

ESTIMATIVA DE NÍVEIS DE TRANSTORNOS MENTAIS COM INTELIGÊNCIA ARTIFICIAL: UMA AVALIAÇÃO DO DESEMPENHO DE CLASSIFICADORES SUPERVISIONADOS

Gustavo França Albano de Paula¹, Luis Felipe Francisco Fermino Ferreira², Mariana Frederico Mançan³, Damaris Bezerra de Lima⁴, Thiago José Lucas⁵

Resumo

Estatísticas recentes apontam para uma proporção alarmante: uma em cada oito pessoas possui algum tipo de transtorno mental. A qualidade de vida de boa parte da população tem sido afetada por conta de problemas com Depressão, Ansiedade ou Stress. Detectar precocemente os níveis dos supracitados transtornos pode ser útil como ferramenta auxiliar aos profissionais da saúde e até mesmo ao público em geral. Esta pesquisa documenta a implementação Inteligência Artificial pela aplicação de algoritmos de Machine Learning para classificar os níveis de Depressão, Ansiedade e Stress. Foi construído um conjunto de dados para treinamento e validação dos modelos baseado no formulário DASS-42. Diversos classificadores foram testados e os melhores resultados obtidos apontam para uma acurácia de 99.98% utilizando Artificial Neural Networks. Portanto, classificadores supervisionados apresentam bom desempenho na estimativa de níveis de transtornos mentais, em especial o *Neural Networks*, o que demonstra a viabilidade de se construir um modelo de Machine Learning.

Palavras-chave: transtorno mental; inteligência artificial; *Machine Learning*.

Abstract

Recent statistics point to an alarming proportion: one in eight individuals has some type of mental disorder. The quality of life for a significant portion of the population has been affected by problems related to depression, anxiety, or stress. Early detection of these disorders' levels can serve as a useful tool for healthcare professionals and even the general public. This research documents the implementation of artificial intelligence by applying machine learning algorithms to classify levels of depression, anxiety, and stress. A dataset was built for training and validating models based on the DASS-42 form. Several classifiers were tested, and the best results obtained indicate an accuracy of 99.98% using Artificial Neural Networks. Therefore, supervised classifiers demonstrate good performance in estimating levels of mental disorders, especially Neural Networks, showing the feasibility of developing a Machine Learning model.

Keywords: mental disorder; artificial intelligence; machine learning.

Introdução

Com a Revolução Industrial no século XIX, o mundo se tornou mais acelerado: o

¹ Análise e Desenvolvimento de Sistemas, FATEC Ourinhos. Discente do curso superior em Análise e Desenvolvimento de Sistemas na FATEC Ourinhos. E-mail: gstvz.franca@gmail.com

² Análise e Desenvolvimento de Sistemas, FATEC Ourinhos. Discente do curso superior em Análise e Desenvolvimento de Sistemas na FATEC Ourinhos. E-mail: luisfelipefferreira@gmail.com

³ Análise e Desenvolvimento de Sistemas, FATEC Ourinhos. Discente do curso superior em Análise e Desenvolvimento de Sistemas na FATEC Ourinhos. Email: marianamancan@gmail.com

⁴ Mestre em Psicologia, UNESP Assis. Psicóloga Judiciária no Tribunal de Justiça do Estado de São Paulo; Docente e supervisora de estágios em Psicologia Jurídica e Avaliação Psicológica na UNIFIO, Centro Universitário das Faculdades Integradas de Ourinhos. E-mail: damarisblima@gmail.com

⁵ Doutor em Ciência da Computação, UNESP. Docente de ensino superior na FATEC Ourinhos. E-mail: thiago@fatecourinhos.edu.br

trabalho precisava ser rápido e constante, com muitas horas de trabalho e poucas de descanso, em condições completamente insalubres, tanto físicas quanto psicológicas, na busca de meios para sobreviver e alcançar uma melhor condição de vida. Apesar de grandes mudanças na forma de produção e garantias de direitos, a vida continua corrida e estressante. Segundo dados da Organização Mundial de Saúde de 2019 (World Health Organization, 2022) estima-se que um bilhão de pessoas sofram com algum transtorno mental e que uma em cada oito pessoas apresente tal sofrimento psíquico (Costa, 2023). Além disso, a Pesquisa Nacional por Amostra de Domicílios realizada pelo Governo brasileiro (Instituto Brasileiro de Geografia E Estatística, 2022) averiguou que 90% dos domicílios brasileiros possuem acesso à Internet. Nesse contexto, fica evidente que a tecnologia se faz bastante presente na vida das pessoas, bem como transtornos mentais, o que demonstra que há margem para o uso da tecnologia para auxiliar no diagnóstico.

A detecção precoce de problemas de saúde mental é fundamental para garantir um tratamento adequado e evitar complicações. No entanto, a detecção desses problemas pode ser difícil, visto que muitas vezes os sintomas são subjetivos e podem variar de pessoa para pessoa. Além disso, muitas pessoas não buscam tratamento por medo de serem estigmatizadas ou por falta de acesso a serviços de saúde mental.

Segundo o Manual de Diagnóstico e Estatístico de Transtornos Mentais da American Psychiatric Association – DSM 5 TR (2023):

Um transtorno mental é uma síndrome caracterizada pela perturbação clinicamente significativa na cognição, na regulação emocional ou no comportamento de um indivíduo que reflete uma disfunção nos processos psicológicos, biológicos ou de desenvolvimento subjacentes ao funcionamento mental. Transtornos mentais estão frequentemente associados a sofrimento ou incapacidade significativos que afetam atividades sociais, profissionais, ou outras atividades importantes (p. 14).

Nesse contexto, as técnicas de Machine Learning podem ser uma ferramenta valiosa para profissionais da saúde. Com um modelo automatizado capaz de detectar níveis de ansiedade, depressão e estresse, é possível identificar esses problemas de forma mais eficiente e rápida, permitindo um tratamento mais adequado e com melhores resultados.

