ECOP

VOL. 1 N. 9 | MAIO 2026



VOLUME 1
NÚMERO 9

ISSN 2526-7574022

ANAIS DO VIII ENCONTRO DE COMPUTAÇÃO DO OESTE POTIGUAR

18 a 20 de Maio de 2026

UNIVERSIDADE FEDERAL RURAL DO SEMI-ÁRIDO

Campus Pau dos Ferros

ANAIS DO ENCONTRO DE COMPUTAÇÃO DO OESTE POTIGUAR

Universidade Federal Rural do Semi-Árido — UFERSA

Volume 1, Número 9 | Pau dos Ferros, RN, Brasil | Ano 2026 | **ISSN 2526-7574**

Universidade Federal Rural do Semi-Árido — UFERSA

Centro Multidisciplinar de Pau dos Ferros

Pau dos Ferros, Rio Grande do Norte, Brasil

Vol. 1, N. 9 — 2026 ISSN 2526-7574

EDITORES

Prof. Dr. Kennedy Reurison Lopes, UFERSA
Prof. Dra. Rosana Cibely Batista Rego, UFERSA

EDITORAÇÃO ELETRÔNICA

Prof. Dra. Rosana Cibely Batista Rego, UFERSA

CONSELHO CIENTÍFICO

- Ádller de Oliveira Guimarães, UFERSA
- Alysson Filgueira Milanez, UFERSA
- Cecílio Martins de Sousa Neto, UFERSA
- Francisco Carlos Gurgel da Silva Segundo, UFERSA
- Huliane Medeiros da Silva, UFERSA
- Jose Ferdinandy Silva Chagas, UFERSA
- Josenildo Ferreira Galdino, UFERSA
- Kennedy Reurison Lopes, UFERSA
- Laysa Mabel De Oliveira Fontes, UFERSA
- Marcos Marreiro Salvatierra, UFERSA
- Reudismam Rolim de Sousa, UFERSA
- Walber José Adriano Silva, UFERSA

APRESENTAÇÃO

Os Anais do Encontro de Computação do Oeste Potiguar (ISSN 2526-7574)

Publicação anual da UFERSA no Centro Multidisciplinar de Pau dos Ferros. Os trabalhos apresentados no ECOP têm como objetivo reunir as melhores produções científicas regionais em Computação. Durante o evento, os participantes assistem a palestras, minicursos, mesas-redondas e interagem com *startups* e empresas de tecnologia. Em 2026, o ECOP realizou sua oitava edição presencial.

Temas abordados:

- Inteligência Artificial
- Informática aplicada à Saúde e Engenharia Biomédica
- Cidades Inteligentes
- Engenharia de Software
- Lógica e Teoria da Computação
- Computação Gráfica e Processamento de Imagens
- Informática Educacional
- Redes de Computadores e Telecomunicações
- Sistemas de Informação
- Banco de Dados
- Big Data
- Automação e Robótica
- Sistemas Embarcados
- Educação e Computação

SUMÁRIO – ARTIGOS PUBLICADOS

1. **Classificação Binária de Vantagem Posicional no Xadrez Com Modelo Perceptron Multicamadas**
Camilo et al. 6

2. **Detecção de Deepfakes Baseada em Metadados Forenses Utilizando Perceptron de Múltiplas Camadas**
Oliveira Xavier et al. 12

3. **Predição de Vagas de Empregos no Mercado de IA e Dados Utilizando Redes Neurais Artificiais**
Gabriel et al. 16

4. **Previsão de Interrupções em Cadeias de Suprimento Globais Utilizando Aprendizado de Máquina**
Medeiros da Silva et al. 22

5. **Multilayer Perceptron-Based System for Behavioral Analysis and Educational Recommendation in Autism Spectrum Disorder**
de Aquino Souza et al. 26

6. **Aplicação de Redes Perceptron Multicamadas no Diagnóstico da Doença de Alzheimer com IA Explicável**
Ferreira Teixeira et al. 32

7. **Include: Repositório de Materiais Adaptados para Pessoas com Necessidades Educacionais Especiais no Ensino Técnico**
Dias et al. 37

8. **Base de Lançamento de Foguetes de Garrafa PET com Controle e Monitoramento Remoto**
Lima Queiroz et al. 41

9. **Rede Neural Perceptron Multicamadas para Classificação Multiclasse de Câncer de Pele**
Ferreira et al. 47

10. **Classificação de Níveis de Obesidade através de Redes Neurais Multicamadas: Uma Abordagem Baseada em Hábitos de Vida e Dados Antropométricos**
Nilton de Araujo et al. 53

11. **ReCiclo: Sistema Inteligente para Gestão e Incentivo da Reciclagem**
Luiza et al. 58

12. **Uma arquitetura de sistema Web de apoio ao ensino gamificado dos Objetivos de Desenvolvimento Sustentável**
Fabricio et al. 63

13. **Gamificação com Hardware de Baixo Custo como Ferramenta de Apoio à Motricidade**
de Lima Santos et al. 68

14. **Deep Learning Algorithm for Hypertension Prediction using Hyperparameter Optimization via Latin Hypercube Sampling in High-Performance Computing Environments**
Silva et al. 72

Classificação Binária de Vantagem Posicional no Xadrez Com Modelo Perceptron Multicamadas

Lucas Mairon O. Camilo
Bacharelado em Engenharia de Software
Universidade Federal Rural do Semi-árido (UFERSA)
Rio Grande do Norte, Brasil
lucasmairon2@gmail.com

Rosana C. B. Rego
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
rosana.rego@ufersa.edu.br

***Resumo*—O xadrez é um jogo de tabuleiro que possui um grande número de posições diferentes, assim, evidenciando que há a possibilidade de, somente com a observação humana, existir dificuldades quanto a verificação de qual lado está com mais vantagem. Assim, o presente trabalho traz o treinamento de um modelo de inteligência artificial, baseado em perceptron multicamadas, que tem o papel de, dado uma posição do tabuleiro, utilizando classificação binária, indicar qual lado do tabuleiro está com mais vantagem. Trazendo ao final os resultados do treinamento do modelo, com acurácia de 79.42%, precisão de 78.93%, recall de 80.36% e F1 score de 79.64%, o que evidencia um progresso na rede.**

***Index Terms*—xadrez, inteligência artificial, modelagem, simulação, aprendizado de máquina**

I. Introdução

O xadrez é um jogo de mesa mundialmente conhecido e jogado, possuindo um tabuleiro com 64 espaços organizados em uma matriz 8×8, e uma grande diversidade de jogadas possíveis. Onde, por meio delas, constrói-se a vantagem no tabuleiro, seja com as peças brancas ou pretas [1]. Isso se dá pelo fato de que cada peça do tabuleiro tem um valor específico de pontos. Tradicionalmente, utiliza-se o sistema de valoração de Reinfeld onde o peão tem valor $v_{\text{peão}} = 1$, cavalo e bispo $v_{\text{cavalo}} = v_{\text{bispo}} = 3$, torre $v_{\text{torre}} = 5$, e dama $v_{\text{dama}} = 9$, enquanto o rei tem valor infinito por ser a peça decisiva do jogo.

