
**ANÁLISE DE SENTIMENTOS DAS ELEIÇÕES BRASILEIRAS DE 2018 USANDO
TWITTER**

**SENTIMENT ANALYSIS OF THE 2018 BRAZILIAN ELECTIONS USING
TWITTER**

Rafael Bilibio Franco¹

Mario Henrique Akihiko da Costa Adaniya²

RESUMO

A ascensão das redes sociais mudou profundamente a forma como as informações e opiniões são propagadas, disponibilizando um montante de dados sem precedentes. Isso trouxe, contudo, novos problemas. Extrair informações relevantes e assertivas de um emaranhado tão grande de dados é um dos maiores e mais recompensadores desafios contemporâneos. A análise de sentimentos se presta a resolver esse problema. Nela, são empregadas técnicas computacionais com o objetivo de construir sistemas que atuem de forma automatizada na classificação de sentimentos extraídos de documentos escritos em linguagem natural, como os provenientes de redes sociais. Neste trabalho, estão reunidos os principais conceitos, padrões e técnicas empregados na análise de sentimentos, com um foco especial sobre os trabalhos que vem sendo desenvolvidos para a predição de eleições governamentais usando dados do Twitter. Após revisados os temas fundamentais que embasam os estudos da área, foi descrito um experimento que empregou a análise de sentimentos para medir a rejeição dos três principais candidatos às eleições presidenciais brasileiras de 2018, a fim de comparar os resultados aqui obtidos com aqueles de metodologias tradicionais de pesquisa, representados aqui pelas pesquisas eleitorais do instituto Datafolha.

1

Palavras-chave: análise de sentimentos; aprendizado de máquina; processamento de linguagem natural; Twitter.

ABSTRACT

The rise of social networks has profoundly changed the way information and opinions are propagated, providing an unprecedented amount of data. This has, however, brought new problems. Extracting relevant and assertive information from such a tangle of data is one of the greatest and most rewarding contemporary challenges. Sentiment analysis lends itself to solving this problem. In it, computational techniques are employed with the objective of building systems that act in an automated way in the classification of feelings extracted from documents written in natural language, such as those coming from social networks. In this work, the main concepts, standards and techniques used in sentiment analysis are gathered, with a special focus

¹ Discente do curso de Ciência da Computação do Centro Universitário Filadélfia.

² Docente do curso de Ciência da Computação do Centro Universitário Filadélfia.

on the works that have been developed for the prediction of government elections using data from Twitter. After reviewing the fundamental themes underlying the studies in this area, an experiment was described that used sentiment analysis to measure the rejection of the three main candidates for the Brazilian presidential elections of 2018, in order to compare the results obtained here with those of traditional methodologies of research, represented here by the electoral surveys of the Datafolha Institute.

Keywords: sentiment analysis; machine learning; natural language processing; Twitter.

1 INTRODUÇÃO

As redes sociais ganharam o mundo rapidamente desde o seu surgimento. O Twitter em especial se destaca pelas interações de caráter imediato. Nele, os usuários possuem microblogs nos quais podem escrever mensagens de até 280 caracteres, denominadas "tweets". Isolados, eles podem parecer aleatórios e pouco representativos da opinião geral, mas quando observados dentro de um contexto maior, essas postagens permitem a análise dos assuntos mais discutidos na Internet em um dado momento, bem como a análise das opiniões sobre os mais variados temas.

À análise das opiniões emitidas sobre um determinado tema ou entidade, dá-se o nome Análise de Sentimentos, ou Mineração de Opinião. O objetivo da análise de sentimentos é garimpar massas de dados, como as geradas pelo Twitter e outras redes sociais, em busca da estruturação de opiniões relevantes a respeito da entidade alvo da análise. Com isso, espera-se partir de um ponto em que há uma abundância de dados, mas uma escassez de informações assertivas, para um ponto no qual essas informações que antes estavam perdidas em meio aos dados estejam sintetizadas e passíveis de serem utilizadas para análise, tomada de decisão ou até mesmo predição de eventos.

Neste trabalho, pretende-se expor algumas das pesquisas e experimentos que vêm sendo feitos sobre o tema da análise de sentimentos, tendo como enfoque o uso do Twitter como fonte de dados para a análise. Intenciona-se mostrar que tal forma de análise pode ter uma precisão similar à das metodologias tradicionais que dependem de seres humanos para a análise, mas com um menor custo e com maior grau de automatização. Serão comentadas algumas das técnicas mais utilizadas na coleta e categorização de sentimentos, bem como a estrutura geral e os padrões empregados nos sistemas comumente construídos.

Como objetivo do experimento realizado neste trabalho, visou-se comparar os resultados obtidos com a aplicação de um sistema de análise de sentimentos para a extração de

opiniões sobre as eleições presidenciais brasileiras de 2018 com os resultados da pesquisa eleitoral do instituto Datafolha para a rejeição dos presidentiáveis. Os resultados mostram que a metodologia aqui proposta, embora ainda precise ser aprimorada, é uma alternativa promissora e de muito menor custo se comparada com os métodos tradicionais.

2 FUNDAMENTAÇÃO TEÓRICA

O objetivo deste capítulo é fornecer o embasamento teórico necessário para a compreensão de trabalhos feitos acerca do tema de Análise de Sentimentos. Também será levantado um argumento sobre a utilidade desse tipo de análise, com alguns exemplos de áreas nas quais ela vem sendo aplicada. Por fim, serão referenciados trabalhos feitos recentemente sobre o tema, com enfoque naqueles cuja análise foi feita a partir de dados obtidos do Twitter.

