

UMA FERRAMENTA PARA ANÁLISE DE SENTIMENTOS DE TWEETS EM PORTUGUÊS

Rodrigo dos Santos Miguel, Yuri de Almeida Malheiros Barbosa

Departamento de Ciências Exatas - Universidade Federal da Paraíba (UFPB)

Rio Tinto - PB - Brasil

{rodrigo.santos, yuri}@dcx.ufpb.br

Resumo. *O Twitter possui milhões de usuários enviando opiniões diariamente sobre os mais variados assuntos. Com esta grande quantidade de opiniões, cresce o interesse em acompanhar, em tempo real, os comentários sobre determinados produtos, serviços, pessoas, etc. A análise de sentimentos é uma área que procura determinar o sentimento expresso em um determinado texto através de computadores. Este trabalho tem como objetivo desenvolver uma ferramenta que colete tweets de acordo com a busca de um determinado assunto e classifique o sentimento (positivo ou negativo) expresso na mensagem. Nela, será possível monitorar as consultas gravadas e verificar a variação do sentimento ao decorrer do tempo.*

Abstract. *Twitter has millions of users posting opinions daily on a wide range of topics. With this large number of opinions, there is a growing interest in monitoring, in real time, comments on certain products, services, people, etc. Sentiment analysis is an area that seeks to determine the feeling expressed in a given text through computers. This work aims to develop a tool that collects tweets according to the search of a subject and classifies the sentiment (positive or negative) expressed in the message. In it, you can monitor the recorded queries and check the variation of the feeling over time.*

1. Introdução

Nos últimos anos a Internet tornou-se essencial em nossa sociedade, permitindo que atividades como fazer compras, jogar e assistir filmes possam ser realizadas em

"Trabalho de Conclusão de Curso (TCC) na modalidade Artigo apresentado como parte dos pré-requisitos para a obtenção do título de Bacharel em Sistemas de Informação pelo curso de Bacharelado em Sistemas de Informação do Centro de Ciências Aplicadas e Educação (CCAIE), Campus IV da Universidade Federal da Paraíba, sob a orientação do professor Yuri de Almeida Malheiros Barbosa."

qualquer lugar. Na rede mundial de computadores, as pessoas também passaram a compartilhar ideias, conhecimentos, críticas e opiniões com muito mais frequência. Segundo LIU (2012), as opiniões são centrais para quase todas as atividades humanas e são influenciadoras de nosso comportamento.

Decisões simples como o que comprar, o que jogar ou qual filme assistir, são baseadas em opiniões de pessoas próximas. Nas organizações isso também acontece, de acordo com BECKER e TUMITAN (2013), as empresas baseiam suas estratégias de negócio e investimentos na opinião de seus clientes sobre seus produtos ou serviços. Hoje em dia, muitas dessas opiniões são compartilhadas através das redes sociais.

Em 2006, o Twitter foi criado como uma plataforma que popularizou o conceito de microblogging, ou seja, permitiu que seus usuários divulgassem o que estavam fazendo através de mensagens curtas. Com isso surge uma nova forma de comunicação, onde as pessoas começaram a divulgar todo o tipo de informação em tempo real com mensagens de até 140 caracteres inicialmente, sendo hoje o limite 280 caracteres para todos ligados à rede (NASCIMENTO et al., 2013).

Com a popularização do Twitter e sua facilidade em publicar conteúdo, as pessoas também passaram a compartilhar suas opiniões sobre diversos assuntos, inclusive comentários sobre produtos/serviços das empresas. Segundo EVANGELISTA e PADILHA (2014), as empresas perceberam que um comentário negativo em uma rede social tem uma grande capacidade de atingir muitas pessoas e prejudicar sua reputação no mercado. E o mesmo pode acontecer com um comentário positivo que, neste caso, pode ter um resultado tão bom quanto uma propaganda.

Atualmente, o Twitter possui cerca de 330 milhões de usuários e registra 500 milhões de tweets por dia¹. Devido a esta enorme quantidade de dados, existe a necessidade de métodos e ferramentas que possam analisar o sentimento de um texto de forma automática. A área de análise de sentimentos tem esse objetivo e reúne

¹ <https://www.omnicoreagency.com/twitter-statistics/>

pesquisas de mineração de dados, recuperação de informação, inteligência artificial, entre outras (BECKER e TUMITAN, 2013).

