

Desenvolvimento de Ferramenta de Análise de Sentimentos para Identificação de Possíveis Sinais de Comportamento Depressivo na Rede Social Twitter

Luan Mendes Gonçalves Freitas¹, Marcelo Ladeira¹, Marcos Fagundes Caetano¹

¹Departamento de Ciência da Computação (CIC)
Universidade de Brasília (UnB), 70910-900, Brasília, DF, Brazil.

luan.mendes@aluno.unb.br / luan.mgf@gmail.com, {mladeira, mfcaetano}@unb.br

Abstract. Research on computerized models for identifying mental health issues in social media users has grown since the 2000s, mainly in English. Choudhury et al. and Coppersmith et al. proposed a method to detect depressive behavior using key attributes from Twitter posts, such as tweet quantity, personal pronouns, depressive terms, emotional tone, posting time, mentions of antidepressants, and follower responses. However, these posts are from before 2014 and don't represent current Twitter user behavior, which now includes oriental characters, emojis, links, media (photos, videos, and gifs), and likes. Two databases of Portuguese tweets were created, covering pre-pandemic (01/01/2018 to 31/12/2019) and pandemic periods (01/01/2020 to 31/12/2021), divided into two categories: "depression" and "control," representing users with and without depression. These databases were used to assess the impact of the new attributes and develop a model for detecting depressive behavior through sentiment analysis of Portuguese tweets.

Resumo. A pesquisa sobre modelos computadorizados para identificar problemas de saúde mental em usuários de redes sociais tem crescido desde os anos 2000, principalmente em inglês. Choudhury et al. e Coppersmith et al. propuseram um método para detectar comportamento depressivo usando atributos-chave de postagens no Twitter, como quantidade de tweets, pronomes pessoais, termos depressivos, tom emocional, horário de postagem, menções a antidepressivos e respostas de seguidores. Para verificar se essas novas formas de expressão melhoraram o desempenho do modelo, este projeto amplia o trabalho de Choudhury et al. e Coppersmith et al. introduzindo cinco novos atributos: caracteres orientais, emojis, mídia, links e curtidas. Foram criadas duas bases de dados de tweets em português, abrangendo períodos pré-pandemia (01/01/2018 a 31/12/2019) e pandemia (01/01/2020 a 31/12/2021), divididas em duas categorias: "depressão" e "controle", representando usuários com e sem depressão. Essas bases de dados foram usadas para avaliar o impacto dos novos atributos e desenvolver um modelo para detectar comportamento depressivo por meio da análise de sentimentos em tweets em português.

1. Introdução

As doenças mentais, incluindo a depressão, estão entre as principais causas de desequilíbrio emocional em todo o mundo [Corbanezi 2018]. As mídias sociais, como o

Twitter, Facebook e outras redes, são amplamente usadas para compartilhar pensamentos e opiniões [Park et al. 2012], possibilitando a análise de mensagens em perfis sociais para revelar comportamentos [Stephen and P 2019]. Técnicas de Mineração de Dados e conceitos em Psicologia, Psiquiatria, Neurociência e Sociolinguística possibilitam a detecção de padrões de comportamento relacionados à depressão [De Choudhury et al. 2013] e ao transtorno de estresse pós-traumático [Coppersmith et al. 2014]. [De Choudhury et al. 2013] propuseram um método de detecção de comportamento depressivo com base em atributos derivados do conteúdo de postagens e atividades de usuários no Twitter. No entanto, essas pesquisas são anteriores a 2014 e não consideram os costumes atuais de interação dos usuários no Twitter.

Os objetivos desta pesquisa são: (1) construir duas bases de dados de tweets em português para os períodos pré-pandemia (2018-2019) e pandemia (2020-2021) usando Mineração de Dados; (2) introduzir cinco novos atributos: caracteres orientais, emojis, links, mídia (fotos, vídeos e gifs) e curtidas, e comparar os resultados com o estudo de [De Choudhury et al. 2013] para avaliar o aprimoramento das previsões dos modelos de aprendizado de máquina; (3) desenvolver um modelo de aprendizado de máquina para identificar sinais de padrões de comportamento depressivo e não depressivo em tweets e incorporá-lo a uma ferramenta de análise de sentimentos.

Este artigo está organizado da seguinte forma: a Seção 2 descreve pesquisas relacionadas à detecção de depressão no Twitter; a Seção 3 detalha a metodologia; a Seção 4 mostra os resultados da análise de dados dos tweets coletados em ambos os períodos e a avaliação dos novos atributos e modelos de algoritmos supervisionados; Por fim, a Seção 5 apresenta as conclusões do projeto e sugestões para pesquisas futuras.