Sistemas de análise de sentimentos

É de conhecimento comum que a maior parte dos dados existentes não apresenta uma estrutura ou forma de organização pré-definida. É sabido, também, que a maior parte desses dados encontra-se na forma de texto, como é o caso de publicações de mídias sociais, notícias, artigos, documentos ou conversas.

Há uma grande inconveniência na existência de um volume tão grande de dados não estruturados, que é a impossibilidade de dar um uso relevante a eles na forma em que se encontram, ainda que o seu potencial seja notável. Sistemas de análise de sentimentos, na condição de subtema da análise de dados, visam eliminar essa inconveniência. Ao extrair sentido desses dados de forma automatizada, é possível agir de forma mais embasada, liberando, ainda, o tempo dos indivíduos que estariam envolvidos na análise manual que teria que ser feita sobre os dados, permitindo que eles se dediquem a outras tarefas onde seu tempo será usado de modo mais produtivo.

Somado a esses ganhos, cabe citar também a melhoria que é obtida na consistência da análise. Com a análise de sentimentos, o mesmo critério de classificação pode ser aplicado para todos os textos analisados, aumentando a consistência da informação obtida, uma vez que essa será produto de um único sistema, e não da análise de múltiplos indivíduos.

Uma vez mencionados esses ganhos obtidos através do uso de sistemas de análise de sentimentos, é interessante citar alguns exemplos de domínios sobre os quais a técnica tem sido aplicada. A previsão de vendas de produtos, como visto em (AHN, 2014), a análise de opiniões emitidas a respeito de filmes, como revisado no trabalho de (BALDANIA, 2017), e a análise de tweets para predição de resultado de eleições são exemplos de áreas nas quais a análise de sentimentos pode ser aplicada.

Definidos os ganhos e os objetivos finais dos sistemas de análise de sentimentos, convém esclarecer alguns termos e conceitos fundamentais que se encontram difundidos na literatura existente sobre o tema abordado neste trabalho.

Dois conceitos primordiais para a compreensão de qualquer trabalho nessa área são os conceitos de fato e opinião. Entende-se por fato toda a expressão objetiva a respeito de um assunto. Opiniões, em oposição, são expressões subjetivas que descrevem os sentimentos de um indivíduo ou grupo de indivíduos sobre um assunto (BALDANIA, 2017).

Outra ideia importante para o tema é a de sentimento. Nesse contexto, um sentimento é uma opinião expressa por um indivíduo ou organização a respeito de uma determinada entidade. É altamente específico e particular de seu emissor. Há dois grandes tipos identificáveis de sentimentos: os sentimentos comuns, e os comparativos. Sentimentos comuns podem ser diretos, quando enunciam algo a respeito de uma entidade explicitamente definida; ou indiretos, caso o sentimento só possa ser abstraído mediante uma análise do contexto. Sentimentos comparativos, por sua vez, são aqueles que tratam de similaridades ou diferenças entre duas ou mais entidades ou aspectos de uma entidade (BALDANIA, 2017).

Continuando o esclarecimento sobre os conceitos de base da mineração de opinião, o próximo conceito relevante é o de documento sentimental. Documentos sentimentais são artefatos que expressam objetiva ou subjetivamente um sentimento. Peças desse tipo extraídas de redes sociais tendem a ser carregadas de subjetividade, característica que as torna especialmente interessantes para a análise de sentimentos, devido à riqueza e facilidade de extração desses sentimentos.

Uma última ideia de grande importância para a compreensão dos trabalhos da área é o conceito de polaridade. A polaridade é um atributo representativo da positividade ou negatividade de um documento sentimental. Comumente definido como um resultado discreto binário ou ternário, sendo no primeiro caso positivo ou negativo, e no segundo caso positivo, neutro ou negativo. A atribuição da polaridade a documentos sentimentais é o caso de uso mais

comum da análise de sentimentos, e é o que permite extrair informações concisas a partir de grandes volumes de dados.

Ainda a respeito do conceito de polaridade, é interessante ressaltar que pode haver diferença entre a polaridade a priori e a polaridade contextual. Por polaridade a priori, entende-se a polaridade assumida para uma palavra de forma isolada, enquanto que por polaridade contextual, entende-se a polaridade assumida considerando-se todo o contexto de uma sentença. A palavra "aprovar", por exemplo, tem polaridade positiva quando classificada aprioristicamente, mas sua polaridade contextual pode ser negativa dependendo da sentença. É fácil observar que a polaridade da sentença "Aprovo o que o candidato fez em seu último mandato" tem polaridade positiva, enquanto a sentença "Impossível aprovar um candidato com esse histórico" tem polaridade negativa, o que torna evidente que somente checar a existência de determinadas palavras é insuficiente para determinar com precisão a polaridade de uma sentença. O trabalho feito por Wilson, Wiebe e Hoffmann (2005) trata com mais detalhe a diferença entre esses dois tipos de polaridade.

Definidos estes conceitos, é possível delinear com maior clareza os problemas de classificação que a análise de sentimentos se dispõe a resolver. O primeiro problema é a classificação de subjetividade de uma sentença, que busca determinar se uma sentença é subjetiva ou objetiva. O segundo problema, por sua vez, é a classificação do sentimento e polaridade de uma sentença, que pode significar desde a polarização da opinião por ela expressa como positiva, negativa ou neutra, até a atribuição de sentimentos como tristeza, insatisfação, ou alegria.

