

UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

**Mineração de opinião iterativa usando redes neurais
para análise dos resultados eleitorais: um estudo de
caso das eleições do Equador**

Andrés Gabriel Delgado Giler

Monografia - MBA em Inteligência Artificial e Big Data

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Andrés Gabriel Delgado Giler

Mineração de opinião iterativa usando redes neurais para análise dos resultados eleitorais: um estudo de caso das eleições do Equador

Monografia apresentada ao Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, como parte dos requisitos para obtenção do título de Especialista em Inteligência Artificial e Big Data.

Área de concentração: Inteligência Artificial

Orientador: Prof. Antonio Jacob Jr.

Versão original

São Carlos

2025

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

D352m Delgado Giler, Andres Gabriel
Mineração de opinião iterativa usando redes neurais para análise dos resultados eleitorais: um estudo de caso das eleições do Equador / Andres Gabriel Delgado Giler; orientador Antonio Fernando Lavareda Jacob Junior. -- São Carlos, 2025.
46 p.

Trabalho de conclusão de curso (MBA em Inteligência Artificial e Big Data) -- Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, 2025.

1. . I. Lavareda Jacob Junior, Antonio Fernando, orient. II. Título.

Andrés Gabriel Delgado Giler

**Iterative opinion mining using neural networks for
analyzing electoral results: a case study of the Ecuadorian
elections**

Monograph presented to the Departamento de Ciências de Computação do Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo - ICMC/USP, as part of the requirements for obtaining the title of Specialist in Artificial Intelligence and Big Data.

Concentration area: Artificial Intelligence

Advisor: Prof. Antonio Jacob Jr.

Original version

São Carlos

2025

*Este trabalho é dedicado a Michelle por me incentivar a fazer este MBA
e ao Andrés do futuro que verá os frutos do Andrés do passado
por se esforçar para concluir este MBA.*

*“Si una palabra sola puede cambiar el curso de la historia
otra palabra, en la oscuridad, derrota la tormenta.”
Manuela Sáenz - Prócer da independência do Equador*

RESUMO

DELGADO GILER, A.G. **Mineração de opinião iterativa usando redes neurais para análise dos resultados eleitorais: um estudo de caso das eleições do Equador**. 2025. 51 p. Monografia (MBA em Inteligência Artificial e Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

As redes sociais tornaram-se ferramentas indispensáveis para acompanhar informações e compartilhar opiniões sobre uma variedade de temas, incluindo política. No contexto eleitoral, a rede social X, anteriormente conhecida como Twitter, tem se mostrado um espaço para debates e manifestações de opiniões, fornecendo uma fonte de dados para análise. Neste trabalho, propomos investigar a viabilidade de aplicar técnicas de aprendizado de máquina para determinar, nas semanas que antecedem o dia da eleição, qual candidato ou partido tem maior apoio da opinião pública com base nas postagens do Twitter, com ênfase em replicar e adaptar a metodologia Iterative Opinion Mining using Neural Networks (IOM-NN). O problema abordado está relacionado às dificuldades em interpretar adequadamente os sinais de polarização. Neste contexto, o Equador oferece um cenário ideal para explorar a aplicação dessa metodologia, dado que recentemente experimentou ciclos eleitorais marcados por polarização intensa junto com o uso massivo de plataformas como Twitter. Embora estudos anteriores sugiram o potencial do aprendizado de máquina na análise de redes sociais, notamos que muitos estudos existentes focados na previsão de eleições no Equador ainda não usaram a metodologia IOM-NN. Este estudo busca abordar essa lacuna investigando como as informações de postagens podem ser correlacionadas com os resultados das pesquisas.

Palavras-chave: Aprendizado de máquina. Eleições presidenciais. Equador. Predição de eleições.

ABSTRACT

DELGADO GILER, A.G. **Iterative opinion mining using neural networks for analyzing electoral results: a case study of the Ecuadorian elections.** 2025. 51 p. Monograph (MBA in Artificial Intelligence and Big Data) - Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos, 2025.

Social media has become an indispensable tool for tracking information and sharing opinions on a variety of topics, including politics. In the electoral context, the social network X, formerly known as Twitter, has proven to be a forum for debates and the expression of opinions, providing a valuable source of data for analysis. In this work, we propose to investigate the feasibility of applying machine learning techniques to determine, in the weeks leading up to Election Day, which candidate or party has the greatest public support based on Twitter posts, with an emphasis on replicating and adapting the Iterative Opinion Mining using Neural Networks (IOM-NN) methodology. The problem addressed is related to the difficulties in adequately interpreting polarization signals. In this context, Ecuador offers an ideal setting to explore the application of this methodology, given that it has recently experienced electoral cycles marked by intense polarization coupled with the massive use of platforms such as Twitter. While previous studies suggest the potential of machine learning in social network analysis, we note that many existing studies focused on predicting elections in Ecuador have not yet used the IOM-NN methodology. This study seeks to address this gap by investigating how information from posts can be correlated with poll results.

Keywords: Machine Learning. Presidential elections. Ecuador. Election predictions.

LISTA DE FIGURAS

Figura 1 – Etapas da metodologia IOM-NN.	32
Figura 2 – Candidatos à presidência às eleições presidenciais equatorianas de 2021: Andrés Arauz à esquerda e Guillermo Lasso à direita.	32
Figura 3 – Visualização do top 100 de hashtags do conjunto de dados.	36
Figura 4 – Exemplo do algoritmo de classificação de postagens para duas iterações.	38
Figura 5 – Função de perda no treinamento da rede neural na primeira iteração de uma das rodadas.	45
Figura 6 – Acurácia no treinamento da rede neural na primeira iteração de uma das rodadas.	45

LISTA DE TABELAS

Tabela 1 – Resultados do primeiro turno das eleições presidenciais equatorianas de 2021.	33
Tabela 2 – Descrição dos atributos do conjunto de dados do Twitter.	34
Tabela 3 – Distribuição das postagens entre 24 de janeiro a 6 de fevereiro de 2021 antes e depois de filtragem de contas fake.	34
Tabela 4 – Exemplo de como funciona o algoritmo de classificação de postagens.	39
Tabela 5 – Resultados parciais para cada iteração alcançados na primeira rodada.	43
Tabela 6 – Porcentagens obtidas para diferentes heurísticas com base no conjunto de dados do primeiro turno da eleição presidencial do Equador em 2021.	44
Tabela 7 – Porcentagens obtidas considerando o promedio de H1, H2 e H3.	44

SUMÁRIO

1	INTRODUÇÃO	21
1.1	Motivação	22
1.2	Objetivos	22
1.2.1	Objetivos específicos	22
2	FUNDAMENTAÇÃO TEÓRICA E TRABALHOS CORRELATOS	25
2.1	Perceptron multicamadas	25
2.1.1	Modelo de neurônio	25
2.1.2	Função de ativação	25
2.1.3	Backpropagation	26
2.2	Representações vetoriais de palavras (Word embeddings)	26
2.3	Trabalhos correlatos	27
2.4	Considerações finais	29
3	METODOLOGIA	31
3.1	Iterative Opinion Mining using Neural Networks (IOM-NN)	31
3.1.1	Entendimento do evento político	31
3.1.2	Preparação de postagens	33
3.1.3	Classificação das postagens	36
3.1.4	Polarização dos usuários	40
3.1.5	Avaliação da performance da rede neural	41
3.2	Considerações finais	41
4	RESULTADOS E DISCUSSÕES	43
4.1	Comparação com outros estudos	46
4.2	Considerações finais	46
5	CONCLUSÕES E DISCUSSÃO	47
	REFERÊNCIAS	49

1 INTRODUÇÃO

As redes sociais tornaram-se ferramentas indispensáveis para acompanhar informações e compartilhar opiniões sobre uma variedade de temas, incluindo política. No contexto eleitoral, a rede social X, anteriormente conhecida como Twitter, tem-se mostrado um espaço para debates e manifestações de opiniões, fornecendo uma fonte de dados para análise (Rajadesingan; Liu, 2014; Wijesekara; Ganegoda, 2020).

Dados estatísticos reforçam a relevância do X como fonte de informação e discussão política: segundo a Kepios Analysis, identidades de usuários ativos de redes sociais ultrapassaram a marca de 5 bilhões em 2024, o que equivale a 62,3% da população mundial. Esse total global aumentou em 266 milhões no último ano, representando um crescimento anual de 5,6% (Kemp, 2024). Além disso, estudos indicam que postagens relacionadas a campanhas e debates aumentam significativamente nos períodos de eleições. Por exemplo, uma pesquisa de opinião do Instituto DataSenado aponta que 45% dos eleitores, no caso brasileiro, votaram nas eleições de 2018 levando em consideração informações vistas em alguma rede social (Agência Senado) (Baptista, 2019). Esses dados destacam o potencial do uso dessas plataformas como fontes de dados para análise e interpretação de cenários políticos.