O objetivo deste trabalho é desenvolver e avaliar uma ferramenta web para análise de sentimentos de tweets em português. Para isso, será necessário treinar um classificador utilizando um conjunto de dados com mensagens já classificadas, coletar tweets de usuários de acordo com a busca realizada e classificá-los em positivo e negativo e salvar em um banco de dados os tweets coletados e classificados pela ferramenta junto com a expressão de busca utilizada.

O restante do artigo está organizado da seguinte forma. A Seção 2 descreve a fundamentação teórica com conceitos sobre análise de sentimentos, aprendizagem de máquina e algoritmo de classificação. A Seção 3 descreve a implementação da ferramenta e os detalhes de cada um dos componentes. A Seção 4 descreve o teste utilizando validação cruzada e os testes de validação do usuário. A seção 5 apresenta alguns trabalhos relacionados. A Seção 6 apresenta a conclusão do trabalho.

2. Fundamentação teórica

Nas próximas subseções serão detalhados assuntos que são base para o entendimento deste trabalho: Análise Sentimentos, Aprendizagem de Máquina e Classificadores de Aprendizagem de Máquina.

2.1. Análise de sentimentos

A análise de sentimentos é o campo de estudo que analisa opiniões, sentimentos, avaliações, atitudes e emoções em relação a entidades como produtos, serviços, organizações, indivíduos, problemas, eventos, tópicos e seus atributos (LIU, 2012).

O principal objetivo da análise de sentimentos é classificar, por meio da verificação das palavras e de forma automática, o sentimento expresso em um determinado texto. De acordo com MALHEIROS (2014), também pode-se compreender

a análise de sentimentos como uma forma computacional de tratamento de opinião, sentimento e subjetividade em um texto.

A identificação do sentimento em um documento pode ocorrer em diferentes níveis: (1) nível de documento, é mais utilizado para identificar opiniões sobre um determinado produto, pois o objetivo é classificar se um documento expressa um sentimento positivo ou negativo; (2) nível de sentença, permite identificar e diferenciar fatos e opiniões; (3) nível de entidade e aspecto, é mais complexo e permite identificar o alvo da opinião quando esta é expressada sobre a entidade ou um de seus aspectos (BECKER e TUMITAN, 2013). A análise de sentimento pode ser executada em qualquer tipo de texto, páginas web, tweets, comentários em posts, etc.

Classificadores de aprendizagem de máquina e lexicons são as duas principais técnicas para se fazer a análise de sentimento (MALHEIROS, 2014).

Um lexicon é um conjunto de palavras ou expressões em que cada uma está relacionada à sua polaridade (positiva, negativa ou neutra). Este conjunto também é conhecido como léxico de sentimento, léxico de opinião ou palavras de polaridade (em inglês sentiment lexicon ou opinion lexicon) (SILVA, 2016).

A aprendizagem de máquina tem o objetivo de descobrir automaticamente regras gerais em grande conjunto de dados, que permitam extrair informações implicitamente representadas. Para isso é necessário um conjunto de dados previamente classificado, que será utilizado como base do treinamento do modelo. A partir do modelo já treinado, novos conteúdos são classificados. (RODRIGUES et al., 2010)

2.2. Classificadores de Aprendizagem de Máquina

As técnicas de aprendizado de máquina podem ser divididas em dois tipos principais: aprendizado não supervisionado e aprendizado supervisionado (BECKER e TUMITAN, 2013).

Classificadores de aprendizado de máquina não supervisionado analisam os exemplos fornecidos e tentam determinar se eles podem ser agrupados de alguma maneira, formando agrupamentos ou *clusters*. Após o agrupamento, geralmente, é preciso realizar uma análise para determinar o que cada agrupamento significa no contexto do problema que está sendo analisado (MONARD e BARANAUSKAS, 2003).