Na literatura da área, convencionou-se a definição de três níveis de análise, indicativos do grau de granularidade sobre o qual a exploração é feita. O trabalho de Baldania (2017) aborda essa categorização.

No nível de menor granularidade, chamado de análise de sentimentos a nível de documento, procura-se classificar todo o documento sentimental, partindo do princípio de que ele diz respeito a uma única entidade. Sua maior utilidade se dá na classificação de textos de grande especificidade, como *reviews* de produtos e notícias de um dado tema.

As análises que ocorrem num nível intermediário de granularidade costumam ser chamadas de análise de sentimentos a nível de sentença. Nesse nível, assume-se que o documento sentimental pode conter diversas opiniões que referenciam, também, diversas entidades. A partir dessa premissa, conclui-se que o menor nível de análise aqui serão as

sentenças do documento. É o nível de análise mais utilizado em investigações feitas sobre redes sociais como o Twitter, que fornecem documentos curtos mas que ainda assim podem possuir uma pluralidade de opiniões e entidades.

Ao resolver problemas com o uso da análise de sentimentos, é comum que sejam desenvolvidos sistemas automatizados elaborados para a execução da tarefa em questão. Esses sistemas possuem algumas etapas idiossincráticas, observados em diversos trabalhos sobre o tema e já bem definidos na literatura, como em Baldania (2017) e Ramzan, Mehta e Annapoorna (2017). Essas etapas são a coleta de dados, pré-processamento, seleção e extração de features, classificação de sentimentos e análise de resultados, e sua descrição, bem como seus procedimentos comuns, serão descritos a seguir:

Coleta de Dados: consiste na obtenção dos dados a partir de sua fonte primária, como *tweets*, artigos de *blogs*, notícias, entre outros. Na coleta de dados qualquer tipo de texto pode ser considerado válido, mas é comum que se escolha um padrão na estrutura e origem dos documentos coletados. Os dados obtidos nesse ponto se encontram em sua forma bruta e não é possível tirar proveito deles de forma eficiente em larga escala.

Pré-processamento: etapa na qual são removidos os dados inconsistentes, incompletos, ou que contém ruídos. Alguns exemplos de procedimentos comuns nessa etapa são a remoção de URL's, a remoção de *stopwords*, que são palavras de pouco sentido semântico e frequentemente desnecessárias para a extração de opinião, e a stemização, técnica que consiste na redução de palavras ao seu radical. É interessante pontuar que o pré-processamento dos dados tem se tornado mais sofisticado, como pode ser observado no estudo de Ibrahim, Abdillah, Wicaksono e Adriani (2015), que obteve bons resultados ao desenvolver um método automatizado de Buzzer Detection, a ser aplicado antes da análise propriamente dita. No trabalho, os Buzzers foram definidos como perfis de usuários que só falavam sobre um dos candidatos das eleições presidenciais analisadas, enquanto criavam uma imagem vilanesca de outros candidatos. Segundo os autores, isso seria um forte indicativo de que se trata de um usuário que emite opiniões artificiais, com a única intenção de direcionar o pensamento de outros usuários, possivelmente se tratando de um robô automatizado para essa tarefa.

Seleção e extração de features: a seleção de features é o processo no qual são identificados os aspectos mais relevantes da entidade para a construção do modelo. Já a extração de features, consiste em efetivamente destacar dos documentos as features relevantes para o contexto da análise. Para isso, são utilizados métodos bem conhecidos de processamento de

texto, como o *bag-of-words*, que extrai o conjunto de palavras presentes na sentença, sem garantia de ordem mas com preservação do número de ocorrências da palavra; e o *n-gram*, técnica que itera sobre as palavras de uma sentença gerando uma sucessão de cadeias que contém a palavra corrente da iteração seguida pelas próximas $n - 1$ palavras da sentença.

Classificação de sentimentos: etapa em que um modelo de classificação estatístico é aplicado para categorizar os dados até então processados em sentimentos bem definidos. Alguns modelos amplamente utilizados nesta etapa são o *Naïve Bayes*, *Support Vector Machine* e *Maximum Entropy*, com destaque para o primeiro, que apresenta os melhores resultados nos trabalhos de mineração de opinião. Como alternativa, pode-se dispensar o uso de um modelo de classificação estatístico ao empregar um léxico que relacione palavras, emoticons e emojis aos sentimentos comumente expressos por eles.

Análise de resultados: a fase final, em que conta-se com uma grande quantidade de dados classificados, mas que por si só ainda não trazem nenhuma conclusão sobre o tema estudado. Nesse ponto, os sentimentos classificados são agrupados e sintetizados na forma de gráficos, tabelas, e outras representações estatísticas, permitindo que algum indivíduo interessado faça uma análise mais assertiva e eficiente da informação, se comparado ao que poderia ser feito com os dados iniciais.

7

Abordagens e Técnicas de Classificação de Sentimentos

A classificação dos sentimentos transmitidos por um texto é uma tarefa que pode parecer bastante subjetiva, mas que é tornada objetiva através dos sistemas automatizados de classificação de sentimentos. Os trabalhos feitos nesse campo costumam se valer de pelo menos uma das três abordagens principais para classificação e polarização dos sentimentos, sendo elas a abordagem baseada em aprendizado de máquina, a abordagem baseada em léxico e a híbrida.