Nas últimas décadas, a comunicação digital passou por diversas transformações significativas. A disseminação de informações por meio de redes sociais, a ampliação do alcance das postagens e a capacidade de engajamento direto entre atores políticos e cidadãos modificaram profundamente as dinâmicas da opinião pública. O problema abordado está relacionado às dificuldades em interpretar adequadamente os sinais de polarização nessas postagens. A polarização se manifesta por distintos tipos de mensagens; por exemplo, discursos pró ou contra candidatos, disseminação de hashtags partidárias e mensagens ideológicas que reforçam posições pré-existentes. A identificação e análise desses sinais representam um desafio tanto técnico quanto conceitual, especialmente em contextos eleitorais marcados por alto engajamento digital.

Neste contexto, o Equador oferece um cenário ideal para explorar a aplicação dessa metodologia, dado que recentemente experimentou ciclos eleitorais marcados por intensa polarização junto com o uso massivo de plataformas como X, antigo *Twitter*. Estudos anteriores demonstram o potencial do aprendizado de máquina na análise de redes sociais (Belcastro *et al.*, 2020), porém notamos que os estudos existentes focados na previsão de eleições no Equador ainda não utilizaram a metodologia IOM-NN (Espin-Riofrio *et al.*, 2022; Quelal *et al.*, 2022; Diaz *et al.*, 2024). Este estudo busca abordar essa lacuna, investigando como as informações de postagens podem ser correlacionadas com os resultados das pesquisas, utilizando a metodologia IOM-NN.

Neste trabalho, propomos investigar a viabilidade de aplicar técnicas de aprendizado de máquina para determinar, nas semanas que antecedem o dia da eleição, qual candidato ou partido tem maior apoio da opinião pública com base nas postagens do Twitter, com ênfase em replicar e adaptar a metodologia Iterative Opinion Mining using Neural Networks (IOM-NN). A metodologia IOM-NN utiliza um processo iterativo baseado em redes neurais feed-forward para analisar as postagens e a polarização dos usuários em relação às diferentes facções políticas em disputa (Belcastro *et al.*, 2020).

1.1 Motivação

A motivação deste trabalho baseia-se em alguns fatores. Primeiro, a predição de eleições usando redes sociais pode oferecer uma alternativa mais rápida e com maior abrangência em comparação às pesquisas eleitorais tradicionais. Essas pesquisas, embora fundamentais, muitas vezes enfrentam problemas enquanto a amostragem, custo econômico para fazer a pesquisa, atrasos na coleta e processamento de dados, além de vieses metodológicos. Em contrapartida, a análise de grandes volumes de postagens online permite analisar tendências com maior rapidez e espaço temporal.

Segundo, estudos como o de (Belcastro *et al.*, 2020) mostram que abordagens baseadas em aprendizado de máquina têm demonstrado potencial para superar métodos convencionais, aproveitando as informações contidas nas opiniões expressas nas postagens, as quais geralmente não são consideradas pelas pesquisas tradicionais.

Neste sentido, o foco geral deste trabalho é replicar a metodologia IOM-NN para prever resultados eleitorais usando as postagens do Twitter referentes às eleições no Equador em um período eleitoral específico. Para isso, foi usado um conjunto de dados correspondente ao primeiro turno das eleições no Equador no ano 2021, incluindo postagens que utilizem palavras-chave ou hashtags relacionadas aos candidatos e partidos políticos. Para isto foi feito um pré-processamento de dados. Finalmente, implementamos os algoritmos de aprendizado de máquina para classificar as postagens e correlacionar os resultados das urnas com nossas predições.

1.2 Objetivos

O objetivo deste trabalho é replicar a metodologia IOM-NN para prever os resultados do primeiro turno das eleições presidenciais equatorianas 2021 usando postagens do Twitter.

1.2.1 Objetivos específicos

- Extrair hashtags de cada publicação e identificar as hashtags mais representativas que apoiam cada partido de forma única.

- Avaliar os modelos treinados com base nos tweets rotulados com as hashtags identificadas para cada partido.
- Definir o voto de um usuário e aplicar métricas ou heurísticas para determinar o resultado da eleição.

2 FUNDAMENTAÇÃO TEÓRICA E TRABALHOS CORRELATOS

Este capítulo apresenta os conceitos essenciais para o desenvolvimento deste trabalho, incluindo fundamentos das redes neurais, representações vetoriais de palavras e técnicas de aprendizado de máquina utilizadas. Além disso, são discutidos trabalhos correlatos que investigam a previsão eleitoral por meio de redes sociais, com o objetivo de situar o presente estudo no estado da arte e evidenciar lacunas que motivam esta pesquisa.

2.1 Perceptron multicamadas

2.1.1 Modelo de neurônio

O Perceptron Multicamadas (Multi-Layer Perceptron – MLP) é um dos modelos de redes neurais artificiais mais utilizados em tarefas de classificação e regressão. Ele consiste em uma rede de neurônios organizados em camadas: uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída. Cada neurônio realiza uma combinação linear das entradas ponderadas pelos respectivos pesos e aplica uma função de ativação para introduzir não linearidade no modelo (Neupert *et al.*, 2022).

O MLP é capaz de aprender relações complexas e não lineares entre variáveis, sendo adequado para problemas de classificação de textos, como a análise de sentimentos e a mineração de opinião. Durante o processo de treinamento, os pesos das conexões entre neurônios são ajustados iterativamente para minimizar o erro entre as saídas previstas e as desejadas.

No contexto deste trabalho, o MLP é utilizado para classificar tweets em diferentes categorias políticas, com base nas representações vetoriais de suas hashtags. Esse modelo é particularmente adequado devido à sua capacidade de generalização e de aprendizado de padrões complexos em dados textuais.

2.1.2 Função de ativação

As funções de ativação são elementos fundamentais das redes neurais, responsáveis por introduzir não linearidade no modelo. Sem elas, uma rede neural se comportaria como uma simples combinação linear, incapaz de aprender relações complexas entre as variáveis.

Entre as funções mais comuns destacam-se (Neupert *et al.*, 2022):

- Sigmoid: transforma a entrada em um valor entre 0 e 1, sendo útil para problemas binários.

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.1)$$

sendo x o valor de entrada do neurônio e σ o valor ativado após passar pela função sigmoide.

- ReLU (Rectified Linear Unit): retorna o valor de entrada x se for positivo, ou zero caso contrário e está definida por:

$$f(x) = \max(0, x) \quad (2.2)$$

É amplamente utilizada em camadas ocultas por favorecer o treinamento rápido e mitigar o problema do vanishing gradient.

- Softmax: utilizada na camada de saída para problemas de classificação multiclasse, produzindo uma distribuição de probabilidades sobre as classes.

2.1.3 Backpropagation

A retropropagação é o algoritmo de aprendizado utilizado para ajustar os pesos das conexões em uma rede neural como o MLP (Rumelhart; Hinton; Williams, 1986). Baseia-se na aplicação da regra da cadeia para calcular o gradiente do erro em relação a cada peso, propagando o erro da saída para as camadas anteriores (Neupert *et al.*, 2022).

O processo ocorre em duas fases:

- Propagação direta (Forward pass): as entradas percorrem a rede até gerar uma saída.
- Propagação inversa (Backward pass): o erro é calculado comparando a saída obtida com a desejada e propagado de volta para atualizar os pesos, geralmente por meio do algoritmo de Gradient Descent.

A atualização dos pesos segue a regra:

$$\omega_{ij}(t+1) = \omega_{ij}(t) - \eta \frac{\delta E}{\delta \omega_{ij}} \quad (2.3)$$

onde $\omega_{ij}(t)$ é o peso da conexão entre neurônios i e j no instante t , $\omega_{ij}(t+1)$ é o novo peso ajustado, η é a taxa de aprendizado, E representa o erro total da rede e $\frac{\delta E}{\delta \omega_{ij}}$ é o gradiente do erro em relação ao peso.

2.2 Representações vetoriais de palavras (Word embeddings)

Para que um algoritmo de aprendizado de máquina possa processar texto, é necessário converter as palavras em representações numéricas. Esse processo é conhecido como vetorização (Mikolov *et al.*, 2013). Os métodos tradicionais, como Bag of Words (BoW) e TF-IDF, representam os textos por meio de contagens ou frequências de palavras, ignorando a semântica e a ordem (Smith, 2020).

Modelos mais avançados, como o Word2Vec, permitem capturar relações semânticas e contextuais entre palavras, mapeando-as em um espaço vetorial contínuo. Assim, palavras com significados semelhantes possuem vetores próximos. Por exemplo, no espaço de embeddings, os vetores de “rei” e “rainha” estão próximos, e as relações lineares entre vetores podem capturar analogias, como: rei – homem + mulher = rainha.

