



MACHINE LEARNING E SUAS APLICAÇÕES EM PROCESSOS ELEITORAIS¹

MACHINE LEARNING AND ITS APPLICATIONS IN ELECTORAL PROCESSES

HAMMES Maicon², MARTINS Anna³, MATTIAZZI Júlia⁴, BRUM Argemiro Luis⁵

¹ Trabalho desenvolvido na disciplina de Tecnologia da Informação e Comunicação da FAHOR

² Doutorando em Desenvolvimento Regional da UNIJUI, Professor da disciplina de Tecnologia da Informação e Comunicação da FAHOR.

³ Acadêmica de Engenharia Mecânica da FAHOR.

⁴ Acadêmica de Engenharia Química da FAHOR.

⁵ Professor Doutor em Economia Internacional da UNIJUI.

RESUMO

O combate à disseminação de robôs e fake news, bem como o gerenciamento de bancos massivos de dados dentro do marketing político, representam grandes desafios dentro do processo eleitoral no século XXI. Desta forma, o presente artigo objetiva compreender como a ferramenta de machine learning pode contribuir para solucionar estas questões. Nele, é empregada a metodologia de natureza aplicada, cunho exploratório com revisões bibliográficas e explanações de exemplos reais, pesquisas descritivas e qualitativas. Após analisar uma série de pesquisas, verificou-se que existem algoritmos de machine learning capazes de identificar contas automatizadas em redes sociais e fake news, bem como analisar o sentimento do eleitorado em relação aos candidatos e suas campanhas eleitorais.

Palavras-chave: Bots. Fake News. Análise de Sentimentos. Democracia.

ABSTRACT

Combating the spread of robots and fake news, as well as managing massive databases within political marketing, represent major challenges within the electoral process in the 21st century. Thus, this article aims to understand how the machine learning tool can contribute to solving these issues. In it, the methodology of an applied nature is used, exploratory in nature with bibliographical reviews and explanations of real examples, descriptive and qualitative research. After analyzing a series of surveys, it was found that there are machine learning algorithms capable of identifying automated accounts on social networks and fake news, as well as analyzing the sentiment of the electorate in relation to candidates and their electoral campaigns.

Keywords: Bots. Fake News. Feeling Analysis. Democracy.

INTRODUÇÃO

Com a aceleração do processo de globalização, maior evolução da tecnologia e alta velocidade da informação, a dinâmica do campo político foi diretamente afetada. Os



principais impactos deste processo foram: o surgimento de mecanismos informais de atuação política e a entrada de novos atores, que alteraram a dinâmica eleitoral, bem como levaram o jogo e as práticas políticas para o ambiente digital (PENTEADO, 2011). Como resultado, percebe-se um novo processo governamental, com diferentes atividades de caráter inovador, dinâmico e altamente instável.

Com a eclosão das redes sociais, a agenda política é constantemente levada ao centro dos debates. Diante de plataformas com alto potencial de construir ou destruir a imagem de candidatos rapidamente, os agentes políticos foram compelidos a alterar o formato tradicional de suas campanhas e se adaptarem ao novo cenário trazido. Neste contexto, a utilização de robôs e a disseminação de notícias falsas se tornaram ferramentas usuais de manipulação da opinião pública online, podendo ter consequências reais nas urnas.

Há inúmeros estudos já publicados acerca das temáticas de robôs, notícias falsas e análise automatizada de sentimentos, porém sem interligá-las. Como exemplos, podemos citar: da Silva (2020) e Nobre, Almeida e Ferreira (2018) trabalhando a temática de bots, Battisti (2020) e Lima e Amaral (2018) sobre fake news e por fim, Viana (2014) e Dutra e Francisco (2018) a análise de sentimentos, fundamental para viabilizar a customização das propagandas eleitorais sem o aumento correspondente do uso de recursos.

O presente artigo busca responder como a ferramenta de machine learning pode contribuir para os processos eleitorais. Para estudar esta questão, será investigado de que forma ela pode auxiliar na identificação de robôs formadores de opiniões e na identificação de fake news, além de compreender a sua interação com a customização de propagandas eleitorais para diferentes clusters de eleitores, por meio da análise de sentimentos.

REFERENCIAL TEÓRICO

Com o advento da tecnologia e da globalização ainda mais forte no século XXI, o volume de informações online disponíveis em incontáveis plataformas se tornou incomensurável. De acordo com Francisco (2015), cerca de 80% dos dados presentes no ambiente virtual encontram-se altamente fragmentados - estão disponíveis, porém não são catalogados ou passíveis de serem mapeados.

Dentro da esfera política, estas novas tecnologias de informação e comunicação deram origem a inéditos mecanismos de atuação para além dos meios de comunicação



institucionais. Dessa forma, uma dinâmica inovadora surgiu nas ferramentas políticas atuais, modificando toda a estrutura convencional do marketing político (PENTEADO, 2011). Nos processos políticos mais recentes¹, além do alto volume de informações online, é possível identificar novos fenômenos, como a utilização de robôs, que visam a manipulação da opinião pública e o maior dimensionamento de determinadas visões e posições do que o real cenário; a criação de algoritmos de monitoramento da receptividade do público-alvo aos posicionamentos dos candidatos, que objetiva a adaptação do discurso utilizado; e a disseminação de notícias falsas sobre candidatos, o que coloca em xeque toda a transparência fundamental ao processo democrático (DUTRA; FRANCISCO, 2018).

