto a que o povo pediu para eu colocar novas fofocas então mandei para mim, eu tô sabendo de nada pq tava viajando eu num entrei na net =(eu sei como uma pessoa vive sem a net não manda manda para mim pu me add gossipeg@hotmai.comE sobre o ultimo <i>post</i> desculpa de que não gosto num tenho culpa de dar comunicação para quem não gosta de ouvir! mais prometo não falar besteira!</p>		
<p>O <i>post</i> foi indicado como 66% NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 73% positiva • Imagem: 68% neutra • Post: 70% positiva <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="width: 50%; vertical-align: top;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: neutro • LIWC: neutro • NLTK: neutro </td> <td style="width: 50%; vertical-align: top;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: negativo • VGG-T4SA: positivo </td> </tr> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 96 palavras e sinais de pontuação, sendo Pontuação: 4, Advérbios modificadores: 12, Conjunção: 0, Negação: 3 e Antônimos: 0. O somatório de palavras das classes é 19 e corresponde a aproximadamente 20% do total de palavras do <i>post</i>. O texto indica 51% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 81% de intensidade para sentimentos extremamente positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como NÃO-contraditório porque não houve a detecção de ironia.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: neutro • LIWC: neutro • NLTK: neutro 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: negativo • VGG-T4SA: positivo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: neutro • LIWC: neutro • NLTK: neutro 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: negativo • VGG-T4SA: positivo 		

Tabela 4.18 – *Post* considerado NÃO-contraditório com emoção predominantemente Positiva, de acordo com o GT.

<p>Imagem</p> 	<p>Texto 1755476765</p> <p>Sorrir não mata , viver não dói , abraçar não arde , beijar não fere , rir não machuca. você não tem motivos para não tentar ser feliz. =)</p>		
<p>O <i>post</i> foi indicado com 100% como NÃO-contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 100% positiva • Imagem: 70% positiva • Post: 85% positiva <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="width: 50%; vertical-align: top;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: positivo </td> <td style="width: 50%; vertical-align: top;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: positivo • VGG-T4SA: positivo </td> </tr> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 29 palavras e sinais de pontuação, sendo Pontuação: 2, Advérbios modificadores: 0, Conjunção: 0, Negação: 7 e Antônimos: 0. O somatório de palavras das classes é 9 e corresponde a aproximadamente 31% do total de palavras do <i>post</i>. O texto indica 54% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 67% de intensidade para sentimentos positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto seria classificado como Não-contraditório porque não houve a detecção de ironia.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: positivo • VGG-T4SA: positivo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: neutro • NLTK: positivo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: negativo • DeepSentiBank: positivo • VGG-T4SA: positivo 		




Figura 4.9 – 10 *post* não contraditórios representados por seus Números do *post* e com a quantificação de palavras de cada classe gramatical. Mais detalhes podem ser verificados nas Tabelas 4.9 a 4.18.

4.3.2 Resultado da análise em amostra de 10 *post* contraditórios

Esta seção apresenta a análise de 10 *posts* considerados contraditórios, de acordo com os sujeitos, no que tange dados quantificados em relação às classes gramaticais escolhidas para análise. Escolheu-se os 7 *posts* unanimemente considerados contraditórios pelos respondentes e mais 3 ditos contraditórios pela maioria. Cada *post* foi representado pelo seu identificador no eixo X da Figura 4.10. O eixo Y indica a quantidade de palavras pertencentes a cada classe gramatical escolhida.

Como pode ser visto, a classe dos antônimos é menos frequente uma vez que foram detectados 4 *post* que tinham palavras com sentido oposto e mesmo assim eram no máximo 2 palavras por *post*. No entanto, outras classes se sobressaíram, em particular advérbios, conjunções, e negação. Para cada *blog* analisado, somente um caso indica menos de 2 advérbios, o restante é acima de 5. No caso das conjunções há pelo menos 1 palavra detectada, visualizadas em 7 *posts*. Temos apenas um caso de *blog* sem negação, podendo dizer que pelo menos 3 palavras são detectadas nos *posts*. As ocorrências médias das classes gramaticas nestes 10 *posts* ditos contraditórios são apresentadas na Tabela 4.19. Para fins de comparação, acrescentamos, nas últimas linhas, os dados dos 10 *posts* não contraditórios e a variação em percentual das presença de classes gramaticas de *posts* não contraditórios e contraditórios.




Figura 4.10 – 10 *posts* contraditórios com a quantificação dos dados de análise que podem ser visualizadas com mais detalhes nas Tabelas 4.20, 4.21, 4.22, 4.23, 4.24, 4.25, 4.26, 4.27, 4.28, 4.29.

Tabela 4.19 – Médias de ocorrência nos 10 *posts* contraditórios e não-contraditórios analisados por classe gramatical.

	Advérbios	Antônimos	Conjunções	Negação	Pontuação
Contraditórios	14,4	0,7	0,8	3,4	5,6
Não-Contraditórios	9,6	0,8	0,3	3	4,5
Diferença %	33,33	14,28	62,50	11,76	19,64

4.3.3 Análise do CBB baseado na detecção de Contradição

Em adição às observações realizadas nas 10 amostras de *posts* contraditórios e não-contraditórios verificamos o CBB inteiro com as técnicas sugeridas sobre detecção de contradição proposta na Seção 3.4.2, sendo o resultado apresentado na Figura 4.11. Os valores médios entre as classes analisadas nos *posts*, indicando contradição ou não, são muito próximos. Acredita-se que esse caso ocorra devido à subjetividade detectada nos textos do CBB. Conforme aFiguras 4.12 é possível verificar que a maior parte dos *posts* (tanto nos contraditórios quanto nos não-contraditórios) apresenta valor de subjetividade em torno de 50%. Isso indica que o CBB, em geral, não tem textos opinativos ou informativos de forma incisiva.