2. Trabalhos Relacionados

Desde o início dos anos 2000, houve um aumento na utilização da tecnologia para compreender e prevenir distúrbios mentais. Isso incluiu a análise de textos escritos, que revelou pistas sobre tendências neuróticas e transtornos psiquiátricos [Rude et al. 2004], bem como a identificação de vieses negativos no processamento de informações verbais que podem prever a depressão subsequente [Williams and Galliher 2006]. Com o crescimento das redes sociais nos anos 2010, os pesquisadores ganharam acesso a um enorme volume de dados que permitiu obter insights relacionados à depressão e outros transtornos mentais. Usando técnicas de mineração de dados com séries temporais, foi demonstrado que esses insights podem estar associados a eventos do mundo real [Bollen et al. 2011].

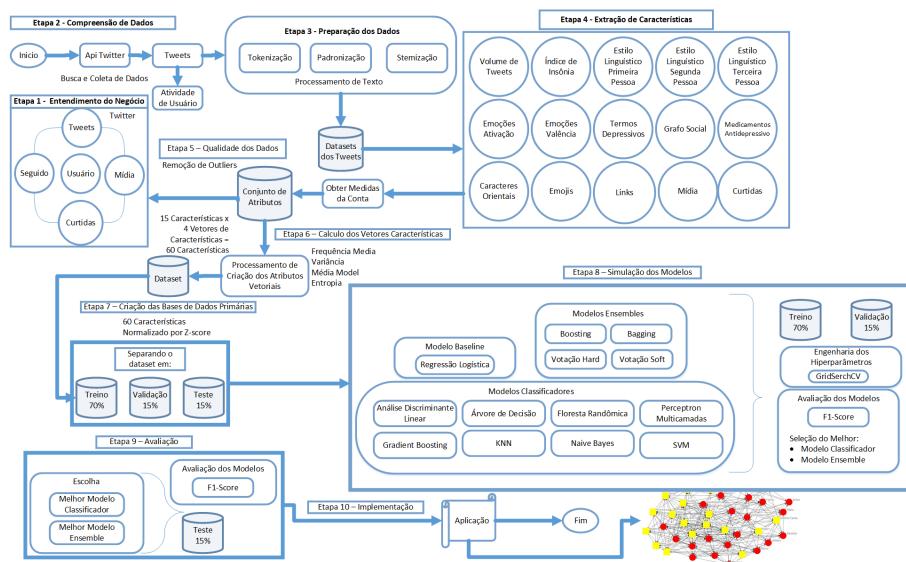
No caso do Twitter, [Park et al. 2012] encontraram evidências de que as pessoas compartilham suas experiências de depressão e tratamento na plataforma, enquanto [De Choudhury et al. 2013] desenvolveram classificadores para estimar o risco de depressão com base em atributos comportamentais relacionados ao engajamento social, emoção, estilo de linguagem, rede social e menções a medicamentos antidepressivos. [Coppersmith et al. 2014] propuseram heurísticas para automatizar a construção de conjuntos de dados, resultando em um conjunto de dados maior, abrangendo não apenas a depressão, mas também outras doenças mentais. Em estudos recentes em língua portuguesa, [von Sperling 2019, von Sperling and Ladeira 2019] extraíram atributos comportamentais relacionados ao engajamento, emoção e estilo de linguagem de tweets em português e desenvolveram um modelo para prever sinais de depressão nos usuários.

Neste artigo, propomos uma abordagem que leva em consideração múltiplos fatores comportamentais e contextuais para a análise e detecção de conteúdo relacionado à depressão, com foco em usuários de língua portuguesa. Nosso objetivo é desenvolver um modelo abrangente e preciso que contribua para uma melhor compreensão dos sinais de padrões de comportamento associados à depressão em ambientes digitais.

3. Metodologia

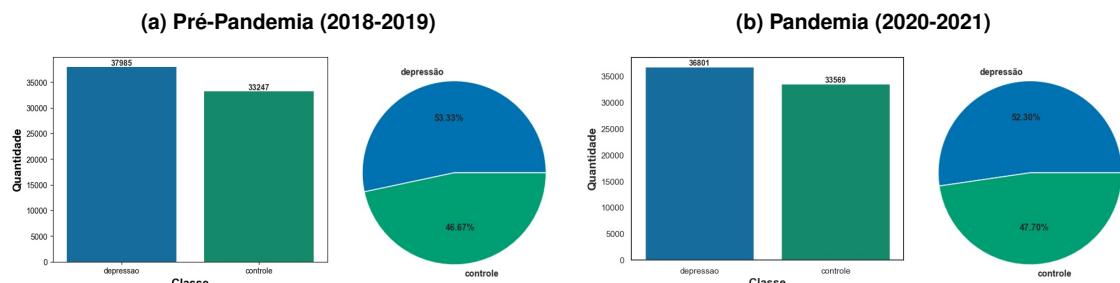
A metodologia utilizada, ilustrada na Figura 1, é composta por 10 etapas e é baseada no modelo de referência CRISP-DM [Schröer et al. 2021].