Ressalta-se que a Resolução do Conselho Federal de Psicologia (CFP), nº 31/2022, define a avaliação psicológica como “um processo estruturado de investigação de fenômenos psicológicos, composto de métodos, técnicas e instrumentos, com objetivo de prover informações à tomada de decisão, no âmbito individual, grupal ou institucional” (Conselho Federal de Psicologia, 2022, s. p.). Neste sentido, as técnicas de Machine Learning se tornam aliadas no processo de avaliação psicológica, pois ao indicarem os níveis de ansiedade, depressão e stress, auxiliam no direcionamento de quais testes e técnicas psicológicas o

profissional de Psicologia poderá utilizar posteriormente considerando os dados já detectados, para confirmação ou não dos transtornos e estruturação do tratamento.

O objetivo deste trabalho foi verificar a viabilidade do uso de um modelo automatizado de Machine Learning para detectar níveis de ansiedade, depressão e estresse. O uso de técnicas de Machine Learning tem se mostrado eficaz na detecção desses níveis e pode ser uma ferramenta valiosa para profissionais da saúde.

Os Objetivos Específicos foram:

1. Levantamento de trabalhos correlatos por meio da Revisão Sistemática da Literatura;
2. Extração das principais variáveis para escolha adequada de algoritmos, conjunto de dados e comparação de resultados;
3. Aplicação do gabarito de classificação de níveis de ansiedade, depressão e estresse em um conjunto de dados de teste (dados úteis para o treinamento);
4. Pré-processamento dos dados para remoção de ruídos e ajustes diversos;
5. Treinamento de diversos classificadores;
6. Teste do desempenho dos classificadores previamente treinados;
7. Obtenção das métricas de avaliação de desempenho para comparação dos resultados.

Assim, a problemática que esta pesquisa busca responder é: é possível utilizar inteligência artificial no auxílio da detecção de transtornos mentais? E quais classificadores supervisionados possuem o melhor desempenho para realizar esta detecção?

No que tange à estrutura, este trabalho foi organizado da seguinte forma: No primeiro capítulo, foi feita uma contextualização do tema pesquisado, apresentada a justificativa, os objetivos gerais e específicos, bem como a problemática; no segundo capítulo, foram descritos os trabalhos correlatos que deram base ao trabalho, a taxonomia dos mesmos e sua análise; no terceiro capítulo, foi descrito o fluxograma seguido para o desenvolvimento da pesquisa e obtenção dos resultados desejados; no quarto capítulo, foram expostas as matrizes de confusão de cada modelo e uma tabela com as respectivas métricas para cada transtorno; por fim, no quarto e último capítulo, foi apresentada a análise dos resultados e as considerações finais da pesquisa.

1 Desenvolvimento

Este capítulo compila os trabalhos correlatos ao tema objeto desta pesquisa. Trabalhos que implementaram Machine Learning para classificar os tipos de transtornos, como ansiedade, depressão e estresse, tendo como base diversos tipos de dados, como dados fisiológicos, dados

de redes sociais e dados de questionários foram objeto de estudo para que esta Seção entregue uma estimativa do estado-da-arte.

Yesudas (2022) em seu trabalho utilizou 3 algoritmos de *Machine Learning*: *Random Forest (RF)*, *NaïveBayes (NB)* e *Neural Networks (NN)*. O software mostrou que os modelos gerados pelo *NaïveBayes (NB)* e *Random Forest (RF)* obtiveram bons resultados para depressão, ansiedade e estresse com 95% de precisão, mas o modelo *Neural Networks (NN)* trouxe uma precisão de 99% para o estudo.

Mary e Jabasheela (2018) buscaram, por meio de um software, prever os níveis de DAS (Depressão, Ansiedade e Estresse) com 5 algoritmos: *LogisticRegression (LR)*, *Multi-layerPerceptron (MLP)*, *J48*, *ReducedErrorPruning (REP)*, *ClassificationandRegressionTrees (CART)*. Com esse software, foram analisados os dados coletados de 600 estudantes com o algoritmo *Multi-layerPerceptron (MLP)*, que apresentou o melhor resultado na classificação dos dados com uma precisão de 90,33% para depressão, 92% para ansiedade e 90,33% para estresse.

O trabalho de Katsis et al. (2011) verificou a efetividade de um dispositivo determinar o estado afetivo de um paciente com base em sinais fisiológicos, por meio de um questionário baseado no banco de dados de imagens *InternationalAffective Picture System (IAPS)*, e o uso de algoritmos de *Neural Networks (NN)*, *Support Vector Machine (SVM)*, *Random Forest (RF)* e *Neuro-Fuzzy System (NFS)*, que obteve uma precisão geral de 84.3%.

Kumara, Garga e Garga (2020) verificaram em sua pesquisa a previsão de transtornos mentais como ansiedade e depressão, utilizando oito tipos de algoritmos, dos quais o melhor desempenho foi dos algoritmos *Radial Basis (RB)*.

O estudo de Al-Ezziet et al. (2022) analisou eletroencefalografias, um teste que mede a atividade elétrica no cérebro, para identificar níveis de transtorno de ansiedade social. O modelo que ocasionou o melhor resultado foi o *NaïveBayes (NB)* com resultado de 86,93%.

No trabalho elaborado por Budiyanto et al. (2019), o software analisou dados coletados com base na escala DASS-21 (Escala de Depressão, Ansiedade e Estresse), e o algoritmo *NaïveBayes (NB)*, para classificação de textos coletados via publicações do Facebook, a fim de identificar sinais iniciais de depressão e ansiedade, mapeando um total de 22.934 posts. Concluiu-se que nos posts dos usuários que foram monitorados, os homens têm uma tendência maior a apresentar os sinais iniciais de depressão e ansiedade do que as mulheres (53% contra 46,4% respectivamente).