Tabela 4.20 – *Post* considerado contraditório com emoção predominantemente Positiva, de acordo com o GT.


Imagem	Texto 1755476248
	<p>Eu só queria saber quem foi o indivíduo que inventou o chocolate? E também queria saber quem inventou a pizza, o pão de queijo, a pipoca, a coca-cola, o pastel, o Mc Donald's, a batata frita, o sorvete e o brownie. Mas o que eu mais queria saber é porque tudo que é bom engorda?p.s.: sim, eu queria todas essas guloseimas agora mesmo.</p>
<p>O <i>post</i> foi indicado como 65% contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 100% positiva • Imagem: 64% negativa • Post: 33% positiva <p>Nesse texto encontramos os seguintes elementos morfológicos que indicaram poder modificar a polaridade, com um total de 45 palavras, sendo Pontuação: 4, Advérbios modificadores: 9, Conjunção: 1, Negação: 0 e Antônimos: 0.</p> <p>O somatório de palavras das classes é 14 e corresponde a aproximadamente 31% do total de palavras do <i>post</i>. O texto indica 52% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 67% de intensidade para sentimentos positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i>, esse texto não teria alteração de polaridade porque não houve a detecção de ironia. Nesse caso, o <i>post</i> permaneceria sendo contraditório.</p>	

Tabela 4.21 – *Post* considerado contraditório com emoção predominantemente Negativa, de acordo com o GT.


<p>Imagem</p> 	<p>Texto 1755476403</p> <p>Flerte FatalIRA!Composição: Edgard Scandurra "São Paulo 5:03 da manhã sinto a ferrugem, telefone continua calado. Chego em casa tomo meu whisky e alimento mais a minha solidão O gosto amargo insiste em permanecer no meu corpo Corpo...corpo...está no... Gelado com o peito ardendo, gritando por socorro, preste a cair do 14º andar... A sacada é curta, o grito é inevitável... Eu vou acordar o vizinho, eu vou riscar os corpos, eu vou te telefonar... E dizer que eu só preciso dormir..."Tanta gente hoje descansa em paz Um rock star agora é lenda Esse flerte é um flerte fatal Esse flerte é um flerte fatal Que vai te consumir Em busca de um prazer individual Esse flerte é um flerte fatal ?? sempre gente muito especial Muita gente já ultrapassou A linha entre o prazer e a dependência E a loucura que faz O cara dar um tiro na cabeça Quando chegam além E os pés não tocam mais no chão Esse flerte é um flerte fatal Esse flerte é um flerte fatal.</p>		
<p>O <i>post</i> foi indicado com 67% como contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 68% negativa • Imagem: 100% neutra • Post: 67% negativa <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <tr> <td style="width: 50%; vertical-align: top;"> <p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: neutro • SentiLex: negativo • LIWC: positivo • NLTK: negativo </td> <td style="width: 50%; vertical-align: top;"> <p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: positivo </td> </tr> </table> <p>Nesse texto, encontramos os seguintes elementos mórficos que indicam poder de modificação da polaridade em um total de 117 palavras, sendo Pontuação: 5, Advérbios modificadores: 19, Conjunção: 0, Negação: 1 e Antônimos: 2.</p> <p>O somatório de palavras das classes é 27 e corresponde a aproximadamente 23% do total de palavras do <i>post</i>. O texto indica 55% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de -89% de intensidade para sentimentos extremamente negativo. Pela análise manual, parece tratar-se de ironia verbal, ou seja, quando o que acontece no texto contrasta entre o que é dito e o que de fato significa. Assim, após análise desse <i>post</i> esse texto seria classificado como contraditório porque houve a detecção de ironia.</p>		<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: neutro • SentiLex: negativo • LIWC: positivo • NLTK: negativo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: positivo
<p>Texto</p> <ul style="list-style-type: none"> • OpLexicon: neutro • SentiLex: negativo • LIWC: positivo • NLTK: negativo 	<p>Imagem</p> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: positivo 		

Tabela 4.22 – *Post* considerado contraditório com emoção predominantemente Negativa, de acordo com o GT.


Imagem	Texto 1755476399				
	<p>Em meio a depressão, tudo fica cinza e preto. Não acreditamos em nossa melhora, imaginamos sempre o pior, sofremos, choramos, achamos que o pior está por vir. Mas isso não é verdadeiro, isso é falso. Uma sensação errada que temos e que parece muito real. Na verdade, o sentimento é real, mas estamos vendo o mundo através de um óculos sujo, riscado e deformado. Aí, achamos que o mundo é assim. Na verdade, o mundo é mal. Mas há nele há beleza, amor e bondade. Para tudo isso que devemos dirigir nossa vida. Mas em meio ao caos, vemos apenas o mal, aquilo que é ruim . Não, não duvide de que o sol brilhará amanhã. Ele brilhará, e você poderá ver sua luz e agradecer por isso . para responder : o que posso agradecer hoje em meu dia? por que duvido que dias melhores virão o que me dá mais raiva. Para meditar: O choro pode durar uma noite, mas a alegria vem pela manhã.</p>				
<p>O <i>post</i> foi indicado 100% como contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 66% negativa • Imagem: 100% neutra • Post: 65% negativa <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Texto</th> <th style="text-align: left;">Imagem</th> </tr> </thead> <tbody> <tr> <td> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: neutro • NLTK: negativo </td> <td> <ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: negativo • VGG-T4SA: negativo </td> </tr> </tbody> </table> <p>Nesse texto, encontramos os seguintes elementos mórficos que indicam poder de modificação da polaridade em 104 palavras, sendo Pontuação: 4, Advérbios modificadores: 12, Conjunção: 1, Negação: 4 e Antônimos: 0. O somatório de palavras das classes é 21 e corresponde a aproximadamente 20% do total de palavras do <i>post</i>. O texto indica 58% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de -97% de intensidade para sentimentos extremamente negativo. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto não teria alteração da polaridade porque não houve a detecção de ironia, continuando a ser um <i>post</i> contraditório.</p>		Texto	Imagem	<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: neutro • NLTK: negativo 	<ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: negativo • VGG-T4SA: negativo
Texto	Imagem				
<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: negativo • LIWC: neutro • NLTK: negativo 	<ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: negativo • VGG-T4SA: negativo 				

Tabela 4.23 – *Post* considerado contraditório com emoção predominantemente Positiva, de acordo com o GT.