Figura 1. Metodologia do Projeto



Na **Etapa 1 - Entendimento do Negócio**, buscamos aprender e compreender a estrutura do Twitter e como utilizar a API do Twitter e o framework Snscreape [JustAnotherArchivist 2022] para extrair tweets com seus metadados. Na **Etapa 2 - Compreensão dos Dados**, realizamos duas coletas de dados de tweets públicos em dois momentos distintos: de 01/01/2018 a 31/12/2019 (antes da pandemia COVID-19) e de 01/01/2020 a 31/12/2021 (durante a pandemia). Os dados foram divididos em duas classes: "depressão" e "controle". No período pré-pandemia, coletamos um total de 71.232 usuários (37.985 depressivos e 33.247 de controle). Durante a pandemia, foram coletados 70.370 usuários (36.801 depressivos e 33.569 de controle), como mostrado na Figura 2.

Figura 2. Distribuição e Balanceamento entre as Classes



A classe "Depressão" incluiu usuários do Twitter que se declararam publicamente como depressivos, identificados por frases de autodeclaração, como "estava com depressão", "fui diagnosticado com depressão" e outras variações. A classe "Controle" consistiu em usuários que não apresentaram tweets com essas frases de autodeclaração de depressão, validando assim os dados para uso nos modelos de aprendizado de máquina supervisionado, distinguindo-os da classe "Depressão" [AlSagri and Ykhlef 2020, Mendes et al. 2021]. Para coletar os tweets de usuários que se autodeclararam como depressivos, utilizamos o framework Snscreape [JustAnotherArchivist 2022] em vez da API Tweepy do Twitter. Para a filtragem de usuários na classe "Controle", aplicamos as mesmas palavras-chave, mas com o operador de negação '-' no início, o que resultou na coleta de tweets que não continham essas palavras-chave [Hassan et al. 2020].

Na Etapa 3 - Preparação de Dados, os tweets extraídos passam pelos seguintes passos de pré-processamento: Tokenização, Padronização e Stemização. Após o pré-processamento, uma cópia do texto original é mantida para a extração dos atributos, incluindo caracteres orientais e emojis.

Na Etapa 4 - Extração das Características, extraímos 15 características dos textos dos tweets e das ações realizadas pelos usuários na plataforma Twitter. Essas características refletem o estado emocional dos usuários durante suas interações na plataforma [Britto and Pacífico 2019]. Como apresentado na Tabela 1, os dez primeiros atributos foram introduzidos por [De Choudhury et al. 2013], e os atributos 11 a 15 são novos, propostos neste projeto. Para a extração dos atributos 6, 7 e 8 foi utilizada uma base de dados auxiliar ANEW-BR [Kristensen et al. 2011], e para o atributo 10 foi construída uma base de dados de medicamentos antidepressivos usados no Brasil.

Nº	Atributo	Descrição
1	Volume de Tweets	Número de tweets postados por um usuário em um dia específico.
2	Índice de Insônia	Relação entre a quantidade de tweets postados durante a noite e durante o dia.
3	Estilo Linguístico na 1ª Pessoa	Quantidade de palavras em primeira pessoa do singular e plural.
4	Estilo Linguístico na 2ª Pessoa	Quantidade de palavras em segunda pessoa do singular.
5	Estilo Linguístico na 3ª Pessoa	Quantidade de palavras em terceira pessoa do singular e plural.
6	Valência de Emoções	Média de valência emocional nos textos dos tweets.
7	Ativação de Emoções	Média de ativação emocional nos textos dos tweets.
8	Termos Depressivos	Frequência de palavras com valência menor que 4 (palavras negativas).
9	Grafo Social	Quantidade de respostas de seguidores em resposta a um tweet.
10	Medicamentos Antidepressivos	Frequência de citações de medicamentos antidepressivos nos tweets.
11	Caracteres Orientais	Quantidade de caracteres Unicode em japonês, chinês ou coreano nos tweets.
12	Emojis	Quantidade de emojis nos tweets no intervalo Unicode.
13	Frequência de Links	Frequência de links nos tweets.
14	Mídia	Número de fotos, vídeos e gifs nos tweets.
15	Número de Curtidas	Número de curtidas recebidas nos tweets.

Tabela 1. Características e/ou Atributos

Os atributos do 11 ao 15 foram introduzidos neste projeto porque podem ser relevantes na análise e identificação de sinais de comportamento depressivo nos tweets, pois levam em consideração as diferentes formas de comunicação e expressão dos usuários no Twitter na língua portuguesa. Na **Etapa 5 - Qualidade dos Dados**, removemos os usuários com mais de 300 tweets em um dia ou menos de 30 tweets em sua conta.

