



UNIVERSIDADE FEDERAL DO CEARÁ
CAMPUS QUIXADÁ
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

ANDRÉ DAVYS CARVALHO MELO DE OLIVEIRA

**IDENTIFICANDO EMOÇÕES EM MANCHETES DE NOTÍCIAS ESCRITAS EM
PORTUGUÊS DO BRASIL UTILIZANDO NAÏVE BAYES**

QUIXADÁ – CEARÁ

2016

ANDRÉ DAVYS CARVALHO MELO DE OLIVEIRA

IDENTIFICANDO EMOÇÕES EM MANCHETES DE NOTÍCIAS ESCRITAS EM
PORTUGUÊS DO BRASIL UTILIZANDO NAÏVE BAYES

Monografia apresentada no curso de Ciência da
Computação da Universidade Federal do Ceará,
como requisito parcial à obtenção do título de
bacharel em Ciência da Computação. Área de
concentração: Computação.

Orientador: Prof. Dr. Paulo de Tarso
Guerra Oliveira

QUIXADÁ – CEARÁ

2016

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca Universitária
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

O45i Oliveira, André Davys Carvalho Melo de.
Identificando emoções em manchetes de notícias escritas em português do Brasil utilizando Naïve Bayes / André Davys Carvalho Melo de Oliveira. – 2016.
47 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Quixadá, Curso de Ciência da Computação, Quixadá, 2016.
Orientação: Prof. Paulo de Tarso Guerra Oliveira.

1. Linguística - Processamento de dados. 2. Processamento de textos (Computação). 3. Algoritmos. I.
Título.

CDD 004

ANDRÉ DAVYS CARVALHO MELO DE OLIVEIRA

IDENTIFICANDO EMOÇÕES EM MANCHETES DE NOTÍCIAS ESCRITAS EM
PORTUGUÊS DO BRASIL UTILIZANDO NAÏVE BAYES

Monografia apresentada no curso de Ciência da
Computação da Universidade Federal do Ceará,
como requisito parcial à obtenção do título de
bacharel em Ciência da Computação. Área de
concentração: Computação.

Aprovada em:

BANCA EXAMINADORA

Prof. Dr. Paulo de Tarso Guerra Oliveira (Orientador)
Campus Quixadá
Universidade Federal do Ceará – UFC

Prof. Me. Carlos Igor Ramos Bandeira
Campus Quixadá
Universidade Federal do Ceará - UFC

Profa. Me. Lívia Almada Cruz
Campus Quixadá
Universidade Federal do Ceará - UFC

Dedico este trabalho a minha família e amigos,
por todo apoio dado nesta longa jornada.

AGRADECIMENTOS

Aos meus pais, Marcelo Melo e Helena Carvalho, que sempre se esforçaram para me dar a melhor educação e me motivaram a seguir bons caminhos.

As minhas avós, Rosa Carvalho e Maria Oliveira, que fizeram de tudo para que pudesse sempre ter o do bom e do melhor e sempre me motivaram a nunca desistir de meus sonhos.

Ao Jonas, Sérgio, Rômulo e Jhonata, meus irmãos nessa cidade, que sempre me apoiaram a seguir nesta longa jornada de graduação.

A Camila Alves, minha querida namorada que esteve do meu lado nos momentos de aflição e preocupação, sempre me motivando a continuar.

Agradeço especialmente ao meu orientador Prof. Dr. Paulo de Tarso Guerra Oliveira, pela excelente orientação, contribuindo para minha vida acadêmica e profissional.

Agradeço a todos os meus amigos e colegas de universidade, por fazerem de minha jornada aqui inesquecível e que trará boas recordações.

Aos professores que tive durante esta jornada acadêmica que contribuíram bastante para minha formação.

Aos professores participantes da banca examinadora pelo tempo, pelas valiosas colaborações e sugestões.

Ao anjo protetor enviado por Deus, que me permitiu estar aqui agradecendo, e encerrando um ciclo importante em minha vida.

Sempre me recordarei de todos que contribuíram de alguma forma durante minha vida acadêmica.

“Podemos apenas ver uma curta distância à frente,
mas podemos ver que há muito lá a ser feito.”

(Alan Turing)

RESUMO

O grande aumento do número de usuários da internet permitiu que dados que contém opinião e/ou sentimento de usuários crescessem em uma velocidade espantosa. Dessa forma, a maioria dos jornais disponibiliza diariamente suas publicações em seus *sites*. Com essa popularização da internet, o volume de dados disponível na internet cresce exponencialmente e analisar tais dados de forma não automatizada pode ser uma tarefa difícil. Visto isso, este trabalho apresenta um método para identificar automaticamente emoções em textos. O objetivo principal é construir um modelo capaz de identificar uma das seis emoções básicas (alegria, tristeza, surpresa, medo, raiva e desgosto) em manchetes de notícias escritas em português do Brasil. Para a construção do modelo é utilizada uma abordagem de aprendizado de máquina baseada no classificador Naïve Bayes. O *corpus* (conjunto de dados) utilizado neste trabalho é composto de manchetes de notícias retiradas de jornais online. Estas notícias foram submetidas a um classificador Naïve Bayes, obtendo uma taxa de acerto média de 59,5%.

Palavras-chave: Classificação de textos. Emoções básicas. Naïve Bayes.

ABSTRACT

The large increase in the number of users on the internet has allowed that data contains opinion or sentiment of user to grow at an amazing speed. In this way, most newspapers offer their daily publications on their sites. Considering the popularization on the internet, this big amount of available data on the internet grows exponentially and analyzing such data in a non-automated way can be a non-trivial problem. Thus, this paper shows a method to identify automatically emotions in text. The goal is to build a model able to identify one of the six basic emotions (joy, sadness, surprise, fear, anger and disgust) in news headlines written in Brazilian Portuguese. For the build of the model, we use a machine learning approach based on the Naïve Bayes classifier. The corpus (dataset) used in this work is composed by news extracted from online newspapers. This news were processed by our Naïve Bayes classifier getting an accuracy rate of 59,5%.

Keywords: Text classification. Basic emotions. Naïve Bayes

LISTA DE FIGURAS

Figura 1 – Técnicas para classificação de sentimentos.	17
Figura 2 – Etapas de um classificador supervisionado aplicadas a um conjunto de dados.	20
Figura 3 – Usando MVS em um problema de classificação.	24
Figura 4 – Formato das manchetes de notícias rotuladas.	26
Figura 5 – Manchete de notícia após o pré-processamento.	28
Figura 6 – Acurácia média obtida pelo classificador Naïve Bayes utilizando divisão fixa.	32
Figura 7 – Acurácia média obtida pelo classificador Naïve Bayes utilizando validação cruzada.	33
Figura 8 – Cobertura média para cada classe utilizando divisão fixa.	34
Figura 9 – Cobertura média para cada classe utilizando validação cruzada	35
Figura 10 – Precisão média para cada classe utilizando divisão fixa.	36
Figura 11 – Precisão média para cada classe utilizando validação cruzada.	37
Figura 12 – Manchete de notícia classificada como “alegria” pelo modelo.	39
Figura 13 – Manchete de notícia classificada como “desgosto” pelo modelo.	39
Figura 14 – Nuvem de palavras referentes à classe alegria.	40
Figura 15 – Nuvem de palavras referentes à classe desgosto.	40
Figura 16 – Nuvem de palavras referentes à classe neutro.	41
Figura 17 – Nuvem de palavras referentes à classe tristeza.	41
Figura 18 – Nuvem de palavras referentes à classe raiva.	42
Figura 19 – Nuvem de palavras referentes à classe surpresa.	42
Figura 20 – Nuvem de palavras referentes à classe medo.	43

LISTA DE TABELAS

Tabela 1 – Definição das emoções.	18
Tabela 2 – Comparação dos resultados das técnicas de avaliação.	34
Tabela 3 – Comparação dos resultados de cada emoção utilizando divisão fixa.	37
Tabela 4 – Comparação dos resultados de cada emoção utilizando validação cruzada.	38
Tabela 5 – Comparação dos resultados entre os trabalhos.	43
Tabela 6 – Comparação dos resultados de cada emoção dos classificadores NB e MVS.	44

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizado de Máquina
AS	Análise de Sentimento
FIFA	Associação da Federação Internacional de Futebol
FN	Falso Negativo
FP	Falso Positivo
LSA	<i>Latent Semantic Analysis</i>
NB	Naïve Bayes
NLTK	<i>Natural Language Toolkit</i>
PNL	Processamento de Linguagem Natural
MVS	Máquinas de Vetores de Suporte
TN	Verdadeiro Negativo
TP	Verdadeiro Positivo

SUMÁRIO

1	INTRODUÇÃO	12
1.1	Contextualização e motivação	12
1.2	Trabalhos relacionados	13
1.2.1	<i>Análise de sentimento para textos em português do Brasil</i>	13
1.2.2	<i>Identificando polaridade utilizando Naïve Bayes</i>	14
2	FUNDAMENTAÇÃO TEÓRICA	16
2.1	Análise de sentimento	16
2.2	Emoções básicas	18
2.3	Análise de sentimento como um problema de classificação	19
2.4	Classificadores supervisionados	20
2.4.1	<i>Naïve Bayes (NB)</i>	21
2.4.2	<i>Máquinas de Vetores de Suporte (MVS)</i>	23
2.4.3	<i>Naïve Bayes vs. Máquinas de Vetores de Suporte</i>	25
3	IDENTIFICANDO EMOÇÕES EM MANCHETES DE NOTÍCIAS	26
3.1	Descrição do <i>corpus</i>	26
3.2	Pré-processamento das manchetes de notícias	27
3.2.1	<i>Remoção de stop words</i>	27
3.2.2	<i>Normalização dos textos</i>	27
3.3	Fase de treinamento e teste do classificador	28
4	EXPERIMENTOS E RESULTADOS	30
4.1	Técnicas para avaliação de modelos	30
4.1.1	<i>Divisão fixa (percentage split)</i>	30
4.1.2	<i>Validação cruzada (cross validation)</i>	30
4.2	Métricas de avaliação	30
4.3	Experimentos	32
4.3.1	<i>Acurácia do classificador Naïve Bayes</i>	32
4.3.2	<i>Cobertura do classificador Naïve Bayes</i>	34
4.3.3	<i>Precisão do classificador Naïve Bayes</i>	35
4.4	Discussão dos resultados	37
5	CONSIDERAÇÕES FINAIS	45
	REFERÊNCIAS	46

1 INTRODUÇÃO

1.1 Contextualização e motivação

As emoções costumam ser objeto no estudo do comportamento humano. No século XIX, Darwin (1965) já realizava estudos para identificar emoções básicas do ser humano. Esse estudo constituiu uma das primeiras fontes de informação sobre as emoções, no qual foi descrito reações de medo, choro, dor, ansiedade, mau humor, surpresa, alegria, raiva, dentre outras. Com o crescimento da tecnologia e de acesso às informações, analisar tais emoções atraiu o interesse de pesquisadores da área de Ciência da Computação, especialmente os interessados no processamento de textos, recuperação da informação e na interação humano-computador (MARTINAZZO, 2010).

A popularização da Internet gera um grande volume de dados. Empresas e organizações por vezes não conseguem acompanhar o que seus clientes estão falando, devido a esse volume de informações que é gerado. No entanto, percebeu-se que, ao analisar essas informações, as organizações poderiam ter a vantagem de conhecer as opiniões dos usuários sobre seus produtos e serviços (GOMES, 2013).