A utilização de bots tem se mostrado cada vez maior em processos políticos dentro das redes sociais². De modo geral, entende-se por bots algoritmos programados para funcionar exatamente como uma conta online de um usuário humano, porém de forma totalmente automatizada. Estes robôs podem ser programados para executar desde funções simples (como espalhar informações baseadas em scripts e aumentar o número de seguidores ou curtidas em dado ambiente na web) até funções de alta complexidade (como preconizar e fomentar um comportamento pré-determinado em uma conta, baseado em outras contas).

De modo geral, a identificação mais precisa de bots ainda gera muitos desafios. No entanto, a fim de definir se dada interação parte de um ser humano ou de um bot, pode-se optar por diferentes abordagens. Inicialmente, há a possibilidade de se mapear contas de robôs de forma manual, conforme realizado por Abokhodair et al. (2015). Apesar de preciso, este método requer muito tempo. Por outro lado, para se ter uma detecção rápida, porém imprecisa, Howard e Kollanyi (2016) estabeleceram um número de tweets por dia para cada usuário humano e classificaram como robôs todas as contas acima dessa métrica. Por fim,

¹ Podemos citar, por exemplo: as eleições norte-americanas de 2016 (Donald Trump x Hillary Clinton), onde foram amplamente utilizados algoritmos para mapeamento de pegadas digitais de eleitores indecisos, possibilitando a criação de uma abordagem política customizada por meio da empresa Cambridge Analytica; e a Primavera Árabe (2010), que se valeu de protestos altamente difundidos pela *internet* e culminou na derrubada do então presidente egípcio Hosni Mubarak (BIJOS; DA SILVA, 2013).

² Os *bots* lideraram 20% dos debates no *Twitter* referentes às eleições para a presidência brasileira em 2014, também influenciaram o *impeachment* do governo Dilma em 2016 e algumas greves gerais em 2017. Além disso, cerca de 33% do tráfego *online* durante o plebiscito que definia a manutenção do Reino Unido como país-membro da União Europeia (*Brexit*), espalhando notícias falsas e influenciando eleitores indecisos (BASTOS; MERCEA, 2017). Por fim, estudos já apontam que a utilização de robôs nas eleições norte-americanas de 2016 (Donald Trump x Hillary Clinton) afetou diretamente as discussões *online* (FERRARA et al., 2016).



recursos mais sofisticados vêm sendo estudados e testados, sendo as principais ferramentas a Botometer API (DAVIS et al., 2016) e o Debot (CHAVOSHI et al., 2017).

A Botometer API, inicialmente pensada por Dong e Liu (2018), traz uma forma automatizada e simples de se detectar bots: ela é composta por mais de mil características pré-definidas em um algoritmo chamado Floresta Aleatória (modelo de aprendizado supervisionado, com retornos em Python), que retorna a probabilidade de dado usuário ser um robô. Este algoritmo se vale da Probabilidade de Automação Completa, que pontua cada conta entre 0 e 1. Usuários que sejam ranqueados como iguais ou maiores do que 0.5 são categorizados como bots (NOBRE et al., 2018; DA SILVA, 2020).

O Debot, é outro modelo online que foi desenvolvido por Chavoshi (2017). Foi elaborado e preparado utilizando como base uma máquina não supervisionada, sem ter a necessidade de parâmetros definidos. Emprega algumas técnicas de correlação de atividades para detectar bots, aplicando um filtro para contas com comportamento semelhante (DA SILVA, 2020).

Os robôs são uma das ferramentas da disseminação de notícias falsas - ou fake news, termo que se popularizou nos últimos anos. Se valendo do alto volume de notícias originadas na web, da dificuldade de validação de informações no ambiente virtual e de locais que incentivam o anonimato (como os aplicativos Reddit e Twitter), usuários que buscam desestabilizar o cenário político e aumentar a popularidade de determinado candidato criam narrativas ilegítimas e espalham desinformações. Como exemplo, é possível citar as eleições norte-americanas de 2016, onde bots do twitter, o site Wikileaks e hackers russos trabalharam em conjunto para vazarem informações dos candidatos na web, se valendo do anonimato para desestabilizar o cenário político do país (MUSSKOPF, 2017).

É notável que a percepção das pessoas em diversos assuntos tem se tornado cada vez menos coerente, pois a disseminação e rapidez com que as fake news são espalhadas causam confusão. Geralmente, o mecanismo usado é similar: criam-se histórias de cunho apelativo, o que acelera sua difusão - e quanto maior for a sua exposição, maior será a chance de ser tida como real, seja pela exposição repetitiva ou pela pressão de grupo, influenciando a opinião pública (BATTISTI, 2020).