Na Etapa 6 - Cálculo dos Vetores de Características, para cada um dos quinze atributos extraídos, calculamos métricas estatísticas diárias para cada usuário. Essas

métricas incluem: média, variância, média móvel ponderada e entropia. A série temporal é então substituída por um registro contendo esses quatro valores, resultando na geração de 60 (15x4) atributos para cada usuário, juntamente com seu rótulo de classe.

Na **Etapa 7 - Criação das Bases de Dados**, as duas bases de dados com 60 atributos passaram por normalização usando a técnica *Z-Score* para garantir escalas uniformes. Em seguida, aplicamos a Matriz de Correlação de Pearson [Mukaka 2012] para selecionar os 30 atributos mais significativos com baixa correlação entre os 60 atributos. Para a implementação nos classificadores, dividimos as bases aleatoriamente em 3 conjuntos principais: treino (70%), validação (15%), e teste (15%). O treino e a validação foram usados em simulações de validação cruzada com 10 *folds* para avaliar 13 modelos de algoritmos supervisionados e examinar a contribuição dos cinco novos atributos. Esses novos atributos foram avaliados junto com os atributos propostos por [De Choudhury et al. 2013]. As simulações usando os conjuntos de teste ocorrerão após a conclusão das simulações de validação, onde os 2 melhores modelos serão selecionados.

Na **Etapa 8 - Simulação dos Modelos - Aprendizado de Máquina**, antes de induzir os conjuntos de treinamento e validação nos modelos, selecionamos os hiperparâmetros dos algoritmos usando GridSearchCV, que avalia e seleciona a melhor combinação de hiperparâmetros para os modelos. Em seguida, realizamos simulações nos 13 modelos configurados nos dados de treinamento e validação, filtrando os 10 atributos de [De Choudhury et al. 2013], para avaliar e selecionar os 2 melhores: um de classificação e um ensemble. Logo após, com os modelos selecionados, avaliamos os 5 novos atributos interagindo com os 10 atributos originais. Por fim, conduzimos simulações de teste com os melhores modelos e atributos avaliados para avaliar a eficácia das bases de dados criadas e dos atributos propostos. O objetivo é avaliar se os modelos são adequados para serem incorporados a uma ferramenta de análise de sentimento que identifica possíveis sinais de padrões comportamentais depressivos no Twitter. Os dados e códigos empregados neste projeto estão disponíveis no repositório do Github.

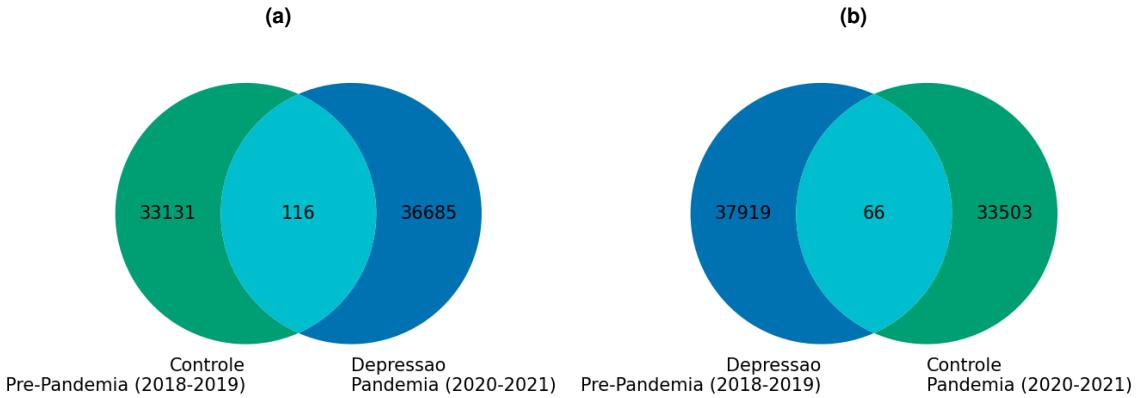
4. Resultados

Nesta seção, apresentamos os resultados da **Etapa 9 - Avaliação**, onde foi feita uma análise exploratória dos dados dos tweets obtidos nas bases coletadas nos períodos pré-pandemia (01/01/2018 a 01/01/2019) e pandemia (01/01/2020 a 01/01/2021). Também incluímos os resultados das simulações de validação aplicadas aos 13 modelos de aprendizado de máquina supervisionado usando os 10 atributos propostos por [De Choudhury et al. 2013], combinados com os 5 novos atributos. Além disso, apresentamos os resultados das simulações de teste.