Essa representação densa e contínua melhora o desempenho de modelos de classificação textual, pois preserva informações semânticas relevantes que os métodos baseados em contagem não captam. Neste trabalho foi usado CountVectorizer da biblioteca Scikit-learn¹ para transformar a coleção de hashtags em uma matriz numérica de contagem de tokens.

2.3 Trabalhos correlatos

Nas últimas décadas, o uso das redes sociais no contexto eleitoral tem aumentado significativamente, dando lugar a diversos trabalhos científicos para inferir tendências eleitorais, prever eleições e compreender a polarização. Nesta seção, apresentamos um levantamento de estudos que analisam a relação entre eventos políticos e redes sociais com foco no uso de aprendizado de máquina para prever tendências políticas. Além disso, mostramos o uso dessas técnicas no contexto da América Latina, especificamente para o caso equatoriano.

De forma geral, as técnicas para previsão de cenários eleitorais podem ser classificadas em duas categorias: análise baseada no volume de dados e análise baseada nos sentimentos dos posts. As técnicas baseadas no volume de dados tentam prever os resultados de uma eleição contando o número de vezes que um candidato ou partido político é mencionado por um usuário (Tumasjan *et al.*, 2010; Skoric *et al.*, 2012).

Uma das primeiras previsões eleitorais baseadas no volume de dados foi feita em 2010 por Tumasjan analisando as eleições de parlamentares na Alemanha (Tumasjan *et al.*, 2010). O trabalho examinou mais de 100 000 posts no Twitter, concluindo que existe uma correlação entre o número de menções de um político/partido e o resultado final da eleição. Os autores também destacaram as limitações no estudo, como a falta de representação do eleitorado, falta de respostas pertencentes às discussões das próprias postagens, e a ausência de uma análise de sentimentos.

Trabalhos estatísticos mostraram resultados diversos nesta abordagem. Por exemplo, foi mostrado que houve uma associação estatisticamente significativa (p-value < 0.05) entre tweets que mencionam um candidato à Câmara dos Representantes dos EUA e seu desempenho nas eleições de 2010 e 2012 (DiGrazia *et al.*, 2013). Porém, no caso das eleições italianas de 2011, um estudo mostrou uma correlação não significativa entre a popularidade de um candidato no Facebook e o desempenho eleitoral (Giglietto, 2021).

¹ Maior informação da biblioteca Scikit-learn pode ser encontrada no site oficial <https://scikit-learn.org/stable/>

Considerar apenas o volume de postagens pode não ser confiável, dado que não representa o eleitorado geral. No trabalho de Gayo Avello, este comportamento é atribuído a fatores como viés demográfico, ou seja, a proporção de usuários do Twitter pertencentes a cada classe social não é considerada (Gayo-Avello, 2012).

Por outro lado, as técnicas baseadas em análise de sentimentos exploram algoritmos de aprendizado de máquina, a fim de entender a opinião de um usuário a respeito de um candidato. Por exemplo, o trabalho de Myilvahanan et al. propôs o uso de K vizinhos próximos para a previsão das eleições indianas de 2019 e observou que os resultados da previsão estão próximos do resultado real (Myilvahanan *et al.*, 2023). Outro estudo relevante na área corresponde a Bovet e Makse (Bovet; Makse, 2019). Eles analisaram o impacto de fake news no Twitter na eleição presidencial dos EUA de 2016 e identificaram padrões de disseminação de fake news mostrando que certos candidatos se beneficiaram da viralização de conteúdos políticos. Isso mostrou a importância de considerar não apenas o volume de postagens, mas também a natureza do conteúdo compartilhado.

Outro aspecto importante é a verificação do desempenho de modelos em diferentes idiomas. Por exemplo, uma estrutura multimodal híbrida que incorpora emojis e texto multilíngue, tem mostrado uma precisão superior a 87% no caso indiano com tweets em idiomas hindi, inglês e hinglish (Shweta; Prasad, 2024). No contexto da América Latina, alguns estudos abordam os desafios encontrados na aplicação dessas técnicas (Brito; Adeodato, 2023). Trabalhos como os de Santos Brito (Brito; Adeodato, 2020) têm mostrado que o aprendizado de máquina fornece vantagens quando são agregadas novas variáveis, como número de likes, compartilhamentos e comentários por postagem. O estudo foi realizado para o caso da eleição presidencial brasileira de 2018, assim como para a eleição presidencial dos EUA de 2016, mostrando melhores resultados no caso brasileiro.

No caso do Equador, a aplicação dessas técnicas ainda é limitada. O trabalho de Andres Quelal (Quelal *et al.*, 2022) tenta identificar a tendência política de bots no Twitter usando análise de sentimentos. O estudo foi feito para as eleições gerais equatorianas de 2021. No trabalho mostra-se que ambos (bots e não bots) tinham sentimentos mais positivos em relação aos seus respectivos candidatos do que sentimentos desfavoráveis em relação aos outros candidatos. Em outro trabalho relacionado, é apresentado que a identificação de potenciais bots pode ser feita de forma simples por meio de classificadores de K vizinhos mais próximos, análises dos padrões de tweets e métricas de engajamento (Diaz *et al.*, 2024). Em outro trabalho relacionado, os autores classificam os usuários de acordo com sua afinidade política analisando posts com técnicas mais simples de aprendizado de máquina como Support Vector Machine (SVM), Naive Bayes, Bernoulli e Multinomial (Espin-Riofrio *et al.*, 2022).

Outro trabalho relevante corresponde a Belcastro et al. que propôs uma metodologia com um processo iterativo (Belcastro *et al.*, 2020). Essa abordagem usa redes neurais

para classificar postagens de usuários e inferir sua polarização política. Diferentemente de métodos tradicionais, que utilizam apenas análise de sentimento ou hashtags, a metodologia IOM-NN constrói regras iterativas, aumentando a precisão da identificação de tendências políticas. A validação da eficácia da técnica foi feita com as eleições nos Estados Unidos (2016) e na Itália (2018), mostrando resultados próximos aos das pesquisas eleitorais tradicionais. Esta técnica será explicada em detalhe posteriormente.

2.4 Considerações finais

Os conceitos e estudos revisados demonstram a relevância das técnicas de aprendizado de máquina aplicadas à análise política e evidenciam a lacuna de pesquisas que utilizam a metodologia IOM-NN em contextos latino-americanos. Essa fundamentação sustenta as escolhas adotadas nos capítulos seguintes.

3 METODOLOGIA

Neste capítulo são descritos os procedimentos adotados para aplicar a metodologia IOM-NN ao conjunto de dados das eleições equatorianas de 2021. Além disso, são detalhadas as etapas de coleta e preparação das postagens, o processo de classificação iterativa usando redes neurais e o cálculo da polarização dos usuários, além dos critérios utilizados para avaliação do modelo.

3.1 Iterative Opinion Mining using Neural Networks (IOM-NN)

Conforme discutido na introdução, a metodologia escolhida para realizar este trabalho foi a *Iterative Opinion Mining using Neural Network* (IOM-NN). Essa metodologia é estruturada em um conjunto de passos que permite estimar a polarização da opinião pública durante um evento de eleição política (Belcastro *et al.*, 2020). A metodologia tem como característica classificar os usuários analisando as hashtags contidas nas postagens que podem ser escritas em qualquer idioma, sem usar dicionários ou sistemas de tradução. A metodologia consiste de quatro etapas: (i) Entendimento do evento político, (ii) preparação de postagens, (iii) classificação das postagens e (iv) polarização dos usuários.


- **Entendimento do evento político:** compreender o contexto do evento político a ser predito.
- **Preparação de postagens:** Essa etapa envolve a adequação das postagens em uma tabela, assim como identificação e extração de hashtags do texto.
- **Classificação das postagens:** as postagens adequadas são classificadas usando um procedimento iterativo implementado por meio de redes neurais, incluindo geração de testes e ajuste de parâmetros do modelo.
- **Polarização dos usuários:** as postagens classificadas são analisadas e a polarização dos usuários em relação a uma facção é determinada.

A Figura 1 mostra os passos da metodologia IOM-NN, indicando cada uma das etapas assim como os termos das variáveis a serem usadas. Os próximos tópicos apresentam cada uma das etapas do IOM-NN neste projeto.

3.1.1 Entendimento do evento político

O evento político a ser analisado corresponde ao primeiro turno das eleições presidenciais equatorianas de 2021, as quais foram realizadas em 7 de fevereiro de 2021 para o mandato de 2021-2025. Esta eleição teve a peculiaridade de ter o maior número

Figura 1 – Etapas da metodologia IOM-NN.



Fonte: Adaptada de (Belcastro *et al.*, 2020).

Figura 2 – Candidatos à presidência às eleições presidenciais equatorianas de 2021: Andrés Arauz à esquerda e Guillermo Lasso à direita.