Imagem	Texto 1755476754										
	<p>Um brinde aos Velhos amigos, as velhas festas de final de ano, a velha (não menos querida) família reunida, aos velhos costumes. Feliz Ano Velho!.Os anos se passam e nos fazem refletir coisas curiosas (e velhas) como: quão interessante é o ciclo da vida, nada termina, tudo recomeça: um dia começa a 0 hora, termina às 23:59 e na próxima 0 hora já é um novo dia, no domingo começa uma nova semana e esta vai embora no próximo sábado à noite para dar lugar a próxima semana, os meses começam no dia 1º e depois do dia 30, 31? o dia 1º do próximo mês nasce..Finais de ano parecem que não fazem parte de ciclo algum. As comemorações, os planos, os desejos de renovação, as "Retrospectivas" da TV e tudo mais que anula o Ano Velho e dá lugar a uma nova chance de sermos o que quisermos ser simplesmente pelo fato de ser O Novo..Já cantava Elis Regis: Ainda somos os mesmos, e vivemos como os nossos pais! cheios de anos novos, que vem e que passam e que pedem outros anos novos, e outros e outros. Nada contra a magia de ano novo, mas já parou pra pensar em quantas coisas desejou para o ano passado e que desapareceram junto com a rotina? Em quantas promessas de fazer tudo diferente no ano passado que você fez e que simplesmente perderam-se em algum lugar no tempo? Já parou pra pensar que as coisas se envelhecem e ficam com gosto de velhas quando a euforia do primeiro momento passa, que perdem o sentido e que quando o fôlego inicial se vai, a tendência é relaxar e esquecer as metas de chegar ao outro lado com superação de limites? É deste Ano Velho que falo..Feliz Ano Velho! Feliz velho 1º de Janeiro... Feliz velha rotina!</p>										
<p>O <i>post</i> foi indicado 67% como contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto: 100% positiva • Imagem: 66% neutra • Post: 67% positiva <p>Para esse <i>post</i>, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Texto</th> <th style="text-align: left;">Imagem</th> </tr> </thead> <tbody> <tr> <td>• OpLexicon: positivo</td> <td>• SentiBank: positivo</td> </tr> <tr> <td>• SentiLex: negativo</td> <td>• DeepSentiBank: positivo</td> </tr> <tr> <td>• LIWC: neutro</td> <td>• VGG-T4SA: negativo</td> </tr> <tr> <td>• NLTK: positivo</td> <td></td> </tr> </tbody> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 385 palavras e sinais de pontuação, sendo Pontuação: 9, Advérbios modificadores: 26, Conjunção: 1, Negação: 2 e Antônimos: 0. O somatório de palavras das classes é 29 e corresponde a aproximadamente 7% do total de palavras do <i>post</i>. O texto indica 38% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica <i>compound</i> mostra o valor de 99% de intensidade para sentimentos extremamente positivos. Pela análise manual, parece tratar-se de ironia situacional, ou seja, quando o que acontece no texto contrasta com o que acontece e o que é esperado. Assim, após análise desse <i>post</i> esse texto seria classificado como contraditório porque houve a detecção de ironia.</p>		Texto	Imagem	• OpLexicon: positivo	• SentiBank: positivo	• SentiLex: negativo	• DeepSentiBank: positivo	• LIWC: neutro	• VGG-T4SA: negativo	• NLTK: positivo	
Texto	Imagem										
• OpLexicon: positivo	• SentiBank: positivo										
• SentiLex: negativo	• DeepSentiBank: positivo										
• LIWC: neutro	• VGG-T4SA: negativo										
• NLTK: positivo											

Tabela 4.24 – *Post* considerado contraditório com emoção Positiva, de acordo com o GT.

Imagem	Texto 1755476317
	<p>Fora de mim, dentro de você, com saudade, verdade. Mar, ar, respirar, amar...Estar ao lado, ficar distante.O amor é contraditório, talvez seja a explicação para tamanha confusão. Eu sou contraditória, e é por isso que quando digo que não me importo com você, estou falando inverdades...Lembre-se disso, sempre que quiser e achar que seja necessário. Agora mesmo: Eu não gosto de você, eu não sinto sua falta, não te preciso aqui. Entenda!</p>

O *post* foi indicado como 65% contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o *post*:

- Texto: 64% negativa
- Imagem: 66% neutra
- Post: 34% positiva

Para esse *post*, temos as seguintes classificações de polaridade para texto e para imagem:

Texto

- OpLexicon: positivo
- SentiLex: positivo
- LIWC: positivo
- NLTK: positivo


Imagem

- SentiBank: positivo
- DeepSentiBank: positivo
- VGG-T4SA: positivo

Nesse texto encontramos os seguintes elementos mórficos que indicam poder de modificação da polaridade, sendo composto de 101 palavras e sinais de pontuação, sendo Pontuação: 6, Advérbios modificadores: 6, Conjunção: 0, Negação: 4 e Antônimos: 0.