4.1. Exploração de Dados

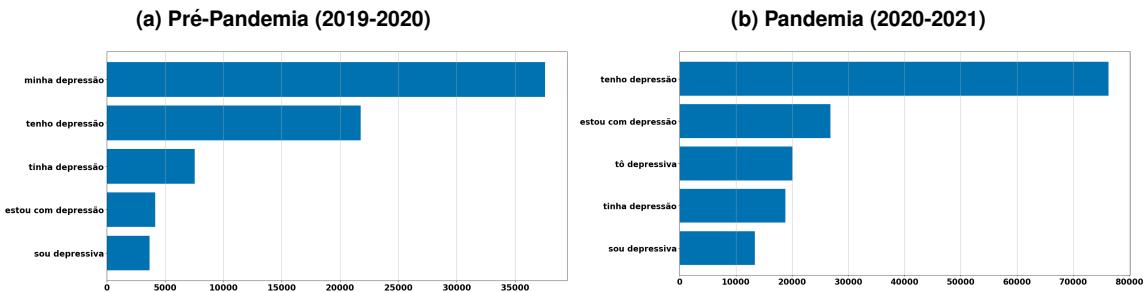
A análise das bases de dados revelou que houve movimentação de usuários do Twitter entre as categorias depressivos e controle (não depressivos). Durante o período pré-pandemia, identificamos 116 usuários que não se declararam depressivos, mas posteriormente autodeclararam depressão durante a pandemia, conforme mostrado na Figura 3a. Além disso, durante o período da pandemia, 66 usuários que não se autodeclararam depressivos anteriormente o fizeram no período pré-pandemia, conforme ilustrado na Figura 3b. Esses resultados indicam a possibilidade de mudanças nos padrões de comportamento dos usuários ao longo do tempo, mostrando sinais de padrões relacionados à depressão.

Figura 3. Interseções entre as Base de Dados



Além disso, na Figura 4, são apresentadas as cinco palavras-chave mais frequentes encontradas nos resultados da busca e filtragem de usuários que se autodeclararam depressivos nos dois períodos. No Gráfico 4a, observamos que no período pré-pandemia, as palavras-chave "minha depressão" e "tenho depressão" foram usadas aproximadamente 37.000 e 21.000 vezes, respectivamente. Já no Gráfico 4b, notamos um aumento significativo no número de usuários que se autodeclararam depressivos durante a pandemia, com mais do dobro das autodeclarações em comparação com o período pré-pandemia.

Figura 4. Top 5 - Frequência de Declarações de Depressão

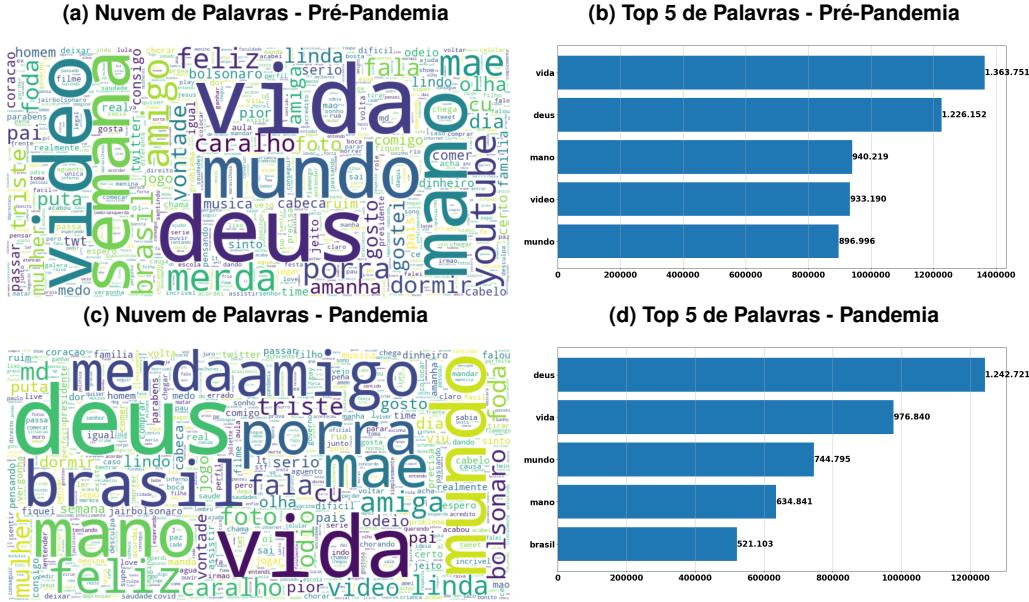


Analizando as nuvens de palavras apresentadas na Figura 5, é possível observar que os termos mais comuns nos tweets são "*Deus*" e "*vida*". Isso sugere que os usuários do Twitter estão fazendo preces a Deus por suas próprias vidas.