O tabuleiro de xadrez pode ser representado de forma visual, assim como citado anteriormente, sendo algo similar a Figura 1, que representa um tabuleiro em seu estado inicial.

Porém, essa não é a única representação possível do tabuleiro, também existe a representação em FEN (*Forsyth-Edwards Notation*), uma sequência de caracteres que define as posições das peças em um estado da partida [2]. Formalmente, uma string FEN pode ser representada como uma tupla FEN $= (P, T, R, E, H, M)$, onde P é a configuração das peças, T indica o turno, R representa os direitos de roque, E a casa *en passant*, H o contador de meio-movimentos, e M o número do movimento completo. Um exemplo disso é a Figura 2, que representa o código FEN: rnbqkbnr/pp1ppppp/8/2p5/4P3/5N2/PPPP1PPP/RNBQKB1R w KQkq c6 0 2. Onde os caracteres indicam em que posições as peças estão, turno de quem deve jogar, a disponibilidade

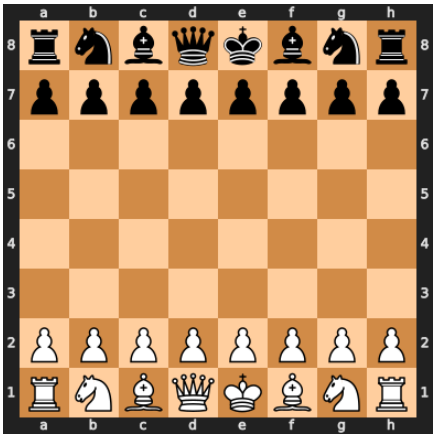


Figura 1. Tabuleiro de xadrez na sua posição original.

de algumas jogadas, e outras informações, em uma sequencia que deve ser lida da esquerda para a direita.

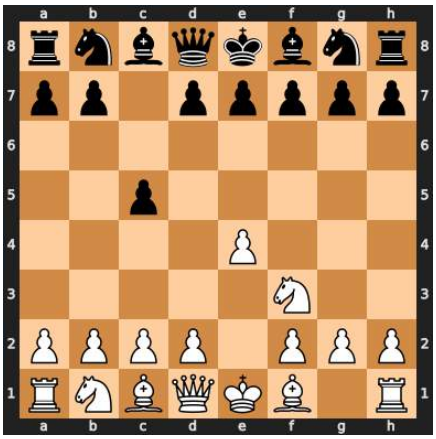


Figura 2. Tabuleiro de xadrez em uma posição específica.

Desta forma, utilizando o FEN citado acima podemos observar barras com sequências de caracteres, com cada barra representando uma linha do tabuleiro e os caracteres indicando

as peças que estão nos espaços entre elas, tendo cada linha 8 casas disponíveis. Logo, os caracteres como r, n, b, q, k e também suas versões em maiúsculo, trazem a inicial da peça que está no espaço, em inglês, como, por exemplo: *rook* (torre, em português) sendo r, *knight* (cavalo) sendo n, e outros. Assim, as letras minusculas indicam as peças pretas e as maiúsculas as brancas. Também observa-se a presença de números entre os caracteres, o que indica a quantidade de casas vazias presentes naquele intervalo [3].

Além disso, os caracteres finais como w, KQkq c6 0 e 2, indicam a ordem de quem é a vez de jogar, neste caso w(indicando a vez das brancas ou *white*), disponibilidade de realizar o roque, tendo KQkq como representação roque disponível tanto das brancas quanto das pretas, c6 representando a casa onde é possível realizar *en passant*, uma jogada especial do tabuleiro, o 0 indicando a quantidade de lances realizados após um movimento de peão ou peça capturada e por fim o 2, trazendo a informação de qual lance o jogo está [3].

Assim, a probabilidade de vitória em um tabuleiro de xadrez não se limita apenas a pontuação das peças, também pode incluir a chance de ganhar nos próximos lances, dependendo das jogadas que serão realizadas em seguida [1]. Matematicamente, pode-se expressar a avaliação de uma posição p como uma função $E(p)$, onde:

$$E(p) = \sum_i v_i \cdot n_i + f_{\text{posicional}}(p) + f_{\text{tática}}(p) \tag{1}$$

onde v_i é o valor da peça tipo i, n_i é a quantidade de peças desse tipo, $f_{\text{posicional}}$ captura vantagens posicionais e $f_{\text{tática}}$ representa oportunidades táticas. Com isso, o presente trabalho pretende traz o treinamento de um modelo de inteligência artificial para calcular, em uma posição selecionada do xadrez, entre as peças pretas e brancas, qual tem mais possibilidade de ganhar a partida.

O interesse quanto a este estudo se deu da curiosidade do presente autor em entender mais sobre as jogadas de xadrez, além de poder, por meio do modelo treinado, aprender mais sobre quais movimentos são mais adequados para uma posição. Também podendo impactar a comunidade de jogadores por meio do mecanismo.

Desta forma, os objetivos do presente trabalho são voltados a criação e treinamento de um modelo de inteligência artificial capaz de, por meio de posições do tabuleiro de xadrez, indicar qual dos lados está com vantagem, se são as peças pretas ou brancas.

II. Levantamento Bibliográfico

O uso de inteligência artificial para interações quanto as jogadas do xadrez também é discutido por meio de outros trabalhos, destacando assim a contribuição que a proposta pode trazer. Assim, os próximos parágrafos trazem trabalhos que possam contribuir e impactar com a presente proposta.