Fonte: Imagem tomada do site de notícias Ecuavisa (ver referência (Ecuavisa, 2021)).

de candidatos na história eleitoral do Equador, com 16 candidatos. Porém, nosso caso de estudo envolve apenas os dois candidatos presidenciais que lideravam as pesquisas naquele momento. Os dois candidatos, Andrés Arauz e Guillermo Lasso (ver figura 2), pertenciam aos dois partidos políticos mais dominantes naquele momento no estado equatoriano e foram eles que avançaram para o segundo turno. Vale a pena ressaltar que esta escolha é unicamente por motivos de disponibilidade de dados.

A tabela 1 mostra os resultados do primeiro turno, onde Andrés Arauz obteve 32.72 % e Guillermo Lasso obteve 19.74 %. Essas porcentagens são os valores que vamos prever neste trabalho. A porcentagem restante de votos foi distribuída entre os candidatos sobranes e não será prevista neste trabalho¹.

O fato de apenas dois candidatos de 16 terem sido considerados tem um impacto que será discutido mais tarde. Para nossos cálculos e daqui em diante, essas duas porcentagens representarão os valores a serem previstos.

¹ Apenas para informação adicional, esses dois candidatos avançaram para o segundo turno, onde o candidato Guillermo Lasso venceu.

Tabela 1 – Resultados do primeiro turno das eleições presidenciais equatorianas de 2021.

Candidatos	Porcentagem de Votos
Andrés Arauz	32.72 %
Guillermo Lasso	19.74 %

Fonte: (CNE, 2021).

3.1.2 Preparação de postagens

As postagens usadas neste trabalho foram extraídas do repositório público no github com título *Sentiment Analysis Ecuador 2021*² criado por (Macias; Campoberde, 2021). Os autores fizeram uma análise de sentimento dos dois candidatos presidenciais que lideravam as pesquisas para as eleições do primeiro turno de 2021 no Equador naquele momento.

Os tweets deste site foram coletados em duas datas: antes e depois das eleições, de 24 de janeiro a 6 de fevereiro e de 8 a 13 de fevereiro de 2021. A data do primeiro turno foi 7 de fevereiro de 2021. No total, o conjunto de dados é composto por 326 389 tweets de ambos os candidatos, sendo 202 320 tweets correspondentes a palavras-chave do candidato Andrés Arauz e 124 069 tweets ao candidato Guillermo Lasso. A descrição das características do conjunto de dados pode ser vista na tabela 2.

A extração dos tweets foi realizada pelos autores (Macias; Campoberde, 2021) utilizando a API do Twitter em conjunto com a biblioteca Python Tweepy³. Os dados foram extraídos usando palavras-chave para cada candidato por separado, como "Andrés Arauz, Andres Arauz, Arauz" e "Guillermo Lasso, Lasso" e filtrados pelo idioma espanhol ficando com aqueles que continham o texto completo segundo.

Os tweets usados nesta análise correspondem apenas ao período entre 24 de janeiro e 6 de fevereiro de 2021. A seção "antes" da tabela 3 mostra o número total de tweets de cada candidato, retirados diretamente do site mencionado. Há 171.528 postagens no total, a maioria das quais são tweets extraídos com palavras-chave de um dos candidatos.

Devido a que eventos políticos têm campanhas de desinformação, pode surgir um grupo de pessoas que estão por trás dessa desinformação e podem influenciar a opinião do eleitorado. Essas contas são conhecidas como contas fake ou trolls. Neste trabalho foi proposto um score de conta fake que leva em conta os seguintes fatores:

- Idade da conta: contas fake costumam ser criadas pouco antes de eventos de eleições.

² <https://github.com/SCAlabUnical/IOM-NN>

³ Atualmente, em 2025, essas ferramentas são limitadas pelas novas políticas de proteção de dados da X (Twitter) e é por isso que decidimos trabalhar com um conjunto de dados pronto.

Tabela 2 – Descrição dos atributos do conjunto de dados do Twitter.

Atributo	Descrição
<code>create_at</code>	Hora UTC em que este Tweet foi criado.
<code>full_text</code>	O texto completo em UTF-8 do Tweet de um usuário.
<code>favorite_count</code>	Indica aproximadamente quantas vezes este Tweet foi "curtido" pelos usuários do Twitter.
<code>id_str</code>	Representação em formato de <i>*string*</i> do identificador único deste Tweet.
<code>metadata.iso_language_code</code>	Código que identifica o idioma em que o Tweet foi escrito.
<code>retweeted_status_created_at</code>	Esta data contém a data de criação do <i>*retweet*</i> em questão.
<code>retweeted_status_full_text</code>	Este atributo contém o texto completo que foi <i>*retweetado*</i> .
<code>user.created_at</code>	A data de criação da conta de usuário que publicou este Tweet.
<code>user.favourites_count</code>	A quantidade de Tweets que este usuário curtiu durante a vida da conta.
<code>user.followers_count</code>	O número de seguidores que esta conta possui atualmente.
<code>user.friends_count</code>	Seguidores que esta conta segue e também a seguem.
<code>user.id_str</code>	Representação em formato de <i>*string*</i> do identificador único deste usuário.
<code>user.location</code>	A localização definida pelo usuário no perfil desta conta.
<code>user.verified</code>	Quando verdadeiro, indica que o usuário possui uma conta verificada.
<code>retweet_count</code>	O número de vezes que este Tweet foi <i>*retweetado*</i> .

Fonte: Pelo autor.

Tabela 3 – Distribuição das postagens entre 24 de janeiro a 6 de fevereiro de 2021 antes e depois de filtragem de contas fake.

Filtragem de contas fake	Candidato	Numero de tweets
Antes	Andrés Arauz	120 747
	Guillermo Lasso	50 781
Depois	Andrés Arauz	117 079
	Guillermo Lasso	49 372

Fonte: Pelo autor.

Se o tempo desde que foi criada a conta e a publicação do tweet for muito curto, a conta poder ser suspeita. Um diferença de tempo maior a 30 e 180 dias acrescenta 0.4 e 0.2 pontos ao score respectivamente.

- Seguidores vs. seguindo (proporção): trolls costumam seguir muitas pessoas, mas têm poucos seguidores. Se o número de seguidores for menor que 50 e maior que 200 adiciona 0.3 ao score. Além disso, uma baixa proporção de seguidores/(seguindo+1) pode ser suspeita. Se a taxa for menor que 0.1 adiciona 0.2 pontos ao score.

- Atividade de favoritos ou curtidas: contas fake raramente interagem de forma genuína. Se o número de curtidas for muito baixo, pode ser ainda mais suspeito. Neste caso, se as curtidas for menor que 5, adiciona 0.1 pontos ao score.

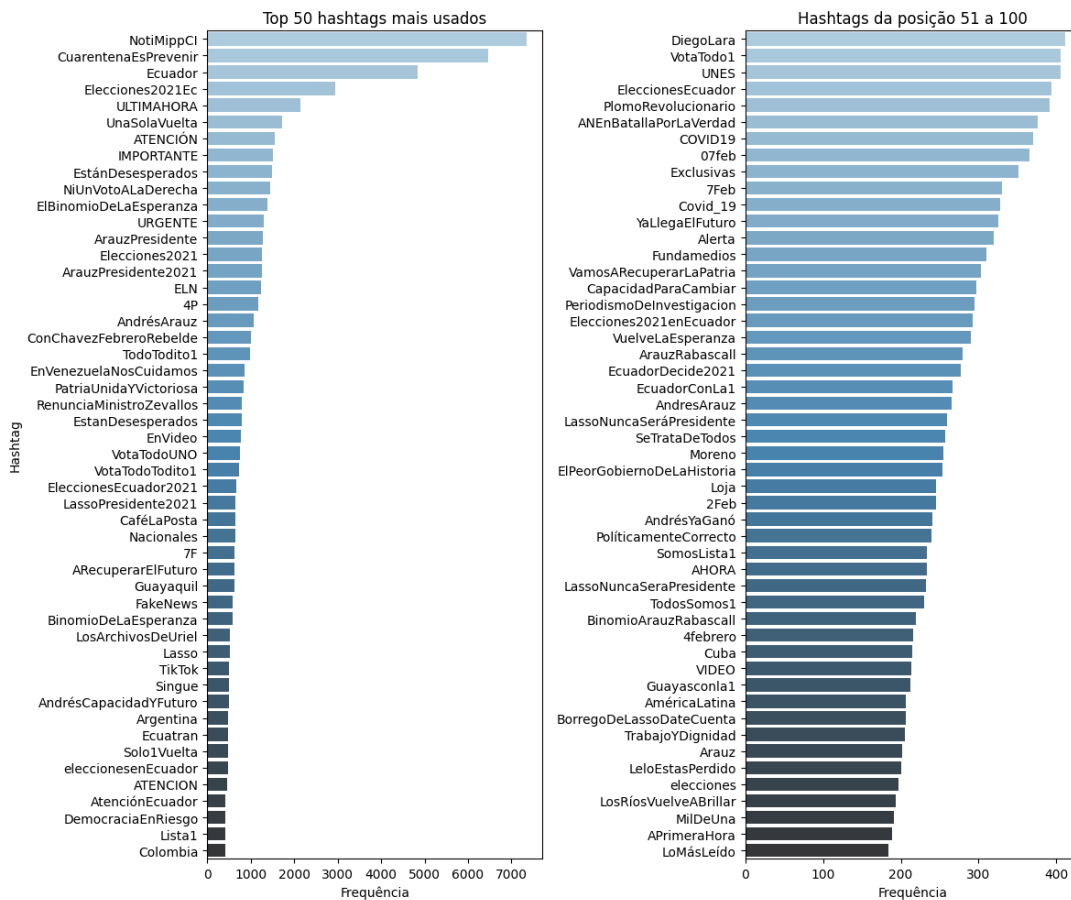
O valor total do score foi calculado para cada tweet. O limite de seleção para saber se um usuário foi um troll é 0.5; todos os valores menores que isso são considerados tweets válidos e não são descartados. A seção "depois" da tabela 3 ilustra o número de tweets para cada candidato depois da filtragem de conta fakes usando o score. O tamanho final do dataset usado para nossa análise foi de 166 451 tweets no total (117079 + 49372).