Classificadores de aprendizagem de máquina supervisionada são capazes de adquirir conhecimentos utilizando técnicas computacionais (BESERRA et al., 2014). Aqui a classificação é dividida em duas etapas: aprender um modelo de classificação através de um treinamento prévio com dados já rotulado com as classes que serão utilizadas (por exemplo, positivo e negativo); e prever a polaridade de novos textos utilizando como base o modelo previamente treinado. Os algoritmos mais utilizados para classificação de textos são Support Vector Machine, Naïve Bayes, Maximum Entropy e algoritmos baseados em redes neurais (BECKER e TUMITAN, 2013).

2.2.1. Naive Bayes

O algoritmo Naive Bayes é um classificador probabilístico, baseado no teorema de Bayes, que calcula um conjunto de probabilidades contando a frequência e combinações de valores em um determinado conjunto de dados (PATIL e SHEREKAR, 2013).

De acordo com o teorema de Bayes, podemos calcular:

$$P(A|B) = \frac{P(B|A) P(A)}{P(B)}$$

No algoritmo Naive Bayes, os textos são representados como *bag of words* para serem classificados com base no modelo probabilístico, isso significa que as posições exatas das palavras são ignoradas (DE FRANÇA e OLIVEIRA, 2013).

O classificador Naive Bayes simplifica o aprendizado assumindo que os recursos são independentes. Segundo DE BRITO (2017), ele assume que existe uma

independência condicional dos atributos, ou seja, o efeito de um valor de atributo em uma determinada classe é independente dos valores dos outros atributos. Esta condição independência não ocorre em aplicações reais, pois os atributos dependem uns dos outros, daí a caracterização do termo Naive, que em português significa ingênuo (PATIL e SHEREKAR, 2013).

Um exemplo de uso do algoritmo Naive Bayes é para detecção de Spam, ou seja, detectar se um e-mail recebido pode ou não ser Spam. Utilizando a fórmula, o A seria a classe (Spam e Não Spam), o B seria o documento a ser classificado. A probabilidade da classe ($P(A)$) é estimada pela proporção de mensagens de treinamento que pertencem a classe Spam e Não Spam. Como exemplo, vamos utilizar a mensagem “secret is secret” e aplicar a fórmula:

$$P(\text{Spam}|\text{secret}) = P \frac{(\text{secret}|\text{Spam})}{P(\text{secret})} * P(\text{Spam})$$

$$P(\text{Spam}|\text{is}) = P \frac{(\text{is}|\text{Spam})}{P(\text{is})} * P(\text{Spam})$$

O mesmo cálculo é feito para a classe Não Spam e os dois resultados são comparados. A mensagem será classificado com a classe que tiver a maior probabilidade.

3. Implementação da Ferramenta

Para alcançar o objetivo do trabalho foi desenvolvida uma ferramenta web² para analisar tweets referentes a um determinado tema e fazer a classificação destes tweets em positivo ou negativo. A ferramenta é composta pelas seguintes funcionalidades:

² <http://analise-de-sentimento.herokuapp.com>

- Coletar tweets de acordo com um termo de busca
- Classificação de sentimento dos tweets
- Alterar a classificação de um tweet
- Listar tweets coletados

O desenvolvimento da ferramenta foi dividido em duas etapas: A primeira etapa foi desenvolver uma API REST utilizando a linguagem Python junto com o Django REST Framework. Todas as requisições da ferramenta são realizadas pela API, desde a comunicação com o Twitter, a classificação dos tweets e a gravação das mensagens no banco e dados. A segunda etapa foi desenvolver as telas da ferramenta e apresentar os dados utilizando o framework VueJS. Este framework permite fazer requisições à API e apresentar os dados sem a necessidade de recarregar a página, o que torna a navegação mais fluida.