Silver et al. [4] destacaram o xadrez quanto aos testes de inteligência artificial. Assim, utilizando o AlphaZero para demonstrar que modelos de inteligência artificial treinados exclusivamente por jogadas do tabuleiro, sem conhecimento humano, pode vencer até mesmo campeões mundiais. Desta forma, destacando o potencial do aprendizado de máquina na área.

Sabatelli et al. [5] trazem um trabalho com a ideia de treinar modelos de inteligência artificial para avaliar posições de xadrez com base no stockfish. Desta formando, utilizando regressão para a resolução de problema, como também comparando algumas arquiteturas.

Pires et al. [6] apresentam a avaliação do desempenho de diferentes algoritmos de aprendizado de máquina quanto a predição do resultado em relação a uma partida de xadrez, tendo com base apenas uma posição do tabuleiro. Demonstrando assim como o tipo de rede proposto no presente trabalho pode realmente aprender padrões do tabuleiro e ser treinado com certa precisão.

Lai [7] traz o destaque quanto a organização de dados, já que, assim como o presente trabalho, o autor também decidiu fazer a passagem de dados quanto as posições sem utilizar imagens de estados do tabuleiro, introduzindo assim parâmetros a mais para auxiliar no processo. Assim, se torna evidente que esse tipo de abordagem também pode ser funcional quanto ao treinamento de redes neurais nesse tipo de solução.

III. Modelo de Rede Neural Proposto

A. Detalhamento do Problema

Dado a complexidade das jogadas de xadrez, a olho humano, muitas vezes torna-se difícil conseguir identificar qual o lado está com a vantagem em relação à posição das peças[3]. Portanto, o modelo desenvolvido pretende resolver o problema de identificação de vantagem estratégica em posições do tabuleiro de xadrez, utilizando classificação binária para isso.

Formalmente, o problema pode ser definido como: dado um conjunto de dados $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^{N}$, onde $\mathbf{x}_i \in \mathbb{R}^{70}$ representa a codificação de uma posição do tabuleiro e $y_i \in \{0, 1\}$ é o rótulo da classe (0 para vantagem das pretas, 1 para vantagem das brancas), deseja-se aprender uma função $f_\theta : \mathbb{R}^{70} \to [0, 1]$ parametrizada por θ que minimize o erro de classificação sobre o conjunto de dados. O objetivo é encontrar os parâmetros ótimos:

$$\theta^* = \arg\min_\theta \mathbb{E}_{(\mathbf{x},y)\sim\mathcal{D}} \left[L(f_\theta(\mathbf{x}), y) \right] \tag{2}$$

onde L é a função de perda escolhida (Binary Cross-Entropy) e $\mathbb{E}$ representa o valor esperado em relação à distribuição dos dados.

B. Organização dos dados

Os dados utilizados para o treino do modelo estão disponíveis por meio do link: https://www.kaggle.com/datasets/ronakbadhe/chess-evaluations. O dataset utilizado possui cerca de 16 milhões de dados distribuídos em duas colunas, sendo elas a FEN, representando uma posição do tabuleiro, e *evaluations*(avaliações), contendo o valor da posição.

Dos quase 16 milhões de dados foram filtrados 250 mil, com a intenção de coletar uma grande número de dados, sem prejudicar significativamente o desempenho da rede. Os

dados da coluna de avaliações do *dataset* foram convertidos em escala binária por meio da função:

$$y = \begin{cases} 1, & \text{se } e > 0 \text{ (vantagem das brancas)} \\ 0, & \text{se } e < 0 \text{ (vantagem das pretas)} \end{cases} \tag{3}$$

onde e representa o valor de avaliação da posição, descartando assim posições equilibradas ($e = 0$). Desta forma, os dados foram balanceados por meio do mecanismo de *undersampling*, voltado a redução dos dados da classe majoritária para igualar a quantidade de dados presentes em ambas as classes[8].

Seja $\mathcal{D}_0 = \{(\mathbf{x}_i, 0)\}$ o conjunto de exemplos da classe 0 e $\mathcal{D}_1 = \{(\mathbf{x}_j, 1)\}$ da classe 1, com $|\mathcal{D}_0| \neq |\mathcal{D}_1|$. O *undersampling* cria um subconjunto balanceado $\mathcal{D}_{\text{bal}}$ tal que:

$$|\mathcal{D}_{\text{bal}} \cap \mathcal{D}_0| = |\mathcal{D}_{\text{bal}} \cap \mathcal{D}_1| = \min(|\mathcal{D}_0|, |\mathcal{D}_1|) \tag{4}$$

gerando um balanceamento de 50/50 dos dados.

Além disso, os dados da coluna FEN também passaram pelo processo de conversão, visto que são sequências de caracteres. Desta forma, cada posição FEN do tabuleiro se tornou um vetor de características $\mathbf{x} \in \mathbb{R}^{70}$, onde dentre essas 70 dimensões, 64 são destinados às peças ocupantes dos espaços do tabuleiro e o restante voltado a valores extras, como turno e vez, para indicar quem tem prioridade de jogada, saldo material, que indica as vantagens em relação aos valores das peças, e por fim a possibilidade de roque, uma jogada popular no xadrez e a mobilidade, voltado ao número de jogadas legais para a posição.

O conjunto de dados balanceado $\mathcal{D}_{\text{bal}}$ foi particionado em três subconjuntos disjuntos:

$$\mathcal{D}_{\text{bal}} = \mathcal{D}_{\text{treino}} \cup \mathcal{D}_{\text{val}} \cup \mathcal{D}_{\text{teste}}, \quad \mathcal{D}_i \cap \mathcal{D}_j = \emptyset \text{ para } i \neq j \tag{5}$$

utilizados respectivamente para treinamento, validação durante o treinamento e avaliação final do modelo.

Desta forma, define-se uma função de mapeamento $f : \mathbb{R}^{70} \to [0, 1]$ onde:

$$f(\mathbf{x}) = \hat{y} = \begin{cases} > 0.5, & \text{indica vantagem das brancas} \\ < 0.5, & \text{indica vantagem das pretas} \end{cases} \tag{6}$$

onde $\mathbf{x}$ é a representação vetorial da posição FEN e $\hat{y}$ é a predição da rede neural.

C. Arquitetura do modelo

O modelo representa uma rede perceptron multicamadas (MLP), sendo assim um modelo sequencial. A arquitetura utilizada tem uma estrutura de 4 camadas, sendo a primeira camada com 128 neurônios, representando uma camada de entrada de dados, duas camadas ocultas de 64 neurônios cada, e uma camada de saída com apenas um neurônio, assim como indicado na Figura 3.