O conjunto de posts foi salvo no formato pandas onde cada coluna está descrita na tabela 2. Uma coluna com os hashtags de cada tweet foi adicionada porque o algoritmo IOM-NN está baseado em palavras-chave com as quais fazer classificação de tweets. Para isso, primeiro identificamos os hashtags em cada tweet usando expressões regulares em Python que permitem encontrar e manipular texto com base em um conjunto de regras. Neste caso, a regra foi salvar as expressões que começam pelo símbolo #. Depois salvamos esses hashtags em uma nova coluna da nossa tabela. As 100 principais hashtags podem ser vistas na figura 3. A partir desta coluna de dados, escolhemos em torno de 4 hashtags base para a iteração zero do método. Este conjunto de hashtags é chamado de palavras-chave positivas de facção (K). Esses hashtags identificados e usados para cada facção ou candidato foram os seguintes:

- **Hashtags de Arauz:** #Arauzpresidente, #AndresCapacidadyFuturo, #elBinomio-delaEsperanza, #votatodouno.
- **Hashtags de Lasso:** #Lassopresidente, #Lassoescambio, #CapacidadParaCambiar, #votatodo2.
- **Hashtags neutrais:** #elecciones2021ec, #elecciones2021, #eleccionesecuador2021.

Depois disto, as publicações coletadas passam por uma fase de pré-processamento para garantir a consistência e a qualidade dos dados. As principais modificações e filtros aplicados foram: (i) normalização do texto, que quer dizer que o texto foi convertido para minúsculas, e os caracteres acentuados são substituídos por seus equivalentes regulares; (ii) stemming (ou radicalização): as palavras são reduzidas ao seu radical para facilitar a correspondência entre formas flexionadas (ex.: votar ou votaram → vot); (iii) remoção de stop words: palavras comuns e sem peso semântico (como artigos e preposições) são removidas usando listas predefinidas; e (iv) filtragem de idioma: todas as publicações escritas em uma língua diferente do espanhol são descartadas.

Figura 3 – Visualização do top 100 de hashtags do conjunto de dados.



Fonte: Pelo autor.

3.1.3 Classificação das postagens

Nesta etapa, o algoritmo realiza a classificação das postagens coletadas na fase anterior. O processo é dividido em duas partes principais: a **iteração inicial (iteração 0)** e as **iterações de aprendizado subsequentes**.

Na iteração 0, ocorre uma classificação preliminar baseada nas palavras-chave (ou hashtags) previamente definidas para cada facção política. Os tweets que contêm exclusivamente palavras-chave ou hashtags associadas a uma única tendência política são automaticamente rotulados com essa classe. Por exemplo, hashtags específicas relacionadas ao candidato Arauz são usadas para classificar tweets na classe 0, enquanto hashtags associadas a Lasso são classificadas na classe 1. Nesta etapa, foram identificados e classificados 2305 tweets na classe 0 (candidato Arauz) e 296 tweets na classe 1 (candidato Lasso) de um total de 51660 tweets. Essa fase inicial tende a gerar um número reduzido de postagens classificadas, pois nem todos os usuários expressam apoio político utilizando explicitamente as palavras do conjunto de palavras-chave (K).

O algoritmo, nesta fase inicial, cria um modelo M_0 com base no conjunto de palavras-chave positivas (K). Esse modelo define um vetor binário, em que o valor é igual a 1 se a postagem contém pelo menos uma palavra de K , e 0 caso contrário. Todas as postagens p pertencentes ao conjunto P são então processadas conforme as seguintes operações:

- Classificar p usando o modelo M_0 , gerando o vetor binário;
- Se p estiver associada apenas a uma facção f , o par (p,f) é adicionado ao conjunto C_0 .

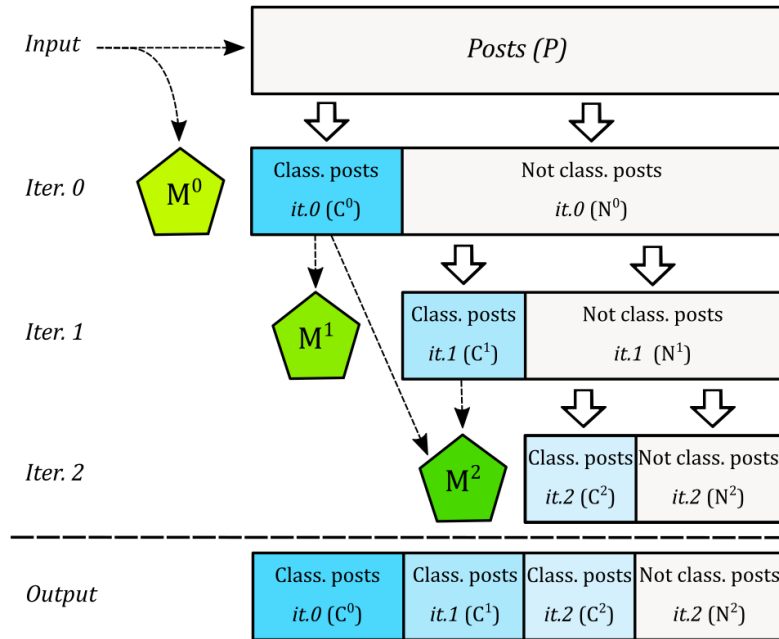
Ao final da iteração 0, o conjunto C_0 contém todas as postagens classificadas, e o conjunto $N_0 = P - C_0$ representa as postagens não classificadas. O equilíbrio entre o número de palavras-chave de cada facção é essencial para evitar vieses no processo de classificação.

Na **segunda parte do algoritmo**, inicia-se o processo de **aprendizado iterativo**, que tem como objetivo refinar a classificação das postagens restantes. O algoritmo executa até max_{iters} iterações (neste trabalho, $max_{iters} = 4$), e em cada uma delas realiza as seguintes etapas:

1. Inicializa-se um conjunto vazio C_i para armazenar as postagens classificadas na iteração i ;
2. Constrói-se um novo modelo M_i treinando uma rede neural perceptron multicamadas (MLP) com todas as postagens classificadas nas iterações anteriores ($C_0 \cup \dots \cup C_{i-1}$);
3. O conjunto de treinamento é balanceado por meio de random under-sampling, evitando que o modelo aprenda de forma enviesada para classes majoritárias;
4. Cada postagem não classificada de N_{i-1} é processada por M_i , produzindo um vetor de probabilidades v_p , em que $v_p[j]$ representa a probabilidade de apoio à facção f_j ;
5. Se o maior valor de v_p for superior ao limiar de polarização th_t , a postagem é atribuída à facção correspondente e adicionada a C_i ;
6. Ao final da iteração, C_i é incorporado a C , e N_i é definido como $N_{i-1} - C_i$;
7. O processo é interrompido caso a razão $\frac{C_i}{N_{i-1}}$ seja inferior a eps ou superior a $1 - eps$.

Ao término das iterações, o algoritmo retorna um dicionário C contendo todas as postagens classificadas em diferentes fases do processo. Como os parâmetros da rede

Figura 4 – Exemplo do algoritmo de classificação de postagens para duas iterações.



Fonte: Imagem tomada do (Belcastro *et al.*, 2020).

neural são inicializados aleatoriamente, a classificação é executada múltiplas vezes, com diferentes sementes, para reduzir o risco de convergência a mínimos locais. A Figura 4 ilustra o funcionamento geral do algoritmo de classificação a partir do conjunto inicial de postagens P .

Durante as iterações seguintes, o modelo M_i é continuamente aprimorado ao ser treinado com a união de todos os conjuntos previamente classificados ($C_0 \cup \dots \cup C_{i-1}$), até que a taxa de crescimento de novas classificações atinja o limite definido por *eps*. Ao final do processo, todas as postagens classificadas são reunidas no conjunto total C , enquanto as restantes (N_i) são consideradas neutras.