O fluxo do processo de coleta e classificação pode ser observado conforme Figura 1:

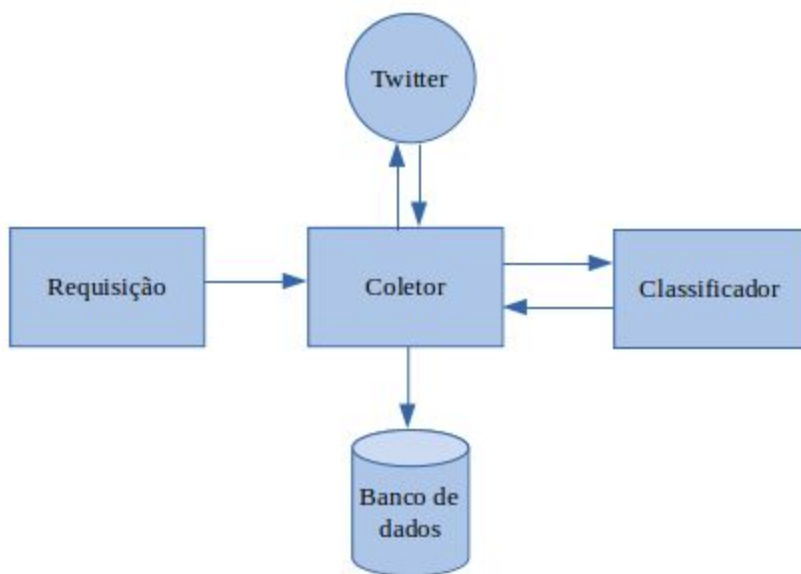


Figura 1: Processo de coleta e classificação dos tweets

Para cada requisição a ferramenta precisa coletar os dados no Twitter, enviar as mensagens coletadas para o classificador fazer a classificação, gravar os dados da coleta no banco de dados e fazer a apresentação dos tweets classificados para o usuário.

3.1. Componente Requisição

O componente Requisição é responsável por apresentar a interface com o usuário.

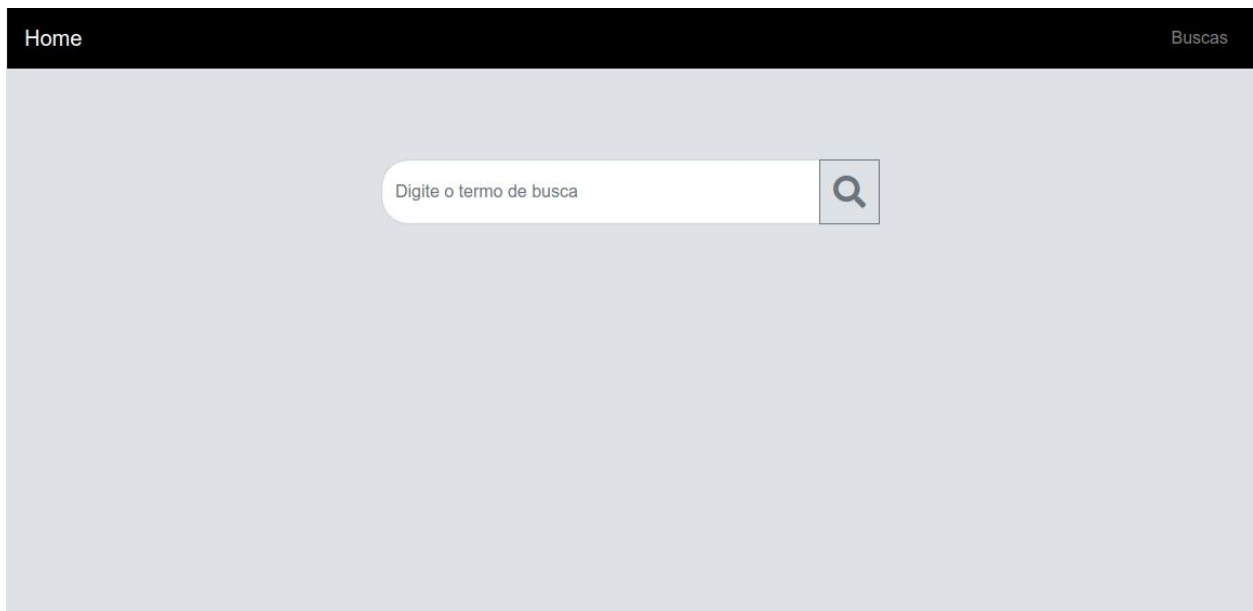


Figura 2: Tela de apresentação da ferramenta

É através deste componente que o usuário faz as requisições à API REST. Para iniciar uma requisição o usuário deve digitar uma expressão na caixa de busca. Esta expressão pode ter uma ou mais palavras e precisa conter no mínimo 3 letras, caso

contrário, a requisição não será realizada. Em caso de sucesso a requisição será enviada ao componente Coletor.