Bhatnagar et al. (2023) buscaram identificar a amplitude da ansiedade e seus efeitos em estudantes universitários de engenharia da Índia, utilizando uma base de dados construída com

um questionário baseado na escala Likert, originalmente desenvolvida por RensisLikert em 1932. É uma ferramenta que permite que os participantes expressem seu nível de concordância ou discordância com uma afirmação em uma escala graduada, geralmente de 5 a 7 pontos, que quantificou o nível da ansiedade, as causas e efeitos por meio de testes estáticos de confiabilidade e solidez. Esses dados foram classificados por meio de algoritmos de *Machine Learning*, quais sejam *NaïveBayes (NB)*, *DecisionTree (DT)*, *Random Forest (RF)* e *Support Vector Machine (SVM)* com base no nível de ansiedade e seus efeitos. Respectivamente, os algoritmos tiveram precisão de 71.05%, 71.05%, 78.9% e 75.5%, o que permitiu concluir que é possível ligar os efeitos às causas de ansiedade, e classificar o nível de ansiedade de acordo com a severidade dos efeitos, para identificar quais estudantes podem estar em risco.

A pesquisa desenvolvida por Maitre *et al.* (2022) teve como objetivo investigar quais variáveis causaram alterações no nível de ansiedade dos estudantes e funcionários da Universidade de Québec durante a pandemia de COVID-19, por meio da exploração de dados via gráficos, estatísticas e métodos univariados, bem como técnicas de predição de *Machine Learning*. Para isso, foi realizado um estudo longitudinal em quatro fases por meio de um questionário online na plataforma LimeSurvey, com o intuito de estabelecer retratos da saúde dos indivíduos nesse período. Diante disso, foi possível concluir que o algoritmo com melhor precisão foi o *CatBoost (CB)*, com um coeficiente de correlação de Pearson no valor de $r^2 = 0.5656$, e que todas as variáveis contribuíram significantemente para as alterações nos níveis de ansiedade, e que certos grupos de indivíduos estão mais inclinados a experenciar ansiedade severa.

Lee *et al.* (2019) buscaram através de sua pesquisa melhorar a eficácia da predição com *Machine Learning* por meio da seleção de características utilizando *Genetic-Algorithm* sobre dados de um questionário do *Korean Longitudinal Study of Aging (KLoSA)* da Coreia do Sul. A seleção de características foi feita com um método que busca um conjunto por meio de uma função de condicionamento físico que maximiza a correlação entre elas e a classificação a ser predita. Com isso, concluiu-se que a escolha de características válidas por meio de um método de seleção melhora a performance e a duração do aprendizado, especialmente quando feito com o uso do *Genetic-Algorithm*, que demonstrou uma margem de erro menor que o método de seleção randômico, pois selecionou melhor as características para a predição.

Muhammad e Al-Ahmadi (2022) em seu estudo desenvolveram um quadro de avaliação para ansiedade por meio de sinais fisiológicos de eletroencefalogramas (EEG) da base de dados “*A Database for Anxious States which is based on a Psychological Stimulation (DASPS)*”, cujos dados passaram por pré-processamento, seleção de canal, extração e seleção de características

e, por fim, classificação por meio de algoritmos de *Machine Learning*. Verificou-se que o algoritmo de *Random Forest (RF)* teve 94.90% e 92.74% de precisão para classificações de dois e quatro níveis e ultrapassou a precisão do quadro de avaliação existente, com o uso de menos características.

Aleem *et al.* (2022) realizaram uma listagem de algoritmos de *Machine Learning* usados na detecção e diagnóstico de depressão, categorizando-os em três classes: classificação, *deep learning* e *ensemble*. Além disso, apresentou um modelo de diagnóstico de depressão por meio de extração de dados, pré-processamento, treinamento de classificador de *Machine Learning* e avaliação de performance, bem como uma visão geral dos objetivos e limitações das pesquisas realizadas nesse sentido. Por fim, concluiu-se que é possível utilizar dados de redes sociais, prontuários médicos, e dados de sensores de dispositivos móveis para identificar transtornos de humor. O classificador mais utilizado para detecção de depressão foi o *Support Vector Machine (SVM)*, pois funciona bem com dados desestruturados e de grande dimensão, com mais de 75% de precisão e que aplicações de *Machine Learning* promovem um progresso potencial significativo para tratamentos de saúde mental, especialmente na predição.

A pesquisa elaborada por Gao, Calhoun e Sui (2018) buscou explorar biomarcadores de transtornos de humor com o uso de *Machine Learning* para o diagnóstico de transtornos depressivos a partir de transtornos bipolares na fase inicial da depressão, por meio da revisão de métodos de *Machine Learning* usados na classificação de imagens cerebrais e predições. Também, revisou pesquisas que usaram imagens de ressonância magnética (MRI) para classificar transtornos ou investigar preditores do resultado de tratamentos. Constatou-se que o uso de dados de ressonância magnética como base para *Machine Learning* promove um avanço na análise de níveis individuais de depressão maior aplicados clinicamente.

No trabalho de Priya *et al.* (2020) foram realizadas predições de ansiedade, depressão e estresse com o uso dos algoritmos *DecisionTree (DT)*, *Random Forest Tree (RFT)*, *NaïveBayes (NB)*, *Support Vector Machine (SVM)* e *K-NearestNeighbors (KNN)* de *Machine Learning*, a partir de uma base de dados de indivíduos empregados e desempregados que responderam ao questionário DASS-21, classificados em cinco níveis. Verificou-se que as classes utilizadas estavam desequilibradas na matriz de confusão, o que foi resolvido com a aplicação da pontuação F1, que permitiu identificar o algoritmo *Random Forest (RF)* como o mais preciso, apesar do *NaïveBayes (NB)* ter sido o que apresentou melhor precisão antes da aplicação da pontuação F1.