Segundo Han e Kamber (2001), somente uma pequena parte das informações existentes é realmente relevante para classificação devido aos textos incoerentes (com erros ou mal formatados) encontrado nas redes sociais. Entretanto, sem saber o que está contido em cada texto, é difícil extrair deles qualquer informação útil. Devido a este problema, foram criadas ferramentas para analisar textos e classificá-los de acordo com categorias pré-definidas ou encontrar padrões que os conectem a outros textos (MARTINAZZO, 2010).

A análise de sentimento é a área que busca identificar emoções em bases textuais de forma automática. Uma possível aplicação para essa finalidade de pesquisa está em sistemas de avaliação de produtos ou serviços. A análise de sentimento de tais revisões pode auxiliar o sistema a recomendar, ou não, determinado produto a uma pessoa que busque informações sobre o mesmo, baseado nas avaliações e nas opiniões de outros usuários (MARTINAZZO, 2010).

O problema de analisar textos pode ser visto como um problema de classificação (GOMES, 2013). Assim, foram desenvolvidos métodos de classificação baseados em Processamento de Linguagem Natural (PNL). Tais métodos são aplicados na análise de sentimento para encontrar emoções em bases textuais. Contudo, existem poucos classificadores desenvolvidos para o idioma português do Brasil. Desta forma, métodos que sejam capazes de

identificar emoções em textos escritos em português do Brasil e que classifiquem emoções são uma contribuição relevante para a área de classificação (DOSCIATTI; FERREIRA, 2013).

Este trabalho propõe a implementação de um método baseado em aprendizado de máquina, o classificador Naïve Bayes, para identificar emoções em manchetes de notícias e classificá-las de acordo com o modelo proposto por Ekman e Friesen (1978) em uma das seis emoções básicas: alegria, tristeza, medo, surpresa, desgosto e raiva.

1.2 Trabalhos relacionados

1.2.1 *Análise de sentimento para textos em português do Brasil*

Martinazzo (2010) propõe um sistema de identificação de emoções em textos escritos em português do Brasil. O objetivo é identificar uma das seis emoções básicas propostas por Ekman e Friesen (1978) (alegria, tristeza, raiva, desgosto, surpresa e medo) em notícias curtas para a animação de um avatar que lê tais textos. O avatar responsável por ler os textos modifica sua expressão facial de acordo com as emoções encontradas pelo sistema de identificação no decorrer do texto. O método desenvolvido para tal problema é baseado no conceito de Latent Semantic Analysis (LSA), que é um método matemático/estatístico para identificar relações entre palavras em textos, partindo do pressuposto que as palavras sempre terão um significado semelhante e estarão inseridas no mesmo contexto. A taxa de acerto neste trabalho ficou em torno de 70% .

Este trabalho propõe identificar as emoções básicas assim como o de Martinazzo (2010), porém se difere por propor utilizar uma abordagem diferente para a automatização na identificação das emoções básicas. Martinazzo (2010) utiliza uma abordagem baseada no LSA, neste é desenvolvido um modelo de predição baseado no método Naïve Bayes.

Outro trabalho neste contexto é o de Dosciatti e Ferreira (2013) que aplica o algoritmo Máquinas de Vetores de Suporte (MVS) em solução multiclasse para identificar uma das seis emoções básicas em manchetes de textos jornalísticos escritos em português do Brasil. Os experimentos realizados mostram que o método é capaz de identificar a emoção predominante em 61% dos textos.

Em comparação com o trabalho anterior, este trabalho difere da abordagem de Dosciatti e Ferreira (2013) por propor o uso de um classificador probabilístico para a classificação. Em contrapartida, assemelha-se por analisar o mesmo *corpus* de notícias.

Existem outros trabalhos de identificação de emoções em textos escritos em português do Brasil, porém estes identificam a polaridade das emoções, ou seja, verificam se o texto possui uma emoção positiva ou negativa. Um desses trabalhos é o de Souza e Vieira (2012) que utiliza um corpus de *tweets* em português, em que utiliza recursos léxicos de sentimentos e analisa técnicas de pré-processamento para classificar os *tweets* como positivos ou negativos.

O trabalho citado acima está relacionado com este trabalho por tratar de um classificador para textos escritos em português do Brasil. Entretanto, a diferença é que ele busca encontrar a polaridade em *tweets* de usuários a partir de um léxico de sentimento, enquanto que a abordagem proposta tenta identificar a emoção predominante em manchetes de sites de notícias a partir do classificador Naïve Bayes.

1.2.2 Identificando polaridade utilizando Naïve Bayes

Kang, Yoo e Han (2012) propõe um Naïve Bayes modificado para resolver o problema de classificações tendenciosas. Segundo os autores, encontrar a polaridade em textos é um pouco tendenciosa, com uma taxa de 10% mais elevada para encontrar uma classificação positiva do que uma classificação negativa. Isto cria um problema, já que a precisão das duas classes são expressas pelo o valor médio. O resultado do experimento mostrou que, quando NB foi utilizado em conjunto com *unigramas* e *bigramas*, a diferença entre a precisão positiva e a precisão negativa foi reduzida para 3,6% em comparação quando utilizado o Naïve Bayes original.

Este trabalho parte da hipótese de que se adaptar o Naïve Bayes original especificamente para identificar uma das seis emoções básicas, assim como Kang, Yoo e Han (2012) fez para melhorar classificações tendenciosas, pode-se obter uma taxa de acerto tão boa quanto a encontrada no trabalho de Dosciatti e Ferreira (2013).

Outro trabalho desenvolvido para o português do Brasil é o de Filho (2014) que analisa *tweets* referentes à Copa do Mundo da FIFA (Associação da Federação Internacional de Futebol) 2014, realizada no Brasil, a fim de classificá-lo como: positivo, negativo, ambíguo ou neutro. A classificação dos *tweets* é baseada em mineração de dados, em que o autor cria um modelo baseado em Naïve Bayes. O autor gera um mapa de calor, que possibilita observar em que regiões do Brasil mais se falaram bem e mal da Copa do Mundo, e uma nuvem de palavras (imagem composta por palavras), que demonstra de maneira visual a frequência da ocorrência de palavras durante a Copa do Mundo. Nos resultados encontrados o modelo apresentou uma taxa

de 88,91% de precisão utilizando o conjunto de treinamento contendo 2634 *tweets*.

O trabalho de Filho (2014) e o de Souza e Vieira (2012) relacionam-se com o nosso por analisar textos em português do Brasil. Apesar de Filho (2014) classificar em quatro classes, ele ainda busca identificar a polaridade em *tweets* de usuários, diferentemente do nosso que, como já foi citado, busca identificar a emoção predominante em manchetes de sites de notícias.

O Capítulo 2 introduz os conceitos chaves para a compreensão deste trabalho. No Capítulo 3 é apresentamos a metodologia e as etapas de execução do modelo de predição de emoções em manchetes de notícias. No Capítulo 4 temos os experimentos e os resultados obtidos neste trabalho, e, por fim, no Capítulo 5 apresentamos as considerações finais e possíveis ideias para trabalhos futuros.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Análise de sentimento

A análise de sentimento (ALM; ROTH; SPROAT, 2005) é uma área da computação que estuda as opiniões, as emoções e as atitudes das pessoas diante de determinada entidade. Esta entidade pode representar indivíduos, eventos ou acontecimentos. A análise de sentimento identifica o sentimento expresso em textos para então analisá-los (MEDHAT; HASSAN; KORASHY, 2014).

As informações textuais podem ser divididas em duas categorias principais: fatos e opiniões. Fatos são expressões objetivas sobre determinado acontecimento. Já opiniões geralmente são expressões subjetivas que descrevem o sentimento das pessoas sobre determinado evento, indivíduo ou acontecimento (LIU, 2012).

As opiniões são o centro de quase todas as atividades humanas, já que elas são as principais influências para o comportamento. Uma maneira de obter uma decisão significa querer saber a opinião das outras pessoas. No mundo empresarial, empresas e organizações sempre querem saber a opinião de seus consumidores sobre seus produtos e serviços. O consumidor quer saber a opinião de outros consumidores antes de comprar determinado produto. O eleitor quer saber a opinião de outros eleitores sobre os candidatos políticos, antes de decidir em quem votar em uma eleição política (INDURKHYA; DAMERAU, 2010).

Com o grande crescimento das mídias sociais nos últimos anos, a análise de sentimento têm se tornado muito ativas devido a várias razões. Primeiro, essa área está presente em quase todos os domínios, o que levou muitas empresas a investirem em aplicações para conhecer a opinião de seus clientes sobre determinado serviço. Segundo, essa área oferece problemas desafiadores para os pesquisadores de Ciência da Computação. Terceiro, toda informação de conteúdo opinativo tornou-se mais acessível a todos e existe um enorme volume desses dados em mídias sociais (LIU, 2012).

De acordo com Pak e Paroubek (2010) existem três níveis principais de classificação em análise de sentimento: em nível de documento, em nível de frase e em nível de aspecto.

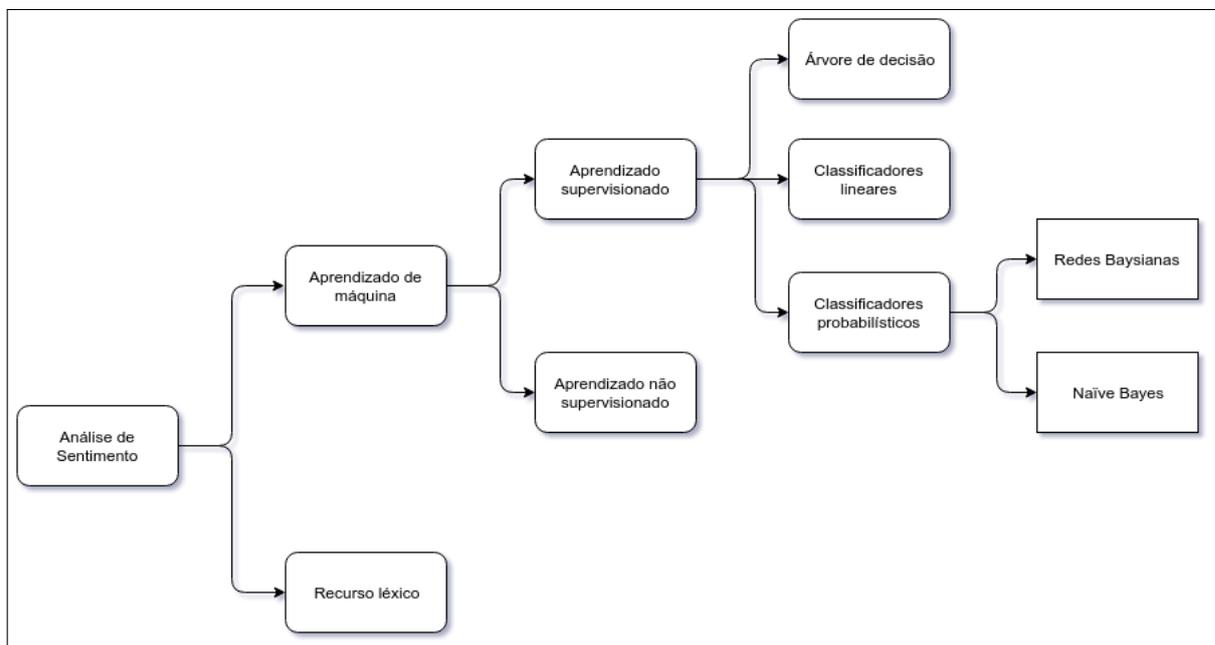
- **Em nível de documento:** a tarefa consiste em analisar um documento inteiro para então classificá-lo em um sentimento positivo ou negativo (PANG; LEE; VAITHYANATHAN, 2002). Por exemplo, dado um comentário sobre um produto ou serviço, esta tarefa se encarrega em saber se este comentário expressa uma opinião positiva ou negativa geral

sobre este serviço.