Importante somente mencionar que antes de se valer da inteligência artificial para



combater as fake news, é fundamental entender quais são os tipos mais comuns e como os diferenciar - este conceito é chamado de domain knowledge. Até o momento, já foram mapeados três tipos principais: de caráter humorístico, que são aqueles que já alertam de início que não possuem a intenção de serem levados a sério (como por exemplo, o Sensacionalista³); de farsas (ou hoaxes), onde a premissa principal é falsa e visa causar grande impacto e confusão, causando grandes danos à imagem das vítimas; e boatos, que são invenções que tentam se passar por notícias ainda não confirmadas como verdadeiras, ou até mesmo que possuem uma publicação aceita. Incluímos nessa classificação aquelas notícias que não apresentam informações verificadas (MUSSKOPF, 2017).

Os boatos são o tipo mais frequente de fake news. Um estudo do jornal The New York Times analisou um clássico boato, onde um site de humor inventou um ataque russo a um navio norte-americano e recebeu confirmações de usuários teoricamente envolvidos via redes sociais. Dada a repercussão do caso, um canal de televisão russo noticiou o acontecido, que culminou em inúmeras reportagens de tabloides nos Estados Unidos (MUSSKOPF, 2017), conforme exposto com detalhes no fluxograma.

Figura 1 - Ataque russo a um navio norte-americano



Fonte: The New York Times

Por fim, outra ferramenta importante em processos eleitorais é a coleta de dados massivos e posterior análise de sentimentos do eleitorado. Conforme Morais e Ambrósio (2017), o processo de descoberta de conhecimento dentro da mineração de textos pode ter como base os dados estruturados (Knowledge Discovery in Databases - KDD), onde há uma base mapeada e organizada, ou os dados não estruturados (Knowledge Discovery from Text - KDT), onde os dados se encontram de forma desordenada dentro de documentos, bases não estruturadas e textos não padronizados.

A exploração do método KDT (para dados não estruturados) é composta pelos seguintes processos: extração de dados independentes de fontes e formatos a partir de sua fonte primária (tweets, blogs, newsfeeds, etc.); pré-processamento composto pela filtragem,

³ Noticiário satírico eletrônico nacional. Pode ser acessado em <https://m.sensacionalista.com.br/>



higienização, eliminação de dados duplicados e limpeza de opiniões artificialmente criadas por robôs com a utilização do Buzzer Detection⁴; processamento e controle, com a detecção de padrões em um conjunto de dados; e avaliação dos dados, onde os sentimentos são posicionados conforme sua polaridade - o que viabiliza a análise da taxa de sucesso do modelo utilizado (MORAIS; AMBRÓSIO, 2017 e ADANIYA; FRANCO, 2018).

De acordo com a literatura de análise de sentimentos, há três níveis distintos, variando conforme o grau de granularidade da exploração realizada. O primeiro deles é a análise de sentimentos em nível de documento. Nela, classifica-se todo o documento sentimental, partindo do pressuposto de que ele diz respeito a uma única entidade. Esta modalidade é bastante usada para textos de grande especificidade, como reviews de produtos.

O segundo deles é a análise de sentimentos em nível de sentença. Nele, é assumido que o documento sentimental pode abranger inúmeras opiniões que são referenciadas, bem como algumas entidades. A partir dessa ideia, pode-se concluir que os menores níveis de análise serão os documentos, como por exemplo, investigações no twitter que fornecem documentos curtos, mas que ainda possuem uma variedade de opiniões e entidades. Importante frisar que boa parte da análise sentimental de eleições é realizada neste nível. Por fim, há também a análise de sentimentos a nível de feature. Nele, o texto analisado é identificado como um aspecto de outra entidade, se tornando o alvo da opinião. Como seria humanamente ineficiente analisar a evolução da opinião pública sobre temas e candidatos durante o processo eleitoral, em função do alto volume de dados, a ferramenta de Text Mining surgiu como um dispositivo de monitoramento. Trata-se de um processo que descobre informações novas, ocultas e até então desconhecidas pela máquina, por meio da extração dos dados não estruturados (principal formato de informações para as análises de sentimentos). Com o uso paralelo da análise de sentimentos, o Text mining permite que se compreenda hábitos, preferências, gostos e opiniões de eleitores, que culminarão na sua escolha de candidato (DUTRA; FRANCISCO, 2018).

A análise de sentimentos, dentro do ambiente político, vai de encontro com a atual fase do marketing de campanha. Conforme mencionado por Penteadó (2011), a fase pós moderna foi marcada pela profissionalização das atividades com o uso de banco de dados e

⁴ Buzzers são algoritmos que definem contas que somente falam sobre um candidato de todas as eleições, enquanto criam uma imagem chocante e espetacularizada de todos os outros candidatos.



ênfase em mensagens personalizadas de acordo com o perfil do usuário. Nesta etapa, observa-se a coordenação de ações de campanha em multiplataformas, onde veículos formais de comunicação são substituídos por redes sociais e blogs na internet. Neste contexto, a análise de sentimentos torna-se uma ferramenta indispensável para o nível de customização e direcionamento de conteúdo buscado por políticos e coordenadores de campanhas.