O trabalho elaborado por Gaziet *et al.* (2021) utilizou *Machine Learning* e detecção fisiológica para detectar níveis de ansiedade fóbica. Para a detecção fisiológica, utilizou dados

extraídos de atividade eletrodérmica (EDA), sinais de esforço respiratório (RSP) e eletrocardiograma (ECG). Com o uso do modelo *Random Forest (RF)* a precisão foi de 85%. Garget *al.* (2021) desenvolveram sua pesquisa utilizando um conjunto de dados multimodal chamado de WESAD, composto por eletrocardiograma (ECG), temperatura corporal (TEMP), respiração (RESP), eletromiograma (EMG) e atividade eletrodérmica (EDA). O objetivo foi detectar estresse nos indivíduos. O melhor resultado foi obtido por meio de técnicas de *Machine Learning*, dentre as quais o melhor resultado foi do algoritmo *Random Forest (RF)* com 83,34% e 65,73%.

O artigo de Giakoumis *et al.* (2012) aplicou um protocolo de indução de estresse *stroopcolour word test* para a detecção automática de estresse por meio de vídeos, acelerômetro e monitoramento fisiológicos e um conjunto de características comportamentais relacionadas à atividade. A avaliação experimental demonstrou que diversas dessas características se correlacionam a relatos de estresse.

1.1 Taxonomia dos trabalhos correlatos

Define-se taxonomia de pesquisa como estruturas classificatórias para organização de domínios de conhecimento, a qual é fundamental para compreender o levantamento dos trabalhos correlatos. Na tabela 1 foram compilados os autores dos trabalhos, os algoritmos classificadores, os conjuntos de dados e os melhores resultados apurados.

Tabela 1– Taxonomia: autores, algoritmos classificadores, conjunto de dados e melhores resultados apurados.

| TRABALHO | CLASSIFIC. | DATASET | DEPRE. | ANS. | ESTRESSE | GERAL |
|--------------------------------|-----------------------------|--------------------------|--------|--------|----------|-------|
| Yesudas (2022) | NN. | FORM DASS-42 | 99% | 99% | 99% | 99% |
| Mary e Jabaheela (2018) | MLP. | FORM DASS-21 | 90,33% | 92% | 90,33% | -- |
| Katsiset <i>et al.</i> (2011) | NN; SVM; RF; NFS; | IAPS | -- | -- | -- | 84,3% |
| Kumara, Garga e Garga (2020) | RB. | FORM DASS-42 | 100% | 93,1% | 91,95% | -- |
| Al-Ezziet <i>et al.</i> (2022) | NB. | EEG | -- | 86,93% | -- | -- |
| Budiyanto <i>et al.</i> (2019) | NB. | FORM DASS-21 | -- | -- | -- | -- |
| Bhatnagar <i>et al.</i> (2023) | RF. | QUESTIONÁRIO PROPRIO | -- | 78,9% | -- | -- |
| Maitre <i>et al.</i> (2022) | CB. | QUESTIONÁRIO PROPRIO | -- | 56,56% | -- | -- |
| Lee <i>et al.</i> (2019) | RF; LR; MLP; SMOREG & KLOSA | CES-D10 | -- | -- | -- | -- |
| Muhammad e Al-Ahmadi (2022) | RF. | EEG | -- | 94,9% | 92,74% | -- |
| Aleemet <i>et al.</i> (2022) | SVM & BDC | CES-D-11; DASS-21; HDRS. | -- | -- | -- | 75% |

| | | | | | | |
|---------------------------|-----|---------------------------|-------|-------|--------|--------|
| Gao, Calhoun e Sui (2018) | CRC | MRI | -- | -- | -- | -- |
| Priya et al. (2020) | NB | FORM DASS-21 | 85,5% | 73,3% | 74,2% | -- |
| Gaziet et al. (2021) | RF. | & EDA; ECG; RSP | -- | 85% | -- | -- |
| Garget et al. (2021) | RF. | ECG; TEMP; RESP; EMG; EDA | -- | -- | 83,34% | 65,73% |
| Giakoumis et al. (2012) | -- | ECG; GSR | 90% | -- | -- | -- |

Fonte: Elaborado pelos autores (2024).

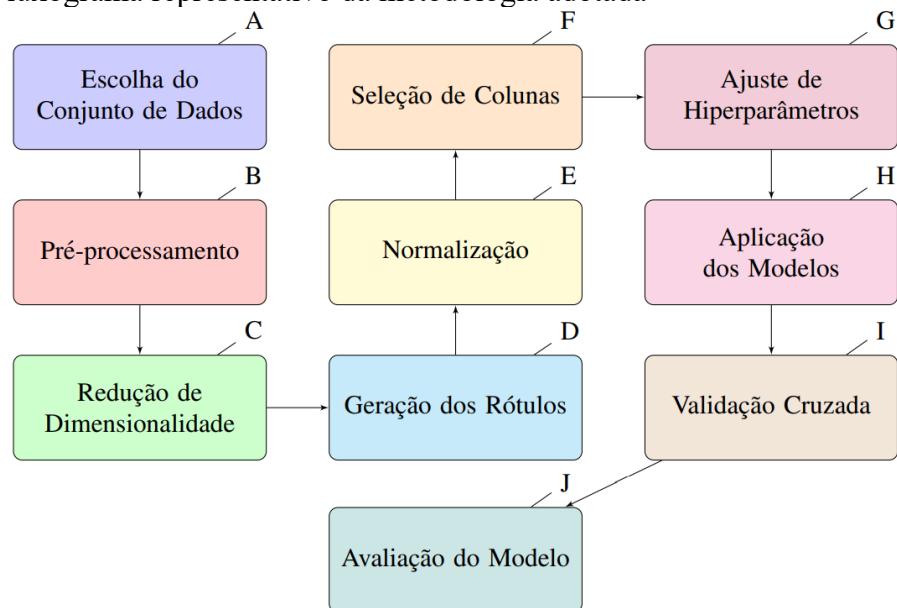
Nota: Nota. NN = Redes Neurais; MLP = Perceptron Multicamadas; RF = Floresta Aleatória