3.2. Componente Coletor

O componente Coletor é o responsável pela coleta dos tweets, pelo envio das mensagens para o classificador fazer a classificação, pela gravação e busca das mensagens classificadas em um banco de dados.

A coleta das mensagens é realizada utilizando a API³ pública do Twitter. Para a realização deste trabalho foram utilizados os seguintes filtros para a busca: são coletadas apenas mensagens em português (`lang=pt`) e um limite de 30 mensagens para cada requisição (`count=30`).

Após a coleta foi necessário realizar o tratamento dos dados. Do arquivo de retorno do Twitter foram utilizados apenas os seguintes campos: *usuário*, *id do tweet*, *o tweet*, *a data e hora do tweet* e *a expressão de busca* utilizada para retornar o tweet.

Com os dados separados, os tweets coletados são enviados para o classificador realizar a classificação. Em seguida, são gravados no banco de dados e enviados para a apresentação ao usuário.

O componente Coletor também é responsável, quando requisitado pelo usuário, por buscar no banco de dados os tweets de uma determinada expressão de busca.

3.3. Componente Classificador

³ <https://dev.twitter.com/>

O componente Classificador é o responsável pela classificação dos tweets em positivo ou negativo. Como é utilizado o aprendizado de máquina supervisionado para a classificação de novas mensagens, foi necessário realizar um treinamento prévio do classificador com um conjunto de dados de mensagens já classificadas.

3.3.1. Conjunto de Dados de Treinamento

O conjunto de dados utilizado para o treinamento do classificador foi obtido através da coleta e classificação de mensagens públicas do Twitter em língua portuguesa. Durante 7 dias um script capturou 1000 tweets a cada hora (500 tweets positivos e 500 tweets negativos). Foram classificadas apenas mensagens que possuíam Emoticons, então, mensagens que continham ":)" ou ":-)" foram classificadas como positivas e mensagens que continham ":((" ou ":-(" foram classificadas como negativas. Ao final da coleta o conjunto de dados continha 75.828 tweets sendo 50% com dados positivos e 50% com dados negativos.

Antes do treinamento do classificador foi realizado um tratamento no conjunto de dados, onde apenas o campo com o texto dos tweets foi utilizado. Além disso, foram retirados os emoticons das mensagens para evitar que o classificador não seja eficaz em classificar mensagens sem esses símbolos.

Para o treinamento foi utilizado o classificador MultinomialNB, baseado no algoritmo Naïve Bayes e implementado pela biblioteca Scikit-Learn⁴.

3.4 Alteração da classificação

⁴ <http://scikit-learn.org/>

Uma funcionalidade da ferramenta é a alteração da classificação de um determinado tweet. Caso o usuário não concorde com a classificação realizada pelo classificador, é possível alterar individualmente cada tweet coletado. Essa alteração tem efeito imediato na contagem total da classificação.

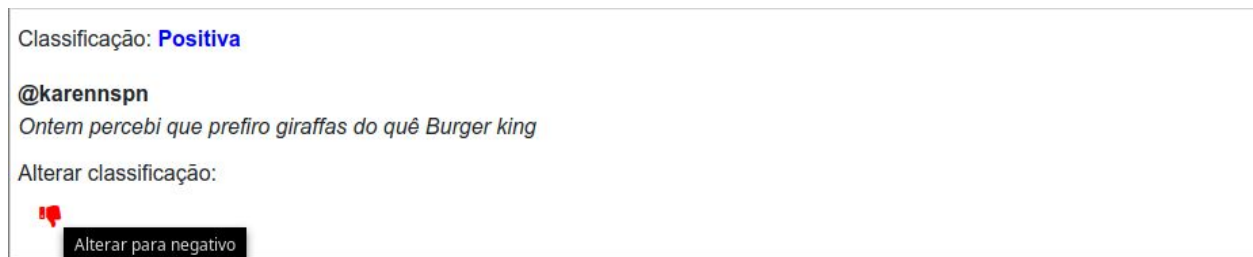


Figura 3: Opção de alteração da classificação de um tweet

Após a classificação dos tweets, é exibida para o usuário a lista de todas as mensagens coletadas e a opção de alterar a classificação dada pela ferramenta. Conforme pode ser verificado no exemplo da Figura 3.