Por fim, há cinco características comportamentais que são mapeadas dentro do marketing político, a fim de classificar os eleitores e lhes direcionar campanhas mais adequadas. São elas: a abertura a novas experiências, a importância dada à organização e à eficiência, o nível de sociabilidade e positividade pessoal, o nível de empatia e a intensidade emocional com que a pessoa reage ao receber informações (DUTRA; FRANCISCO, 2018). Com o auxílio da análise de sentimentos, é possível agrupar pessoas por similaridades e customizar materiais com maior aderência pessoal, buscando um maior número de eleitores com menor utilização de recursos.

MATERIAL E MÉTODOS

O tema do presente estudo é a utilização da ferramenta de machine learning aplicada a processos eleitorais democráticos. Assim, a pergunta norteadora é: como o machine learning pode contribuir para os processos eleitorais?

O objetivo geral do trabalho foi compreender como a ferramenta de machine learning pode contribuir para os processos eleitorais. Para chegarmos a tal análise, abordaremos os seguintes objetivos específicos: a) Compreender de que forma a ferramenta de machine learning pode auxiliar na identificação de robôs formadores de opiniões. B) Analisar como o machine learning pode auxiliar na identificação de fake news. C) Entender a interação entre o machine learning e a customização de propagandas eleitorais para diferentes clusters de eleitores, por meio da análise de sentimentos.

Com a massificação dos meios de comunicação, a alta velocidade da informação e o anonimato trazido pela internet, o processo eleitoral teve sua dinâmica fortemente afetada. Novas ameaças tornam a disputa entre candidatos mais desafiadora, como a disseminação de fake news e a criação de contas falsas, cujos objetivos variam desde emitir opiniões para influenciar a arena política até denegrir a imagem de determinados candidatos e promover a de outros, por vezes baseados em informações falsas. A pesquisa, então, se faz importante



para identificar formas com as quais a ferramenta de machine learning possa contribuir para combater inverdades e formadores artificiais de opiniões. Além disso, ela também contribui para tornar as campanhas eleitorais mais assertivas, com inputs para customização de todo o arcabouço do marketing político. Assim, é possível garantir a transparência e a confiabilidade de todo o processo eleitoral, fatores-chave para a manutenção da democracia e da credibilidade dos candidatos envolvidos.

Quanto a classificação da pesquisa: de acordo com Gil (2018), a natureza aplicada sempre visa a aquisição de conhecimentos inovadores com inúmeras aplicações e está voltada a solucionar problemas reais. Desta forma, o presente trabalho propõe formas de suporte na resolução de problemas recorrentes e específicos dentro do processo eleitoral, buscando aliar as novas tecnologias à manutenção democrática ao redor do mundo.

Ainda segundo Gil (2018), as pesquisas podem ser exploratórias quando têm o objetivo de tornar o problema mais rotineiro e familiar, para que a construção de hipóteses se torne mais simples. Nesta modalidade, a coleta de dados geralmente envolve o levantamento bibliográfico, entrevistas com pessoas da área analisada e/ou explanações por meio de exemplos. Dentro desta pesquisa, há as etapas de coleta de dados via revisões bibliográficas e a utilização de exemplos práticos para analisar as possíveis relações entre o machine learning e os processos eleitorais.

Há também pesquisas descritivas cujo objetivo é o de identificar características de dado fenômeno para levantar hipotéticas relações entre variáveis. Contribuindo com este ponto, as pesquisas de caráter tanto exploratório quanto descritivo não somente observam o comportamento do fenômeno tratado, mas também proporcionam uma nova visão do mesmo. Assim, este artigo busca entender os mecanismos de machine learning que suportam as resoluções das questões trabalhadas, ampliando a sua aplicabilidade.

Por fim, Coutinho (2013) afirma que o foco de pesquisas qualitativas é o de descrever fenômenos por palavras, utilizando relações numéricas somente como ferramentas de apoio secundárias. O propósito é o de entender os fenômenos a partir de análises realistas considerando o tempo e o espaço onde se desenvolve o estudo.

RESULTADOS E DISCUSSÃO

Durante as eleições presidenciais brasileiras em 2018, foi anunciado pela mídia que a



atuação de bots nas redes sociais foi essencial para a disseminação de fake news e para a manipulação do engajamento de determinados candidatos. Para investigar esta afirmativa, Nobre, Almeida e Ferreira (2018) qualificaram o comportamento de contas artificiais no twitter dentro do período, buscando analisar se robôs de fato afetaram as discussões online ou se sua influência não teve impacto significativo sobre o engajamento dos concorrentes.

Os dados coletados para análise foram do sétimo dia anterior ao quinto posterior ao primeiro e ao segundo turno das eleições, totalizando 26 dias e 15 milhões de tweets de mais 2,3 milhões de usuários, por meio da ferramenta do Twitter Stream API. Para delimitar a busca de tweets, foram utilizadas as palavras-chave que mesclam os candidatos e figuras políticas influentes no momento (NOBRE et al., 2018). Para o cálculo de métricas de usuários, foi utilizado o Botometer API que recebe como entrada o identificador de um usuário e retorna com a probabilidade da conta ser de um usuário completamente automatizado. Também, foram utilizadas o número de retweets⁵ e as centralidades de usuários na rede de retweets.