Matematicamente, a saída de cada camada l pode ser expressa como:

$$\mathbf{h}^{(l)} = \sigma^{(l)} \left(\mathbf{W}^{(l)} \mathbf{h}^{(l-1)} + \mathbf{b}^{(l)} \right) \tag{7}$$

onde $\mathbf{W}^{(l)}$ são os pesos da camada l, $\mathbf{b}^{(l)}$ é o vetor de viés, $\mathbf{h}^{(l-1)}$ é a saída da camada anterior, e $\sigma^{(l)}$ é a função de ativação.

Para as camadas de entrada e ocultas, utiliza-se a função de ativação ReLU (Rectified Linear Unit):

$$\text{ReLU}(z) = \max(0, z) = \begin{cases} z, & \text{se } z > 0 \\ 0, & \text{caso contrário} \end{cases} \tag{8}$$

A camada de saída utiliza a função sigmoid para produzir uma probabilidade no intervalo $[0, 1]$:

$$\sigma(z) = \frac{1}{1 + e^{-z}} \tag{9}$$

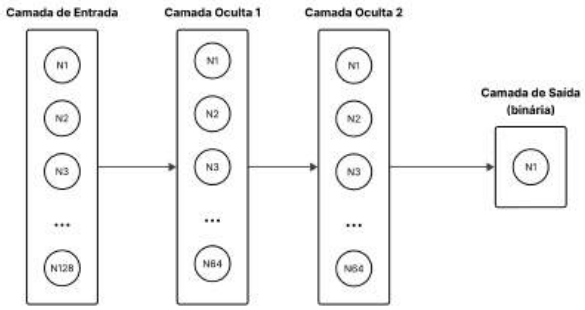


Figura 3. Representação das camadas da rede.

Dentre as camadas citadas também estão presentes as de *dropout* e *batch normalization*, utilizadas visando um maior desempenho da rede em relação a overfitting e as métricas em geral. O *dropout* aplica a operação:

$$\mathbf{h}_{\text{drop}} = \mathbf{h} \odot \mathbf{m}, \quad \mathbf{m} \sim \text{Bernoulli}(p) \tag{10}$$

onde $\odot$ representa a multiplicação elemento a elemento, $\mathbf{m}$ é uma máscara binária e p é a probabilidade de manter um neurônio ativo.

A *batch normalization* normaliza as ativações:

$$\text{BN}(\mathbf{h}) = \gamma \frac{\mathbf{h} - \mu_B}{\sqrt{\sigma_B^2 + \epsilon}} + \beta \tag{11}$$

onde μ_B e σ_B^2 são a média e variância do lote, γ e β são parâmetros aprendíveis, e ϵ é uma constante para estabilidade numérica.

D. Treinamento

O treinamento da rede foi realizado com 100 épocas, utilizando o mecanismo de parada forçada (*early stopping*) monitorando a validação da função perda. O critério de parada é definido como:

$$\text{parar se } L_{\text{val}}(t) > L_{\text{val}}(t - k) \text{ para todo } k \in \{1, 2, \ldots, p\} \tag{12}$$

onde $L_{\text{val}}(t)$ é a perda de validação na época t e p é a paciência do algoritmo (número de épocas sem melhoria antes de parar).

A função de perda utilizada é a *Binary Cross-Entropy*, definida como:

$$L(\mathbf{y}, \hat{\mathbf{y}}) = -\frac{1}{N}\sum_{i=1}^{N}[y_i \log(\hat{y}_i) + (1-y_i)\log(1-\hat{y}_i)] \quad (13)$$

onde N é o número de exemplos, y_i é o rótulo verdadeiro e $\hat{y}_i$ é a predição para o exemplo i.

Para evitar *overfitting*, aplica-se regularização L2 aos pesos da rede:

$$L_{\text{total}} = L(\mathbf{y}, \hat{\mathbf{y}}) + \lambda \sum_{l} \|\mathbf{W}^{(l)}\|_2^2 \quad (14)$$

onde λ é o coeficiente de regularização e $\|\mathbf{W}^{(l)}\|_2^2 = \sum_{i,j}(W_{ij}^{(l)})^2$ é o quadrado da norma L2 dos pesos.

O otimizador Adam atualiza os pesos segundo as regras:

$$\mathbf{m}_t = \beta_1 \mathbf{m}_{t-1} + (1-\beta_1)\nabla_{\mathbf{W}} L \quad (15)$$

$$\mathbf{v}_t = \beta_2 \mathbf{v}_{t-1} + (1-\beta_2)(\nabla_{\mathbf{W}} L)^2 \quad (16)$$

$$\hat{\mathbf{m}}_t = \frac{\mathbf{m}_t}{1-\beta_1^t}, \quad \hat{\mathbf{v}}_t = \frac{\mathbf{v}_t}{1-\beta_2^t} \quad (17)$$

$$\mathbf{W}_t = \mathbf{W}_{t-1} - \alpha \frac{\hat{\mathbf{m}}_t}{\sqrt{\hat{\mathbf{v}}_t} + \epsilon} \quad (18)$$

onde α é a taxa de aprendizado, β_1 e β_2 são os coeficientes de decaimento dos momentos, e ϵ é uma constante para estabilidade numérica. Os valores atribuídos a estes parâmetros para a execução das simulações estão detalhados na Tabela I. O *batch size* utilizado foi de 256 exemplos.

Tabela I
VALORES DOS HIPERPARÂMETROS UTILIZADOS NAS SIMULAÇÕES

Parâmetro	**Valor**
Taxa de aprendizado (α)	0.0001
Decaimento do momento 1 (β_1)	0.9
Decaimento do momento 2 (β_2)	0.999
Constante numérica (ϵ)	10^{-8}
Tamanho do lote (*batch size*)	256

Os gradientes $\nabla_{\mathbf{W}} L$ são computados eficientemente usando o algoritmo de retropropagação (*backpropagation*), baseado na regra da cadeia do cálculo:

$$\frac{\partial L}{\partial W_{ij}^{(l)}} = \frac{\partial L}{\partial h_i^{(l)}} \cdot \frac{\partial h_i^{(l)}}{\partial W_{ij}^{(l)}} = \delta_i^{(l)} \cdot h_j^{(l-1)} \quad (19)$$

onde $\delta_i^{(l)} = \frac{\partial L}{\partial h_i^{(l)}}$ é o erro retropropagado para o neurônio i da camada l.