- **Em nível de frase:** visa classificar o sentimento expresso em cada frase. O primeiro passo é identificar se a sentença é subjetiva ou objetiva. Se a sentença é subjetiva, essa tarefa irá determinar se a frase exprime opiniões positivas ou negativas (WILSON; WIEBE; HOFFMANN, 2005).
- **Em nível de aspectos:** este nível baseia-se na ideia de que uma opinião é constituída por um sentimento (positivo ou negativo) e um alvo (de opinião). Por exemplo, mesmo que a frase “Embora o serviço não seja tão bom, eu ainda amo este restaurante” tenha claramente um tom positivo, não se pode dizer que esta frase é inteiramente positiva. De fato, a frase é positiva a respeito do restaurante, mas é negativa a respeito dos serviços. Portanto, o objetivo deste nível é descobrir os sentimentos relacionados as entidades e seus aspectos.

Segundo Medhat, Hassan e Korashy (2014) existem diversas técnicas para identificar emoções em textos, conforme são apresentadas na Figura 1.

Figura 1 – Técnicas para classificação de sentimentos.



Fonte: Elaborada pelo autor. Adaptado de Medhat, Hassan e Korashy (2014).

Na Figura 1 podemos observar que existem as técnicas baseadas em aprendizado de máquina e baseadas em recurso léxico. A abordagem em recurso léxico busca classificar os textos de acordo com o sentido semântico de cada palavra. Já a abordagem em aprendizado de máquina tenta encontrar correlações entre os textos com o intuito de classificar um novo

texto baseado no conteúdo dos textos processados anteriormente. As técnicas baseadas em aprendizado de máquina dividem-se em duas: aprendizado supervisionado e não supervisionado.

Este trabalho tem como objetivo utilizar uma abordagem baseada em aprendizado de máquina supervisionado. Mais especificamente, utilizar um classificador probabilístico para identificar sentimentos em textos em português e classificá-los em um conjunto de emoções básicas, descritas na próxima seção.

2.2 Emoções básicas

Embora ainda não exista um consenso sobre a definição de emoção, pode-se dizer que as emoções são estados mentais e psicológicos associados com uma grande variedade de sentimentos, pensamentos e comportamentos (FEHR; RUSSELL, 1984).

As emoções utilizadas neste trabalho são chamadas de Emoções Básicas (ou Puras). Estas emoções foram propostas por Ekman e Friesen (1978), em que o modelo proposto consiste em seis emoções: ¹

Tabela 1 – Definição das emoções.

Emoção	Definição
Tristeza	qualidade ou estado do que é triste; mágoa; pena; pesar.
Raiva	grande irritação; ódio; aversão; rancor; ânsia.
Medo	terror; susto; pavor; receio.
Alegria	a manifestação de contentamento; júbilo; prazer moral; aquilo que alegra.
Desgosto	descontentamento; desprazer; repugnância.
Surpresa	ato ou efeito de surpreender; prazer inesperado; sucesso imprevisto.

Fonte: Elaborado pelo autor.

Recentemente, o estudo das emoções tem atraído também a atenção de pesquisadores da área de Ciência da Computação, especialmente no que tange a interação entre homens e máquinas (FRIEDER; GROSSMANN, 2004). Entre as pesquisas realizadas, Martinazzo (2010) e Dosciatti e Ferreira (2013) desenvolveram diferentes métodos para a identificação automática dessas emoções básicas.

¹ A definição de cada uma das emoções foi retirada do dicionário (FERNANDES; LUFT, 1984)

2.3 Análise de sentimento como um problema de classificação

A classificação é responsável por agrupar diferentes textos em classes como em positivo ou negativo (DUARTE, 2013). Este trabalho classificará os textos em sete classes, das quais seis classes representam cada uma das emoções básicas e uma classe neutro, que representa a não predominância de nenhuma das emoções básicas

Os classificadores de aprendizado de máquina são algoritmos usados no intuito de classificar objetos com determinadas características em classes específicas. Alguns destes algoritmos são treinados com exemplos, e este treinamento é usado como base para encontrar o melhor padrão das características de um texto em tal classe, e então, classificar o texto naquela classe (DUARTE, 2013). Portanto, classificar um sentimento pode ser visto como um problema de classificação de textos.

Tradicionalmente, classifica-se textos em diferentes temas como política, ciência e esporte. Nessa classificação, as palavras relacionadas ao assunto são as principais características para definir o tema daquele texto. Entretanto, em análise de sentimentos as palavras que indicam sentimento ou opinião positiva ou negativa é o que há de mais importante para identificar uma emoção como bom, excelente, incrível, ruim, péssimo, horrível, etc (LIU, 2012).

De acordo com Liu (2012) a chave para classificação de sentimentos é entender o conjunto de recursos eficazes que podemos utilizar. Alguns dos exemplos destes recursos são:

- **Termos e suas frequências (*terms e their frequency*)**. Esse recurso consiste em analisar palavras individuais (*unigram*) ou podemos generalizar o *unigram* para analisar uma sequência de n palavras em um texto (*n-gram*). São comumente utilizadas para a classificação de textos em determinado tema.
- **Parte do discurso (*part of speech*)**. Este recurso diz que palavras de diferente parte do discurso podem ser tratadas de forma diferente. Por exemplo, adjetivos são importantes indicadores de opiniões. Portanto, estes devem ser tratados de forma especial quando queremos identificar sentimento ou opinião.
- **Sentimento em frases e palavras (*sentiment words and phrases*)**. *Sentiment words* são palavras na linguagem que expressam um sentimento positivo ou negativo. Por exemplo, *bom*, *maravilhoso* e *incrível* denotam um sentimento positivo sendo *sentiment words* positivas. Em contrapartida, *ruim*, *terrível* e *horroroso* são *sentiment words* negativas. A maioria delas são adjetivos e advérbios, porém substantivos (e.g., lixo ou porcária) e

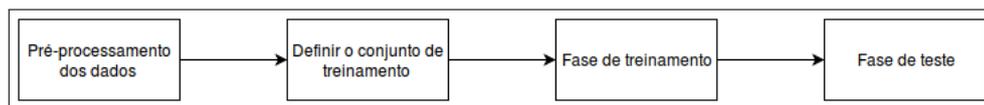
verbos (e.g., amar, odiar, adorar) também podem expressar sentimento.

- **Regras de opiniões (*rules of opinions*).** Além de poder encontrar sentimento em frases e palavras, existem também outras expressões ou composições de linguagem que podem indicar sentimentos e opiniões. Estas expressões devem ser analisadas com cuidado, pois muitas vezes podem mudar o sentido do texto. Por exemplo, na frase “*José foi desta para melhor.*” A frase se analisada por alguém que não conhece a expressão “*desta para melhor*”, será interpretada sendo um sentimento positivo. Entretanto, a expressão significa que alguém veio a falecer, ou seja, indica um sentimento negativo. Portanto, se tais expressões são desconsideradas o resultado não será correto.
- **Alternadores de sentimento (*sentiment shifters*).** Essas são expressões que podem mudar o sentimento de positivo para negativo e vice-versa. Palavras de negação como *não, nunca, ninguém, nenhum* são o tipo mais comum de alternadores de sentimentos. Advérbios como *difícilmente e raramente* também podem mudar o sentido do texto. Por exemplo, na frase “A câmera funciona” indica algo positivo, porém na frase, “A câmera *difícilmente* funciona” indica uma opinião negativa em relação a câmera. Portanto, identificar este tipo de característica em textos também é de extrema importância.

2.4 Classificadores supervisionados

Os classificadores supervisionados baseiam-se em aprendizado supervisionado. Para este tipo de classificação o classificador necessita de um conhecimento prévio sobre os dados, cujo conhecimento é usado para classificar estes dados. A Figura 2 mostra as etapas de um classificador supervisionado.

Figura 2 – Etapas de um classificador supervisionado aplicadas a um conjunto de dados.



Fonte: Elaborada pelo autor. Adaptado de Kotsiantis, Zaharakis e Pintelas (2007).

A primeira etapa é preparar os dados para submeter ao classificador, ou seja, aplicar técnicas de pré-processamento de dados ao *corpus*. A segunda etapa é definir uma parcela do *corpus* como conjunto de treinamento e outra como conjunto de teste. A próxima etapa é a fase de

aprendizado do classificador, na qual o classificador irá adquirir um conhecimento prévio sobre os dados, baseando-se no conjunto de treinamento definido na etapa anterior. Após a realização dessas etapas o classificador estará apto para classificar os dados presentes no conjunto de testes. A classificação é feita na fase de teste, que consiste na submissão dos dados ao classificador e o classificador classificará os dados (KOTSIANTIS; ZAHARAKIS; PINTELAS, 2007). A seguir apresenta-se algumas abordagens de classificadores baseados em aprendizado supervisionado.

2.4.1 Naïve Bayes (NB)

O classificador Naïve Bayes calcula a probabilidade do texto pertencer a cada classe, com base na distribuição das palavras no documento, porém a posição das palavras no texto é ignorada. Utiliza-se o teorema de Bayes para saber a probabilidade de uma palavra ou de um conjunto de palavras pertencer a determinada classe (MEDHAT; HASSAN; KORASHY, 2014). No escopo do trabalho uma classe representa uma emoção.

De acordo com Barbetta, Reis e Bornia (2004), o **teorema de Bayes** está intimamente relacionado ao teorema da probabilidade total. Basicamente, o teorema de Bayes permite obter a probabilidade de que um dos eventos E_i ocorra, dado que o evento F ocorreu. Supondo que, os eventos E_i são mutuamente exclusivos e que F é um evento qualquer, o teorema de Bayes é dado por 2.1:

$$P(E_i|F) = \frac{P(E_i) \cdot P(F|E_i)}{P(F)}, \quad (2.1)$$

em que $P(E_i)$ é a probabilidade a priori dos eventos E_i ocorrerem, $P(F)$ é a probabilidade a priori do evento F ocorrer e $P(F|E_i)$ é a probabilidade do evento F ocorrer dado que E_i ocorreu.

Para aplicarmos o teorema de Bayes para identificar emoções em textos, supomos que todas as palavras são independentes e que cada emoção é mutuamente exclusiva. Basicamente, o teorema calculará a probabilidade de uma palavra pertencer a uma emoção.

Na fase de treinamento do classificador Naïve Bayes calcula-se a probabilidade $P(F|E_i)$ para cada classe, ou seja, é calculada a probabilidade de um atributo (palavra) pertencer a uma classe (emoção). Assumindo que um texto é composto por um conjunto de atributos, a fase de classificação calcula qual classe tem maior probabilidade de ter gerado aquele texto.

Na fase de treinamento, faz-se necessário ter sete listas, uma para cada classe (seis emoções básicas e neutro), em que serão armazenadas um conjunto de atributos. Nesta fase, será

submetido ao classificador textos que já estão rotulados, ou seja, o classificador saberá a qual emoção é aquele texto. Assim, todas as palavras presentes no texto serão armazenadas na lista referente a sua emoção. Dessa forma, ao final da fase de treinamento, têm-se um conjunto de palavras para cada uma das emoções básicas e para neutro.