Após realizar a análise proposta, o autor identificou a presença de aproximadamente 2 mil bots entre 100 mil contas verificadas além de 5 mil contas suspensas e/ou suspeitas. Com isso, conclui-se que os robôs estavam ativos nas discussões dentro da plataforma. Além disso, verificando a frequência de acessos ao Twitter, o nível de atividade e de engajamento de outros usuários, percebeu-se a presença de três diferentes tipos de robôs: os que geram conteúdo, os que repostam e promovem o conteúdo e os que fazem ambas as atividades.

Por fim, o autor calculou as variáveis presentes na métrica de influência e concluiu que usuários comuns retweetaram bots e que os mesmos ocuparam posições centrais nas discussões da rede. Este resultado indica que robôs influenciam, de fato, os usuários comuns. Apesar de manterem um baixo nível de atividade, as contas automatizadas se mantiveram ativas o suficiente para influenciar a opinião política de pessoas reais.

Considerando a ampla disseminação da internet e a crescente velocidade de difusão de informações características do atual período, a propagação de fake news se tornou uma preocupação perante o direito ao acesso à informação de toda a sociedade. Como forma de combate, soluções de inteligência artificial vêm conquistando espaço e sendo cada vez mais utilizadas na identificação de textos falsos. Para contribuir com estes mecanismos de

⁵ Retweet é uma métrica que contabiliza quantas vezes um usuário teve sua mensagem replicada por outro no período em análise, indicando a sua influência (NOBRE et al., 2018).



enfrentamento, Costa (2019) propôs e testou modelos preditivos mesclando técnicas de word embedding⁶, algoritmos de aprendizado de máquinas⁷ e deep learning⁸. Para desenvolver um classificador de fake news, o autor utilizou técnicas para converter palavras em vetores. Após esta etapa de início, os dados são separados entre as categorias treino e teste. Por fim, são utilizados modelos para treinar o algoritmo e testar o dataset, visando ensinar a máquina os processos de refinamento de dados e a medição de eficácia das previsões e classificações realizadas por ela própria.

Para realizar a análise, foram utilizados 28712 artigos, sendo 13000 falsos e 15712 reais. As notícias verdadeiras foram retiradas dos sites jornalísticos CNN, New York Times, Reuters, BBC e abcnews. Já as falsas, dos sites 100percentfedup, dennis-michaelyllych, dclothesline. Essa base de dados foi dividida entre treino e teste, ficando o pacote de treino com 18749 artigos e o de teste, com 9236. Para trabalhar a base de dados, foi utilizado o jupyter notebook, ambiente de execução de inúmeras linguagens de programação, durante as fases de treino e de testes. Primeiramente, foi usada a biblioteca Pandas, dentro da linguagem Python⁹, para remover notícias incompletas e/ou não aplicáveis do dataset. Em seguida, foi utilizada a biblioteca Natural Language Toolkit (NLTK) para o pré-processamento. E, para a programação e análise de dados em si, foram empregadas as bibliotecas: sklearn.metrics import classification_report e API do Keras.

Após realizar testes utilizando cinco diferentes algoritmos, os dois que melhor desempenharam foram o Logistic Regression (LR) e o Support Vector Machines (SVM), sendo o primeiro um modelo de redes neurais convolucionais¹⁰ e o segundo, de redes neurais

⁶ Forma de representação de palavras que dá aos algoritmos de aprendizado de máquinas a compreensão de sinônimos (GOLDBERG; LEVY, 2014).

⁷ Trata-se de uma subárea da Inteligência Artificial que estuda algoritmos capazes de solucionar problemas sem o apoio humano. De maneira geral, eles reconhecem e retiram padrões de volumosas bases de dados, se valendo de seu algoritmo para tomar as melhores decisões e realizar as mais exatas previsões (MARSLAND, 2011).

⁸ Trata-se de uma subárea do aprendizado de máquinas que se vale de um dado grupo de algoritmos com entendimento de diversos níveis de abstração, sempre utilizando camadas de processamento não lineares (ARAÚJO et al., 2017).

⁹ São um conjunto de módulos e funções pré-definidas que minimizam a utilização de código no programa principal.

¹⁰ São expressivas ampliações neurais com várias camadas, sendo utilizadas em aprendizagem de detecção de padrões de altíssima precisão em aplicações de diferentes tipos (COSTA, 2019).



feedforward¹¹. Como primeiro fator de análise de resultados, foi trazido o conceito da matriz de confusão. Ela é utilizada para mapear quatro valores necessários a análise comparativa de modelos preditivos:

Quadro 1 - Matriz de confusão (*confusion matrix*)