O código contendo o treinamento do modelo está disponível no GitHub por meio da licença MIT, no link: https://github.com/ClassNeuralNetwork/classification-chess.

A arquitetura completa pode ser expressa como uma composição de funções:

$$\mathbf{h}^{(1)} = \text{ReLU}(\mathbf{W}^{(1)}\mathbf{x} + \mathbf{b}^{(1)}) \quad (20)$$

$$\mathbf{h}^{(2)} = \text{ReLU}(\mathbf{W}^{(2)}\mathbf{h}^{(1)} + \mathbf{b}^{(2)}) \quad (21)$$

$$\mathbf{h}^{(3)} = \text{ReLU}(\mathbf{W}^{(3)}\mathbf{h}^{(2)} + \mathbf{b}^{(3)}) \quad (22)$$

$$f_\theta(\mathbf{x}) = \sigma(\mathbf{W}^{(4)}\mathbf{h}^{(3)} + \mathbf{b}^{(4)}) \quad (23)$$

onde $\theta = \{\mathbf{W}^{(l)}, \mathbf{b}^{(l)}\}_{l=1}^{4}$ representa todos os parâmetros treináveis da rede.

IV. Resultados e Simulações

A Figura 4 exibe o resultado da função perda aplicada ao modelo, onde, o eixo x representa a quantidade de épocas executadas, enquanto o eixo y apresenta o valor da função perda. Demonstrando assim um treinamento com um potencial, já que a linha de treino está bem alinhada com a linha de validação do modelo. A convergência da função perda indica que o processo de otimização gradiente descendente está minimizando efetivamente a função objetivo:

$$L_{\text{total}}(\theta) = L_{\text{treino}}(\theta) + \lambda\Omega(\theta) \quad (24)$$

onde L_{treino} é a perda no conjunto de treinamento e $\Omega(\theta)$ é o termo de regularização.

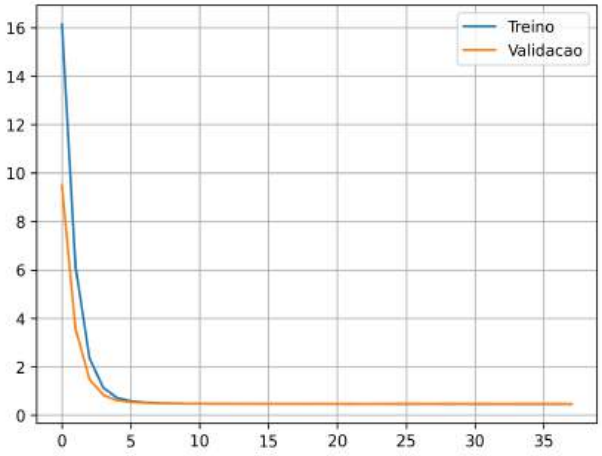


Figura 4. Função perda do modelo.

Por meio da Figura 5 podemos observar a matriz de confusão do modelo. A matriz de confusão é definida como:

$$C = \begin{bmatrix} \text{VP} & \text{FN} \\ \text{FP} & \text{VN} \end{bmatrix} \quad (25)$$

onde VP (verdadeiros positivos) representa predições corretas da classe 1, VN (verdadeiros negativos) da classe 0, FP (falsos positivos) são classificações incorretas como classe 1, e FN (falsos negativos) classificações incorretas como classe 0.

A matriz demonstra uma precisão considerável, ao conter a diagonal principal em destaque. Porém, ainda permitindo visualizar que o modelo está errando um considerável número de dados. Trazendo assim um número considerável tanto de falsos positivos quanto de falsos negativos, algo que se pretende investigar futuramente para ser melhorado.

Como é possível analisar por meio da Tabela II, as métricas, sendo elas acurácia, precisão, recall e f1-score, ficaram em torno de 0.78 a 0.80, indicando um bom desempenho da rede, mesmo que evidenciando a necessidade de fazer melhorias nela. Estas métricas são definidas matematicamente como:

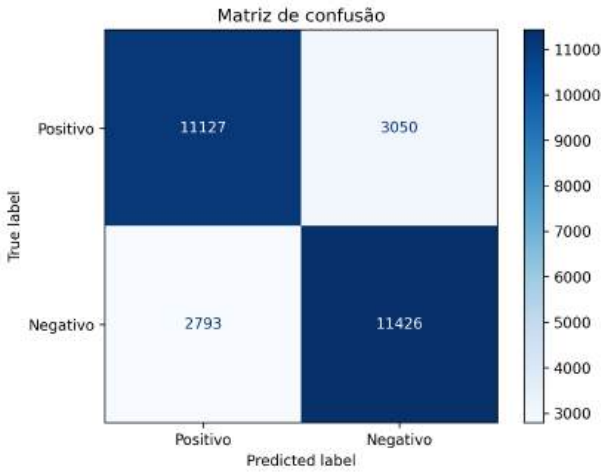


Figura 5. Matriz de confusão do modelo.

Acurácia: Proporção de predições corretas

$$\text{Acurácia} = \frac{\text{VP} + \text{VN}}{\text{VP} + \text{VN} + \text{FP} + \text{FN}} \tag{26}$$

Precisão: Proporção de predições positivas que são corretas

$$\text{Precisão} = \frac{\text{VP}}{\text{VP} + \text{FP}} \tag{27}$$

Recall (Sensibilidade): Proporção de positivos verdadeiros corretamente identificados

$$\text{Recall} = \frac{\text{VP}}{\text{VP} + \text{FN}} \tag{28}$$

F1-Score: Média harmônica entre precisão e recall

$$\text{F1-Score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}} = \frac{2\text{VP}}{2\text{VP} + \text{FP} + \text{FN}} \tag{29}$$

Tabela II
MÉTRICAS DE DESEMPENHO DO MODELO

Métrica	Valor
Acurácia	0.7942
Precisão	0.7893
Recall	0.8036
F1-score	0.7964

Tendo como base a Figura 6 podemos observar os impactos dos parâmetros passados no treinamento da rede, sendo eles obtidos ou por meio do FEN, com base no estado do tabuleiro, ou estando contidos nele. Assim, percebe-se o destaque que os parâmetros de saldo material, vez e mobilidade causam na rede, impactando diretamente para um treinamento melhor. Ao observar atentamente, também é possível notar que algumas casas, que representam os espaços do tabuleiro, geram impacto no treinamento, indicando assim que o treinamento não está sendo guiado apenas pelos parâmetros auxiliares.