A Tabela 4 exemplifica o funcionamento do algoritmo em um subconjunto de seis tweets do dataset. A entrada do algoritmo é composta pelo conjunto de tweets e pelas palavras-chave das facções políticas. Por exemplo, na iteração 0, o modelo M_0 classifica três tweets; na iteração 1, o modelo M_1 , treinado com C_0 , infere novas regras de classificação. Entre as novas associações aprendidas, o modelo identifica, por exemplo:

- Postagens com as palavras *#ecuador*, *#creo* e *#ElCambioEstaEnTusmanos* são associadas ao candidato Lasso, por tratarem de frases relacionadas à palavra *cambio*;
- Postagens contendo *#EcuadorTodo1* e *#YaLlegaElFuturo* são associadas ao candidato Arauz, em referência ao hashtag base do candidato.

Nas iterações seguintes, o modelo aprende novas relações semânticas, como temas de imigração ou economia, refletindo as divergências entre os candidatos. O processo de aprendizado iterativo é encerrado quando não há mais novas regras a serem inferidas nem postagens passíveis de classificação

Os modelos M são perceptrons multicamadas compostas por três camadas. A primeira camada recebe um vetor *one-hot* de hashtags, obtido com o método *CountVectorizer*⁴, que transforma a coleção de hashtags em uma matriz numérica de contagem de tokens (Pedregosa *et al.*, 2012). A camada oculta possui o mesmo número de neurônios que a camada de entrada, e a camada de saída com função de ativação *softmax*, contem dois neurônios correspondentes às classes políticas (1, 0) para Arauz e (0, 1) para Lasso.

Tabela 4 – Exemplo de como funciona o algoritmo de classificação de postagens.

Iteration	TweetId	Tweet	UserId	Class
Iter. 0	t1	#UnaSolaVuelta el Ecuador ya tiene presidente con Andrés Arauz, vamos con @ecuarauz En una sola vuelta #ElBinomioDeLaEsperanza #ARrecuperarElFuturo	u1	Pro-Arauz
	t2	#YaLlegaElFuturo no nos pueden arrebatar nuestra democracia #EcuadorTodo1 y todos ganaremos con Andrés Arauz, el candidato que luchará por solucionar nuestras necesidades	u1	Não classificado
	t3	Un país con educación es un país con un futuro próspero. Con Guillermo Lasso será posible. #ElCambioEstáEnTusManos #LassoPresidente2021	u2	Não classificado
	t4	Los Correistas lo pusimos al shunso de Moreno y los banqueros lo compraron. #Lasso ha cogobernado. Desde 2018 CREO no ha dejado de apoyar en la Asmblea leyes propuestas por el Lerdin!! #Ecuador	u3	Não classificado
	t5	FELICIDADES MI PRESIDENTE ANDRÉS ARAUZ #ArauzPresidente2021 #ArauzPresidente #ecuarauz #HappyBirthday #Presidente #MiPanaAndrez	u4	Pro-Arauz
	t6	#LaBarraDelEmpleo es la barra de Guillermo Lasso. #CapacidadParaCambiar #LassoPresidente2021	u5	Pro-Lasso
...				
Iter. 1	t4	Los Correistas lo pusimos al shunso de Moreno y los banqueros lo compraron. #Lasso ha cogobernado. Desde 2018 CREO no ha dejado de apoyar en la Asmblea leyes propuestas por el Lerdin!! #Ecuador	u3	Pro-Lasso
	...			
Iter. 2	t2	#YaLlegaElFuturo no nos pueden arrebatar nuestra democracia #EcuadorTodo1 y todos ganaremos con Andrés Arauz, el candidato que luchará por solucionar nuestras necesidades	u1	Pro-Arauz
	t3	Un país con educación es un país con un futuro próspero. Con Guillermo Lasso será posible. #ElCambioEstáEnTusManos #LassoPresidente2021	u2	Pro-Lasso
	...			

Fonte: Pelo autor.

⁴ CountVectorizer é uma classe da biblioteca Scikit-learn que pode ser encontrada no site oficial <https://scikit-learn.org/stable/>

3.1.4 Polarização dos usuários

Nesta etapa, os votos dos usuários são contabilizados com base nas postagens previamente classificadas pelo modelo. A partir dessa coleção de tweets, foi gerada uma tabela onde cada linha corresponde a uma publicação contendo o identificador do usuário e a classe atribuída pelo modelo de classificação, sendo **0** para o candidato Arauz e **1** para o candidato Lasso.

Para cada usuário, constrói-se um vetor de contagens denominado **preferências**, que indica o número de tweets classificados em cada classe. Por exemplo, um usuário que publicou 10 tweets, sendo 8 classificados na classe 0 (Arauz) e 2 na classe 1 (Lasso), terá o vetor **preferências** = [8, 2]. Com base nesse vetor, definem-se as seguintes variáveis:

- **p** = **max(preferências)** → número de tweets na classe dominante (por exemplo, 8);
- **s** = **sum(preferências)** → número total de tweets publicados pelo usuário (por exemplo, 10);
- **polarização** = **p / s** → grau de polarização do usuário, isto é, a proporção de seus tweets pertencentes à classe dominante (por exemplo, 0,8).

A partir dessas informações, realiza-se a filtragem dos usuários considerados válidos para o cálculo das previsões. Um usuário é aceito se atender simultaneamente aos seguintes critérios:

1. possuir uma polarização superior ao limiar definido $th_u = 2/3$ (polarização > 0.67);
2. ter publicado pelo menos $min_{tweets} = 5$ tweets ($s \geq 5$);
3. não ultrapassar o limite máximo de $max_{tweets} = 100$ tweets ($s \leq 100$), evitando que usuários ou bots hiperativos dominem a amostra.

Somente os usuários que satisfazem essas três condições são incluídos no cálculo das previsões. As estimativas agregadas são então obtidas por meio de três métricas heurísticas: **H1**, **H2** e **H3**. Essas heurísticas são definidas da seguinte forma:

- **H1**: considera apenas a contagem de usuários. Cada usuário representa um voto inteiro para sua classe dominante ($resultado_1[class] += 1$).
- **H2**: leva em conta a força da polarização. Cada voto é ponderado pela proporção de tweets pertencentes à classe dominante ($resultado_2[class] += p/s = 0.8$).

- **H3:** considera as proporções de ambas as classes, distribuindo o peso do voto de acordo com a proporção de tweets em cada uma delas (resultado₃ += preferências / s = [0.8, 0.2]).

Por exemplo, supondo $min_{tweets} = 5$ e $th_u = 2/3$, um usuário A com 10 tweets, dos quais 8 são da classe 0 e 2 da classe 1 (**preferências** = [8, 2]), terá $s = 10$, $p = 8$ e $p/s = 0.8$. Como sua polarização é superior ao limiar, ele é considerado válido. Nesse caso H1 contribui com 1 voto à classe 0, H2 contribui com 0,8 de um voto à classe 0 e H3 contribui com [0.8, 0.2] votos distribuídos entre as classes 0 e 1.

Um usuário B com preferências = [3, 2], $s=5$, $p=3$, $p/s=0.6$, não é aprovado, pois sua polarização está abaixo do limiar ($0.6 < th_u$). Assim, não contribui com votos na predição final. Já um usuário C, com preferências = [4, 1] e valores $s=5$, $p=4$, $p/s=0.8$, satisfaz o limiar e contribui de forma análoga ao usuário A, segundo as proporções definidas por cada heurística.

3.1.5 Avaliação da performance da rede neural

A avaliação das predições depende da performance do algoritmo de classificação. Para quantificar a qualidade das predições em tarefas de classificação, as seguintes métricas foram utilizadas: acurácia e F1-macro. O cálculo das métricas utiliza o número de casos verdadeiros positivos (TP), verdadeiros negativos (TN), falsos positivos (FP) e falsos negativos (FN).

A acurácia indica a proporção de predições corretas em relação ao total de amostras, oferecendo uma visão geral do modelo. Embora seja uma medida útil, a acurácia pode ser insuficiente em cenários com classes desbalanceadas, onde o modelo pode alcançar alta acurácia favorecendo a classe majoritária. Seu cálculo é definido por:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.1)$$

3.2 Considerações finais

Neste capítulo foram detalhadas as etapas práticas adotadas para aplicar a metodologia IOM-NN ao caso das eleições do Equador. A descrição da coleta, limpeza, classificação iterativa e das heurísticas de polarização evidencia a viabilidade operacional do método em um contexto real. Esses procedimentos formam a base técnica que permite, no capítulo seguinte, avaliar o desempenho e as implicações dos resultados obtidos.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados e discutidos os resultados obtidos a partir das experimentações realizadas com o método IOM-NN ajustados ao contexto do projeto. A análise visa avaliar não apenas o desempenho do método em termos de métricas quantitativas, como acurácia, mas também interpretar esses resultados levando em consideração os objetivos estabelecidos no capítulo anterior.