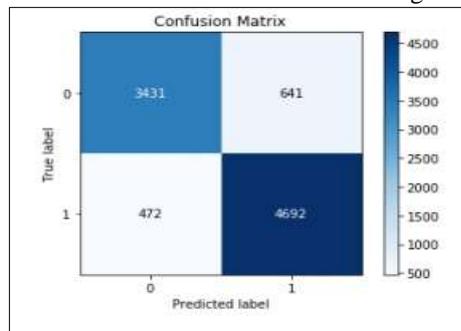
	Predicted: fake (0)	Predicted: real (1)
Atual: Fake News (0)	True Negatives (TN)	False Positives (FP)
Atual: Real News (1)	False Negatives (FN)	True Positives (TP)

Fonte: COSTA (2019)

Dentro dos quatro resultados possíveis, tem-se: True positives (TP): os casos para os quais o classificador previu real news e as notícias eram realmente real news. True negatives (TN): os casos para os quais o classificador previu fake news e as notícias eram realmente fake news. False positives (FP): os casos para os quais o classificador previu real news, mas, as notícias eram fake news. False negatives (FN): os casos para os quais o classificador previu fake news, mas, as notícias eram real news.

Para medir a eficiência de cada algoritmo, além da matriz de confusão, foram utilizadas duas principais métricas: a de precisão e a de recall. A primeira consiste no quão precisa são as predições positivas. Para alcançar este índice, é preciso dividir os acertos da máquina na identificação de notícias reais pelo somatório deste mesmo número de acertos com notícias classificadas erroneamente como real news. Já a segunda traz a cobertura da amostra positiva real. Para obter o valor é preciso dividir os acertos da máquina na identificação de notícias reais pelo somatório deste mesmo número de acertos com notícias classificadas erroneamente como fake news. Para o algoritmo Logistic Regression (LR)¹², tem-se os resultados da matriz de confusão conforme dispostos a seguir.

Figura 1 - Resultados da Matriz de Confusão Logistic Regression



Fonte: COSTA (2019)

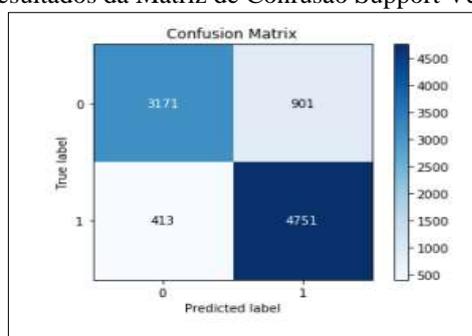
¹¹ São unidades de processamento interligadas, similares aos neurônios humanos, com a tendência de armazenar aprendizados experimentais e os utilizar em análises (HAYKIN et al., 2009).

¹² Modelo linear de aprendizagem supervisionada que tem como objetivo categorizar variáveis em concordância de um dado conjunto (COSTA, 2019).



Com base nela, é possível perceber que o classificador acertou uma totalidade de 8123 notícias, errando somente 1113 títulos. Isso confere uma precisão total de 88%, enquanto o recall apresentou uma leve diferença somente nas classes fake news e real news, chegando aos indicadores de 84% na primeira classe e 91% na segunda. Assim, é notável o sucesso deste modelo de machine learning para identificar quais notícias são reais e quais são falsas, possivelmente sendo disseminadas por robôs, conforme debatido no tópico anterior deste artigo. Para o algoritmo Support Vector Machines (SVM)¹³, tem-se os resultados da matriz de confusão mostrados a seguir.

Figura 2 - Resultados da Matriz de Confusão Support Vector Machines



Fonte: COSTA (2019)

Com base nela, é possível perceber que o classificador acertou uma totalidade de 7922 notícias, errando somente 1314 títulos. Isso confere uma precisão total de 86%, enquanto o recall apresentou 78% na classe de notícias falsas e 92% na de notícias reais. Apesar dos resultados serem levemente menores do que o algoritmo Logistic Regression, entende-se que os valores ainda são suficientemente altos, tornando o SVM bem sucedido e também estando apto a utilização para validação de notícias em massa.

O grande volume de dados produzidos dentro das redes sociais amplia as possibilidades das organizações extraírem informações valiosas para ampliar sua vantagem competitiva dentro de mercados com alta concorrência. Dentro deste contexto, o setor de Marketing Político vem desenvolvendo estratégias de análise de banco de dados massivos e ferramentas de mineração para traçar estratégias eleitorais mais assertivas, voltadas para os eleitores indecisos. Partindo deste cenário, Dutra e Francisco (2018) se valeram das ferramentas de Text Mining para entender, por meio da análise de sentimentos, quais foram as

¹³ O SVM é um algoritmo supervisionado de aprendizagem de máquinas, cuja principal função é a de classificar ou regredir um determinado *dataset* (ADDAN, 2019).



palavras mais citadas e os tipos de sentimentos predominantes durante as eleições presidenciais brasileiras de 2018.

A base de dados inicial teve suas informações coletadas para análise no período de 24 a 30 de Junho de 2018 dentro do Twitter, totalizando 1.204.036 manifestações. Da mesma forma que no estudo sobre robôs, os autores também optaram por utilizar a API e toda documentação já fornecida pela rede social. Após a coleta de dados, foi realizada uma etapa de pré-processamento para limpar a base de dados com a exclusão de caracteres numéricos, especiais e de pontuação, a remoção de repetição de letras entre outros ajustes. Para tratamento dos dados e posterior teste e validação do modelo, os autores optaram por utilizar o modelo de aprendizagem probabilística Naive Bayes¹⁴. Após o treino e o teste da base, foi criada a matriz de confusão abaixo, para avaliar o desempenho da máquina.