4.2. Avaliação dos Modelos - Validação

Na Tabela 2, apresentamos os resultados das simulações básicas, onde pré-selecionamos os dois melhores modelos somente com dados de treino e validação das bases de dados divididas. Foram induzidos 13 modelos de algoritmos de aprendizado de máquina supervisionados com hiperparâmetros selecionados e ajustados pelo GridSearchCV e com validação cruzada com 10 *folds*. Os modelos foram avaliados através das métricas de avaliação precisão (P), recall (R), F1-score (F1) e acurácia (ACC), com foco particular no F1-score (média harmônica entre precisão e recall). Os modelos que se destacaram foram Gradient Boosting (GB) e Perceptron Multicamadas (MLP) entre os demais modelos. Esses modelos foram escolhidos para as próximas simulações com foco em analisar a contribuição dos 5 novos atributos: caracteres orientais, emojis, mídia, frequência de

Figura 5. Análise de tweets de Usuários de Depressão e Controle - Pré-Pandemia



links e número de curtidas, onde avaliamos se esses novos atributos têm efeito significativo quando combinados com os 10 atributos de [De Choudhury et al. 2013].

Tabela 2. Simulações Básicas: Pré-Seleção dos Modelos

Pré-Pandemia (2018-2019)					Pandemia (2020-2021)				
Classificadores					Classificadores				
Modelo	Acurácia	Precisão	Recall	F1-Score	Modelo	Acurácia	Precisão	Recall	F1-Score
Perceptron Multicamadas (MLP)	76.1	75.5	87.4	81.0	Perceptron Multicamadas (MLP)	74.5	74.5	87.4	80.4
Árvore de Decisão (DT)	74.7	74.1	86.9	80.0	Árvore de Decisão (DT)	72.9	72.9	87.2	79.4
KNN	70.5	70.6	84.7	77.0	SVM	65.9	65.9	89.2	75.8
SVM	68.3	68.9	83.1	75.3	KNN	68.0	69.3	83.5	75.7
Análise Discriminante Linear (LDA)	66.9	67.3	84.2	74.8	Análise Discriminante Linear (LDA)	65.0	64.9	90.7	75.6
Rregressão Logística (LR) (Baseline)	58.3	58.3	100.0	73.7	Rregressão Logística (LR) (Baseline)	59.9	59.9	100.0	74.9
Naive Bayes (NB)	59.1	71.3	49.9	58.7	Naive Bayes (NB)	57.8	70.9	50.3	58.9
Ensemble									
Modelo	Acurácia	Precisão	Recall	F1-Score	Modelo	Acurácia	Precisão	Recall	F1-Score
Gradient Boosting (GB)	77.2	75.5	90.1	82.2	Gradient Boosting (GB)	75.5	74.4	90.0	81.5
Boosting	77.3	76.2	88.8	82.0	Boosting	75.6	75.0	88.8	81.3
Floresta Randômica (RF)	76.6	74.8	90.1	81.8	Floresta Randômica (RF)	74.8	73.5	90.6	81.2
Bagging	76.5	75.9	87.6	81.3	Bagging	75.1	75.2	87.3	80.8
Votação Soft	76.1	75.8	86.7	80.9	Votação Hard	74.5	74.4	87.7	80.5
Votação Hard	75.7	75.7	85.8	80.5	Votação Soft	74.1	74.4	86.4	80.0

Na Tabela 3, apresentamos os resultados das simulações com 2 modelos GB e MLP pré-selecionados nas simulações básicas, onde aplicamos os dados de validação nos modelos, realizando combinações com os 10 atributos de [De Choudhury et al. 2013], juntamente com cada um dos novos atributos individualmente, para avaliar se os atributos melhoraram ou não o desempenho do modelo. Se o atributo tivesse sucesso, ele é adicionado junto com os 10 atributos nas próximas simulações, enquanto os demais são retirados. Esse processo foi repetido até obtermos um resultado conclusivo se os atributos são úteis ou não. Analisamos e concluímos que nenhum dos novos atributos teve efeito significativo no desempenho dos modelos em comparação com os resultados das simulações básicas. Logo, os 5 atributos foram removidos, ficando somente os 10 atributos originais.