Na fase de classificação, aplica-se a regra de Bayes para calcular a probabilidade de um texto pertencer a uma dada classe. É importante lembrar que este cálculo só é possível devido a suposição inicial de todas as palavras presentes no texto são independentes em cada classe e que as classes são mutuamente exclusivas. Então, o classificador é definido por 2.2:

$$\text{classificar}(w_1, w_2, \dots, w_n) = \underset{c_j}{\operatorname{argmax}} P(c_j) \prod_{x_1}^{x_n} P(w_i | c_j) \quad (2.2)$$

em que w_i é a palavra da posição i do texto x_i , $x_i \in X$ tal que X é o conjunto de textos de treinamento, $c_j \in C$ tal que C é o conjunto de emoções e o operador argmax retornará a classe c_j que obter o maior valor.

A Equação 2.2 afirma que para cada classe, multiplica-se a probabilidade condicional de cada palavra. Ou seja, para se implementar o classificador, precisa-se calcular essas probabilidades condicionais para cada palavra e classe, $P(w_i | c_j)$, e multiplicar pela probabilidade a priori da classe c_j , $P(c_j)$. A classe que obtiver o maior valor será retornado pelo classificador.

O primeiro passo é a partir do conjunto de treinamento, contar o número de ocorrências de uma palavra w_i aparecer nos textos de uma classe c_j e dividir pelo número de ocorrências da classe c_j . Isso é representado matematicamente por 2.3:

$$P(w_i | c_j) = \frac{\text{cont}(w_i, c_j)}{\sum \text{cont}(v, c_j)}, \quad (2.3)$$

em que $\text{cont}(w_i, c_j)$ é o número de ocorrências da palavra w_i na classe c_j e $\sum \text{cont}(v, c_j)$ é o número de ocorrências da classe c_j .

Em seguida, a probabilidade a priori da classe c_j é calculado por 2.4:

$$P(c_j) = \frac{\text{textocont}(c_j)}{N}, \quad (2.4)$$

em que $\text{textocont}(c_j)$ é o número de ocorrências de textos rotulados com a classe c_j e N é o número de textos presente no *corpus*.

Na metodologia descrita há um problema proveniente do conjunto de treinamento. Ao submeter um novo texto ao classificador, se neste texto contém alguma palavra que não foi processada na fase de treinamento, a probabilidade da ocorrência desta palavra em determinada classe seria 0, $P(w_i|c_j) = 0$, conseqüentemente, o classificador retornaria probabilidade zero para todas as classes. Entretanto, só porque uma palavra não ocorreu durante o treinamento, não significa que ela nunca ocorrerá na fase de classificação. Para evitar tal problema, é utilizado a suavização de Laplace, que consiste em adicionar um valor fixo para cada contagem zero. A fórmula para calcular $P(w_i|c_j)$ após a suavização é dada por 2.5:

$$P(w_i|c_j) = \frac{\text{cont}(w_i, c_j) + 1}{\sum(\text{cont}(v, c_j) + 1)} = \frac{\text{cont}(w_i, c_j) + 1}{\sum \text{cont}(v, c_j) + |V|}, \quad (2.5)$$

em que V é o conjunto de palavras presentes no corpus de treino e $|V|$ é a cardinalidade de V .

Desta forma, se uma palavra que não ocorreu durante o treinamento de uma classe c_j , a probabilidade desta palavra pertencer à aquela classe é muito baixa, ao invés desta probabilidade ser nula.

2.4.2 Máquinas de Vetores de Suporte (MVS)

As Máquinas de Vetores de Suporte (MVS) proposta por Vapnik (2013) é uma técnica de aprendizado de máquina fundamentada na Teoria do Aprendizado Estatístico. A ideia básica de uma MVS é construir um hiperplano ótimo como superfície de decisão, de tal forma que a margem de separação entre as classes seja máxima, ou seja, o classificador MVS procura determinar separadores lineares no espaço de busca que pode melhor separar as diferentes classes.

Para a classificação binária (2 classes), o problema é encontrar uma função que defina um hiperplano de separação das classes. Seja T um conjunto de entrada do tipo (X_i, Y_i) em que X_i representa a i -ésima tupla de entrada e Y_i sua respectiva classe, tal que $Y = -1, 1$, T é linearmente separável se é possível separar os dados das classes -1 e 1 por um hiperplano (LORENA; CARVALHO, 2007). A superfície de decisão de um hiperplano que realiza essa separação para as classes -1 e 1 são dadas pelas Equações 2.6 e 2.7:

$$w^T \hat{x} + b < 0 \text{ para } Y = -1, \quad (2.6)$$

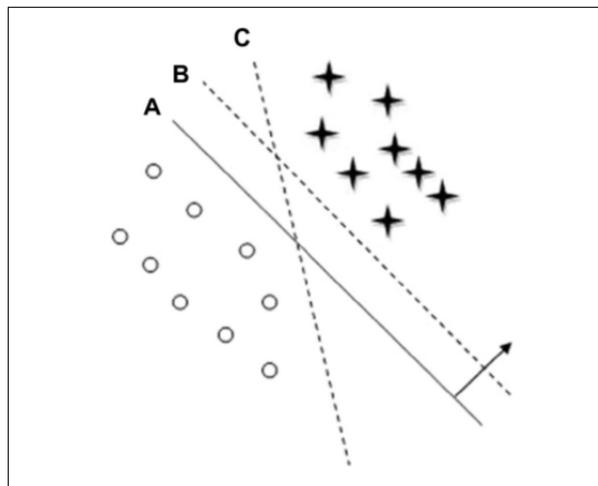
$$w^T \dot{x} + b \geq 0 \text{ para } Y = +1, \quad (2.7)$$

em que x é um vetor de entrada, w é um vetor de peso ajustável e b é um bias.

Para um dado vetor w e um bias b , a separação entre o hiperplano definido pelas Equações 2.6 e 2.7 e o ponto de dado mais próximo é denominada a margem de separação, representada por p . Sempre que $p > 0$ existirão infinitos hiperplanos de separação para as duas classes. O objetivo de uma MVS é encontrar o hiperplano em que maximize a margem de separação p (HAYKIN, 2000).

Na Figura 3, temos duas classes (x, o) e temos três hiperplanos (A, B e C). Neste exemplo, o hiperplano A fornece a melhor separação entre as classes porque a distância para qualquer ponto no conjunto de dados é a maior. Portanto, o hiperplano A representa a margem máxima de separação (MEDHAT; HASSAN; KORASHY, 2014).

Figura 3 – Usando MVS em um problema de classificação.



Fonte: Medhat, Hassan e Korashy (2014).

As MVS são usadas em muitas aplicações Chen e Tseng (2011) propuseram um método baseado em MVS para avaliar a qualidade de produtos analisando avaliações dos usuários sobre determinado produto. Li e Li (2013) propuseram um *framework* que fornece uma sumarização compacta de opiniões em *micro-blogs*. Eles identificaram e extraíram comentários de usuários que expressavam a opinião sobre determinado tema (política, economia, futebol) e, em seguida, classificaram os comentários usando um classificador MVS.

Para problemas com mais de duas classes, é usado duas estratégias na qual estas simulam o problema multiclasse como um problema de duas classes. Estas duas estratégias são descritas a seguir.

2.4.3 Naïve Bayes vs. Máquinas de Vetores de Suporte

O Naïve Bayes (JOHN; LANGLEY, 1995) é um dos algoritmos mais usados em aprendizado de máquina, sendo considerado um dos mais eficientes em tempo de processamento (SCHMITT, 2013). Pardo e Nunes (2002) afirmam que NB tem desempenho melhor quando há um grande conjunto de treinamento. As Máquinas de Vetores de Suporte, por sua vez, apresentam grande potencial para classificação quando se dispõe de um conjunto de treinamento limitado (LORENA; CARVALHO, 2007).

Pak e Paroubek (2010) utilizam NB e MVS para identificar se um *tweet* possui teor positivo, negativo ou neutro. Nos experimentos o NB apresentou melhores resultados. Pang, Lee e Vaithyanathan (2002) realizam diversos experimentos comparando classificadores MVS e NB para identificar a polaridade de comentários sobre filmes. Os resultados obtidos mostraram que MVS obteve uma melhor taxa de acerto apesar dos resultados terem sido muito próximos.

No classificador Naïve Bayes a taxa de acerto depende do conjunto de treinamento utilizado. Por isso, para alguns casos em que o conjunto de treinamento não é ideal ele pode ter resultados não tão eficientes. Visto esse problema, este projeto utilizará listas que associam palavras à cada uma das seis emoções básicas. Dessa forma, partimos da hipótese que ao utilizar Naïve Bayes com um recurso léxico de *sentiment words* para aumentar o conjunto de treinamento, podemos encontrar resultados melhores do que os resultados encontrado no trabalho de Dosciatti e Ferreira (2013).

Dosciatti e Ferreira (2013) realiza experimentos para comparar o classificador SVM em solução multiclasse e NB para identificar as seis emoções básicas. Os resultados mostram que utilizar SVM em solução multiclasse têm-se uma taxa de 10% de acerto maior que utilizar NB original.

3 IDENTIFICANDO EMOÇÕES EM MANCHETES DE NOTÍCIAS

As seções seguintes apresentam de forma geral a metodologia proposta nesse trabalho.

3.1 Descrição do *corpus*

Este trabalho utiliza manchetes de notícias de um *corpus* (conjunto de notícias) já existente disponibilizado por Dosciatti e Ferreira (2013)¹, retiradas do site [globo.com](http://www.globo.com)². O *corpus* disponível tem atualmente 1750 notícias rotuladas. Neste contexto, uma notícia rotulada é uma notícia na qual foi atribuída uma das seis emoções básicas. Caso o texto não tenha uma emoção predominante, a notícia é rotulada como “neutra”. Destas 1750 notícias presentes no *corpus*, têm-se 250 notícias rotuladas para cada uma das seis emoções e 250 notícias rotuladas como “neutro”.

A Figura 4 apresenta uma notícia de cada classe rotulada conforme descrito acima.

Figura 4 – Formato das manchetes de notícias rotuladas.

EUA lançam projeto para incentivar a venda de veículos: Presidente Barack Obama e legisladores chegaram a um acordo. Consumidores vão receber bônus para trocar carro velho por novo. <u>alegria</u>
Frente fria chega ao Sudeste no fim de semana: Previsão é de fortes pancadas de chuva em São Paulo. Segundo Cptec/Inpe, chuvas continuam no Norte e Nordeste. <u>desgosto</u>
Ladrões fazem arrastões em restaurante e em igreja evangélica. Bandidos fizeram arrastão em um restaurante e em uma igreja evangélica neste domingo, em São Paulo. <u>medo</u>
Arqueólogos descobrem no Egito cemitério da época anterior a Cristo. Pelos primeiros relatos, o cemitério era uma construção de dois andares e atualmente está sob águas. <u>neutro</u>
Mãe suspeita de agredir filha de 12 anos a pauladas é presa em Teresina. Criança teve traumatismo craniano e está internada, diz polícia. Enfermeira que atendeu a menina denunciou o caso. <u>raiva</u>
Cão policial dispara arma acidentalmente nos EUA. Ivan, pastor alemão de 3 anos, puxou o gatilho com sua pata, diz polícia. Ninguém, nem humano nem canino, se feriu no incidente. <u>surpresa</u>
Tecnologia em excesso contribui para insônia entre adolescentes, diz pesquisa: Estudos foram realizados em universidades dos Estados Unidos. Consumo de cafeína também contribui para distúrbios do sono. <u>tristeza</u>

Fonte: Elaborada pelo autor.

¹ Corpus disponível em <<http://www.ppgia.pucpr.br/~paraiso/mineracaodeemocoas/>>

² <site:<http://www.globo.com/>>

3.2 Pré-processamento das manchetes de notícias

O pré-processamento dos dados é uma etapa importante para a classificação. Nesta etapa são aplicadas técnicas de PNL para preparar os dados antes de serem submetidos para o modelo de predição analisá-los. Para as técnicas de PNL aplicadas neste trabalho foi utilizado a ferramenta NLTK (*Natural Language Toolkit*³).