Na abordagem baseada em aprendizado de máquina, são aplicados algoritmos supervisionados, não-supervisionados, ou semi-supervisionados para a classificação dos sentimentos. A classe de algoritmos mais utilizada é a dos supervisionados, uma vez que ainda há uma grande dificuldade na utilização eficaz de técnicas não-supervisionadas neste campo. Alguns estudos aplicaram os algoritmos *Support Vector Machine*, *Maximum Entropy*, *Naïve Bayes* com resultados satisfatórios (ANJARIA *et al.*, 2014; YANG *et al.*, 2017), sendo o *Naïve Bayes* o modelo mais frequentemente utilizado, por trazer os melhores resultados.

Nesta abordagem, não é necessário um dicionário que vincule um valor de sentimento a uma palavra, pois baseia-se em métodos estatísticos para prever o sentimento de um documento com base em um modelo prévio, geralmente classificado por seres humanos. No entanto, a implementação dessa abordagem demanda a anotação de um conjunto de dados que sirva como treino para o modelo estatístico desenvolvido. Uma alternativa é utilizar bases de dados públicas já classificadas (ARAÚJO *et al.*, 2013).

Na abordagem baseada em léxico, os documentos são classificados a partir de uma estrutura de dados que contém palavras associadas aos seus respectivos valores sentimentais e/ou de polaridade. Esses dicionários costumam ser construídos a partir de pesquisas na área e podem ser aprimorados ao longo do tempo. Para a língua inglesa, o SentiWordNet é o mais popular dos léxicos de sentimentos (BACCIANELLA *et al.*, 2010). Para o português brasileiro, existe o projeto OpenWordNet-PT, que traduz o WordNet original (PAIVA *et al.*, 2012). Outro exemplo é o SentiLex-PT01, que possui um número limitado de adjetivos predicativos humanos (SILVA *et al.*, 2010).

A abordagem híbrida combina as duas abordagens anteriores e tem sido apontada em alguns estudos como a que traz um nível mais alto de acurácia na classificação (ANJARIA *et al.*, 2014).

8

Métodos e Métricas de avaliação de sistemas de análise de sentimentos

Como exposto até aqui, sistemas de análise de sentimentos são, em sua essência, sistemas de classificação. Por isso, é possível aplicar sobre eles os métodos utilizados para a avaliação de desempenho de sistemas de classificação. Isso permite estabelecer a eficácia de um dado modelo estatístico de análise de sentimentos, e também permite que seja feito um benchmark entre os modelos. Na presente seção, serão descritas as principais métricas e técnicas utilizadas na avaliação dos sistemas de mineração de opinião.

Validação Cruzada

A validação cruzada é um método estatístico frequentemente utilizado para a validação de modelos de sistemas de classificação de diversos tipos, sendo bastante eficiente para esse

propósito (KOHAVI, 1995). Esse método consiste na divisão do conjunto de dados em dois subconjuntos: o de treinamento e o de validação. Como os nomes sugerem, o subconjunto de treinamento é usado para treinar o modelo, enquanto o subconjunto de validação, que obrigatoriamente deve conter dados diferentes do subconjunto de treinamento, é utilizado para validar as classificações feitas pelo modelo treinado. Esse processo é então repetido múltiplas vezes, sempre variando os conjuntos de treinamento e validação, para depois calcular uma média a partir dos resultados obtidos nas iterações.

Por determinar que os subconjuntos de treinamento e validação variem nas diferentes iterações, a validação cruzada ajuda a prevenir o problema do *overfitting*, conceito estatístico que consiste na produção de um modelo que corresponde de forma muito próxima ou exata a um conjunto particular de dados, podendo, conseqüentemente, falhar em contemplar dados adicionais estranhos ao modelo inicial.

Abrangência e Concordância

Entende-se por abrangência de um sistema de análise de sentimentos o percentual de documentos que o sistema é capaz de analisar em um determinado conjunto de dados. Para exemplificar a relevância dessa medida, pode-se citar o trabalho de (ARAUJO, 2013), no qual verificou-se que o sistema de análise baseada em emoticons conseguiu uma abrangência de no máximo 13% para os eventos considerados quando utilizado sozinho, ainda que tenha atingido um alto grau de concordância com os demais métodos comparados no estudo. Analisando outras medidas, é provável que a limitação desse sistema não fique tão evidente, mas o baixo nível de abrangência se justifica na incapacidade do sistema de analisar documentos sem emoticons, que acabam por ser a maioria dos documentos encontrados na web.

A concordância, por sua vez, é uma medida relevante quando deseja-se comparar os resultados obtidos por diferentes sistemas de análise de sentimentos. Como o nome sugere, ela mede o percentual de vezes em que os documentos analisados foram classificados como tendo a mesma polaridade dado dois ou mais sistemas de análise.

Citando novamente o trabalho de (ARAUJO, 2013), verificou-se que há uma grande dificuldade em desenvolver um sistema que apresente um alto nível de abrangência e concordância simultaneamente, uma vez que dos \$8\$ sistemas comparados no estudo nenhum conseguiu esse feito quando utilizado sozinho.

Trabalhos Relacionados

Devido à relevância das redes sociais na sociedade e à sua recente expansão, há um grande interesse em compreender melhor o que se pode extrair dessas mídias, resultando em uma abundância de trabalhos sobre análise de sentimentos. Dentre as pesquisas relevantes, destaca-se o estudo de Baldania (2017) que revisou conceitos e metodologias na análise de resenhas de filmes. Embora o domínio analisado não seja o mesmo deste trabalho, as técnicas para análise de documentos sentimentais são similares, especialmente em nível de sentença.