Por meio do levantamento dos trabalhos, percebeu-se que os melhores resultados foram obtidos através de algoritmos que utilizaram algum classificador do tipo *Ensemble learning*, algoritmos que possuem um aprendizado corporativo supervisionado. Além disso nota-se que apesar do modelo de *Neural Networks* ter alcançado um bom resultado, ele foi explorado em apenas um artigo. A maioria dos dados foram obtidos através de formulários próprios baseados em formulários DASS, desenvolvidos pelos pesquisadores Lovibond e Lovibond (1995), atualmente mantido pela *Psychology Foundation of Australia*. Seu intuito é medir os níveis emocionais do entrevistado por meio de 42 perguntas, que devem ser respondidas de acordo com a frequência (*never, sometimes, often, almostalways*), e são divididas em 3 escalas (ansiedade, depressão, estresse) com 14 itens cada}, enquanto os que não foram baseados em formulário utilizaram dados de exames clínicos como EEG e ECG. A respeito dos resultados, a maioria dos estudos não abrangeram os três transtornos (ansiedade, depressão e estresse), como nesta pesquisa. A partir da análise deste levantamento, foi escolhido o conjunto de dados a ser utilizado para a avaliação de desempenho dos algoritmos.

2 Metodologia

Para o desenvolvimento da pesquisa, foi elaborado o fluxo de processos apresentado na Figura 1 para ser utilizado como Metodologia. As letras indicam as etapas do processo algorítmico e são usadas para detalhar o fluxo sistêmico:

Figura 1- Fluxograma representativo da metodologia adotada



Fonte: Elaborado pelos autores (2024).

Etapa A - Após uma análise exploratória da taxonomia, decidiu-se utilizar o conjunto de dados previamente explorado por Yesudas (2022), composto por 39.775 respostas a um formulário composto pelo questionário DASS-42, bem como itens opcionais de personalidade de informações demográficas dos participantes.

Etapas B e C - Na fase de pré-processamento e redução de dimensionalidade, removeram-se os dados *server-sided*, que consistiam em dados técnicos do dispositivo no qual o entrevistado respondeu o questionário, bem como dados técnicos do questionário, como tempo de resposta de cada item e tempo total para responder o questionário. Também foram removidas as colunas cujas respostas eram texto livre, nas quais o entrevistado respondia de forma aberta.

Etapa D - Para a criação dos rótulos pelas fórmulas, com base nas especificações do dicionário de dados, separaram-se as colunas correspondentes a cada um dos rótulos desejados, somaram-se os resultados para obter o volume e, por fim, foi feita a relação dos resultados com as faixas correspondentes do questionário DASS, o que resultou em 3 colunas novas, que seriam os rótulos, cada uma com 5 níveis, de 0 a 4, que correspondem a *Normal, Mild, Moderate, Severe e Extremely Severe*, respectivamente.

Etapa E - Na fase de normalização dos dados, que é a técnica de transformar os valores numéricos do conjunto de dados em um intervalo de valores comuns, sem distorcer a faixa de valores ou perder informação, foi utilizada a técnica Min-Max no Azure Machine Learning Studio.

A técnica Min-Max padroniza as escalas das variáveis independentes em um conjunto de dados, o que é bastante útil em algoritmos de *Machine Learning*, porque é importante que as variáveis tenham a mesma escala.

De acordo com Lantz (2015), a fórmula para normalização Min-Max é dada por:

$$Z_{norm} = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (1)$$

Nota 1:

- X: valor original da variável;
- Z_{norm} : valor normalizado da variável;
- X_{min} : valor mínimo observado da variável;
- X_{max} : valor máximo observado da variável.

Com isso, garante-se que os valores das variáveis estejam todos dentro do intervalo desejado, o que facilita o treinamento de modelos de *Machine Learning* e evita problemas decorrentes de escalas diferentes.

Etapa F - Para a seleção das colunas, no conjunto de dados original, as colunas definidas como rótulos foram separadas das demais, para evitar que o modelo fosse treinado ou testado com os dados dos resultados.

Etapa G - Foi utilizado o ajuste dos hiperparâmetros de modelo com o objetivo de encontrar as melhores configurações para melhorar o desempenho do modelo, utilizando técnicas de varredura aleatória, nas quais o modelo é treinado com uma seleção aleatória de parâmetros, de acordo com um número definido de interações.

Etapa H - Na etapa de aplicação dos modelos foram utilizados os seguintes algoritmos:

- *MulticlassDecision Forest* (MICROSOFT, 2019a) - O *MulticlassDecision Forest* é um método de aprendizado que usa várias árvores de decisão para tomar uma decisão final: cada árvore cria um histograma e normaliza os resultados para obter a probabilidade de cada rotulo, tendo como resultado a melhor árvore final por comparação com as demais.
- *MulticlassDecisionJungle* (MICROSOFT, 2019b) - O *MulticlassDecisionJungle* é um modelo de classificação semelhante ao *MulticlassDecision Forest*, porém, em vez de usar árvores como base, emprega Grafos Acíclicos Direcionados (DAGs). Esta estrutura é mais eficiente em termos de memória, pois elimina a necessidade de repetição de nós-folha, embora demande um pouco mais de tempo computacional durante o treinamento.
- *Multiclass Neural Networks* (MICROSOFT, 2019c) - O *Multiclass Neural Networks* é um conjunto de camadas interconectadas, no qual as entradas são conectadas a uma camada de saída por um grafo acíclico ponderado. Nele, pode conter camadas ocultas para modelar níveis

de profundidade semântica. O treinamento da rede com dados de entrada permite aprender a relação entre entradas e saídas. Os valores em cada nó são calculados pela soma ponderada dos valores da camada anterior, seguida pela aplicação de uma função de ativação. *Neural Networks* profundas têm sido eficazes em tarefas complexas, como reconhecimento de imagem ou fala. Utilizamos como parâmetro de especificação de camada oculta o *fully-connected case*, que cria um modelo usando a arquitetura padrão de *Neural Networks*.