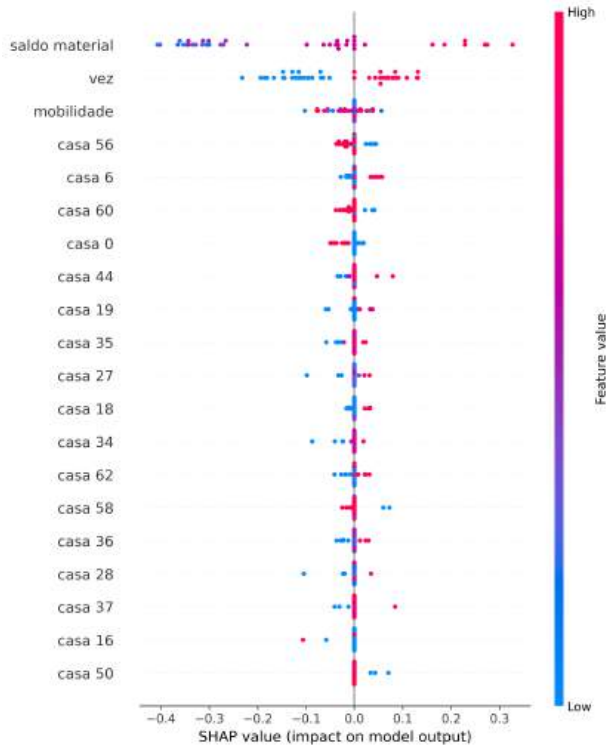


Figura 6. Impacto de parâmetros no treinamento da rede.

V. Conclusões

Por meio do exposto durante este trabalho percebe-se que o modelo já alcança bons desempenhos, podendo, ao ser aprimorado, ser utilizado para resolver problemas propostos. O modelo treinado atingiu uma taxa de acurácia de aproximadamente 79.42%, indicando que $P(\hat{y} = y) \approx 0.7942$ onde $\hat{y}$ é a predição do modelo e y é o rótulo verdadeiro. Este resultado demonstra que o modelo aprende padrões relevantes da estrutura posicional do xadrez, superando significativamente a baseline de classificação aleatória que teria acurácia de 50%.

Algumas das limitações quanto ao estudo realizado se trata da arquitetura da rede, já que, por ser uma perceptron multi camadas, não possui um desempenho adequado para o tipo de problema estudado quando comparado a arquiteturas mais sofisticadas como redes convolucionais ou transformers.

Como trabalhos futuros, pretende-se incrementar o modelo, almejando assim melhorar tanto suas métricas como os gráficos gerados para validação. Desta forma, melhorando os resultados do mesmo. Além disso, serão analisados novos tipos de redes para o problema, assim, podendo modificar o atual visando o aprimoramento do treinamento, já que pode se tornar mais eficiente.

Futuramente também pretende-se modificar a ideia para complementar as funcionalidades que o modelo poderá fazer, como, por exemplo, classificar qual próxima jogada seria a mais vantajosa, sugerir defesas e também apresentar justifica-

tivas quanto aos determinados tipos de respostas dados pelo modelo.

Uso de Inteligência Artificial

Em conformidade com as diretrizes de integridade científica e boas práticas acadêmicas recomendadas pela CAPES, os autores declaram que utilizaram ferramentas de inteligência artificial, incluindo Claude e Gemini, exclusivamente para auxiliar na melhoria da linguagem e legibilidade deste manuscrito. O uso dessas ferramentas foi realizado sob supervisão humana, e os autores revisaram e editaram cuidadosamente o conteúdo, assumindo total responsabilidade pelo texto final publicado.

Agradecimentos

Os autores agradecem à disciplina de Redes Neurais do curso de Engenharia de Software da Universidade Federal Rural do Semi-Árido (UFERSA), no âmbito da qual este trabalho foi desenvolvido.

Referências

[1] C. Castro, "Uma história cultural do xadrez," *Cadernos de teoria da comunicação, Rio de Janeiro*, vol. 1, no. 2, pp. 3–12, 1994.

[2] L. V. C. Zanella, "Tutor de xadrez, uma abordagem web," 2017.

[3] R. F. d. O. Cardozo, "Desenvolvimento de um agente de inteligência artificial para o jogo de xadrez baseado no algoritmo minimax," 2025.

[4] D. Silver, T. Hubert, J. Schrittwieser, I. Antonoglou, M. Lai, A. Guez, M. Lanctot, L. Sifre, D. Kumaran, T. Graepel *et al.*, "A general reinforcement learning algorithm that masters chess, shogi, and go through self-play," *Science*, vol. 362, no. 6419, pp. 1140–1144, 2018.

[5] M. Sabatelli, F. Bidoia, V. Codreanu, and M. Wiering, "Learning to evaluate chess positions with deep neural networks and limited lookahead," in *7th International Conference on Pattern Recognition Applications and Methods*. SciTePress, 2018, pp. 276–283.

[6] H. Pires, H. Pedrini, R. Técnico-IC-PFG, and P. F. de Graduação, "Métodos de aprendizado de máquina aplicados ao jogo de xadrez," 2022.

[7] M. Lai, "Giraffe: Using deep reinforcement learning to play chess," *arXiv preprint arXiv:1509.01549*, 2015.

[8] M. S. Shelke, P. R. Deshmukh, and V. K. Shandilya, "A review on imbalanced data handling using undersampling and oversampling technique," *Int. J. Recent Trends Eng. Res*, vol. 3, no. 4, pp. 444–449, 2017.