Yang (2017) realizou uma revisão dos métodos de aprendizado de máquina mais utilizados na análise de sentimentos, comparando algoritmos como Support Vector Machine, Naive Bayes, Maximum Entropy e Artificial Neural Network. O algoritmo Naive Bayes se destacou por combinar alta precisão com rápida velocidade de treinamento, o que é relevante na avaliação desse tipo de técnica.

Anjaria (2014) examinou duas eleições presidenciais distintas nos Estados Unidos e na Índia, comparando diferentes métodos de extração de features, como Unigram, Bigram, Bag of Words e o híbrido. Concluiu-se que o método híbrido é o mais eficaz, seguido pelo Bag of Words. Notou-se uma taxa de acerto maior na análise das eleições dos Estados Unidos, possivelmente devido à diferença na proporção de usuários do Twitter em relação à população.

Ramzan (2017) adotou uma abordagem diferente, analisando 10.000 tweets das eleições de 2017 na Índia e armazenando-os em um banco de dados NoSQL, o MongoDB, para análise posterior. Joyce (2017) utilizou o OpinionFinder Lexicon para a classificação dos tweets em positivos ou negativos, sendo um sistema desenvolvido por universidades americanas que identifica sentenças subjetivas e agentes de opinião automaticamente. O estudo contabilizou o número de palavras positivas e negativas em cada tweet, classificando-os como positivos, negativos ou neutros, dependendo da contagem resultante.

3 DESENVOLVIMENTO

Neste capítulo será descrita a metodologia e os resultados obtidos a partir do experimento realizado para este trabalho, que consistiu na análise dos sentimentos contidos em tweets que mencionam ao menos um dos três principais candidatos das eleições presidenciais brasileiras de 2018, sendo eles *Ciro Gomes*, *Fernando Haddad* e *Jair Bolsonaro*. Os tweets

foram classificados conforme a sua polaridade, e pretendeu-se comparar o resultado obtido aqui com a pesquisa feita pelo Datafolha na mesma data da coleta dos tweets, em 7 de outubro de 2018, a fim de avaliar se a análise aqui feita obteve resultados semelhantes aos da pesquisa do Datafolha para a rejeição dos candidatos, pesquisa essa feita com metodologias tradicionais.

Coleta de Dados

Para a coleta dos dados utilizados no experimento aqui descrito, foi utilizada a API gratuita do Twitter, que permite filtrar em tempo real os tweets publicados que contenham determinadas palavras chaves, com um limite de 1% do total de tweets. Para fazer uso desse recurso, empregou-se a biblioteca Tweepy, que fornece um cliente de fácil uso na linguagem Python. Os dados foram coletados entre os dias 6 e 7 de outubro de 2018, na véspera e na data em que ocorreram as eleições presidenciais de 2018, portanto.

O nome de cada candidato foi usado como filtro, limitando a um candidato por vez, uma vez que o nível gratuito da API do Twitter impõe a restrição de um único consumidor de streaming por usuário autenticado. Os tweets coletados foram salvos em um arquivo separado por vírgulas para cada candidato, junto do identificador do tweet, data de publicação, e identificador do usuário autor do tweet. Foram coletados 168492 tweets sobre o candidato Ciro Gomes, 147394 tweets com o nome do candidato Fernando Haddad, e 139796 tweets que mencionam o nome do candidato Jair Bolsonaro. Nessa etapa não foi feito nenhum tipo de filtro ou tratamento adicional sobre os dados obtidos.

11

Pré-processamento

Assim como descrito na subseção 2.4, foi aplicado um pré-processamento sobre os dados coletados, com a finalidade de eliminar dos tweets aqueles elementos textuais que na verdade não transmitem nenhum tipo de opinião. Mais especificamente, foram removidas menções a outros usuários do Twitter, identificadas por um '@' seguido por um nome, URLs, pontuações, e espaços em branco repetidos.

Considerou-se fazer uso dos métodos de stemização e remoção de *stopwords*, que consistem na redução da palavra ao seu radical e na remoção de palavras de pouco valor semântico, respectivamente. Contudo, essa abordagem não foi empregada na versão final do

analisador, porque testes preliminares indicaram que esses procedimentos afetam negativamente o desempenho do classificador, o que sinalizou que eles estavam filtrando elementos textuais relevantes.

Todos os procedimentos aplicados nesta etapa foram implementados na linguagem Python, com o uso de expressões regulares para os tratamentos mencionados no primeiro parágrafo desta seção, e o uso da biblioteca NLTK (*Natural Language Toolkit*) para a stemização e remoção de *stopwords*, que, como dito anteriormente, acabaram não sendo incorporados na versão final.

Extração de Features

Para a extração de features, processo também descrito, foi aplicado o método *bigram*, reconhecido na literatura pela sua eficácia quando aplicado nesse tipo de tarefa, conforme já descrito no capítulo anterior. Aqui, a ferramenta utilizada foi a biblioteca scikit-learn, também escrita em Python e que conta com implementações de métodos de extração de feature como o *n-gram* e o *bag-of-words*, ambos muito utilizados na análise de sentimentos. O método *bigram* foi aplicado sobre os dados retornados após aplicado o pré-processamento.

12

Classificação de Sentimentos

Na classificação dos sentimentos dos tweets coletados, foi empregado o classificador Naive Bayes, método de aprendizado de máquina supervisionado, que possui implementação na biblioteca scikit-learn, utilizada neste trabalho.