4. Testes do Classificador

É necessário medir a acurácia do classificador para saber sua eficiência. Para isso, dois métodos foram utilizados:

- O primeiro método é a validação cruzada. Este método consiste em dividir o conjunto de dados em subconjuntos, onde uma parte dos dados é separada para o treinamento e a outra parte para testes (Witten et al., 2016).
- O segundo método é a avaliação do próprio usuário. Após coletar os tweets, a ferramenta permite que o usuário altere a classificação que foi dada automaticamente para cada tweet.

4.1. Validação Cruzada

Para executar o método de validação cruzada, o conjunto de dados foi dividido em cinco partes, sendo quatro partes destinadas ao treinamento (80% dos dados) e uma parte destinada ao teste (20% restantes). A validação cruzada foi executada cinco vezes e para cada iteração os dados de treinamento e de teste foram alterados, conforme mostrado na Tabela 1.

1ª iteração	Treino	Treino	Treino	Treino	Teste
2ª iteração	Treino	Treino	Treino	Teste	Treino
3ª iteração	Treino	Treino	Teste	Treino	Treino
4ª iteração	Treino	Teste	Treino	Treino	Treino
5ª iteração	Teste	Treino	Treino	Treino	Treino

Tabela 1: Iterações da validação Cruzada

Após a realização da validação cruzada as taxas de acerto do classificador foram obtidos e apresentados na Tabela 2. É possível observar que a taxa de acerto entre as iterações variou entre 72% e 74%.

1ª iteração	2ª iteração	3ª iteração	4ª iteração	5ª iteração
0.73407622	0.74185678	0.72899908	0.73565871	0.72902928

Tabela 2: Resultado de cada iteração da validação cruzada

4.2. Avaliação do Usuário

Para visualizar a quantidade de tweets que foram alterados pelo usuário, a ferramenta disponibiliza a opção de listar os tweets coletados de uma determinada expressão de busca. Ao listar os tweets a ferramenta informa o total de mensagens

coletadas, o total de classificações positivas e negativas e quantos tweets tiveram a classificação alterada pelo usuário.



Figura 4: Exemplo do resultado da coleta exibido ao listar os tweets

Para obter a taxa de acerto do classificador de acordo com o próprio usuário foi utilizado a seguinte fórmula:

$$TA = \frac{(C - A)}{C}$$

Onde:

- **TA:** taxa de acerto
- **C:** total de tweets coletados
- **A:** total de tweets alterados

Foram analisados doze buscas realizadas por sete usuários diferentes. Cinco usuários fizeram duas buscas e dois fizeram uma busca. Cada usuário alterou a classificação conforme sua própria avaliação. O resultado pode ser verificado na Tabela 3.

Busca	Tweets Coletados	Positivos	Negativos	Tweets Alterados	Taxa de Acerto
Neymar	30	7	23	24	0.2

bolsonaro	30	16	24	8	0.7333333333
lula	5	4	1	0	1
Lula	5	4	1	0	1
bolsonaro	30	22	8	8	0.7333333333
Comida	30	5	25	2	0.9333333333
Lula	16	12	4	3	0.8125
cristiano ronaldo	28	25	3	2	0.9285714286
flamengo	30	26	4	2	0.9333333333
burger king	30	26	4	5	0.8333333333
brasileirao 2018	23	23	0	0	1
eleições 2018	30	24	6	2	0.9333333333

Tabela 3: Resultado da avaliação do usuário

Podemos verificar que a taxa de acerto do classificador, conforme a avaliação do usuário, varia entre 20% e 100%. O caráter subjetivo de cada usuário pode ter influência na classificação, por exemplo, em buscas com a mesma expressão realizadas por usuários diferentes, podem ter julgamentos diferentes para o mesmo tweet, conforme podemos comparar na Figura 5.