O somatório de palavras das classes é 16 e corresponde a aproximadamente 16% do total de palavras do *post*. O texto indica 65% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica *compound* mostra o valor de 55% de intensidade para sentimentos positiva. Pela análise manual, parece tratar-se de ironia verbal, ou seja, quando o que acontece no texto contrasta entre o que é dito e o que de fato significa. Assim, após análise desse *post* esse texto seria classificado como contraditório porque houve a detecção de ironia.

Tabela 4.25 – Post contraditório com emoção predominantemente Negativa, de acordo com o GT.

Imagem	Texto 1755476406
	<p>Corpos esteticamente modificados, Cérebros meramente malhados. O externo se sobrepõe o interno, As pessoas são o seu próprio inferno. Olhos fechados para a realidade, Ninguém está afim de ver a verdade. Tá mais fácil consertar o corpo, Do que consertar o mundo - tão torto. Não se roubam mais corações... A moda agora é roubar milhões. Não há mais gentileza nem amor. Sobrou um mundo de guerra e dor. Há crianças morrendo de fome. "E dá, não sei nem seus nomes." Não há mais coletividade, Em um mundo de pura individualidade. A sociedade reclama clandestinamente. Desse jeito, que futuro tem-lhe em mente? Não adianta reclamar e fugir. A solução é simples: é só agir.</p>

O *post* foi indicado com 66% como contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o *post*:

- Texto: 100% negativa
- Imagem: 66% neutra
- Post: 66% negativa

Para esse post, temos as seguintes classificações de polaridade para texto e para imagem:

Texto

- OpLexicon: positivo
- SentiLex: positivo
- LIWC: negativo
- NLTK: negativo


Imagem

- SentiBank: negativo
- DeepSentiBank: negativo
- VGG-T4SA: positivo

Nesse texto encontramos os seguintes elementos mórficos que podem modificar a polaridade da palavra seguinte. É um texto com 161 palavras e sinais de pontuação, sendo Pontuação: 7, Advérbios modificadores: 10, Conjunção: 0, Negação: 5 e Antônimos: 2.

O somatório de palavras das classes é 24 e corresponde a aproximadamente 15% do total de palavras do *post*. O texto indica 39% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica *compound* mostra o valor de -86% de intensidade para sentimentos extremamente negativa. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse *post* esse texto não teria alteração de polaridade porque não houve a detecção de ironia, continuando a ser um *post* contraditório.

Tabela 4.26 – *Post* considerado contraditório com emoção Negativa, de acordo com o GT.

<p>Imagem</p> 	<p>Texto 1755476831</p> <p>Você quer gritar e não pode. Você quer chorar, mas segura. Você quer morrer, mas não se mata. Você quer sumir, mas não some. Aí é que tem. Você não faz nada disso pra não preocupar a sua família, certo? Aí você pega, vai pro banheiro, e chora lá, escondida(o). E não tem ninguém pra te dar apoio. É bem isso aí.</p>
---	--

O *post* foi indicado com 66% como contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o *post*:

- Texto: 100% negativa
- Imagem: 100% positiva
- Post: 33% negativa

Para esse *post*, temos as seguintes classificações de polaridade para texto e para imagem:

Texto

- OpLexicon: negativo
- SentiLex: positivo
- LIWC: neutro
- NLTK: positivo

Imagem

- SentiBank: positivo
- DeepSentiBank: positivo
- VGG-T4SA: positivo

Nesse texto encontramos os seguintes elementos mórficos que podem modificar a polaridade da palavra seguinte. É um texto com 81 palavras e sinais de pontuação, sendo Pontuação: 4, Advérbios modificadores: 3, Conjunção: 1, Negação: 6 e Antônimos: 0.

O somatório de palavras das classes é 14 e corresponde a aproximadamente 17% do total de palavras do *post*. O texto indica 45% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica *compound* mostra o valor de 89% de intensidade para sentimentos extremamente positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse *post* esse texto não teria alteração de polaridade porque não houve a detecção de ironia, continuando a ser um *post* contraditório.

Tabela 4.27 – Post contraditório com emoção Positiva, de acordo com o GT.


Imagem	Texto 1755476836				
	<p>Eu acreditei. Nós acreditamos. A gente sempre acredita. Nós sonhamos demais, rimos, choramos, brigamos, sentimos ciúmes bestas, olhamos um para o outro, nos beijamos até o último minuto. Fomos felizes. Se houvesse uma balança neste instante e colocasse o que foi bom e ruim, com certeza ela cairia de tão pesada para o lado bom. ?? você foi importante, você se tornou mais importante a cada dia. E por fim, aquele romance de adolescente, acabou. Como em muitos outros relacionamentos que tem tudo para dar certo, mas também tudo para dar errado. Sabe o que fiquei guardado? Tudo bom. Cada gesto e palavra, sorriso e carinho. E de ruim, eu coloquei em um saco plástico e joguei no lixo.</p>				
<p>O <i>post</i> foi indicado como sendo 65% contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o post:</p> <ul style="list-style-type: none"> • Texto: 63% negativa • Imagem: 100% positiva • Post: 34% positiva <p>Para esse post, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table style="width: 100%; border: none;"> <thead> <tr> <th style="text-align: left;">Texto</th> <th style="text-align: left;">Imagem</th> </tr> </thead> <tbody> <tr> <td style="vertical-align: top;"> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: positivo • NLTK: positivo </td> <td style="vertical-align: top;"> <ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: positivo </td> </tr> </tbody> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 147 palavras e sinais de pontuação, sendo Pontuação: 3, Advérbios modificadores: 14, Conjunção: 1, Negação: 0 e Antônimos: 0. O somatório de palavras das classes é 14 e corresponde a 12%. O texto indica 54% de subjetividade de acordo com NLTK. A métrica <i>compound</i> mostra o valor de 93% de intensidade para sentimentos extremamente positivos. Pela análise manual, parece tratar-se de ironia situacional, ou seja, quando o que acontece no texto contrasta com o que acontece e o que é esperado. Assim, após análise desse <i>post</i> esse texto seria classificado como contraditório porque houve a detecção de ironia.</p>		Texto	Imagem	<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: positivo • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: positivo
Texto	Imagem				
<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: positivo • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: positivo • DeepSentiBank: positivo • VGG-T4SA: positivo 				

Tabela 4.28 – Post contraditório com emoção Positiva, de acordo com GT.