Etapa I - Para a validação dos modelos, utilizou-se *10-fold*, que é uma técnica robusta para avaliar o desempenho de modelos de aprendizado de máquina, conforme descrito por James *et al.* (2013). Nesse método, os dados de treinamento são divididos em 10 subconjuntos (*folds*) de tamanhos iguais. Cada *fold* é utilizado como conjunto de validação uma vez, enquanto os 9 *folds* restantes são utilizados para treinar o modelo. Esse processo é repetido 10 vezes, obtendo 10 estimativas de erro de teste que são médias para a estimativa final de validação cruzada. Ao final, as 10 estimativas de erro de teste obtidas são médias, resultando na estimativa final de validação cruzada de *10-fold*.

Etapa J - Por fim, na avaliação do Modelo, analisou-se o desempenho dos modelos através de métricas fundamentais, como a matriz de confusão e medidas de acurácia, *recall*, precisão e *F1-Score*. Estas análises fornecem uma compreensão aprofundada do comportamento de cada modelo.

Cada etapa da metodologia foi pensada e aplicada a fim de manter a integridade e qualidade dos dados originais. A análise exploratória inicial permitiu a seleção adequada do conjunto de dados, enquanto o pré-processamento e a redução de dimensionalidade garantiram que apenas informações relevantes fossem consideradas. A normalização foi importante para padronizar as variáveis, facilitando o desempenho dos modelos. O ajuste de hiperparâmetros otimizaram o treinamento dos algoritmos aplicados e juntamente com a validação cruzada proporcionou uma avaliação robusta e confiável, resultando em uma análise detalhada do desempenho dos modelos por meio das métricas geradas

3 Resultados

Com a obtenção das métricas após a execução da metodologia descrita no capítulo anterior, foi elaborada a tabela a partir da equação 1, composta pelas métricas de acurácia, precisão, *Recall* e *F1 Score*, as quais são descritas abaixo.

Tem-se que a acurácia é uma medida geral da precisão do modelo. Ela representa a proporção de previsões corretas (verdadeiros positivos e verdadeiros negativos) em relação ao total de amostras, conforme equação 2.

$$Acurácia = \frac{Verdadeiros Positivos + Verdadeiros Negativos}{Total da Amostra} \quad (2)$$

Nota 1:

- Verdadeiros positivos são os dados que foram corretamente classificados como verdadeiros.
- Verdadeiros negativos foram os dados que foram erroneamente classificados como verdadeiros.

Por sua vez, o *Recall* mede a proporção de exemplos positivos que foram corretamente identificados pelo modelo. Em outras palavras, é a capacidade do modelo de encontrar todos os exemplos positivos, conforme a equação 3.

$$Recall = \frac{Verdadeiros Positivos}{Verdadeiros Positivos + Falsos Negativos} \quad (3)$$

Nota 1:

- Verdadeiros positivos são os que foram corretamente classificados como verdadeiros.
- Verdadeiros negativos foram os que foram erroneamente classificados como verdadeiros.

Já a precisão é a proporção de exemplos positivos identificados corretamente pelo modelo em relação a todos os exemplos identificados como positivos (incluindo os falsos positivos). Ela representa a precisão das previsões positivas do modelo, conforme equação 4.

$$Precisão = \frac{Verdadeiros Positivos}{Verdadeiros Positivos + Falsos Positivos} \quad (4)$$

Nota1:

- Verdadeiros positivos são os que foram corretamente classificados como verdadeiros.
- Verdadeiros negativos foram os que foram erroneamente classificados como verdadeiros.

Por fim, o *F1-Score* é uma métrica que combina precisão e *Recall* em um único valor. Ele é calculado como a média harmônica entre precisão e *Recall*, conforme equação 5.

$$F1 Score = 2 \times \frac{Precisão \times Recall}{Precisão + Recall} \quad (5)$$

Nota 1:

- Precisão é a proporção de exemplos positivos identificados corretamente pelo modelo em relação a todos os exemplos identificados como positivos.
- Recall mede a proporção de exemplos positivos que foram corretamente identificados pelo modelo.

Tabela 2 - Métricas dos modelos aplicados

| MODELO | ACURÁCIA | PRECISÃO | RECALL | F1 SCORE |
|---|----------------|----------------|----------------|----------------|
| DEPRESSÃO - DECISION FOREST | 0,87308 | 0,83628 | 0,82751 | 0,83100 |
| DEPRESSÃO - DECISION JUNGLE | 0,88047 | 0,85124 | 0,83316 | 0,83958 |
| DEPRESSÃO - NEURAL NETWORKS | 0,99980 | 0,99980 | 0,99977 | 0,99978 |
| ANSIEDADE - DECISION FOREST | 0,82182 | 0,73711 | 0,70767 | 0,70987 |
| ANSIEDADE - DECISION JUNGLE | 0,83851 | 0,78938 | 0,70409 | 0,69148 |
| ANSIEDADE - NEURAL NETWORKS | 0,99995 | 0,99997 | 0,99993 | 0,99995 |
| ESTRESSE - DECISION FOREST | 0,87449 | 0,87979 | 0,86458 | 0,87172 |
| ESTRESSE - DECISION JUNGLE | 0,87507 | 0,88480 | 0,86083 | 0,87174 |
| ESTRESSE - NEURAL NETWORKS | 0,89183 | 0,99817 | 0,99815 | 0,99770 |

Fonte: Elaborado pelos autores (2024).

A partir das métricas evidenciadas na Tabela 2, verifica-se que o modelo de *Neural Networks* se destacou dentre os demais, razão pela qual foram geradas as suas matrizes de confusão para avaliação de suas classificações.