Usuário: @kalenamoraes
Tweet: RT @congemfoco: Bolsonaro apoiou grupo de extermínio que cobrava R\$ 50 para matar jovens da periferia. "Enquanto o Estado não tiver coragem...
Classificação: 
Alterada: Sim

Figura 5: Classificação alterada para negativa

Na mensagem da Figura 5 o usuário alterou a classificação para negativa, enquanto outro usuário, em uma busca diferente, aceitou a classificação da ferramenta (positiva) para a mesma mensagem.

5. Trabalhos Relacionados

A seguir serão apresentados alguns trabalhos que foram publicados sobre análise de sentimentos em língua portuguesa utilizando redes sociais.

O trabalho de DE FRANÇA e OLIVEIRA (2014) tinha o objetivo de analisar sentimentos de tweets relacionados com os protestos ocorridos no Brasil entre o período de junho a agosto de 2013. Para isso, foi utilizada aprendizagem de máquina supervisionada com o algoritmo Naive Bayes para realizar a classificação automática de tweets. A base de dados para o treinamento do classificador foi criada através da coleta de tweets com base em uma lista de hashtags relacionadas com os protestos. Como resultado, foi verificado que a maior parte das mensagens foram classificadas como positivas e, ao final da coleta, o número de mensagens classificadas como negativas teve um pequeno aumento. Este resultado era o esperado quando comparado as matérias sobre os protestos publicadas no mesmo período.

No trabalho de EVANGELISTA e PADILHA (2014) foi criada uma ferramenta para analisar sentimentos de publicações nas redes sociais *Facebook* e *Twitter* de usuários de 3 empresas brasileiras de comércio eletrônico e classificá-los como positivo, negativo ou neutro. Foram utilizados dois tipos de classificadores para a criação da ferramenta: o algoritmo Naive bayes e o recurso léxico SentiWordNet. A base de treinamento do classificador foi criada a partir das avaliações dos usuários e-bit do site Buscapé. As avaliações do tipo “Elogio” foram consideradas como positiva, as do tipo “Reclamação” foram consideradas como negativa e para as neutras foram utilizadas a timeline de alguns usuários do Twitter como “ponto”, “boaspromocoes”, “guiapromocoes” e “familiaextra”. Na comparação dos dois classificadores o Naive Bayes obteve uma taxa de acerto superior variando de 71% a 95%. Enquanto o SentiWordNet obteve 57% como a sua maior taxa de acerto.

6. Conclusão

Este trabalho teve como objetivo desenvolver uma ferramenta para análise de sentimentos de tweets em português. A ferramenta foi dividida em 3 componentes: Requisição, Coletor e Classificador. Estes componentes são responsáveis por apresentar os dados ao usuário, coletar as mensagens no Twitter, classificar as mensagens coletadas em positivo ou negativo e salvar os dados em um banco de dados. Para isso, foi utilizado um conjunto de dados com mais de 70 mil tweets como dados de treinamento. O algoritmo utilizado para o classificador foi o Naive Bayes e a coleta das mensagens foi feita utilizando a API de busca do Twitter.

Foram realizados dois tipos de testes com o classificador: validação cruzada e validação do usuário. Os testes utilizando validação cruzada obtiveram como resultado uma taxa de acerto entre 72% e 74%. Já os testes realizados com a validação do usuário obtiveram uma taxa de acerto entre 20% e 100%. Essa diferença da avaliação do usuário tem caráter subjetivo e pode ter ocorrido devido a polarização da classificação em positivo e negativo. A diferença poderia ser mais próxima da validação cruzada caso existisse uma classificação neutra.

O limite de 30 mensagens coletadas e classificadas é um número baixo para testar um classificador, mas um número maior poderia ser um impeditivo e tornar a avaliação cansativa para o usuário.