3.2.1 Remoção de stop words

Stop words são palavras que estão presentes na maioria dos textos não apresentam teores emocionais (por exemplo, “que”, “de”, “em”, “teu”, “aqueles”) não são relevantes para serem enviadas para o classificador analisá-las. Assim, faz-se necessário um pré-processamento dos textos para remover o que é irrelevante antes de submeter ao classificador. As *stop words* são removidas de acordo com uma lista de palavras composta por pronomes, proposições e substantivos.

3.2.2 Normalização dos textos

Após remover *stop words* dos textos, é necessário normalizá-los antes de submeter ao classificador. Para isso, são utilizadas as seguintes técnicas:

- **Letras maiúsculas:** Letras maiúsculas presentes nos textos são convertidas para minúsculas. Essa conversão permite que palavras começadas com letras maiúsculas não sejam entendidas como palavras diferentes quando estão escritas em minúsculas.
- **Stemming:** Esta técnica tenta reduzir as palavras que estão em formas derivadas para sua forma de radical, baseando-se em uma heurística para retirar os sufixos das palavras. Por exemplo, as derivações de “prestigiei” e “prestigiaram” são transformadas para sua forma base “prestig”.
- **Número e caracteres especiais:** Números e caracteres especiais também são removidos dos textos, pois, estes não agregam valor para identificar uma emoção predominante em textos.

A representação do texto após este pré-processamento é conhecida como *bag-of-words*. A Figura 5 apresenta uma das manchetes de notícia descritas na Figura 4 após o

³ Ferramenta disponível em <<http://www.nltk.org/>>

pré-processamento.

Figura 5 – Manchete de notícia após o pré-processamento.

<p>tecnolog excess contribu par insôn entr adolescentes diz pesquisa estud realiz univers est unidos consum cafeín contribu par distúrbi sono tristeza</p>
--

Fonte: Elaborada pelo autor.

3.3 Fase de treinamento e teste do classificador

Este trabalho tem como objetivo identificar emoções em manchetes de textos jornalísticos. Para isso será utilizado uma abordagem de aprendizado de máquina baseado no método de Naïve Bayes descrito na Seção 3.4. Após realizado o pré-processamento das manchetes de notícias presentes no corpus, descrito na seção 4.2, temos um *bag-of-words* de cada texto do *corpus*. Feito isso, o próximo passo é definir o conjunto de treinamento.

O conjunto de dados será dividido em dois conjuntos: um conjunto será utilizado para realizar o treinamento do classificador, denominado conjunto de treinamento, e o outro conjunto será utilizado para avaliar o classificador, denominado conjunto de teste. Ao realizar esta etapa, a próxima etapa é a fase de treinamento.

Na fase de treinamento do método são criadas sete listas de palavras, uma para cada emoção básica e outra para a classe “neutro”. Ao processar cada manchete de notícia do corpus de treinamento, cada palavra é armazenada na lista que representa a emoção previamente rotulada manchete de aquela notícia. O formato das manchetes de notícias que são submetidas para o modelo de predição do classificador construir seu aprendizado consiste em um par texto-emoção como ilustrado na Figura 4.

Pode-se observar que cada manchete de notícia submetida nesta fase está rotulada com sua emoção ao final do texto processado. Deste modo, torna-se possível para o modelo de predição do classificador associar as palavras do texto processado a uma emoção (previamente rotulada) e construir seu aprendizado. Este aprendizado será usado na fase de teste para o classificador predizer a emoção de determinada manchete de notícia.

Dessa forma, ao final da fase de treinamento têm-se seis listas de palavras relacionadas a cada uma das seis emoções básicas e uma lista que relaciona com a classe neutro. No Naïve Bayes original o próximo passo seria a fase de classificação. Entretanto, na abordagem utilizada neste trabalho tem uma fase intermediária, denominada fase de incremento das listas.

Para que seja possível associar as palavras a cada uma das seis emoções básicas de uma forma mais precisa, serão incrementadas as seis listas de palavras associadas a cada uma das emoções básicas geradas na fase de treinamento. Em outras palavras, ao submeter as manchetes do conjunto de treinamento ao classificador teremos um dicionário de palavras para cada uma das classes. Este dicionário será incrementado com as palavras presente nas seis listas de palavras que estão associadas a cada emoção básica. Dessa forma, o aprendizado do classificador é composto das palavras presentes nas manchetes de notícias do conjunto de treinamento e das palavras presente nas listas associadas a cada emoção básica.

As listas de palavras foram disponibilizadas inicialmente por Strapparava e Mihalcea (2008) em seis arquivos diferentes (um para cada lista), em inglês. Portanto, fez-se necessário uma tradução das listas para o português do Brasil. Essa tradução já foi realizada e está disponibilizada em Martinazzo (2010).

Realizada essa etapa intermediária, o próximo passo é aplicar o método de Naïve Bayes descrito na Seção 2.4 sobre as manchetes de notícias presentes no conjunto de teste (definido antes da fase de treinamento). Os resultados encontrados neste trabalho são apresentados no próximo capítulo.

4 EXPERIMENTOS E RESULTADOS

4.1 Técnicas para avaliação de modelos

Para avaliar o classificador foram realizados diversos experimentos com 1750 textos previamente rotulados, no qual têm-se 250 textos rotulados com cada uma das 6 emoções básicas e 250 textos rotulados como neutros. Um experimento consiste em escolher uma técnica de avaliação de modelos e aplicá-la ao classificador. Neste trabalho, foram utilizadas duas técnicas para a avaliação do modelo.

4.1.1 Divisão fixa (*percentage split*)

Esta técnica consiste em dividir o *corpus* em dois subconjuntos, um subconjunto para treinamento e outro subconjunto para teste, e submeter o conjunto de teste ao classificador para ele avaliar de acordo com o aprendizado adquirido pelo conjunto de treinamento. O *corpus* foi dividido em 88% para treinamento e 12% para teste, mesmo valor usado em Dosciatti e Ferreira (2013).

4.1.2 Validação cruzada (*cross validation*)

Esta técnica consiste em dividir o *corpus* em dois conjuntos, o conjunto de treinamento e o conjunto teste. Dividimos o conjunto de treinamento em 10 subconjuntos, para então, ser realizado 10 experimentos menores utilizando 9 destes subconjuntos para treinamento e o subconjunto restante para teste. Feito isso, o subconjunto usado no teste que obteve a menor acurácia não é usado para realizar o treinamento do modelo. Dessa forma, o conjunto de teste é submetido ao classificador para ele avaliar de acordo com o aprendizado adquirido pelo novo conjunto de treinamento, composto dos 9 “melhores subconjuntos” do conjunto de treinamento original.

4.2 Métricas de avaliação

As métricas de avaliação usadas neste trabalho são baseadas nos conceitos a seguir:

- **TP** (*true positive* ou verdadeiro positivo): representa a quantidade de instâncias pertencentes a uma classe que foram classificadas corretamente. Por exemplo, se o classificador classifica uma notícia como “alegria” e a classe deste notícia era

realmente “alegria” temos um verdadeiro positivo para a classe “alegria”.

- **FP** (*false positive* ou falso positivo): representa a quantidade de instâncias que não pertencem a uma classe mas foram classificadas pertencentes àquela classe. Por exemplo, se o classificador classifica uma notícia como “alegria”, mas a notícia era “surpresa” temos um falso positivo para a classe “alegria”.
- **FN** (*false negative* ou falso negativo): representa a quantidade de instâncias que pertencem a uma classe mas foram classificadas como não pertencentes àquela classe. Por exemplo, se o classificador classifica uma notícia como “alegria”, mas a notícia era “surpresa” temos um falso negativo para a classe “surpresa”.
- **TN** (*true negative* ou verdadeiro negativo): representa a quantidade de instâncias que não pertencem a uma classe e foram classificadas como não pertencentes àquela classe. Por exemplo, o classificador classifica uma notícia como “alegria” e a notícia era “alegria”, temos um verdadeiro negativo para todas as classes que não são “alegria”.

Avaliamos os resultados do classificador quanto a sua *acurácia*, *cobertura* e *precisão*.

A *acurácia* é a métrica que calcula a taxa de acerto geral do classificador, isto é, a *acurácia* determina a taxa que o classificador obteve ao identificar corretamente uma classe. A *acurácia* do classificador é dada pela equação

$$\frac{TPA}{QN}, \quad (4.1)$$

em que *TPA* representa a quantidade de verdadeiros positivos de todas as classes e *QN* é a quantidade de notícias presente no conjunto de teste.

A *cobertura* (*recall*) é uma métrica para a avaliação de modelos que representa a porcentagem que o modelo de predição obteve para identificar corretamente os elementos de uma determinada classe. A *cobertura* do classificador é dada pela equação

$$\frac{TP}{TP + FN}, \quad (4.2)$$

em que é calculado os verdadeiros positivos e falsos negativos para cada classe.

A *precisão* (*precision*) é uma métrica para a avaliação de modelos que representa a proporção da quantidade de instâncias classificadas corretamente em uma determinada classe

pela quantidade de instâncias que foram classificadas à esta classe. Em outras palavras, diz para as instâncias classificadas em uma classe quantas estão corretas. A precisão é dada pela equação

$$\frac{TP}{TP + FP}, \quad (4.3)$$

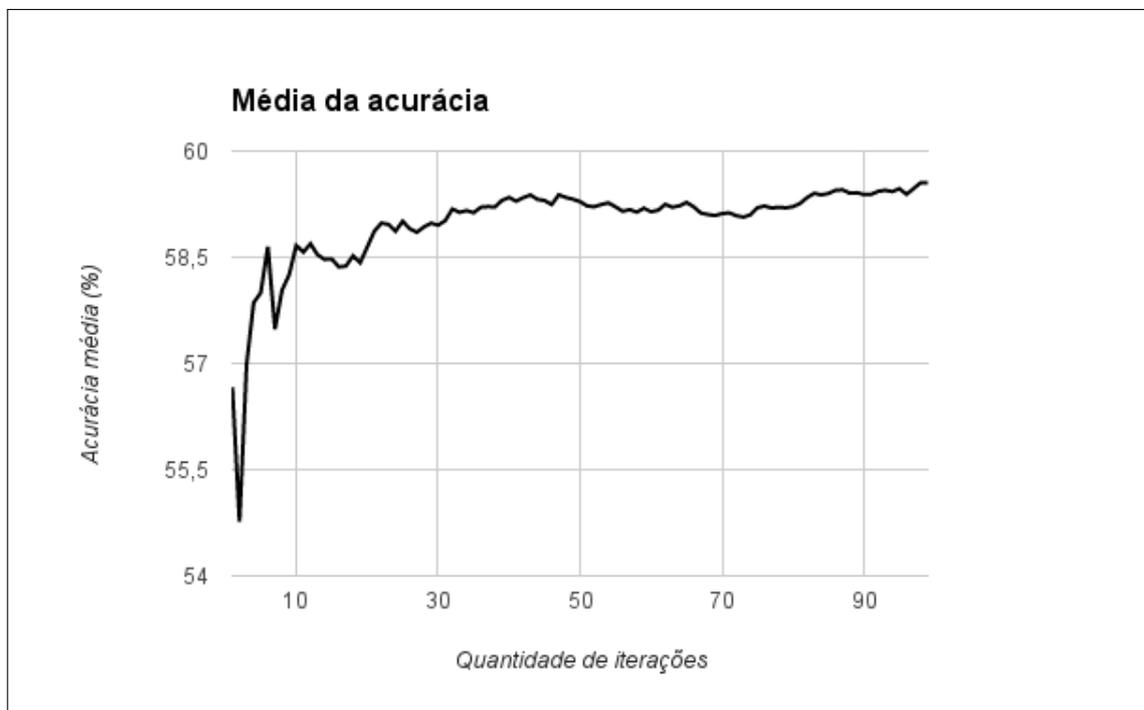
em que é calculado os verdadeiros e falsos positivos para cada classe.