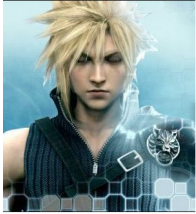

Imagem	Texto 1755476640				
	<p>Homem com feições de menino, Com olhos brilhantes e sorriso largo, Seu coração é generoso, amável e sonhador, Tens o dom da bondade e a incapacidade de dizer não, mesmo quando se é necessário. Seus sonhos voam alto, Tão qual a sua capacidade de fazê-los virar realidade. Pode ser que não veja isso Porém credes, você pode tudo! Forte, Inteligente, Lindo, Sensível, Consegues se machucar tanto ao ponto de machucar aos outros para poder se defender; Mas mesmo assim, ainda se culpa por se defender. De onde eu te conheço? De que mundo você veio? Fico noites acordada tentando descobrir, Como foi que perdi minha vivência no primeiro dia que vi o seu olhar. Onde eu estava a primeira vez que eu te conheci? Quem roubou o meu ar? Quem me tirou o direito de dormir? Como vou poder lhe mostrar o mundo se eu sequer consigo ver? Me resta forçar meus pulmões para que o oxigênio entre e me mantenha viva, O Tempo será meu maior aliado, resolveré todas as minhas dores, como sempre fez! Até lá, eu sonho acordada Busco no trabalho um refúgio, Busco nos amigos o consolo, E nas fotos que tem seu sorriso busco a alegria de saber que você existe!</p>				
<p>O <i>post</i> foi indicado como sendo 67% contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o <i>post</i>:</p> <ul style="list-style-type: none"> • Texto - 100% negativo • Imagem - 100% neutro • Post - 34% positivo <p>Para esse post, temos as seguintes classificações de polaridade para texto e para imagem:</p> <table border="0" style="width: 100%;"> <thead> <tr> <th style="text-align: left;">Texto</th> <th style="text-align: left;">Imagem</th> </tr> </thead> <tbody> <tr> <td> <ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: positivo • NLTK: positivo </td> <td> <ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: positivo • VGG-T4SA: negativo </td> </tr> </tbody> </table> <p>Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 265 palavras e sinais de pontuação, sendo Pontuação: 6, Advérbios modificadores: 23, Conjunção: 2, Negação: 2 e Antônimos: 2. O somatório de palavras das classes é 35 e corresponde a aproximadamente 13% do total de palavras. O texto indica 59% de subjetividade de acordo com NLTK e a métrica <i>compound</i> mostra o valor de 98% de intensidade para sentimentos extremamente positivos. Pela análise manual, aparentemente o texto não indica ironia. Assim, após análise desse <i>post</i> esse texto não teria alteração de polaridade porque não houve a detecção de ironia, continuando a ser um <i>post</i> contraditório.</p>		Texto	Imagem	<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: positivo • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: positivo • VGG-T4SA: negativo
Texto	Imagem				
<ul style="list-style-type: none"> • OpLexicon: positivo • SentiLex: positivo • LIWC: positivo • NLTK: positivo 	<ul style="list-style-type: none"> • SentiBank: neutro • DeepSentiBank: positivo • VGG-T4SA: negativo 				

Tabela 4.29 – *Post* considerado contraditório com emoção Positiva, de acordo com o GT.

Imagem	Texto 1755476992
	<p>Beth Ditto - A gorda mais linda do mundo! *</p> <p>Quem nunca leu um livro ou texto e ao terminar ficou tentando achar algum sentido pra própria vida??? Pois é... isso sempre acontece comigo!</p> <p>Estava lendo um texto no blog Cem Homens Em Um Ano, outro dia, onde a Letícia falava sobre ser feliz como se é. Li o texto e simplesmente me senti a pior pessoa do mundo por tentar ser aquilo que não sou, nem em alma!</p> <p>No escrito ela conta sobre o fato de ter engordado muito e como aceitou essa mudança que não à vista como uma coisa muito positiva.</p> <p>Li e reli o texto mil vezes e o que mais me chamou atenção foi o fato dela estar feliz com o próprio corpo.</p> <p>Sim, eu tenho problemas com meu corpo. Tenho estrias, celulites, peito pequeno, mas o que me incomoda mesmo é o quadril mega largo. Eu sempre fui assim, OK!, e com quase 22 anos de idade já deveria ter me acostumado. O problema é que não me acostumei! Não aguento olhar no espelho e me deparar com minha redondeza. Me sinto entre parênteses e assim deposito minha felicidade no futuro. No 'quando eu for magra'! Assim surge outro problema: será que vale a pena esperar o futuro? Será que vai chegar? E quando chegar, será que eu vou ser REALMENTE feliz? Não sei! ...</p>

O *post* foi indicado como sendo 66% contraditório entre texto e imagem, de acordo com o GT. Os dados abaixo mostram os maiores valores obtidos, acordados pelos respondentes, no GT, e usados para classificação quando analisando os domínios separadamente e em conjunto para o *post*:

- Texto - 65% negativo
- Imagem - 100% positivo
- Post - 34% positivo

Para esse *post*, temos as seguintes classificações de polaridade para texto e para imagem:

Texto

- OpLexicon: positivo
- SentiLex: positivo
- LIWC: positivo
- NLTK: positivo

Imagem

- SentiBank: neutro
- DeepSentiBank: positivo
- VGG-T4SA: negativo

Nesse texto, encontramos elementos mórficos que podem modificar a polaridade do texto. O texto é composto de 435 palavras e sinais de pontuação, sendo Pontuação: 8, Advérbios modificadores: 25, Conjunção: 1, Negação: 10 e Antônimos: 1.