Detecção de *Deepfakes* Baseada em Metadados Forenses Utilizando Perceptron de Múltiplas Camadas

Claudio Caueh O. Xavier
Estudante de Engenharia de Software
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
cqueholiveira@gmail.com

Rosana C. B. Rego
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
rosana.rego@ufersa.edu.br

***Abstract*—As tecnologias de síntese de mídias falsas, denominadas *deepfakes*, constituem um dos principais desafios contemporâneos à segurança digital. Com o avanço das ferramentas de manipulação de vídeo e áudio, a distinção entre conteúdo autêntico e sintetizado artificialmente tornou-se progressivamente complexa. Este trabalho propõe uma abordagem baseada em metadados forenses: em vez de realizar análise em nível de *pixel*, o método proposto opera sobre características numéricas abstratas da mídia, tais como inconsistências na sincronização audiovisual e anomalias de compressão. Utilizou-se um *dataset* científico contendo essas métricas forenses, sobre o qual foi desenvolvida uma Rede Neural Artificial do tipo *Multilayer Perceptron* (*MLP*). O modelo proposto demonstrou capacidade de classificação binária entre mídias autênticas e *deepfakes*. Os resultados confirmam que as assinaturas forenses estruturais presentes em *deepfakes* constituem características discriminativas suficientes para sistemas de detecção computacionalmente eficientes, demandando recursos substancialmente inferiores quando comparados a abordagens baseadas puramente em visão computacional profunda. O modelo alcançou acurácia de 100% no conjunto de teste, com ausência total de falsos positivos e falsos negativos.**

***Index Terms*—*deepfake*, forense digital, redes neurais artificiais, aprendizado de máquina, *multilayer perceptron*, interpretabilidade**

I. Introdução e Revisão de Literatura

A. O Problema dos Deepfakes na Sociedade

A geração automatizada de conteúdo multimídia por meio de inteligência artificial (IA) proporcionou significativos avanços em diversos domínios, contudo, introduziu desafios substanciais à autenticidade digital: os *deepfakes* [1]. Essa tecnologia, frequentemente fundamentada em *Generative Adversarial Networks* (*GANs*), possibilita a substituição de faces e a síntese de voz em imagens e vídeos com elevado grau de realismo visual e acústico.

Esse cenário configura-se como um desafio crítico para pesquisadores de segurança da informação, uma vez que os *deepfakes* podem ser empregados para disseminação de desinformação, fraudes financeiras e difamação de indivíduos públicos. O problema central reside na democratização das ferramentas de síntese, cuja barreira técnica para produção de *deepfakes* de alta qualidade foi substancialmente reduzida, possibilitando que usuários sem conhecimento especializado tenham acesso a sistemas avançados de geração de faces sintéticas.

O crescimento exponencial dessas mídias sintéticas demanda métodos de detecção cada vez mais eficientes e precisos. Inicialmente, as abordagens de identificação de *deepfakes* baseavam-se em inspeção visual manual, todavia, as imagens sintéticas contemporâneas apresentam qualidade perceptual próxima à de mídias autênticas [2]. Consequentemente, a utilização de IA para detectar artefatos gerados por outras arquiteturas de *machine learning* consolidou-se como abordagem predominante na literatura científica. Entretanto, grande parte desses métodos fundamenta-se em análise intensiva de características em nível de *pixel*, demandando infraestrutura computacional de alto desempenho e processos de treinamento extensos, com duração de múltiplas horas ou dias. Essa elevada demanda computacional limita sua aplicabilidade em sistemas escaláveis de detecção automatizada, como plataformas de redes sociais.

B. Proposta Focada em Metadados Forenses

As diversas técnicas de síntese de mídias audiovisuais artificiais geram diferentes assinaturas forenses imperceptíveis à percepção humana direta. A literatura científica evidencia que os processos de geração de *deepfakes* apresentam significativa heterogeneidade metodológica [4]. Essa premissa tem direcionado pesquisadores a uma mudança de paradigma: em vez de analisar o conteúdo visual em nível de *pixel*, investigar metadados forenses e características estatísticas secundárias.

Essa abordagem motiva o emprego de atributos multidimensionais, tais como os indicadores forenses utilizados no presente estudo [4]. Diversos estudos demonstram que a detecção pode ser realizada de forma mais eficiente fundamentando-se nessas anomalias sutis de compressão e inconsistências estruturais. Uma vez que os algoritmos geradores de mídias sintéticas otimizam prioritariamente a fidelidade visual, aspectos secundários do processamento, como estabilidade de compressão em regiões de fundo e sincronia labial, frequentemente apresentam artefatos detectáveis estatisticamente.

A utilização dessas características tabuladas demanda apenas uma fração mínima de recursos computacionais quando comparada aos métodos tradicionais de visão computacional. Portanto, o objetivo fundamental e explícito desta pesquisa consiste em apresentar uma abordagem preditiva de baixo custo computacional baseada em metadados forenses para a detecção de *deepfakes*. Pretende-se estruturar e validar um algoritmo *Multilayer Perceptron* (*MLP*) capaz de operar sobre características numéricas abstratas e gerar predições em escala de milissegundos.

C. Trabalhos Relacionados

A literatura científica evidencia que os processos de geração de *deepfakes* apresentam significativa heterogeneidade metodológica [4]. Trabalhos recentes indicam uma mudança de paradigma: em vez de focar puramente na inspeção de conteúdo em nível de *pixel*, diversos estudos demonstram que a detecção e classificação podem ser realizadas de forma mais eficiente empregando metadados e atributos multidimensionais fundamentados em anomalias sutis de compressão [4]. O método proposto neste artigo avança nessa discussão ao explorar uma arquitetura leve operando estritamente sobre características de inconsistência estrutural e sincronia, visando superar a elevada demanda de recursos das abordagens tradicionais de visão computacional.

II. Características da Modelagem Experimental

A. A Base de Dados Original

Para garantir uma avaliação científica rigorosa e reprodutível, os dados utilizados no escopo desta pesquisa pertencem ao *dataset* público internacional intitulado "*Deepfake and Synthetic Media Detection*" [3]. Esse repositório, amplamente utilizado para fins de pesquisa acadêmica, contém atributos e características representativas de cenários reais, refletindo as assinaturas forenses presentes tanto em mídias sintéticas (classe *Fake*) quanto em mídias autênticas não manipuladas (classe *Real*).

O *dataset* não contém arquivos multimídia brutos, mas sim características numéricas pré-extraídas e tabuladas para cada registro. Após a etapa de análise exploratória de dados e auditoria de interpretabilidade, o modelo foi otimizado para operar estritamente sobre três atributos forenses essenciais:

1) Índice de dessincronização labial: métrica que quantifica a discrepância temporal entre os movimentos labiais e o sinal de áudio correspondente (*lip sync score*).
2) Pontuação de artefatos visuais: métrica que avalia a presença de anomalias e artefatos de compressão em regiões de fundo da imagem (*visual artifacts score*).
3) Pontuação de inconsistência de iluminação: métrica que detecta padrões atípicos ou incoerentes de iluminação decorrentes de manipulações digitais (*lighting inconsistency score*).