4.3 Experimentos

4.3.1 Acurácia do classificador Naïve Bayes

Com o mesmo conjunto de dados usado por Dosciatti e Ferreira (2013), nosso classificador Naïve Bayes obteve uma acurácia média de 59,55% utilizando a técnica divisão fixa. A Figura 6 mostra um gráfico da média de acurácia obtida do classificador pela quantidade de experimentos realizados.¹

Figura 6 – Acurácia média obtida pelo classificador Naïve Bayes utilizando divisão fixa.



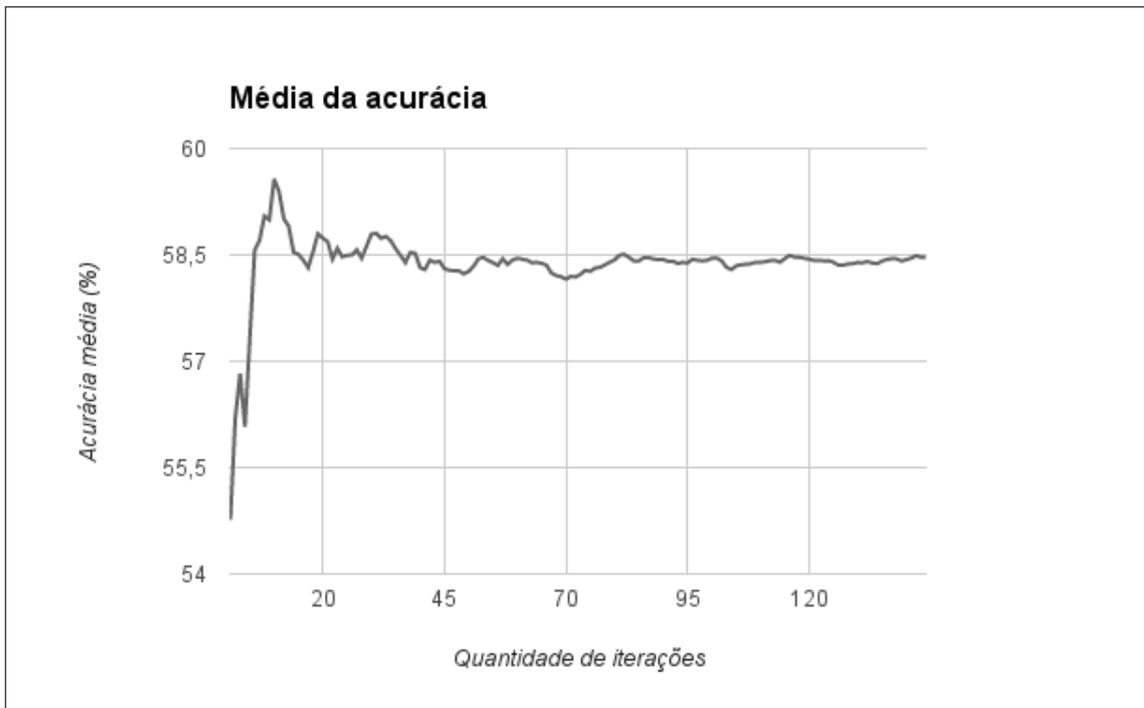
Fonte: Elaborada pelo autor.

¹ Vale ressaltar que em cada experimento os conjuntos de treinamento e teste são gerados de forma aleatória sempre com a mesma proporção.

Pode-se visualizar que na Figura 6 a partir da iteração 80 a média da acurácia varia pouco e que a acurácia do classificador está convergindo por volta de 59,5%.

Utilizando a técnica validação cruzada para avaliar o modelo, o classificador obteve uma acurácia média de 58,46%. A Figura 7 mostra o gráfico da média de acurácia obtida do classificador pela quantidade de experimentos realizados.

Figura 7 – Acurácia média obtida pelo classificador Naïve Bayes utilizando validação cruzada.



Fonte: Elaborada pelo autor.

Na Figura 7 é possível visualizar que por volta da iteração 110 a média da acurácia tem uma variação mínima e que a acurácia do classificador está convergindo para 58,46%

A condição de parada para o algoritmo de classificação é se a média da acurácia da iteração atual for inferior do que 0,001% em relação a média da acurácia da iteração anterior. De acordo com essa condição de parada, o classificador utilizando a técnica divisão fixa realizou 99 iterações para encontrar uma acurácia média de 59,55% e realizou 144 iterações para encontrar uma acurácia média de 58,46% utilizando a técnica validação cruzada.

A partir das Figuras 6 e 7, é possível concluir que o modelo de predição baseado no método de Naïve Bayes obteve melhores resultados de acurácia utilizando a técnica divisão fixa

para avaliar o modelo. A Tabela 2 mostra os resultados obtidos de acurácia, precisão e cobertura² comparando as duas técnicas de avaliação de modelos apresentadas na Seção 5.1.

Tabela 2 – Comparação dos resultados das técnicas de avaliação.

Técnica de avaliação	Acurácia (%)	Precisão (%)	Cobertura (%)
Divisão fixa	59,55	59,34	59,86
Validação cruzada	58,50	58,54	59,44

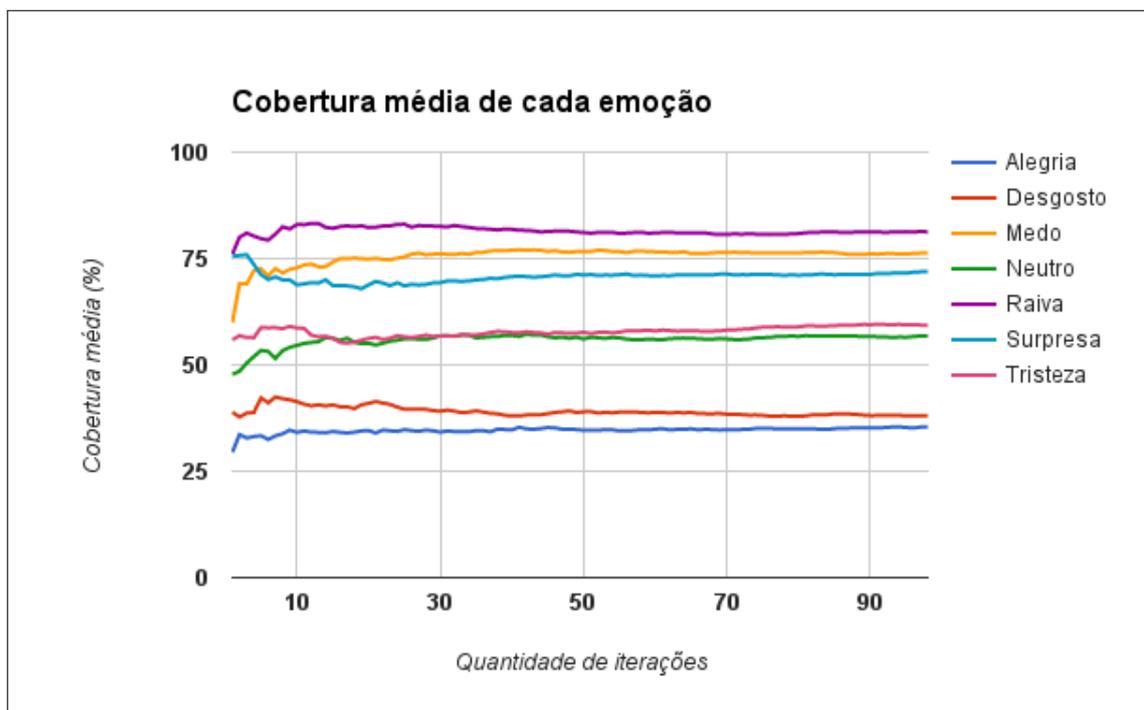
Fonte: Elaborado pelo autor.

A partir da Tabela 2, é possível visualizar que o Naïve Bayes obteve melhor resultado utilizando a técnica divisão fixa.

4.3.2 Cobertura do classificador Naïve Bayes

Utilizando a técnica divisão fixa, a cobertura média para cada classe é apresentada na Figura 8.

Figura 8 – Cobertura média para cada classe utilizando divisão fixa.



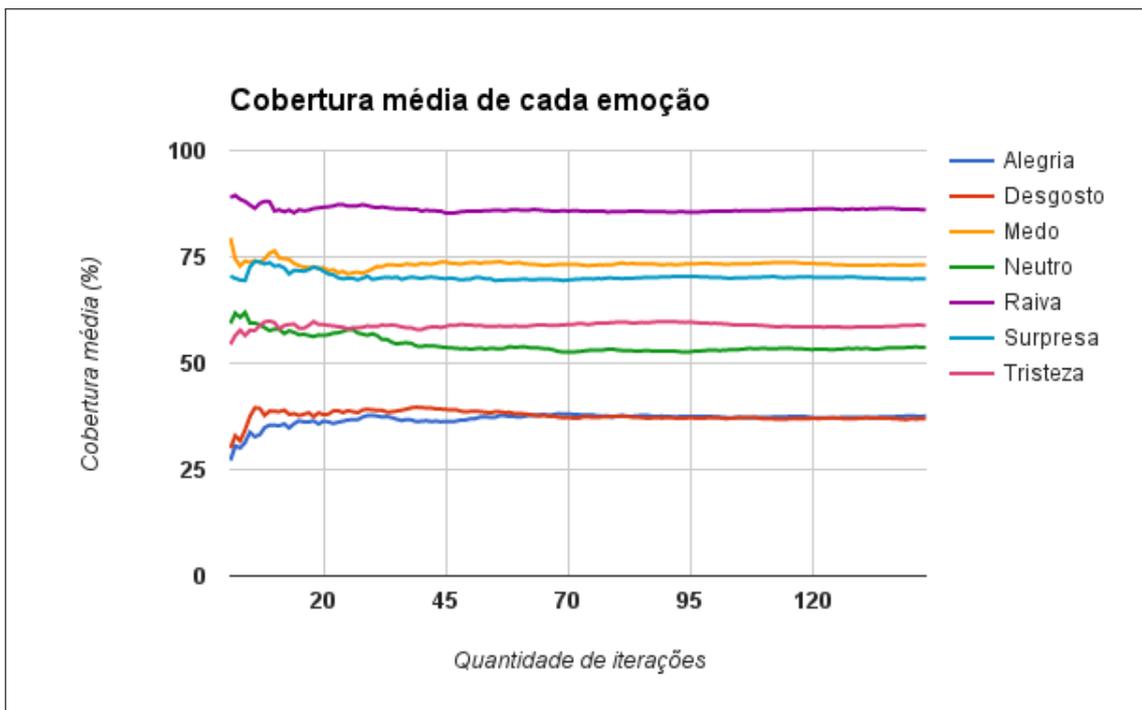
Fonte: Elaborada pelo autor.

² As métricas de cobertura e precisão geral é composta pela média das taxas de cobertura e precisão de todas as classes.

Na Figura 8 é possível visualizar que as classes “alegria” e “desgosto” obtiveram resultados de 35% e 38%, respectivamente. As classes “tristeza” e “neutro” obtiveram resultados de 59% e 56%, respectivamente. As classes “medo”, “surpresa” e “raiva” obtiveram resultados de 76%, 71% e 81%, respectivamente.