De forma similar ao estudo sobre fake news conduzido por Costa (2019), também foram utilizados os parâmetros de precisão e recall para análise do modelo proposto, acrescidos da acurácia. De modo geral, os principais objetivos destes três fatores são os de testar a sensibilidade da máquina e identificar o total de amostras classificadas positivamente. É possível notar, portanto, que o modelo selecionado obteve sucesso na acuracidade e precisão da classificação de sentimentos (seja neutro, positivo ou negativo). Após a distribuição final dos resultados, tem-se o seguinte cenário:

Quadro 2 - Classificação final dos resultados

Candidato	Negativo		Positivo		Neutro	
	Quantidade	%	Quantidade	%	Quantidade	%
Amoedo	3.912	27,91%	5.750	41,02%	4.354	31,06%
Ciro	6.988	30,78%	8.279	36,46%	7.437	32,76%
Eleições	14.524	31,78%	16.656	36,45%	14.520	31,77%
Geraldo Alckmin	4.142	31,71%	4.589	35,13%	4.333	33,17%
Jair Bolsonaro	24.473	31,59%	30.466	39,33%	22.531	29,08%
Manuela	25.495	38,14%	21.296	31,86%	20.056	30,00%
Marina	2.144	29,24%	2.374	32,38%	2.814	38,38%
Total Geral	81.678	33,05%	89.410	36,18%	76.045	30,77%

Fonte: Dutra e Francisco (2018).

Considerando que o maior volume de dados coletados se concentrou nos candidatos Jair Bolsonaro e Manuela Dávila, a análise de sentimentos e de palavras mais citadas se concentrou somente neles. Para o primeiro, as palavras de maior relevância se concentram no espectro negativo. Dentre as principais encontram-se preso, bandido e ódio. Já para o

¹⁴ Trata-se de um algoritmo de aprendizagem simples utilizado para calcular a probabilidade de um dado evento ocorrer, considerando um evento anterior concretizado (probabilidade condicional) (HAYKIN, 2009).



segundo, os termos se concentraram no espectro positivo. Dentre as palavras mencionadas, podemos mencionar estupro¹⁵, mulher e roda.

Por fim, após o estudo ser concluído, os autores Dutra e Francisco (2018) classificaram, de fato, a atuação do modelo como satisfatório. No entanto, ainda há dificuldades para adotar esta prática de forma sistemática, uma vez que é preciso traduzir todos os tweets da base (o API encontra-se em inglês), podendo gerar distorções de posicionamentos, além de haver gírias e regionalismos que dificultam o entendimento da máquina. Assim, o resultado deste estudo é apontado como promissor, porém ainda precisando de mais ajustes, refinamentos e inovações tecnológicas para estar melhor preparado.

CONSIDERAÇÕES FINAIS

O objetivo geral deste artigo era o de compreender como a ferramenta de machine learning pode contribuir para os processos eleitorais, baseado em três diferentes óticas de análise: compreender de que maneira a ferramenta poderia auxiliar na identificação de robôs formadores de opiniões; analisar como o machine learning poderia identificar as fake news; e entender a interação existente entre o modelo de aprendizado de máquina e a customização de propagandas eleitorais para diferentes clusters de eleitores, por meio da análise de sentimentos. Como visto, portanto, foi possível alcançar tanto os objetivos secundários, quanto a pergunta central.

De modo geral, percebeu-se que os algoritmos de machine learning são eficazes para identificar contas automatizadas dentro das redes sociais. Além disso, também ficou evidente que estes robôs influenciam usuários comuns, podendo ser decisivos em debates na arena política. Em relação a identificação de fake news, foi possível identificar dois diferentes modelos de aprendizagem supervisionado com resultados precisos e satisfatórios. Por fim, os estudos da aplicação de algoritmo para analisar os sentimentos de eleitores se mostram promissores, porém ajustes e refinamentos ainda se fazem necessários para que se possa ter uma aplicação de forma sistemática dentro do marketing político. O presente trabalho trouxe também a possibilidade de se desenvolver pesquisas futuras na área. Dentro do cenário político atual, investigações sobre a disseminação de fake news por políticos influentes têm

¹⁵ Apesar da conotação negativa do termo, o classificador o analisou como positivo, já que se tratavam de tweets parabenizando a candidata por ter defendido propostas mais efetivas quanto a valorização da mulher e a condenação de estupradores em uma entrevista para o programa "Roda Viva" no final de Junho de 2018.



sido recorrentes, podendo ser suportada por modelos de aprendizagem de máquina. Além disso, também pode ser analisada a extensão de um algoritmo que não apenas identifique contas automatizadas e notícias falsas, mas também denuncie diretamente aos times responsáveis pelas redes sociais. Por fim, também é interessante estudar um modelo de algoritmo que reduza as distorções na análise de sentimentos causadas por regionalismos, gírias e problemas de tradução.