Foi disponibilizado no Github todo o código da API REST⁵ criada para a manipulação do conjunto de dados e treinamento do classificador, assim como o código para a apresentação dos dados⁶. Dessa forma, é possível, em trabalhos futuros, utilizar um conjunto de dados de outros idiomas para treinar o classificador, ou mesmo adicionar classificadores diferentes do Naive Bayes.

⁵ <https://github.com/rodrigsmig/tcc>

⁶ <https://github.com/rodrigsmig/tcc-vue>

REFERÊNCIAS

- BECKER, K.; TUMITAN, D. Introdução à Mineração de Opiniões: Conceitos, Aplicações e Desafios. Simpósio Brasileiro de Banco de Dados, 2013.
- BESERRA, C. A.; DA TRINDADE, C. C., SOUZA, E. P. R., de MAGALHÃES, C. V. C.; de SOUZA SANTOS, R. E. Aplicação de Técnicas de Aprendizagem de Máquina em Objetos de Aprendizagem baseado em Software: um Mapeamento Sistemático a partir das Publicações do SBIE. *RENOTE*, 12(1). 2014.
- DE BRITO, E. M. N. Mineração de Textos: detecção automática de sentimentos em comentários nas mídias sociais. *Projetos e Dissertações em Sistemas de Informação e Gestão do Conhecimento*, 6(1). 2017.
- 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 (BRASNAN)*. p. 128-139. 2014.
- ESULI, Andrea; SEBASTIANI, Fabrizio. SentiWordNet: a high-coverage lexical resource for opinion mining. *Evaluation*, v. 17, p. 1-26, 2007.
- EVANGELISTA, T. ; PADILHA, T. P. P. . Monitoramento de Posts Sobre Empresas de E-Commerce em Redes Sociais Utilizando Análise de Sentimentos. *III Brazilian Workshop on Social Network Analysis and Mining (BraSNAM 2014)*, 2014, Brasília.
- FERREIRA, Emanuel de Barros Albuquerque. Análise de Sentimento Em Redes Sociais Utilizando Influência das Palavras. Trabalho de Graduação-Universidade Federal de Pernambuco-UFPE. Departamento de Ciência da Computação, 2010.

LIU, B. Sentiment Analysis and Opinion Mining, Morgan & Claypool Publishers, Maio de 2012. Synthesis Lectures on Human Language Technologies.

MALHEIROS, Y. Emotte: Uma Ferramenta De Análise de Sentimentos para o Twitter. XX Brazilian Symposium on Multimedia and the Web - Webmedia 2014, 2014.

MONARD, M. C.; BARANAUSKAS, J. A. Conceitos sobre aprendizado de máquina. Sistemas Inteligentes-Fundamentos e Aplicações, v. 1, n. 1, p. 32, 2003.

NASCIMENTO, P.; OSIEK, B. A.; XEXÉO, G. Análise de Sentimento de Tweets com Foco em Notícias . Revista Eletrônica de Sistemas de Informação, v. 14, n. 2, p. 1-14, 2015.

PATIL, Tina R.; SHEREKAR, S. S. Performance analysis of Naive Bayes and J48 classification algorithm for data classification. International journal of computer science and applications, v. 6, n. 2, p. 256-261, 2013.

RODRIGUES, C. A. S.; VIEIRA, L. L.; MALAGOLI, L.; TIMMERMANN, N. Mineração de Opinião/Análise de Sentimentos. Trabalho acadêmico, Universidade Federal de Santa Catarina, Florianópolis. www.inf.ufsc.br/~alvares/INE5644/MineracaoOpinioao.pdf. 2010

SILVA, N. F. F. d. Análise de sentimentos em textos curtos provenientes de redes sociais. PhD thesis, Universidade de São Paulo. 2016

SILVA, N. G. R. d. BestChoice: Classificação de Sentimento em Ferramentas de Expressão de opinião. TCC (Graduação) - Curso de Ciência da Computação, Centro de Informática, Universidade Federal de

Pernambuco, Recife, 2010. Disponível em:
<<http://www.cin.ufpe.br/~tg/2010-2/ngrs.pdf>>. Acesso em: 11 ago. 2018.

WITTEN, Ian H. et al. Data Mining: Practical machine learning tools and techniques.
Morgan Kaufmann, 2016.