Os resultados de cobertura média para cada classe utilizando validação cruzada podem ser vistos na Figura 9.

Figura 9 – Cobertura média para cada classe utilizando validação cruzada



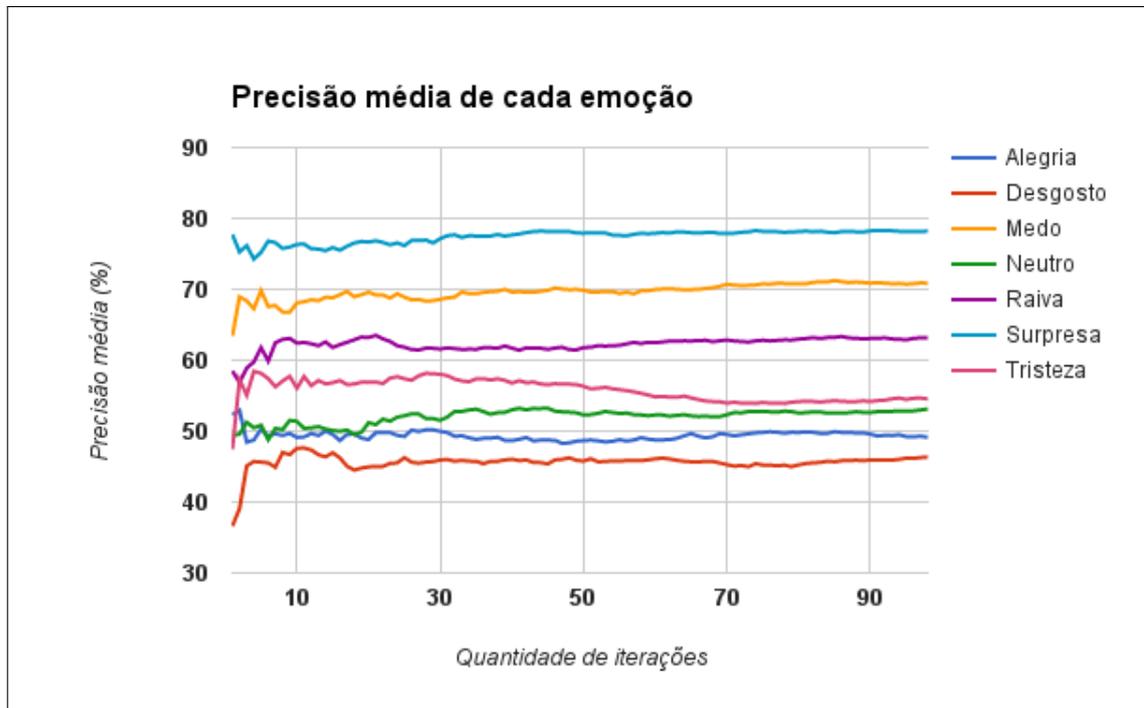
Fonte: Elaborada pelo autor

De acordo com a Figura 9, pode-se verificar que as classes “alegria” e “desgosto” obtiveram resultados de 37% ambas, as classes “tristeza” e “neutro” obtiveram resultados de 56% e 53%, respectivamente. As classes “surpresa” e “medo” obtiveram resultados de 69% e 73%, respectivamente. E a classe “raiva” obteve resultados com 86%.

4.3.3 Precisão do classificador Naïve Bayes

Utilizando a técnica divisão fixa, a precisão média para cada classe pode ser visualizada na Figura 10.

Figura 10 – Precisão média para cada classe utilizando divisão fixa.

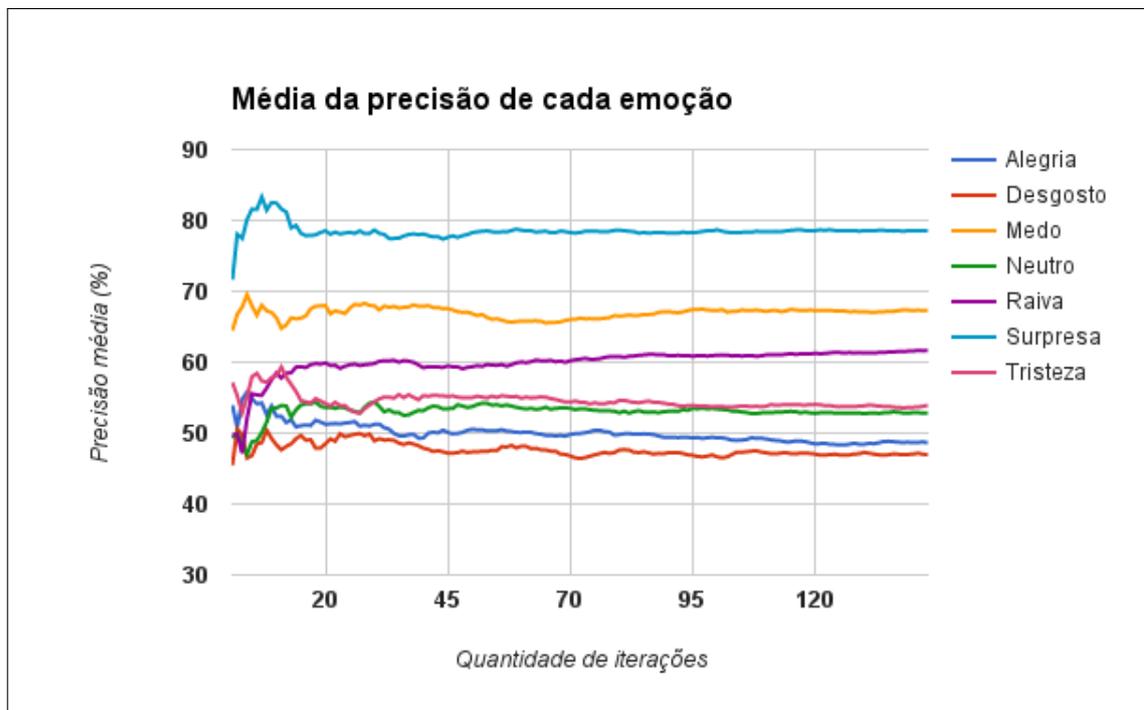


Fonte: Elaborada pelo autor.

Na Figura 10, temos que as classes “desgosto” e “alegria” obtiveram os piores resultados com 46% e 49%, respectivamente. As classes “neutro” e “tristeza” obtiveram resultados semelhantes com 53% e 54%, respectivamente. As classes “raiva”, “medo” e “surpresa” obtiveram as melhores taxas de precisão média com 63%, 70% e 78%, respectivamente.

Os resultados de precisão média para cada classe utilizando validação cruzada podem ser visualizados na Figura 11.

Figura 11 – Precisão média para cada classe utilizando validação cruzada.



Fonte: Elaborada pelo autor.

Na Figura 11, temos que as classes “desgosto” e “alegria” obtiveram as piores taxas de precisão média com 46% e 48%, respectivamente. As classes “neutro” e “tristeza” obtiveram semelhantes com 52% e 53%, respectivamente. As classes “raiva”, “medo” e “surpresa” obtiveram as melhores taxas de precisão média com 61%, 67% e 78%, respectivamente.

4.4 Discussão dos resultados

A Tabela 3 mostra os resultados de precisão e cobertura para cada emoção utilizando divisão fixa.

Tabela 3 – Comparação dos resultados de cada emoção utilizando divisão fixa.

Emoção	Precisão (%)	Cobertura (%)
Alegria	49,13	35,39
Desgosto	46,35	38,04
Medo	70,87	76,34
Neutro	53,13	56,80
Raiva	63,15	81,28
Surpresa	78,19	71,91
Tristeza	54,54	59,25

Fonte: Elaborado pelo autor.

A Tabela 4 mostra os resultados de precisão e cobertura para cada emoção utilizando validação cruzada.

Tabela 4 – Comparação dos resultados de cada emoção utilizando validação cruzada.

Emoção	Precisão (%)	Cobertura (%)
Alegria	48,65	37,58
Desgosto	46,96	36,95
Medo	67,30	73,14
Neutro	52,81	53,68
Raiva	61,62	86,10
Surpresa	78,55	69,81
Tristeza	53,93	58,83

Fonte: Elaborado pelo autor.

De acordo com os dados mostrados na Tabela 4, é possível perceber que as emoções “alegria” e “desgosto” obtiveram índices relativamente baixos de precisão e cobertura quando comparadas com as demais classes.

Um fato curioso é que a emoção “raiva” teve uma taxa de cobertura alta (86%) mas teve uma taxa de precisão de 61% apenas um pouco maior que a média, ou seja, o classificador Naïve Bayes desenvolvido neste trabalho tem resultados muito bons com uma taxa de 86% para identificar uma manchete de notícia rotulada com “raiva” no conjunto de teste, mas de todas as manchetes de notícias que foram classificadas como “raiva” apenas 61% realmente pertenciam a classe “raiva”.

Comparando os dados das Tabelas 3 e 4, para a técnica divisão fixa, as classes “alegria”, “medo”, “neutro”, “raiva” e “tristeza” obtiveram taxas de precisão melhores e as classes “desgosto”, “medo”, “neutro”, “surpresa” e “tristeza” obtiveram taxas de cobertura melhores. Para a técnica validação cruzada, as classes “desgosto” e “surpresa” obtiveram taxas de precisão melhores e as classes “alegria” e “raiva” obtiveram taxas de cobertura melhores.

A partir dos dados mostrados anteriormente, pode-se perceber que o classificador possui uma dificuldade para identificar as classes de “alegria” e “desgosto”. Durante os testes realizados, percebeu-se que isso se deve ao fato do classificador confundir a emoção de “alegria” com “desgosto” e “neutro”, e confundir a emoção de “desgosto” com “tristeza” e “alegria”. O que se leva a acreditar é que estão presentes palavras em comum nas manchetes de notícias destas classes, tornando difícil para o classificador diferenciar tais classes.

A Figura 12 mostra um exemplo de uma manchete de notícia em que o classificador

a classifica como pertencente a classe “alegria”. Todavia, percebe-se que a manchete de notícia pertence a classe “neutro”, ou seja, o classificador confundiu para distinguir as classes “alegria” e “neutro”.

Figura 12 – Manchete de notícia classificada como “alegria” pelo modelo.

<p>Em um mês, programa habitacional tem pedidos para 55 mil moradias: Caixa Econômica Federal analisa 270 projetos de construtoras. Setor espera contratar mais de 600 mil moradias até meados de 2010. neutro</p>
--

Fonte: Elaborada pelo autor.

A Figura 12 é um exemplo comum que mostra a deficiência do classificador para prever manchetes de notícias referentes as classes “alegria” e “neutro”. Pode-se perceber que no texto é sutil a diferença entre as emoções “alegria” e “neutro”. Possivelmente isso influencia o classificador Naïve Bayes fazendo com que ele não consiga construir informação suficiente para diferenciar estas classes.

Outro tipo de erro comum do classificador é não ter a capacidade de distinguir as classes “desgosto” e “tristeza”. A Figura 13 mostra uma manchete de notícia em que é classificada como “desgosto” mas é uma notícia pertencente a classe “tristeza”.

Figura 13 – Manchete de notícia classificada como “desgosto” pelo modelo.

<p>Dia do Trabalho é marcado por protestos pelo mundo: Na Alemanha e Turquia, houve confrontos com a polícia. No México, sindicatos tiveram que suspender ações por conta da doença. tristeza</p>

Fonte: Elaborada pelo autor.