4 Conclusão

Percebeu-se, por meio da revisão de trabalhos correlatos e sua taxonomia, que as técnicas de *Machine Learning* são alvo de pesquisas para uso na área da saúde, notadamente para transtornos mentais, e com desempenhos satisfatórios para diferentes casos. No entanto, a maioria das pesquisas se atreve a um tipo de transtorno mental e alguma situação específica, como estudantes ou trabalhadores, identificação de sintomas por meio de textos ou imagens e a pandemia de COVID-19. Assim, este trabalho buscou verificar o desempenho dos classificadores para os três transtornos mentais, a partir de um conjunto de dados recente e mais específico para o diagnóstico deles, como os DASS.

A partir do conjunto de dados selecionado, foi realizado um pré-processamento dos dados diferente da metodologia utilizada no artigo original de Yesudas (2022), para utilizar apenas as respostas ao questionário DASS, removendo questões extras, opcionais, de texto livre e dados técnicos. Com isso, reduziu-se o número de colunas e foram criados os rótulos, um para

cada transtorno, com 5 níveis cada, bem como foram normalizados os dados numéricos em intervalos comuns para facilitar o treinamento.

Dessa forma, foi possível aplicar os algoritmos *MulticlassDecision Forest*, *MulticlassDecisionJungle* e *Multiclass Neural Networks* ao conjunto de dados e observar que os modelos gerados obtiveram acurácia acima de 80%, sendo o mais notável o de *Neural Networks*, que teve um desempenho acima de 89,13% para os três transtornos, bem como suas matrizes de confusão apontaram poucos erros de classificação.

Fica evidente, portanto, que classificadores supervisionados apresentam bom desempenho na estimativa de níveis de transtornos mentais, em especial o *Neural Networks*, o que demonstra a viabilidade de se construir um modelo de *Machine Learning* para o auxílio na identificação desses transtornos a partir de um conjunto de dados baseado num formulário DASS.

Além disso, o desenvolvimento desse trabalho serviu como aplicação prática das matérias de Metodologia da Pesquisa Científico-Tecnológica e, principalmente, Inteligência Artificial, na qual se aprendeu sobre a história da inteligência artificial, algoritmos de *Machine Learning*, e técnicas para obter melhores resultados na aplicação desses algoritmos para gerar modelos, conhecimentos que foram aplicados neste trabalho e contribuíram imensamente na formação de um repertório técnico sobre a área e sedimentam o caminho para uma especialização neste assunto.

Por fim, a partir deste trabalho, futuramente, pode ser realizada nova pesquisa com o objetivo de melhorar os resultados do modelo, aplicando técnicas de pré-processamento ou diferentes ajustes de hiperparâmetros, bem como desenvolver uma aplicação que utilize o modelo para auxiliar no diagnóstico e posterior tratamento dos transtornos mentais aqui citados.

Referências

ALEEM, S., HUDA, N., AMIN, R., KHALID, S., ALSHAMRANI, S., and ALSHEHRI, A. **Machine learning algorithms for depression**: Diagnosis, insights, and research directions. *electronics* 2022, 11, 1111, 2022.

BHATNAGAR, S., AGARWAL, J., and SHARMA, O. R. **Detection and classification of anxiety in university students through the application of machine learning**. *Procedia Computer Science*, 218:1542–1550, 2023.

BUDIYANTO, S.; SIHOMBING, H. C.; IM, F. R. Depression and anxiety detection through the closed-loop method using DASS-21. **TELKOMNIKA (Telecommunication Computing Electronics and Control)**, Yogyakarta, v. 17, n. 4, p. 2087–2097, dez. 2019. Disponível em: <https://doi.org/10.12928/telkomnika.v17i4.12619>. Acesso em: 10 dez. 2025.

CONSELHO FEDERAL DE PSICOLOGIA. **Resolução CFP nº 31, de 15 de dezembro de 2022.** CFP. Brasília, DF, 2022. Disponível em: <https://atosoficiais.com.br/cfp/resolucao-do-exercicio-profissional-n-31-2022-estabelece-diretrizes-para-a-realizacao-de-avaliacao-psicologica-no-exercicio-profissional-da-psicologa-e-do-psicologo-regulamenta-o-sistema-de-avaliacao-de-testes-psicologicos-satepsi-e-revoga-a-resolucao-cfp-no-09-2018>. Acesso em: 10 dez. 2025.

COSTA, J. **Ansiedade e depressão são os principais vilões da saúde mental.** Senado Federal. Brasilia-DF, 28 nov. 2023. Disponível em: <https://www12.senado.leg.br/institucional/sis/noticias-comum/ansiedade-e-depressao-sao-os-principais-viloes-da-saude-mental>. Acesso em: 09 dez., 2025.

AMERICAN PSYCHIATRIC ASSOCIATION. **Manual diagnóstico e estatístico de transtornos mentais: DSM-5-TR.** 5. ed. rev. Tradução de D. Vieira, M. V. Cardoso e S. M. M. da Rosa; revisão técnica de J. A. de S. Crippa, F. de L. Osório e J. D. R. de Souza. Porto Alegre: Artmed, 2023.

GAO, S.; CALHOUN, V. D.; SUI, J. Machine learning in major depression: from classification to treatment outcome prediction. **CNS Neuroscience&Therapeutics**, v. 24, n. 11, p. 1037–1052, 2018. Disponível em: <https://doi.org/10.1111/cns.13091>. Acessoem: 10 dez. 2025.

GARG, P.; SANTHOSH, J.; DENGEL, A.; ISHIMARU, S. Stress detection by machine learning and wearable sensors. In: **Proceedings of the 26th International Conference on Intelligent User Interfaces – Companion**, p. 43-45. Disponívelem: <https://doi.org/10.1145/3397482.3450732>. Acessoem: 09 dez. 2025.