O somatório de palavras das classes é 45 e corresponde a aproximadamente 10% do total de palavras do *post*. O texto indica 60% de subjetividade de acordo com as análises feitas usando o NLTK. A métrica *compound* mostra o valor de 99% de intensidade para sentimentos extremamente positivos. Pela análise manual, parece tratar-se de ironia situacional, ou seja, quando o que acontece no texto contrasta com o que acontece e o que é esperado. Assim, após análise desse *post* esse texto seria classificado como contraditório porque houve a detecção de ironia.




Figura 4.11 – Média Aritmética do número de palavras das classes gramaticais detectadas por *post*.




Figura 4.12 – Quantidade de *post* não-contraditórios (851 posts) do CBB distribuídos conforme o percentual de subjetividade à esquerda. À direita indica a quantidade de *post* contraditórios (29 posts) do CBB distribuídos conforme o percentual de subjetividade.

Identificar ironia no texto para alterar a sua polaridade também foi uma tarefa que se tentou avaliar manualmente nas detecções de sentimentos nos *post* a fim de validar os padrões da literatura. Mas, trata-se de uma atividade bastante complexa e que envolve um conhecimento de mundo que ainda é privilégio do ser humano, como o caso do gestual que pode indicar com plenitude se uma pessoa está sendo irônica ou não. Mesmo assim, detectou-se textos com caráter irônico, segundo as referências das Tabelas 4.14, 4.15, 4.20, 4.21, 4.23.

5. CONCLUSÃO

Neste trabalho, foram descritas as motivações, detalhes e processo de construção do corpus *Cross-media Brazilian Blog* (CBB), criado com base nas redes sociais. Além da criação do corpus, utilizou-se a ferramenta *Figure Eight* para criação do *Ground truth* considerado como sendo as respostas de sujeitos em relação a polaridade de imagens e textos em *blogs*, de maneira conjunta ou separadamente. O CBB foi testado usando 1 Classificador e duas Redes Neurais Artificiais (RNAs) disponíveis na literatura para classificação de sentimentos em imagens, além de quatro léxicos para análise dos textos.

O principal objetivo foi estudar técnicas disponíveis na literatura e avaliar o Corpus, provendo disponibilização de todas as análises para a comunidade científica. Conforme foi discutido no texto, as redes apresentaram acurácia relativamente baixa na análise das imagens do CBB em comparação ao GT. Para fins de comparação de performance, também criamos e testamos um dataset com as mesmas redes e imagens obtidas na internet, cujas emoções eram mais explícitas. Com isso, hipotetizamos que a razão da baixa acurácia no CBB é que trata-se de um Corpus espontâneo e real, o que não invalida essa pesquisa, mas aponta novos desafios. Como exemplo podemos citar que um trabalho seria a construção de um corpus com variabilidade das emoções para treinamento de novas redes, focando em imagens *wild*, ou seja espontâneas e reais.

Sobre a análise das classificações de texto com o uso dos léxicos, as acurácias obtidas foram ainda mais baixas em comparação as imagens. Por isso, investigamos, no contexto de textos, a possibilidade das contradições estarem interferindo na baixa acurácia. Análise empírica que ainda necessita de aprofundamento, mas que juntamente com a análise de ironias (ambas feitas manualmente) parece apresentar potencial para novas pesquisas na área. Nossa primeira ideia de automatização seria utilizar a contagem de palavras das classes gramaticais para tentar classificar os *posts* em dois diferentes grupos (contraditórios e não contraditórios). No caso dos textos estudados, suas características não foram significativamente diferentes para permitir a classificação dos grupos. Portanto, mais pesquisas são necessárias para permitir essa análise.

A abordagem tratada no trabalho de Joshi et al. [JDF⁺11] na Seção 2 parece mostrar que possíveis razões para a baixa acurácia resultante das técnicas testadas são as diferenças culturais, sociais e pessoais na exposição de *posts* em imagens como em textos. Inclusive, os autores Joshi et al. [JDF⁺11] comentam da importância da semântica para tratar de estética, que é um tema subjetivo, e também sobre julgamentos emocionais devido ao fato de a semântica variar entre as culturas. No caso deste trabalho, as redes utilizadas para classificação de imagens foram criadas para uso em ambientes sociais, mas não no contexto brasileiro. Os léxicos, apesar de serem em português, não tratam de gírias utilizadas em redes sociais e não se estendem a linguagens adotadas por indivíduos de uma

certo grupo. Acredita-se que esses fatores possam ter contribuído para uma baixa acurácia nessa pesquisa e conforme dito anteriormente podem apresentar uma potencial nova área de pesquisa.

Quanto aos trabalhos futuros, acreditamos que ainda há muitas atividades a serem desenvolvidas, principalmente em relação à análise de sentimentos contraditórios, sendo a detecção de ironia uma delas, conforme já citado. Almejamos criar uma aplicação que possa analisar texto e imagem em posts e informar se há contradição, incluindo sua acurácia, bem como indicando as predições de cada domínio envolvido. Outra ideia é trabalhar com as emoções em vídeos e posteriormente também verificar possíveis contradições.