A tabela 5 mostra os resultados obtidos em cada iteração para uma rodada do código, especificando o número de tweets classificados e não classificados, a razão $C_i/(N^{i-1})$ e a precisão da rede neural. O limiar de polarização de tweets th_t ¹ e o incremento mínimo eps ² foram definidos como 0.6 e 5%, respectivamente. Neste teste, o algoritmo de pós-classificação terminou em 3 iterações, anotando 12 752 tweets, o que representou cerca de 24.68% do total de tweets de entrada.

O método IOM-NN permitiu analisar o comportamento desses usuários que escreveram os 51 660 tweets a fim de determinar seu grau de polarização em relação às facções consideradas. Segundo a tabela 5 os resultados indicam que, em termos de acurácia, os modelos apresentam desempenho bom em todas as iterações.

Tabela 5 – Resultados parciais para cada iteração alcançados na primeira rodada.

Iter	Tweet input	Classificado (Cⁱ)	Não class. (Nⁱ)	% de tweets class.	$\frac{C^i}{N^{i-1}}$	Acurácia train/teste
0	51 660	2601	49 059	5.03	5.03	–
1	49 059	4807	44 252	9.31	9.80	0.994/0.994
2	44 252	4566	39 686	8.83	9.31	0.990/0.989
3	39 686	778	38 908	1.51	1.75	0.995/0.994
Total	51660	12752	38908	24.68	–	–

Fonte: Pelo autor.

Como os parâmetros da rede neural são inicializados de forma aleatória, o processo foi repetido cinco vezes com diferentes sementes, de modo a avaliar a estabilidade e a convergência dos resultados. A tabela 6 mostra uma comparação das porcentagens obtidas para as três heurísticas definidas anteriormente H1, H2 e H3 separadas por candidato: Arauz e Lasso.

Os resultados mostram que, em quatro das cinco rodadas, as heurísticas atribuíram

¹ A rede neural considera um tweet polarizado se sua probabilidade prevista for maior que th_t .

² Corresponde à sensibilidade ao progresso por iteração. Se a taxa dos classificados e não classificados da iteração anterior for menor que eps , o processo para.

Tabela 6 – Porcentagens obtidas para diferentes heurísticas com base no conjunto de dados do primeiro turno da eleição presidencial do Equador em 2021.

Rodada	Candidato Arauz			Candidato Lasso		
	H1	H2	H3	H1	H2	H3
primeira (3 iteracoes)	50.17	50.20	44.98	2.29	2.26	7.48
segunda (2 iteracoes)	49.64	49.88	48.16	2.82	2.58	4.30
terceira (2 iteracoes)	47.93	48.19	45.93	4.53	4.27	6.53
quarta (2 iteracoes)	49.14	49.38	47.45	3.32	3.08	5.01
quinta (3 iteracoes)	33.99	33.72	30.84	18.47	18.74	21.62
Valores médios	46.17	46.27	43.47	6.29	6.19	8.99
Porcentagens reais		32.72			19.74	

Fonte: Pelo autor.

ao candidato Arauz entre 47% e 50% de apoio, enquanto o candidato Lasso obteve valores entre 2% e 7%. No entanto, na quinta rodada, as três heurísticas convergiram para valores muito próximos aos resultados reais da eleição de 2021: aproximadamente 32% para Arauz e 19% para Lasso. Essa rodada apresentou, portanto, a melhor aproximação entre previsão e resultado real.

A tabela 7 resume os valores promédios considerando as heurísticas H1, H2 e H3 ou H2 e H3 de todas as rodadas, assim como na quinta rodada. Como pode ser visto, apesar da discrepância numérica, o método mostra-se consistente em apontar o vencedor, reforçando sua robustez qualitativa.


Tabela 7 – Porcentagens obtidas considerando o promedio de H1, H2 e H3.

	Arauz %	Lasso %
Porcentagens reais	32.72	19.74
<i>promedio H2 e H3</i>	44.87	7.59
<i>promedio H1, H2, H3</i>	45.30	7.16
<i>Só quinta rodada (H2 e H3)</i>	32.28	20.18

Fonte: Pelo autor.


As figuras 5 e 6 mostram a evolução da função de perda e da acurácia durante o treinamento da rede neural em uma das rodadas. Observa-se uma redução gradual da função de perda e um aumento consistente da acurácia, indicando boa convergência do modelo. Resultados semelhantes foram observados nas demais rodadas, o que reforça a estabilidade do processo de treinamento.

Figura 5 – Função de perda no treinamento da rede neural na primeira iteração de uma das rodadas.



Fonte: Pelo autor.

Figura 6 – Acurácia no treinamento da rede neural na primeira iteração de uma das rodadas.



Fonte: Pelo autor.

4.1 Comparação com outros estudos

Os resultados obtidos neste trabalho podem ser comparados aos estudos identificados na revisão de literatura. Trabalhos baseados em volume de postagens, como (Tumasjan *et al.*, 2010) e (Skoric *et al.*, 2012), mostraram que a simples contagem de menções possui correlação limitada com resultados eleitorais e tende a enviesar a predição em favor do candidato mais citado, a mesma tendência observada em nossas rodadas que superestimaram Arauz devido ao maior volume de tweets classificados a ele.

Abordagens baseadas em análise de sentimentos, como as utilizadas por (Quelal *et al.*, 2022) e (Myilvahanan *et al.*, 2023), demonstram maior precisão ao captar polaridade textual, mas dependem fortemente do desempenho de modelos supervisionados e de dicionários linguísticos. Em contraste, a metodologia IOM-NN empregada neste trabalho utiliza um processo iterativo para aprender a partir de um conjunto de palavras-chave conhecidas, que são então usadas para treinar modelos e classificar outros tweets.

O estudo de (Belcastro *et al.*, 2020), criadores da IOM-NN, demonstrou que a metodologia obtém resultados próximos aos das pesquisas tradicionais em cenários com dois candidatos bem definidos. Nossos resultados reproduzem essa tendência, embora as estimativas numéricas tenham variado, todas as execuções identificaram corretamente o candidato vencedor, confirmando a robustez qualitativa do método.

Assim, este trabalho reforça que a metodologia IOM-NN apresenta desempenho competitivo quando comparada a técnicas tradicionais de previsão eleitoral, especialmente em ambientes onde a disponibilidade de dados estruturados é limitada e as postagens refletem forte polarização.

4.2 Considerações finais

Os resultados mostram que a metodologia IOM-NN alcançou estimativas próximas aos resultados oficiais, identificando corretamente o vencedor do primeiro turno. A discussão sobre variações entre execuções, desequilíbrio de dados e limitações do processo reforça a robustez qualitativa do método, ao mesmo tempo que aponta possibilidades de refinamento.

5 CONCLUSÕES E DISCUSSÃO

Este trabalho propôs o uso da metodologia IOM-NN, para estimar a polarização da opinião pública em relação ao primeiro turno nas eleições de Equador de 2021. A metodologia usada, disponível na literatura¹, depende de um procedimento iterativo baseado em redes neurais feed-forward para analisar as hashtags das postagens publicadas por usuários de Twitter.

Os resultados obtidos ao longo das cinco execuções do algoritmo IOM-NN indicam que, apesar das variações entre as rodadas, o modelo foi capaz de prever corretamente o candidato vencedor do primeiro turno das eleições presidenciais do Equador em 2021. Também foi observado que, na maioria das execuções, as porcentagens estimadas para o candidato Andrés Arauz ficaram próximas de 49%, enquanto para Guillermo Lasso variaram entre 3% e 7%. Esses valores diferem significativamente dos resultados reais (32,72% e 19,74%, respectivamente), mas mantêm a tendência correta de vitória de Arauz, o que demonstra que o modelo capturou de forma geral a polarização das interações na rede social.

A quinta rodada apresentou um comportamento distinto das demais, aproximando-se mais dos valores reais com 33,99% para Arauz e 18,47% para Lasso. Essa aproximação pode estar associada a fatores estocásticos do processo de treinamento da rede neural, uma vez que os pesos iniciais do modelo são inicializados aleatoriamente. Assim, diferentes execuções podem ter conduzido o modelo a mínimos locais distintos na função de erro, resultando em variações no desempenho. Outro fator que pode ter contribuído é o número de iterações realizadas nessa rodada (três iterações, semelhante à primeira), o que pode ter permitido um ajuste mais equilibrado das regras de classificação e uma melhor generalização dos padrões de linguagem presentes nos tweets.