4.3. Avaliação dos Modelos - Teste

Agora apresentamos os resultados finais das simulações do projeto, onde os melhores modelos GB e MLP foram aplicados com dados de teste e somente com os 10 atributos

Tabela 3. Simulações de Validação dos Novos Atributos

Modelo	Pré-Pandemia (2018-2019)																Atributos De Choudhury + Curtidas			
	Atributos De Choudhury				Atributos De Choudhury + Caracteres Orientais				Atributos De Choudhury + Emojis				Atributos De Choudhury + Links				Atributos De Choudhury + Midia			
	ACC	P	R	F1	ACC	P	R	F1	ACC	P	R	F1	ACC	P	R	F1	ACC	P	R	F1
GB	77.2	75.5	90.1	82.2	77.2	75.5	90.2	82.2	77.3	75.9	89.5	82.1	77.0	75.4	89.9	82.0	77.3	75.6	90.1	82.2
MLP	76.1	75.5	87.4	81.0	76.4	76.0	87.0	81.1	76.3	75.9	86.9	81.0	76.3	75.7	87.5	81.2	76.1	75.6	87.2	81.0

Modelo	Pandemia (2020-2021)																Atributos De Choudhury + Curtidas			
	Atributos De Choudhury				Atributos De Choudhury + Caracteres Orientais				Atributos De Choudhury + Emojis				Atributos De Choudhury + Links				Atributos De Choudhury + Midia			
	ACC	P	R	F1	ACC	P	R	F1	ACC	P	R	F1	ACC	P	R	F1	ACC	P	R	F1
GB	75.5	74.4	90.0	81.5	75.5	74.4	90.0	81.5	76.0	74.8	90.3	81.8	75.6	74.5	90.0	81.5	75.4	74.5	89.7	81.4
MLP	74.5	74.5	87.4	80.4	74.2	74.0	87.8	80.3	75.1	75.1	87.5	80.8	74.6	74.6	87.4	80.5	74.5	74.2	88.1	80.6

de [De Choudhury et al. 2013], já que nenhum dos 5 novos atributos teve desempenho significativo nas simulações de validação. Os modelos tiveram resultados promissores, com média de F1-score em torno de 80%. Com isso, concluímos que os resultados são promissores, sugerindo que os modelos têm a capacidade de serem incorporados com sucesso em uma ferramenta de análise de sentimentos na **Etapa 10 - Implementação** na tarefa de detecção de sinais de padrões de comportamento depressivo em novos dados de usuários do Twitter.

Tabela 4. Simulações de Teste: Resultados Finais

Modelo	Pré-Pandemia (2018-2019)								Pandemia (2020-2021)								Média F1-Score			
	Experimento - 10 Atributos De Choudhury				Experimento - 10 Atributos De Choudhury				Experimento - 10 Atributos De Choudhury				Experimento - 10 Atributos De Choudhury				Experimento - 10 Atributos De Choudhury			
	Acurácia	Precisão	Recall	F1-Score	80.75	80.0	80.75	80.0												
Gradient Boosting (GB)	76.8	75.5	88.9	81.6	74.2	73.2	87.8	79.9	75.4	74.5	89.7	81.4	75.6	74.5	90	81.5				
Perceptron Multicamadas (MLP)	75.8	75.4	86.5	80.6	74.2	74.2	85.4	79.4	74.5	74.2	88.1	80.6	74.5	74.2	88	80.6				

5. Discussão/Conclusão

Este projeto destaca o potencial de utilizar o Twitter como ferramenta para identificar padrões de comportamento associados à depressão em usuários de língua portuguesa. Foram coletados dados de tweets usando o framework Snscape e construídas duas bases de dados abrangendo períodos pré-pandemia e pandemia, cada uma com 10 atributos propostos por [De Choudhury et al. 2013] e 5 novos atributos para melhorar a detecção de comportamento depressivo no Twitter. Os resultados não mostraram evidências estatísticas significativas de que a pandemia COVID-19 tenha causado um aumento nos casos de depressão.

Foram realizadas simulações de validação com 13 modelos de aprendizado de máquina, destacando os modelos Gradient Boosting (GB) e Perceptron Multicamadas (MLP). No entanto, os 5 novos atributos propostos não contribuíram significativamente para melhorar o desempenho dos modelos e foram excluídos das simulações de teste. Nas simulações de teste, o modelo GB obteve uma média de F1-Score de 81,0%, e o modelo MLP alcançou uma média de F1-Score de 80,2%. Esses resultados indicam que esses modelos têm potencial para serem incorporados em uma ferramenta de análise de tweets na detecção de sinais de padrões de comportamento depressivo.

Para trabalhos futuros, sugere-se a inclusão de novos atributos relacionados a aspectos sociais e a outros transtornos mentais, bem como a exploração de algoritmos de aprendizado profundo, como redes neurais recorrentes (RNN) ou modelos Transformers, para melhorar ainda mais a capacidade de predição de padrões comportamentais. Isso poderia fornecer suporte na formulação de políticas públicas para ajudar pessoas com transtornos mentais.

Agradecimentos

Agradeço ao Programa de Iniciação Científica 2021-2022 da Universidade de Brasília (UnB) e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela bolsa de estudos que possibilitou a dedicação integral ao projeto do estudo.