GAZI, A. H.; LIS, P.; MOHSENI, A.; OMPI, C.; GIUSTE, F. O.; SHI, W.; INAN, O. T.; WANG, M. D. Respiratory markers significantly enhance anxiety detection using multimodal physiological sensing. In: **2021 IEEE EMBS International Conference on Biomedical and Health Informatics**. IEEE, p. 1-4, 2021. Disponível em: https://www.researchgate.net/profile/Asim-Gazi/publication/353810047_Respiratory_Markers_Significantly_Enhance_Anxiety_Detection_Using_Multimodal_Physiological_Sensing/links/612e601d0360302a006f498c/Respiratory-Markers-Significantly-Enhance-Anxiety-Detection-Using-Multimodal-Physiological-Sensing.pdf. Acessoem: 09 dez. 2025.

GIAKOUMIS, D.; DROSOU, A.; CIPRESSO, P.; TZOVARAS, D.; HASSAPIS, G.; GAGGIOLI, A.; RIVA, G. Using activity-related behavioural features towards more effective automatic stress detection. **PLoS ONE**, 7(9): e43571. Disponível em: <https://doi.org/10.1371/journal.pone.0043571>. Acesso em: 09 dez. 2025.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Internet chegou a 90% dos domicílios brasileiros no ano passado.** IBGE, Brasília, DF, 2022. Disponível em: <https://www.gov.br/pt-br/noticias/educacao-e-pesquisa/2022/09/internet-chegou-a-90-dos-domicilios-brasileiros-no-ano-passado>. Acessoem: 10 dez. 2025.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning.** Springer: New York, 2013. Disponível em: <https://doi.org/10.1007/978-1-4614-7138-7>. Acesso em: 09 dez. 2025.

KATSIS, C. D.; KATERTSIDIS, N. S.; FOTIADIS, D. I. An integrated system based on physiological signals for the assessment of affective states in patients with anxiety disorders. **Biomedical Signal Processing and Control**, v. 6, n. 3, p. 261–268, 2011. Disponível em: <https://doi.org/10.1016/j.bspc.2010.12.001>. Acesso em: 10 dez. 2025.

KUMARA, P.; GARG, S.; GARG, A. Assessment of anxiety, depression and stress using machine learning models. **Procedia Computer Science**, v. 171, p. 1989–1998, 2020. Disponível em: <https://doi.org/10.1016/j.procs.2020.04.213>. Acessoem: 10 dez. 2025.

LANTZ, B. **Machine learning with R**. Packt Publishing, 2015.

LEE, S.-J. *et al.* Genetic algorithm-based feature selection for depression scale prediction. In: **proceedings of the genetic and evolutionary computation conference companion**. New York: ACM, 2019. p. 65–66. Disponível em: <https://doi.org/10.1145/3319619.3326779>. Acesso em: 10 dez. 2025.

LOVIBOND, S. H.; LOVIBOND, P. F. **Manual for the Depression Anxiety Stress Scales**. 2 ed., Psychology Foundation of Australia, 1995.

MAITRE, J.; BERGERON-LECLERC, C.; MALTAIS, D.; GABOURY, S. Exploring anxiety of Quebec university community during COVID-19 pandemic via machine learning. In **Proceedings of the 2022 ACM Conference on Information Technology for Social Good**.Roma: ACM, 2022. p. 55–60. Disponível em: <https://doi.org/10.1145/3524458.3547236>. Acesso em: 10 dez. 2025.

MARY, S. A.; JABASHEELA, L. An evaluation of classification techniques for depression, anxiety and stress assessment. In: **Proceedings of the International Conference for Phoenixes on Emerging Current Trends in Engineering and Management (PECTEAM 2018)**, Atlantis Press, p. 64–69. Disponível em: <https://www.atlantis-press.com/proceedings/pecteam-18/25893600>. Acesso em: 09 dez. 2025.

MICROSOFT. **Multiclass decision forest module reference**. 2019a. Disponível em: <https://learn.microsoft.com/en-us/previous-versions/azure/machine-learning/studio-module-reference/multiclass-decision-forest>. Acesso em: 09 dez. 2025.

MICROSOFT. **Multiclassdecisionjungle module reference**. 2019b. Disponível em: <https://learn.microsoft.com/en-us/previous-versions/azure/machine-learning/studio-module-reference/multiclass-decision-jungle>, 2019b. Acesso em: 09 dez. 2025.

MICROSOFT. **Multiclass neural network module reference**.2019c. Disponível em: <https://learn.microsoft.com/en-us/previous-versions/azure/machine-learning/studio-module-reference/multiclass-neural-network>. Acessoem: 09 dez. 2025.

MUHAMMAD, F.; AL-AHMADI, S. Human state anxiety classification framework using EEG signals in response to exposure therapy. **PLOS ONE**, v. 17, n. 3, p. e0265679, 2022. Disponível em: <https://doi.org/10.1371/journal.pone.0265679>. Acessoem: 09 dez. 2025.

PRIYA, A., GARG, S., & TIGGA, N. P. Predicting anxiety, depression and stress in modern life using machine learning algorithms. **Procedia Computer Science**, v. 167, p. 1258–1267,

2020. Disponível em: <https://doi.org/10.1016/j.procs.2020.03.442>. Acesso em: 09 dez. 2025. 2020.

WORLD HEALTH ORGANIZATION. **World mental health report: transforming mental health for all.** Geneva: WHO, 2022. Disponível em: <https://www.who.int/publications/i/item/9789240049338>. Acesso em: 10 dez. 2025.

YESUDAS, A. **A machine learning framework to predict depression, anxiety and stress.** 2022. 98 f. Dissertação (Mestradoem Master of Science in Data Analytics) – National College of Ireland, Dublin, 2022. Disponível em: <https://norma.ncirl.ie/5531/1/oritsejolomisanoneyor.pdf> . Acesso em: 10 dez. 2025.