A Figura 14 mostra as palavras mais frequentes nos textos da classe alegria. De acordo com a nuvem de palavras podemos perceber que as palavras mais frequentes foram “é”, “diz”, “presidente”, “governo”, “país”.

Figura 20 – Nuvem de palavras referentes à classe medo.



Fonte: Elaborada pelo autor.

De acordo com as Figuras 18, 19 e 20, vemos que as palavras mais frequentes destas classes estão presentes com menos frequência nas demais classes. O que justifica o fato do classificador obter taxas de acerto melhores as estas classes (surpresa, medo e raiva) em relação as demais classes (alegria, desgosto, neutro e tristeza).

No intuito de comparar os resultados obtidos neste trabalho com o trabalho de Dosciatti e Ferreira (2013), foram escolhidas 1540 notícias para treinamento e 210 notícias para teste. Dosciatti e Ferreira (2013) classificam as notícias em uma das emoções básicas utilizando MVS com configuração multiclasse, obtendo uma acurácia média de 61% ao identificar uma emoção predominante de um texto. A Tabela 5 mostra os resultados encontrados neste trabalho comparados ao de Dosciatti e Ferreira (2013).

Tabela 5 – Comparação dos resultados entre os trabalhos.

Técnica de avaliação	Acurácia (%)	Precisão (%)	Cobertura (%)
Naïve Bayes com divisão fixa	59	59	60
Naïve Bayes com validação cruzada	58	58	59
Trabalho de Dosciatti e Ferreira	61	58	61

Fonte: Elaborado pelo autor.

De acordo com a Tabela 5, vemos que nosso classificador Naïve Bayes com a abordagem de divisão fixa obteve uma taxa de precisão melhor do que o trabalho de Dosciatti e Ferreira (2013), mas obteve resultados inferiores para as taxas de acurácia e cobertura.

Na Tabela 6 temos os resultados de precisão e cobertura para cada emoção utilizando para os classificadores MVS e NB.

Tabela 6 – Comparação dos resultados de cada emoção dos classificadores NB e MVS.

Emoção	Precisão MVS (%)	Precisão NB (%)	Cobertura MVS (%)	Cobertura NB (%)
Alegria	48	49	45	35
Desgosto	42	46	39	38
Medo	72	71	81	76
Neutro	52	53	50	57
Raiva	76	63	75	81
Surpresa	75	78	81	72
Tristeza	55	54	54	59

Fonte: Elaborado pelo autor.

A partir dos dados da Tabela 6 vemos que o classificador MVS também tem dificuldade para classificar as classes “alegria” e “desgosto” com taxas de precisão e cobertura inferiores que 50%.

Analisando os resultados da Tabelas 6 podemos visualizar que nosso classificador NB obteve resultados de precisão melhores para as classes “alegria”, “desgosto”, “neutro” e “surpresa” e resultados de precisão piores para as classes “medo”, “raiva” e “tristeza”. Para a métrica de cobertura nosso classificador NB obteve resultados melhores para as classes “neutro”, “raiva” e “tristeza” e resultados piores para as classes “alegria”, “desgosto”, “medo” e “surpresa”.

De acordo com os resultados obtidos, vimos que o classificador Naïve Bayes obteve uma taxa de acerto por volta de 1% inferior ao classificador MVS. Entretanto, devido a simples complexidade computacional que o classificador NB oferece utilizá-lo neste cenário parece ser mais adequado.

5 CONSIDERAÇÕES FINAIS

Este trabalho apresenta o desenvolvimento de um método para identificação de emoções em bases textuais escritas em português do Brasil utilizando o classificador Naïve Bayes. O objetivo principal é identificar uma das seis emoções básicas descritas no modelo de Ekman e Friesen (1978) em manchetes de notícias por meio de NB.

Para realização do trabalho, foram aplicadas técnicas de processamento de linguagem natural e aprendizado de máquina no desenvolvimento do método e na realização dos experimentos. O método foi desenvolvido na linguagem de programação Python utilizando a ferramenta NLTK (*Natural Language ToolKit*) para o auxílio na fase de pré-processamento das manchetes de notícias. A NLTK foi escolhida devido a fácil utilização e integração com a linguagem de programação Python.

Concluída a implementação do classificador, foram realizados experimentos para avaliar as taxas de acurácia, precisão e cobertura (descritas na Seção 4.2) utilizando duas técnicas diferentes para a avaliação dos modelos, divisão fixa e validação cruzada. Os resultados obtidos neste trabalho foram relativamente semelhantes aos obtidos por Dosciatti e Ferreira (2013). A abordagem utilizando a técnica divisão fixa obteve os melhores resultados para o classificador Naïve Bayes. De acordo com os experimentos realizados, vimos que é possível identificar emoções de forma automatizada através do classificador Naïve Bayes.

Como trabalhos futuros, pretendemos incrementar o conjunto de manchetes de notícias e melhorar a forma de extração de características para reduzir a dimensionalidade dos atributos. Nosso trabalho considera que um atributo representa uma palavra. Visto isso, uma maneira de reduzir a dimensionalidade dos atributos seria aplicar outras técnicas de PNL para realizar o pré-processamento dos textos ou atribuir pesos a determinados atributos que possuem um maior teor emocional, mas para isso é necessário ter ferramentas de dicionário de palavras em português do Brasil que atribuam pesos para cada uma das seis emoções básicas. Outro trabalho futuro seria aplicar o modelo para identificação de emoções básicas em outras bases textuais escritas em português do Brasil como em bases de redes sociais (*twitter* e *facebook*).

REFERÊNCIAS

- ALM, C. O.; ROTH, D.; SPROAT, R. Emotions from text: machine learning for text-based emotion prediction. In: ASSOCIATION FOR COMPUTATIONAL LINGUISTICS. **Proceedings of the conference on human language technology and empirical methods in natural language processing**. [S.l.], 2005. p. 579–586.
- BARBETTA, P. A.; REIS, M. M.; BORNIA, A. C. **Estatística: para cursos de engenharia e informática**. [S.l.]: Atlas São Paulo, 2004. v. 3.
- CHEN, C. C.; TSENG, Y.-D. Quality evaluation of product reviews using an information quality framework. **Decision Support Systems**, Elsevier, v. 50, n. 4, p. 755–768, 2011.
- DARWIN, C. **The expression of the emotions in man and animals**. [S.l.]: University of Chicago press, 1965. v. 526.
- DOSCIATTI, M. M.; FERREIRA, E. C. L. P. C. Identificando emoções em textos em português do brasil usando máquina de vetores de suporte em solução multiclasse. **ENIAC-Encontro Nacional de Inteligência Artificial e Computacional. Fortaleza, Brasil, 2013**.
- DUARTE, E. S. **Sentiment analysis on twitter for the portuguese language**. Tese (Doutorado) — Faculdade de Ciências e Tecnologia, 2013.
- EKMAN, P.; FRIESEN, W. V. **Facial Action Coding System: Investigatoris Guide**. [S.l.]: Consulting Psychologists Press, 1978.
- FEHR, B.; RUSSELL, J. A. Concept of emotion viewed from a prototype perspective. **Journal of experimental psychology: General**, American Psychological Association, v. 113, n. 3, p. 464, 1984.
- FERNANDES, F.; LUFT, C. P. **Dicionário brasileiro globo**. [S.l.]: Editôra Globo, 1984.
- FILHO, J. A. C. **Mineração de textos: análise de sentimento utilizando tweets referentes à copa do mundo 2014**. 2014.
- FRIEDER, O.; GROSSMANN, D. Information retrieval. algorithms and heuristics. **The Information Retrieval Series**, 2004.
- GOMES, H. J. C. **Text Mining: análise de sentimentos na classificação de notícias**. Tese (Doutorado), 2013.
- HAN, J.; KAMBER, M. Data mining: concepts and techniques. 2001. **Morgan Kauffman**, 2001.
- HAYKIN, S. S. Redes neurais artificiais: princípio e prática. **2ª Edição, Bookman, São Paulo, Brasil, 2000**.
- INDURKHYA, N.; DAMERAU, F. J. **Handbook of natural language processing**. [S.l.]: CRC Press, 2010. v. 2.
- JOHN, G. H.; LANGLEY, P. Estimating continuous distributions in bayesian classifiers. In: MORGAN KAUFMANN PUBLISHERS INC. **Proceedings of the Eleventh conference on Uncertainty in artificial intelligence**. [S.l.], 1995. p. 338–345.

- KANG, H.; YOO, S. J.; HAN, D. Senti-lexicon and improved naïve bayes algorithms for sentiment analysis of restaurant reviews. **Expert Systems with Applications**, Elsevier, v. 39, n. 5, p. 6000–6010, 2012.
- KOTSIANTIS, S. B.; ZAHARAKIS, I.; PINTELAS, P. **Supervised machine learning: A review of classification techniques**. 2007.
- LI, Y.-M.; LI, T.-Y. Deriving market intelligence from microblogs. **Decision Support Systems**, Elsevier, v. 55, n. 1, p. 206–217, 2013.
- LIU, B. Sentiment analysis and opinion mining. **Synthesis lectures on human language technologies**, Morgan & Claypool Publishers, v. 5, n. 1, p. 1–167, 2012.
- LORENA, A. C.; CARVALHO, A. C. de. Uma introdução às support vector machines. **Revista de Informática Teórica e Aplicada**, v. 14, n. 2, p. 43–67, 2007.
- MARTINAZZO, B. **Um Método de Identificação de Emoções em Textos Curtos para o Português do Brasil**. Tese (Doutorado) — Pontifícia Universidade Católica do Paraná, 2010.
- MEDHAT, W.; HASSAN, A.; KORASHY, H. Sentiment analysis algorithms and applications: A survey. **Ain Shams Engineering Journal**, Elsevier, v. 5, n. 4, p. 1093–1113, 2014.
- PAK, A.; PAROUBEK, P. Twitter as a corpus for sentiment analysis and opinion mining. In: **LREc**. [S.l.: s.n.], 2010. v. 10, p. 1320–1326.
- PANG, B.; LEE, L.; VAITHYANATHAN, S. Thumbs up?: sentiment classification using machine learning techniques. In: ASSOCIATION FOR COMPUTATIONAL LINGUISTICS. **Proceedings of the ACL-02 conference on Empirical methods in natural language processing-Volume 10**. [S.l.], 2002. p. 79–86.
- PARDO, T. A. S.; NUNES, M. d. G. V. Aprendizado bayesiano aplicado ao processamento de línguas naturais. **Série de Relatórios Técnicos do Instituto de Ciências Matemáticas e de Computação-ICMC, Universidade de São Paulo**, 2002.
- SCHMITT, V. F. **Uma análise comparativa de técnicas de aprendizagem de máquina para prever a popularidade de postagens no facebook**. 2013.
- SOUZA, M.; VIEIRA, R. Sentiment analysis on twitter data for portuguese language. In: **Computational Processing of the Portuguese Language**. [S.l.]: Springer, 2012. p. 241–247.
- STRAPPARAVA, C.; MIHALCEA, R. Learning to identify emotions in text. In: ACM. **Proceedings of the 2008 ACM symposium on Applied computing**. [S.l.], 2008. p. 1556–1560.
- VAPNIK, V. **The nature of statistical learning theory**. [S.l.]: Springer Science & Business Media, 2013.
- WILSON, T.; WIEBE, J.; HOFFMANN, P. Recognizing contextual polarity in phrase-level sentiment analysis. In: ASSOCIATION FOR COMPUTATIONAL LINGUISTICS. **Proceedings of the conference on human language technology and empirical methods in natural language processing**. [S.l.], 2005. p. 347–354.