É importante destacar que, neste trabalho, apenas dois candidatos foram considerados — Andrés Arauz e Guillermo Lasso —, embora o primeiro turno de 2021 tenha contado com dezesseis candidatos. Essa limitação foi imposta apenas pela disponibilidade de dados. Essa simplificação pode ter introduzido viés no processo de classificação, uma vez que tweets referentes a outros candidatos foram eventualmente classificados como pertencentes a uma das duas classes principais. Esse fenômeno poderia ter inflado artificialmente as proporções atribuídas aos dois candidatos analisados.

Outro ponto relevante diz respeito à origem dos dados. Os tweets utilizados foram obtidos de um repositório público no GitHub, que coletou publicações por meio de palavras-chave genéricas como “Andrés Arauz”, “Arauz”, “Guillermo Lasso” e “Lasso”, extraídas

¹ <https://github.com/SCAlabUnical/IOM-NN>

via API do Twitter em 2021. Embora o repositório seja confiável, o fato de não termos realizado a coleta diretamente e de termos dependido de um conjunto já filtrado pode ter influenciado a representatividade e o equilíbrio das amostras. Do total de 171.528 posts, aproximadamente 120.000 referem-se a Arauz e 50.000 a Lasso, uma diferença que se mantém mesmo após a remoção de contas falsas. Esse desequilíbrio de classes tende a afetar o processo de aprendizado da rede, favorecendo o candidato com maior volume de dados e levando o modelo a superestimar a popularidade de Arauz.

Neste sentido e com base na análise dos resultados e na metodologia aplicada, é possível identificar algumas fontes potenciais de erro que poderiam explicar a diferença entre as porcentagens previstas e as reais: (i) limitação do conjunto de candidatos, considerando apenas dois candidatos, onde o modelo foi forçado a classificar tweets de outros candidatos em uma das duas categorias, distorcendo as proporções finais; e (ii) aleatoriedade na inicialização da rede neural de tal forma que diferentes seeds podem levar a mínimos locais distintos, resultando em variações nos resultados entre rodadas; (iii) ruído e ambiguidades nos hashtags podem ter sido mal interpretadas pela rede, afetando a precisão da classificação; e (iv) dependência de dados de terceiros, implicando falta de controle sobre a amostragem e eventuais vieses de coleta, como a predominância de determinados grupos políticos ou regiões geográficas.

Finalmente, apesar dessas limitações, o modelo IOM-NN demonstrou capacidade de identificar tendências políticas gerais e de reproduzir o comportamento agregado dos usuários no Twitter durante o período eleitoral. Embora as estimativas numéricas apresentem discrepâncias, a correta predição do vencedor evidencia o potencial do método para análises exploratórias de sentimento político em redes sociais. Em trabalhos futuros, a inclusão de todos os candidatos e a coleta direta dos dados de forma mais rigorosa poderão aprimorar a precisão e a robustez dos resultados obtidos.

REFERÊNCIAS

- BAPTISTA, R. **Redes sociais influenciam voto de 45% da população, indica pesquisa do DataSenado**. 2019. Disponível em: <https://www12.senado.leg.br/noticias/materias/2019/12/12/redes-sociais-influenciam-voto-de-45-da-populacao-indica-pesquisa-do-datasenado>. Acesso em: 2025-05-11.
- BELCASTRO, L. *et al.* Learning political polarization on social media using neural networks. **IEEE Access**, v. 8, p. 47177–47187, 2020.
- BOVET, A.; MAKSE, H. A. Influence of fake news in twitter during the 2016 us presidential election. **SN Computer Science**, v. 10, p. 7, Jan. 2019. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/30602729/>.
- BRITO, K.; ADEODATO, P. J. L. Machine learning for predicting elections in latin america based on social media engagement and polls. **Government Information Quarterly**, v. 40, n. 1, p. 101782, 2023. ISSN 0740-624X. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0740624X22001186>.
- BRITO, K. d. S.; ADEODATO, P. J. L. Predicting brazilian and u.s. elections with machine learning and social media data. *In: 2020 International Joint Conference on Neural Networks (IJCNN)*. [S.l.: s.n.], 2020. p. 1–8.
- CNE. **Presentación de resultados finales elecciones generales 2021**. 2021. Disponível em: <https://app01.cne.gob.ec/Resultados2021>. Acesso em: 2025-10-28.
- DIAZ, J. *et al.* Identifying bot accounts on twitter during the 2023 ecuadorian presidential election. **PREPRINT (Version 1) available at Research Square**, 01 2024. Disponível em: <https://doi.org/10.21203/rs.3.rs-3867297/v1>.
- DIGRAZIA, J. *et al.* More tweets, more votes: Social media as a quantitative indicator of political behavior. **PLOS ONE**, Public Library of Science, v. 8, n. 11, p. 1–5, 11 2013. Disponível em: <https://doi.org/10.1371/journal.pone.0079449>.
- ECUAVISA. **La segunda vuelta en las redes, ¿más ficción que realidad?** 2021. Disponível em: <https://www.ecuavisa.com/noticias/la-segunda-vuelta-en-las-redes-mas-ficcion-que-realidad-LJEC697581>. Acesso em: 2025-09-02.
- ESPIN-RIOFRIO, C. *et al.* Determining political affinity of ecuadorian twitter users using machine learning techniques for authorship attribution. *In: 20th LACCEI International MultiConference for Engineering, Education, and Technology*. [S.l.: s.n.], 2022. Disponível em: <http://dx.doi.org/10.18687/LACCEI2022.1.1.535>.
- GAYO-AVELLO, D. No, you cannot predict elections with twitter. **IEEE Internet Computing**, v. 16, n. 6, p. 91–94, 2012.
- GIGLIETTO, F. If likes were votes: An empirical study on the 2011 italian administrative elections. **Proceedings of the International AAAI Conference**

on **Web and Social Media**, v. 6, n. 1, p. 471–474, Aug. 2021. Disponível em: <https://ojs.aaai.org/index.php/ICWSM/article/view/14286>.

KEMP, S. **Digital 2024 Global Overview Report**. 2024. Disponível em: <https://datareportal.com/reports/digital-2024-global-overview-report>. Acesso em: 2025-05-11.

MACIAS, M. A.; CAMPOBERDE, J. **SentimentAnalysisEcuador2021**. [S.l.: s.n.]: GitHub, 2021. <https://github.com/MigeruDev/SentimentAnalysisEcuador2021.git>.

MIKOLOV, T. *et al.* **Efficient Estimation of Word Representations in Vector Space**. 2013. Disponível em: <https://arxiv.org/abs/1301.3781>.

MYILVAHANAN, K. *et al.* A study on election prediction using machine learning techniques. In: **2023 Third International Conference on Artificial Intelligence and Smart Energy (ICAIS)**. [S.l.: s.n.], 2023. p. 1518–1520.

NEUPERT, T. *et al.* **Introduction to Machine Learning for the Sciences**. 2022. Disponível em: <https://arxiv.org/abs/2102.04883>.

PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in python. **Journal of Machine Learning Research**, v. 12, 01 2012.

QUELAL, A. *et al.* Identifying the political tendency of social bots in twitter using sentiment analysis: A use case of the 2021 ecuadorian general elections. In: ABAD, K.; BERREZUETA, S. (ed.). **Doctoral Symposium on Information and Communication Technologies**. Cham: Springer International Publishing, 2022. p. 184–196. ISBN 978-3-031-18347-8.

RAJADESINGAN, A.; LIU, H. Identifying users with opposing opinions in twitter debates. In: KENNEDY, W. G.; AGARWAL, N.; YANG, S. J. (ed.). **Social Computing, Behavioral-Cultural Modeling and Prediction**. Cham: Springer International Publishing, 2014. p. 153–160. ISBN 978-3-319-05579-4.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, v. 323, p. 533–536, 1986. Disponível em: <https://api.semanticscholar.org/CorpusID:205001834>.

SHWETA, K.; PRASAD, S. M. Machine learning-based election results prediction using twitter activity. **SN Computer Science**, v. 5, p. 819, Aug. 2024. Disponível em: <https://doi.org/10.1007/s42979-024-03180-x>.

SKORIC, M. *et al.* Tweets and votes: A study of the 2011 singapore general election. In: **2012 45th Hawaii International Conference on System Sciences**. [S.l.: s.n.], 2012. p. 2583–2591.

SMITH, N. A. **Contextual Word Representations: A Contextual Introduction**. 2020. Disponível em: <https://arxiv.org/abs/1902.06006>.

TUMASJAN, A. *et al.* Predicting elections with twitter: What 140 characters reveal about political sentiment. **Proceedings of the International AAAI Conference on Web and Social Media**, v. 4, n. 1, p. 178–185, May 2010. Disponível em: <https://ojs.aaai.org/index.php/ICWSM/article/view/14009>.

WIJESEKARA, M.; GANEGODA, G. U. Source credibility analysis on twitter users. *In: 2020 International Research Conference on Smart Computing and Systems Engineering (SCSE)*. [*S.l.: s.n.*], 2020. p. 96–102.