Por se tratar de um método supervisionado, houve a necessidade de rotular manualmente parte dos dados para o treino do modelo. Para isso, foram selecionados aleatoriamente 250 tweets de cada candidato, para então classificar cada um como positivo ou negativo. Como critério de classificação dos tweets negativos, adotou-se o seguinte: foram classificados como negativos todos os tweets que se referiam ao candidato em questão de forma negativa, seja explícita ou implicitamente, e foram também classificados como negativos todos os tweets que, ao comparar o candidato alvo com outros candidatos, desfavoreciam o candidato alvo. Os tweets que não obedeciam nenhuma dessas duas condições foram classificados como positivos.

Como exemplo de classificação desses critérios, tomemos três tweets, dois classificados

como negativos e um classificado como positivo. No tweet "ciranda, cirandinha, vamos todos cirandar nem pt nem bolsonaro vote 12 pra mudar", quando tendo como alvo o candidato Jair Bolsonaro, foi atribuída polaridade negativa, visto que o presidenciável em questão teve valor inferior na comparação feita com os demais. Outro exemplo de tweet negativo, dessa vez com afirmações explicitamente negativas sobre o candidato Fernando Haddad, é o seguinte: "Já pensou que daora se Ciro Gomes e nem Lula (Haddad é só fantoche do presidiário) ganhassem a eleição, e os seus eleitores cumprissem a promessa de sair do Brasil. Aí sim, eu acredito que o Brasil teria jeito de dar certo!". Para exemplificar um tweet classificado como positivo, tomemos o seguinte: "tomara que o Ciro ganhe, papo reto". Nesse exemplo, verificamos que não há nenhuma afirmação negativa e nem comparação desfavorável feita sobre o candidato Ciro Gomes, o que de acordo com os critérios adotados, implica na classificação positiva do tweet.

Com esses critérios, foram classificados 210 tweets positivos e 40 negativos para o candidato Ciro Gomes, 136 tweets positivos e 114 negativos para o candidato Fernando Haddad, e 126 tweets positivos contra 124 negativos para o candidato Jair Bolsonaro.

Para verificar a eficácia dos modelos elaborados, foi aplicada a validação cruzada com 10 iterações, e foram extraídas as métricas de acurácia, precisão e recall, sendo essas duas últimas divididas entre as categorias positivo (+) e negativo (-), conforme a Tabela 1:

Tabela 1 - Métricas de desempenho por candidato

	Acurácia	Precisão (+)	Precisão (-)	Recall (+)	Recall (-)
Ciro Gomes	76,00%	93,10%	36,84%	77,14%	70,00%
Fernando Haddad	68,40%	73,95%	63,36%	64,70%	72,81%
Jair Bolsonaro	78,8%	79,67%	77,95%	77,78%	79,84%

Analisando a Tabela 1, pode-se constatar que houve um melhor desempenho nos casos em que a base aleatória de treino contava com um equilíbrio maior na relação entre tweets positivos e negativos, como no caso de Fernando Haddad e Jair Bolsonaro. Finalizando esta etapa, foram aplicados os modelos de classificação em suas respectivas bases de tweets pré-processados e com features já extraídas.

É importante salientar que retweets, que são re-publicações de tweets normalmente feitas por usuários diferentes do autor original, foram mantidos no conjunto de dados final classificado, mas foram filtrados das bases de treino. No caso da base de treino, a decisão foi

tomada para garantir maior diversidade nos dados, que passam a conter mais construções diferentes se os retweets forem filtrados. Já no conjunto de dados classificado de forma automatizada, esse tipo de publicação foi mantida por conta da suposição de que os retweets representam um reforço de uma determinada opinião, ainda que essa tenha sido emitida originalmente por outro indivíduo.

4 RESULTADOS

Nesta seção serão descritos e discutidos os resultados do experimento, acompanhados de hipóteses sobre possíveis fatores externos que influenciaram nos resultados. Após aplicar os classificadores aos seus respectivos conjuntos de dados, obteve-se a seguinte distribuição, conforme a Tabela 2:

Tabela 2 - Resultados da classificação de tweets por candidato

	Ciro Gomes	Fernando Haddad	Jair Bolsonaro
Negativos	7330 (4,35%)	61556 (41,76%)	55120 (39,43%)
Positivos	161162 (95,65%)	85838 (58,24%)	84676 (60,57%)

14

Em posse desses dados, é possível fazer uma comparação com os índices de rejeição de cada candidato conforme a pesquisa do instituto Datafolha realizada entre os dias 5 e 6 de outubro, que foi a pesquisa mais próxima à data da eleição dentre as realizadas pelo instituto. Na pesquisa, foi apontado 21% de taxa de rejeição para *Ciro Gomes*, 41% de rejeição para *Fernando Haddad*, e 44% de rejeição para *Jair Bolsonaro*.

Diante disso, podemos afirmar que a rejeição verificada na análise de tweets foi próxima para os candidatos *Fernando Haddad* e *Jair Bolsonaro*, contudo, houve uma grande divergência no índice verificado para o candidato *Ciro Gomes*. Uma possível explicação para esse fenômeno é a campanha que foi feita pelo candidato às vésperas das eleições, que teve enfoque especial no Twitter e elevou a hashtag #viraviraciro ao primeiro lugar entre as mais comentadas da rede social no Brasil no dia das eleições.