REFERÊNCIAS BIBLIOGRÁFICAS

- [AGBC13] Araújo, M.; Gonçalves, P.; Benevenuto, F.; Cha, M. “Métodos para análise de sentimentos no twitter”. In: Proceedings of the 19th Brazilian Symposium on Multimedia and the Web, 2013, pp. 5–8.
- [BCJC13] Borth, D.; Chen, T.; Ji, R.; Chang, S.-F. “Sentibank: large-scale ontology and classifiers for detecting sentiment and emotions in visual content”. In: Proceedings of the 21st ACM International Conference on Multimedia, 2013, pp. 459–460.
- [BFPA13] Balage Filho, P. P.; Pardo, T. A. S.; Aluísio, S. M. “An evaluation of the brazilian portuguese liwc dictionary for sentiment analysis”. In: Proceedings of the 9th Brazilian Symposium in Information and Human Language Technology, 2013, pp. 215–219.
- [BRSS15] Bahrapour, S.; Ramakrishnan, N.; Schott, L.; Shah, M. “Comparative study of caffe, neon, theano, and torch for deep learning”. In: Proceeding of the 4th International Conference on Learning Representations, 2015, pp. 1–11.
- [CBDC14] Chen, T.; Borth, D.; Darrell, T.; Chang, S.-F. “DeepSentibank: Visual sentiment concept classification with deep convolutional neural networks”, *arXiv preprint*, vol. 1410.8586, Oct 2014, pp. 1–7.
- [CMGS10] Cireşan, D. C.; Meier, U.; Gambardella, L. M.; Schmidhuber, J. “Deep, big, simple neural nets for handwritten digit recognition”. In: Proceedings of the Neural Computation, Set 2010, pp. 3207–3220.
- [CS15] Carvalho, P.; Silva, M. J. “Sentilex-pt: Principais características e potencialidades”, *Oslo Studies in Language*, vol. 7–1, Mar 2015, pp. 425—438.
- [CZYL17] Chen, M.; Zhang, L.-L.; Yu, X.; Liu, Y. “Weighted co-training for cross-domain image sentiment classification”. In: Proceedings of the Journal of Computer Science and Technology, Jul 2017, pp. 714–725.
- [dAT25] de Almeida Tôrres, A. “Moderna gramática expositiva da língua portuguesa”. Editora Fundo de Cultura, 1963, pp. 107–125.
- [DB16] Dias, M.; Becker, K. “Detecção semi-supervisionada de posicionamento em tweets baseada em regras de sentimento.” In: Anais do Simpósio Brasileiro de Banco de Dados, 2016, pp. 40–51.

- [DDS⁺09] Deng, J.; Dong, W.; Socher, R.; Li, L.-J.; Li, K.; Fei-Fei, L. “Imagenet: A large-scale hierarchical image database”. In: *Proceeding of the IEEE Conference on Computer Vision and Pattern Recognition*, Jun 2009, pp. 248–255.
- [dFO14] de França, T. C.; Oliveira, J. “Análise de sentimento de tweets relacionados aos protestos que ocorreram no brasil entre junho e agosto de 2013”. In: *Proceedings of the III Brazilian Workshop on Social Network Analysis and Mining*, Mar 2014, pp. 128–139.
- [DLW08] Datta, R.; Li, J.; Wang, J. Z. “Algorithmic inferencing of aesthetics and emotion in natural images: An exposition”. In: *Proceeding of the 15th IEEE International Conference on Image Processing*, 2008, pp. 1–4.
- [DMRM08] De Marneffe, M.-C.; Rafferty, A. N.; Manning, C. D. “Finding contradictions in text”. In: *Proceedings of Association for Computational Linguistics*, 2008, pp. 1039–1047.
- [dRdSdM⁺15] dos Reis, J. C. S.; de Souza, F. B.; de Melo, P. O. S. V.; Prates, R. O.; Kwak, H.; An, J. “Breaking the news: First impressions matter on online news”. In: *Proceedings of the 9th International AAI Conference on Web and Social Media*, 2015, pp. 1–10.
- [dSWV18] dos Santos, H. D. P.; Woloszyn, V.; Vieira, R. “Blogset-br: A brazilian portuguese blog corpus”. In: *Proceedings of the Eleventh International Conference on Language Resources and Evaluation*, 2018, pp. 1–4.
- [GDR⁺15] Gonçalves, P.; Dalip, D. H.; Reis, J. C.; Messias, J.; Ribeiro, F.; Melo, P. “Bazinga! caracterizando e detectando sarcasmo e ironia no twitter”. In: *Proceedings of the Brazilian Workshop on Social Network Analysis and Mining*, 2015, pp. 1–13.
- [HG14] Hutto, C. J.; Gilbert, E. “Vader: A parsimonious rule-based model for sentiment analysis of social media text”. In: *Proceedings of the 8th International AAI Conference on Weblogs and Social Media*, 2014, pp. 1–10.
- [HHL06] Harabagiu, S.; Hickl, A.; Lacatusu, F. “Negation, contrast and contradiction in text processing”. In: *Proceedings of the AAI Conference on Artificial Intelligence and Interactive Digital Entertainment*, 2006, pp. 755–762.
- [HOS03] Hillard, D.; Ostendorf, M.; Shriberg, E. “Detection of agreement vs. disagreement in meetings: Training with unlabeled data”. In: *Proceedings of the Conference of the North American Chapter of the Association for*

Computational Linguistics on Human Language Technology, 2003, pp. 34–36.