Conclui-se que a ferramenta de machine learning trouxe uma nova gama de inovações e aplicações para o campo político, sendo possibilitadas somente pelo avanço da tecnologia da informação. Apesar de ainda estar no começo, os modelos matemáticos trazidos já se tornaram de suma importância para que se transformem dados em informações valiosas. Assim, é importante que estudos nesta área continuem sendo realizados, para qualificar cada vez mais os processos políticos dentro de países democráticos.

REFERÊNCIAS BIBLIOGRÁFICAS

ADDAN, Diego. Support Vector Machine. 2019.

ARAÚJO, Flávio HD et al. Redes neurais convolucionais com tensorflow: Teoria e prática. **SOCIEDADE BRASILEIRA DE COMPUTAÇÃO. III Escola Regional de Informática do Piauí. Livro Anais-Artigos e Minicursos**, v. 1, p. 382-406, 2017.

BASTOS, Marco T.; MERCEA, Dan. The Brexit botnet and user-generated hyperpartisan news. **Social science computer review**, v. 37, n. 1, p. 38-54, 2019.

BATTISTI, Fernando et al. Detecção de notícias falsas utilizando aprendizado de máquina. 2020.

BIJOS, Leila Maria Da'juda; SILVA, Patrícia Almeida da. Análise da primavera árabe: um estudo de caso sobre a revolução jovem no Egito. **Revista Cej**, v. 17, n. 59, 2013.

COSTA, Lucas Gomes. Classificação de fake news utilizando algoritmos de aprendizado de máquina e aprendizado profundo, 2019.

COUTINHO, Clara Pereira- Metodologia de Investigação. em Ciências Sociais e Humanas: Teoria e Prática. 2013.

DE REZENDE FRANCISCO, Eduardo. A tendência do big data. **GV EXECUTIVO**, v. 14, n. 2, p. 71, 2015.

DUTRA, Daniela Aparecida Monteiro; DE REZENDE FRANCISCO, Eduardo. TEXT MINING: ANÁLISE DE SENTIMENTOS NAS ELEIÇÕES 2018. In: **Congresso Transformação Digital 2018**. 2018.



FERRARA, Emilio et al. The rise of social bots. **Communications of the ACM**, v. 59, n. 7, p. 96-104, 2016.

FRANCO, Rafael Bilibio; DA COSTA ADANIYA, Mario Henrique Akihiko. Sistemas de análise de sentimentos usando dados do Twitter. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, v. 34, n. esp., p. 111-118, 2018.

GIL, Antonio Carlos. Como Elaborar Projetos de Pesquisa. Rio de Janeiro: **Atlas**, 2017. ISBN 9788597012934. Disponível em: <http://fahor.com.br/totvts/?biblioteca&isbn=9788597012934>. Acesso em: 10 jun. 2021.

GOLDBERG, Yoav; LEVY, Omer. word2vec Explained: deriving Mikolov et al.'s negative-sampling word-embedding method. **arXiv preprint arXiv:1402.3722**, 2014.

HAYKIN, Simon. **Neural networks and learning machines**, 3/E. Pearson Education India, 2010.

LIMA, Pablo; AMARAL, Érico. EXISTEM FERRAMENTAS DIGITAIS CAPAZES DE REDUZIR A DISSEMINAÇÃO DAS FAKE NEWS?. **Anais do Salão Internacional de Ensino, Pesquisa e Extensão**, v. 10, n. 2, 2018.

MARSLAND, Stephen. **Machine learning: an algorithmic perspective**. CRC press, 2015.

MATOS, Fernanda Fernandes; DE MAGALHÃES, Lúcia Helena; SOUZA, Renato Rocha. Recuperação e classificação de sentimentos de usuários do Twitter em período eleitoral. **Informação & Informação**, v. 25, n. 1, p. 92-114, 2020.

MORAIS, Edison Andrade Martins; AMBRÓSIO, Ana Paula L. Mineração de textos. **Relatório Técnico-Instituto de Informática (UFG)**, 2007.

MUSSKOPF, Irio. A ciência da detecção de fake news, 2017

NOBRE, Gabriel P.; ALMEIDA, Jussara M.; FERREIRA, Carlos HG. Caracterização de bots no Twitter durante as Eleições Presidenciais no Brasil em 2018. In: **Anais do VIII Brazilian Workshop on Social Network Analysis and Mining**. SBC, 2019. p. 107-118.

PENTEADO, CLAUDIO LUIS DE CAMARGO. Marketing político na era digital: perspectivas e possibilidades. **Revista USP**, n. 90, p. 6-23, 2011.

RADICCHI, Laura Betti Monteiro; BARION, Michele Cristiani; FERREIRA, Adriano. Arquitetura de machine learning para análise de reportagens textuais em redes sociais para a detecção de fake news.

SILVA, Ana Valeria Vieira da. **Detecção de contas anômalas e influência em redes sociais na propaganda política e em eleições**. 2021. Tese de Doutorado.

VIANA, Zarathon Lopes. Mineração de textos: análise de sentimentos utilizando Tweets referentes às eleições presidenciais 2014.