Outro fenômeno observado que acredita-se ter influenciado os resultados deste experimento foi o uso de apelidos para se referir aos candidatos. Ao observar aleatoriamente a base de tweets, foram observados diversos desses nomes usados principalmente para se referir

ao candidato Jair Bolsonaro. Alguns nomes pareceram ter claro caráter pejorativo, como 'Salnorabo', 'Bonoro', ou 'Bozo', que combinados apareceram um total de 8306 vezes em meio aos 168492 tweets coletados que mencionam Ciro Gomes, e 14431 vezes nos 147395 tweets coletados sobre o candidato Fernando Haddad, enquanto nos tweets de Jair Bolsonaro, as alcunhas apareceram 2072 vezes somente.

É importante salientar que fenômenos como a campanha de Ciro Gomes no Twitter e o uso de apelidos ao se referir a candidatos, embora não sejam de muito impacto em pesquisas que empregam metodologias tradicionais baseadas em consultas por telefone ou entrevistas, como as do instituto Datafolha, tem grande impacto quando se pretende construir um sistema de análise de sentimentos para captar a opinião pública.

No caso do Twitter, é necessário escolher palavras-chave que serão usadas para filtrar os tweets, e caso não haja conhecimento prévio dos outros nomes usados para referenciar as entidades alvo da análise, como foi o caso nesse trabalho, pode haver alguma distorção nos resultados da pesquisa, visto que opiniões válidas e de interesse do estudo seriam deixadas de fora do corpo de análise.

Outro ponto é que analisar somente uma fonte torna os resultados obtidos menos confiáveis. Isso se dá principalmente pela possibilidade de inflar determinados tópicos em uma determinada mídia, tarefa muito mais difícil de se aplicar para múltiplas plataformas diferentes. Por isso, é interessante que, para estudos nos quais pretende-se tirar conclusões mais assertivas sobre um determinado domínio, sejam utilizadas mais fontes de dados, de modo a buscar uma maior representatividade e aproximação com a realidade da população estudada.

Dito isso, vale reforçar que embora existam divergências houve uma proximidade considerável entre os resultados das pesquisas eleitorais mencionadas e os resultados obtidos aplicando a análise de sentimentos, que embora ainda se mostre uma metodologia em desenvolvimento, já demonstra grande redução nos recursos gastos se comparado às metodologias tradicionais, além de fornecer um grau de automatização e reaproveitamento de trabalho impensáveis no caso de entrevistas e pesquisas de telefone, por exemplo.

5 CONCLUSÃO

A análise de sentimentos é um campo de grande interesse tanto para a computação quanto para as ciências sociais aplicadas, uma vez que permite extrair informações relevantes

sobre os sentimentos de uma quantidade massiva de indivíduos, o que é impossível utilizando métodos tradicionais de pesquisa e consulta popular.

Assim como outras aplicações do Processamento de Linguagem Natural, há uma constante e rápida evolução nos métodos empregados, que atualmente já permitem um grau de acerto comparável ao de métodos de análise estatística convencionais, como os utilizados em pesquisas eleitorais ou de opinião, por exemplo. Espera-se, portanto, que esta técnica seja cada vez mais utilizada em cenários do tipo, trazendo uma visão mais dinâmica acerca dos sentimentos sobre eventos e/ou entidades.

Este trabalho expôs os principais conceitos e técnicas utilizadas em sistemas de análise de sentimento, bem como um estudo de caso analisando as rejeições dos três principais candidatos às eleições presidenciais brasileiras de 2018 e comparando-as com os resultados da pesquisa eleitoral do instituto Datafolha para a rejeição dos candidatos.

Foi possível constatar que, ainda que tenha havido considerável divergência no caso do candidato Ciro Gomes, os resultados obtidos para os dois principais candidatos, Fernando Haddad e Jair Bolsonaro, foram bastante semelhantes e atingiram a expectativa deste trabalho de demonstrar que é possível levantar informações desse tipo a um custo muito menor do que o das metodologias tradicionais, como a utilizada pelo instituto Datafolha, e espera-se que tenha ficado evidente que, embora muito já tenha sido feito, ainda há grande possibilidade de avanço na produção de conhecimento sobre as questões aqui levantadas.

16

REFERÊNCIAS

AHN, H.; SPANGLER, W. S. Sales Prediction with Social Media Analysis. *In: ANNUAL SRII GLOBAL CONFERENCE, 2014, USA. Proceedings [...].* USA: IEEE, 2014. p. 213-222. DOI:10.1109/SRII.2014.37

ANJARIA, M.; GUDDITI, R. M. R. Influence factor based opinion mining of Twitter data using supervised learning. *In: INTERNATIONAL CONFERENCE ON COMMUNICATION SYSTEMS AND NETWORKS (COMSNETS), 6., 2014, India. Proceedings [...].* India: IEEE, 2014. p. 1-8. DOI:10.1109/COMSNETS.2014.6734907

ARAÚJO, M.; GONÇALVES, P.; BENEVENUTO, F. Métodos para Análise de Sentimentos no Twitter. *In: BRAZILIAN SYMPOSIUM ON MULTIMEDIA AND THE WEB (WebMedia'13), 19., 2013. Proceedings [...].* 2013.

BACCIANELLA, S.; ESULI, A.; SEBASTIANI, F. SentiWordNet 3.0: An Enhanced Lexical Resource for Sentiment Analysis and Opinion Mining. *In: INTERNATIONAL*

CONFERENCE ON LANGUAGE RESOURCES AND EVALUATION (LREC), 10., 2010, Malta. **Proceedings** [...]. Malta: ELRA, 2010.