- [JDF⁺11] Joshi, D.; Datta, R.; Fedorovskaya, E.; Luong, Q.-T.; Wang, J. Z.; Li, J.; Luo, J. “Aesthetics and emotions in images”. In: Proceedings of the IEEE Signal, 2011, pp. 94–115.
- [JS15] Jindal, S.; Singh, S. “Image sentiment analysis using deep convolutional neural networks with domain specific fine tuning”. In: Proceedings of the International Conference on Information Processing, 2015, pp. 447–451.
- [KBDB13] Kontopoulos, E.; Berberidis, C.; Dergiades, T.; Bassiliades, N. “Ontology-based sentiment analysis of twitter posts”. In: Proceedings of the Expert Systems with Applications, Ago 2013, pp. 4065–4074.
- [KC07] Kreuz, R. J.; Caucci, G. M. “Lexical influences on the perception of sarcasm”. In: Proceedings of the Workshop on Computational Approaches to Figurative Language, 2007, pp. 1–4.
- [LB02] Loper, E.; Bird, S. “Nltk: the natural language toolkit”, *arXiv preprint*, vol. 0205028, May 2002, pp. 1–8.
- [LBD⁺08] LeCun, Y.; Boser, B.; Denker, J. S.; Henderson, D.; Howard, R. E.; Hubbard, W.; Jackel, L. D. “Backpropagation applied to handwritten zip code recognition”, *Neural Computation*, vol. 1–4, Mar 2008, pp. 541–551.
- [MSR⁺16] Moraes, S. M.; Santos, A. L.; Redecker, M.; Machado, R. M.; Meneguzzi, F. R. “Comparing approaches to subjectivity classification: A study on portuguese tweets”. In: Proceedings of the International Conference on Computational Processing of the Portuguese Language, 2016, pp. 86–94.
- [PHZ17] Peng, Y.; Huang, X.; Zhao, Y. “An overview of cross-media retrieval: Concepts, methodologies, benchmarks and challenges”. In: Proceedings of the IEEE Transactions on Circuits and Systems for Video Technology, 2017, pp. 1–14.
- [Plu80] Plutchik, R. “Emotion: A psychoevolutionary synthesis”. In: Proceedings of the Harper & Row, 1980, pp. 1–440.
- [SGJ⁺17] Soleymani, M.; Garcia, D.; Jou, B.; Schuller, B.; Chang, S.-F.; Pantic, M. “A survey of multimodal sentiment analysis”. In: Proceedings of the Image and Vision Computing, 2017, pp. 3–14.
- [Sin12] Singh, R. K. “Humour, irony and satire in literature”. In: Proceedings International Journal of English and Literature, 2012, pp. 65–72.

- [SNB14] Sarlan, A.; Nadam, C.; Basri, S. "Twitter sentiment analysis". In: Proceedings of the 6th International Conference on Information Technology and Multimedia, 2014, pp. 212–216.
- [SS09] Schmidt, S.; Stock, W. G. "Collective indexing of emotions in images. a study in emotional information retrieval". In: Proceedings of the Journal of the Association for Information Science and Technology, 2009, pp. 863–876.
- [SV12] Souza, M.; Vieira, R. "Sentiment analysis on twitter data for portuguese language". In: Proceedings of the International Conference on Computational Processing of the Portuguese Language, 2012, pp. 241–247.
- [SZ14] Simonyan, K.; Zisserman, A. "Very deep convolutional networks for large-scale image recognition", *arXiv preprint*, vol. 1409.1556, Set 2014, pp. 1–10.
- [TPD11] Tsytsarau, M.; Palpanas, T.; Denecke, K. "Scalable detection of sentiment-based contradictions". In: Proceedings of the 1st International Workshop on Knowledge Diversity on the Web, 2011, pp. 9–16.
- [Var16] Vargas, D. S. "Detecting contrastive sentences for sentiment analysis", Dm, Faculdade de Informática – UFRGS, Porto Alegre, RS, Brasil, 2016, 66p.
- [VCC+17] Vadicamo, L.; Carrara, F.; Cimino, A.; Cresci, S.; Dell'Orletta, F.; Falchi, F.; Tesconi, M. "Cross-media learning for image sentiment analysis in the wild". In: Proceedings of the The IEEE International Conference on Computer Vision, 2017, pp. 308–317.
- [WHK18] Wiesen, A.; HaCohen-Kerner, Y. "Overview of uni-modal and multi-modal representations for classification tasks". In: Proceeding of the International Conference on Applications of Natural Language to Information Systems, 2018, pp. 397–404.
- [XCLL14] Xu, C.; Cetintas, S.; Lee, K.-C.; Li, L.-J. "Visual sentiment prediction with deep convolutional neural networks", *arXiv preprint*, vol. 1411.5731, Nov 2014, pp. 1–10.
- [YLJY15] You, Q.; Luo, J.; Jin, H.; Yang, J. "Robust image sentiment analysis using progressively trained and domain transferred deep networks." In: Proceedings of the Association for the Advancement of Artificial Intelligence, 2015, pp. 381–388.
- [YLMZ16] Yu, Y.; Lin, H.; Meng, J.; Zhao, Z. "Visual and textual sentiment analysis of a microblog using deep convolutional neural networks", *Algorithms*, vol. 9–2, Fev 2016, pp. 41.

- [YNL+16] Yan, Y.; Nie, F.; Li, W.; Gao, C.; Yang, Y.; Xu, D. “Image classification by cross-media active learning with privileged information”, *Proceedings of the IEEE Transactions on Multimedia*, vol. 18–12, 2016, pp. 2494–2502.



Pontifícia Universidade Católica do Rio Grande do Sul
Pró-Reitoria de Graduação
Av. Ipiranga, 6681 - Prédio 1 - 3º. andar
Porto Alegre - RS - Brasil
Fone: (51) 3320-3500 - Fax: (51) 3339-1564
E-mail: prograd@pucrs.br
Site: www.pucrs.br