Referências

- AlSagri, H. S. and Ykhlef, M. (2020). Machine Learning-based Approach for Depression Detection in Twitter Using Content and Activity Features. *IEICE Transactions on Information and Systems*, E103.D(8):1825–1832. arXiv:2003.04763 [cs, stat].
- Bollen, J., Pepe, A., and Mao, H. (2011). Modeling public mood and emotion: Twitter sentiment and socio-economic phenomena. *arXiv:0911.1583 [cs]*. arXiv: 0911.1583.
- Britto, L. and Pacífico, L. (2019). Análise de Sentimentos para Revisões de Aplicativos Mobile em Português Brasileiro. In *Anais do Encontro Nacional de Inteligência Artificial e Computacional (ENIAC)*, pages 1080–1090. SBC. ISSN: 2763-9061.
- Coppersmith, G., Dredze, M., and Harman, C. (2014). Quantifying Mental Health Signals in Twitter. In *Proceedings of the Workshop on Computational Linguistics and Clinical Psychology: From Linguistic Signal to Clinical Reality*, pages 51–60, Baltimore, Maryland, USA. Association for Computational Linguistics.
- Corbanezi, E. (2018). Transtornos Depressivos e Capitalismo Contemporâneo. *Caderno CRH*, 31:335–353. Publisher: Universidade Federal da Bahia - Faculdade de Filosofia e Ciências Humanas - Centro de Recursos Humanos.
- De Choudhury, M., Gamon, M., Counts, S., and Horvitz, E. (2013). Predicting Depression via Social Media. In Kiciman, E., Ellison, N. B., Hogan, B., Resnick, P., and Soboroff, I., editors, *Proceedings of the Seventh International Conference on Weblogs and Social Media, ICWSM 2013, Cambridge, Massachusetts, USA, July 8-11, 2013*. The AAAI Press.
- Hassan, N. Y., Gomaa, W. H., Khoriba, G. A., and Haggag, M. H. (2020). Credibility Detection in Twitter Using Word N-gram Analysis and Supervised Machine Learning Techniques. *International Journal of Intelligent Engineering & Systems*, 13(1).
- JustAnotherArchivist (2022). Snsrape. original-date: 2018-09-09T20:16:31Z.
- Kristensen, C. H., Gomes, C. F. d. A., Justo, A. R., and Vieira, K. (2011). Normas brasileiras para o Affective Norms for English Words. *Trends in Psychiatry and Psychotherapy*, 33:135–146. Publisher: Associação de Psiquiatria do Rio Grande do Sul.
- Mendes, A. R., Passador, R. V. P., and Caseli, H. M. (2021). Identificando sintomas de depressão em postagens do Twitter em português do Brasil. In *Anais do Simpósio Brasileiro de Tecnologia da Informação e da Linguagem Humana (STIL)*, pages 162–171. SBC. ISSN: 0000-0000.
- Mukaka, M. (2012). A guide to appropriate use of Correlation coefficient in medical research. *Malawi Medical Journal : The Journal of Medical Association of Malawi*, 24(3):69–71.
- Park, M., Cha, C., and Cha, M. (2012). Depressive moods of users portrayed in Twitter. *Proceedings of the 18th ACM International Conference on Knowledge Discovery and Data Mining, SIGKDD 2012*, pages 1–8.

- Rude, S., Gortner, E.-M., and Pennebaker, J. (2004). Language use of depressed and depression-vulnerable college students. *Cognition and Emotion*, 18(8):1121–1133. Publisher: Routledge _eprint: <https://doi.org/10.1080/02699930441000030>.
- Schröer, C., Kruse, F., and Gómez, J. M. (2021). A Systematic Literature Review on Applying CRISP-DM Process Model. *Procedia Computer Science*, 181:526–534.
- Stephen, J. J. and P, P. (2019). Detecting the magnitude of depression in Twitter users using sentiment analysis. *International Journal of Electrical and Computer Engineering (IJECE)*, 9(4):3247–3255. Number: 4.
- von Sperling, O. (2019). UnB Sense : a web application to probe for signs of depression from user profiles on social media. Accepted: 2021-02-01T16:59:26Z.
- von Sperling, O. and Ladeira, M. (2019). Mining Twitter Data for Signs of Depression in Brazil. In *Anais do Symposium on Knowledge Discovery, Mining and Learning (KDMiLe)*, pages 25–32. SBC. ISSN: 2763-8944.
- Williams, K. L. and Galliher, R. V. (2006). Predicting Depression and Self-Esteem from Social Connectedness, Support, and Competence. *Journal of Social and Clinical Psychology*, 25(8):855–874. Publisher: Guilford Publications Inc.