BALDANIA, R. Sentiment analysis approaches for movie reviews forecasting: A survey. *In: INTERNATIONAL CONFERENCE ON INNOVATIONS IN INFORMATION, EMBEDDED AND COMMUNICATION SYSTEMS (ICIIECS)*, 2017, India. **Proceedings** [...]. India: IEEE, 2017. p. 1-6. DOI:10.1109/ICIIECS.2017.8275938

FRANÇA, T. C.; OLIVEIRA, J. Análise de Sentimento de Tweets Relacionados aos Protestos que ocorreram no Brasil entre Junho e Agosto de 2013. *In: Brazilian Workshop on Social Network Analysis and Mining (BRASNAN)*, 3., 2014, Porto Alegre. **Proceedings** [...]. Porto Alegre: Sociedade Brasileira de Computação, 2014. p. 128-139.

IBRAHIM, M.; ABDILLAH, O.; WICAKSONO, A. F.; ADRIANI, M. Buzzer Detection and Sentiment Analysis for Predicting Presidential Election Results in a Twitter Nation. *In: INTERNATIONAL CONFERENCE ON DATA MINING WORKSHOP (ICDMW)*, 2015, USA. **Proceedings** [...]. USA: IEEE, 2015. p. 1348-1353. DOI:10.1109/ICDMW.2015.113

JOYCE, B.; DENG, J. Sentiment analysis of tweets for the 2016 US presidential election. *In: MIT UNDERGRADUATE RESEARCH TECHNOLOGY CONFERENCE (URTC)*, 2017. **Proceedings** [...], 2017. p. 1-4. DOI:10.109/URTC.2017.8284176

KRIPPENDORFF, K. **Content Analysis: An Introduction to Its Methodology**. 2.rd. [S.l.]: Sage Publications, 2004.

17

KOHAVI, R. A Study of Cross-validation and Bootstrap for Accuracy Estimation and Model Selection. *In: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE*, 14., 1995, Canadá. **Proceedings** [...]. Montreal, Quebec, Canada: Morgan Kaufmann Publishers Inc., 1995. v. 2, p. 1137-1143.

MARTINS, R. F.; PEREIRA, A.; BENEVENUTO, F. An Approach to Sentiment Analysis of Web Applications in Portuguese. *In: BRAZILIAN SYMPOSIUM ON MULTIMEDIA AND THE WEB (WebMedia '15)*, 21., 2015, New York. **Proceedings** [...]. New York, NY, USA: ACM, 2015. p. 105-112.

NASCIMENTO, P.; AGUAS, R.; DE LIMA, D.; KONG, X.; OSIEK, B.; XEXÉO, G.; DE SOUZA, J. Análise de sentimento de tweets com foco em notícias. **Revista Eletrônica de sistemas de informação**, v. 14, n. 2, 2012.

PAIVA, V.; RADEMAKER, A.; DE MELO, G. OpenWordNet-PT: An Open Brazilian Wordnet for Reasoning. *In: COLING 2012: Demonstration Papers*, 2012, Índia. **Proceedings** [...]. Mumbai, India: The COLING, 2012. 2012. p. 353-360.

PAK, A.; PAROUBEK, P. Twitter as a Corpus for Sentiment Analysis and Opinion Mining. *In: INTERNATIONAL LANGUAGE RESOURCES AND EVALUATION (LREC'10)*, 7., 2010. **Proceedings** [...]. European Languages Resources Association (ELRA). 2010. Disponível in: <http://www.aclweb.org/anthology/L10-1263>

- RAMZAN, M.; MEHTA, S.; ANNAPOORNA, E. Are tweets the real estimators of election results? *In: INTERNATIONAL CONFERENCE ON CONTEMPORARY COMPUTING (IC3)*, 10., 2017, India. **Proceedings** [...]. India: IEEE, 2017. p. 1-4. DOI: 10.1109/IC3.2017.8284309
- SAIF, H.; FERNANDEZ, M.; HE, Y.; ALANI, H. Evaluation Datasets for Twitter Sentiment Analysis: a survey and a new dataset, the STS-Gold. **CEUR Workshop Proceedings**, v. 1096, 2013.
- SILVA, M. J.; CARVALHO, P.; COSTA, C.; SARMENTO, L. **Automatic Expansion of a Social Judgment Lexicon for Sentiment Analysis (Tech. Rep. No. TR 10-08)**. University of Lisbon, Faculty of Sciences, LASIGE, 2010. Disponivel in: <http://hdl.handle.net/10455/6694>
- YANG, P.; CHEN, Y. A survey on sentiment analysis by using machine learning methods. *In: INFORMATION TECHNOLOGY, NETWORKING, ELECTRONIC AND AUTOMATION CONTROL CONFERENCE (ITNEC)*, 2., 2017. **Proceedings** [...]. [S.l.]: IEEE, 2017. p. 117-121.
- WILSON, T.; WIEBE, J.; HOFFMANN, P. Recognizing Contextual Polarity in Phrase-level Sentiment Analysis. *In: CONFERENCE ON HUMAN LANGUAGE TECHNOLOGY AND EMPIRICAL METHODS IN NATURAL LANGUAGE PROCESSING*, 2005. **Proceedings** [...]. Vancouver, British Columbia, Canada: Association for Computational Linguistics, 2005. p. 347-354. DOI:10.3115/1220575.1220619