Para evitar que o modelo memorizasse informações em vez de aprender padrões reais, identificadores que causam *Data Leakage* foram estritamente removidos.

B. A Padronização e Divisão do Processo

Em seguida, as três características numéricas contínuas selecionadas foram submetidas a padronização estatística. Esta etapa é fundamental para prevenir que atributos com escalas numéricas distintas introduzam viés no processo de otimização dos pesos sinápticos. Utilizando a biblioteca *Scikit-learn* [6], o método *StandardScaler* normalizou cada característica para apresentar média $\mu = 0$ e desvio padrão $\sigma = 1$.

Por fim, os dados foram submetidos ao particionamento estratificado. Utilizou-se a função `train_test_split` para separar 80% das amostras para o conjunto de treinamento, e os 20% remanescentes constituíram o conjunto de teste (*test set*), preservando a proporção original das classes mediante estratificação [6].

C. Proposição da Arquitetura e Modelagem Matemática

A arquitetura proposta consiste em um modelo *Multilayer Perceptron* (*MLP*) adaptado para dados de baixa dimensionalidade (3 características de entrada). De natureza *feedforward*, a rede executa propagação unidirecional da camada de entrada até a camada de saída. A arquitetura modular proposta pode ser observada na Figura 1. Para a otimização dos pesos sinápticos, empregou-se o algoritmo *Adaptive Moment Estimation* (*Adam*). A função de perda adotada foi a entropia cruzada binária (*Binary Cross-Entropy*), matematicamente definida como:

$$\mathcal{L} = -\frac{1}{N}\sum_{i=1}^{N}\left[y_i \log(\hat{y}_i) + (1 - y_i)\log(1 - \hat{y}_i)\right] \qquad (1)$$

onde N é o número de amostras, y_i é a classe verdadeira (0 ou 1) e $\hat{y}_i$ é a probabilidade predita pelo modelo.

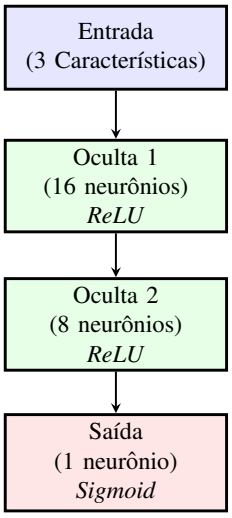


Fig. 1. Diagrama visual do sequenciamento arquitetural da rede neural *Multilayer Perceptron*.

Para capturar relações não lineares nos dados, empregou-se a função de ativação *Rectified Linear Unit* (*ReLU*) nas

camadas ocultas. A equação que define a função *ReLU* é dada por:

$$f(x) = \max(0, x) \tag{2}$$

Devido à sua simplicidade computacional e às suas propriedades de gradiente, essa função otimiza o processo de treinamento ao mitigar o problema de desvanecimento do gradiente (*vanishing gradient*). A saída da última camada oculta é processada por uma camada densa final que utiliza a função de ativação sigmoide (*Sigmoid*), matematicamente expressa por:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{3}$$

Esta função mapeia os valores de saída para o intervalo contínuo $[0, 1]$, possibilitando a interpretação probabilística do resultado, onde valores próximos a 1 indicam classe *Fake* e valores próximos a 0 indicam classe *Real*.

III. Análise de Simulações e Resultados

A. Treinamento e Convergência

O processo de treinamento da rede foi configurado para 100 épocas. O modelo apresentou convergência ao longo das iterações, as métricas de desempenho convergiram. A arquitetura simplificada, operando sobre apenas três características de entrada, aliada ao emprego de regularização *L2*, permitiu que a rede capturasse os padrões discriminativos de forma robusta, sem apresentar instabilidades numéricas, conforme mostra a Figura 2.

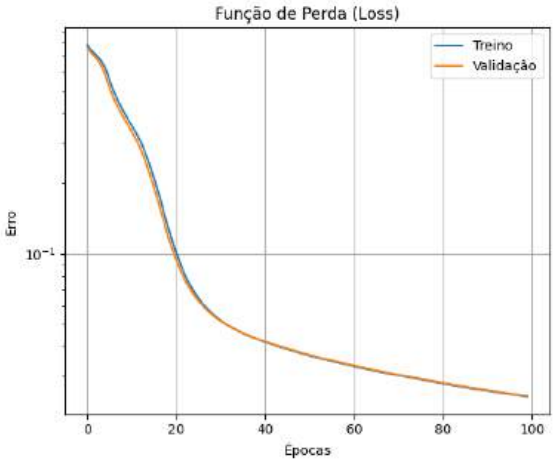


Fig. 2. Convergência contínua das curvas de Perda durante o processo de treinamento, evidenciando a ausência de sobreajuste.

Analisando a evolução do processo de treinamento ilustrada nas Figuras 2 e 3, observa-se comportamento de convergência altamente estável. Em paralelo, a Figura 3 evidencia que a acurácia do modelo partiu de valor inicial moderado e apresentou crescimento acentuado, atingindo acurácia de $1,0$ antes da décima época. A manutenção dessa métrica em valor unitário até o término do treinamento confirma que os metadados

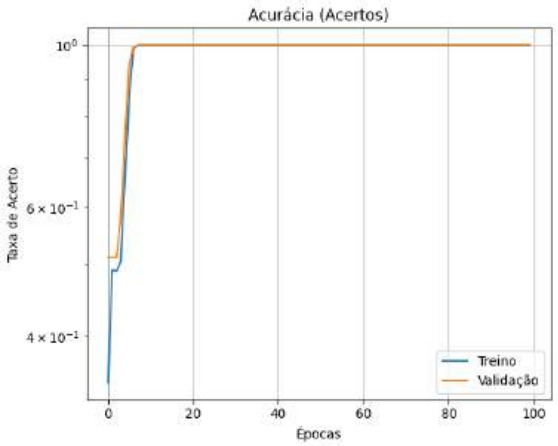


Fig. 3. Evolução em escala logarítmica da acurácia, comprovando a estabilização rápida e consistente dos acertos.

forenses selecionados constituem características discriminativas suficientemente representativas, permitindo convergência rápida e estável do modelo, dispensando ciclos extensos de otimização.

B. Desempenho no Conjunto de Testes

Para a avaliação final de desempenho, empregou-se o conjunto de teste previamente isolado (20% do *dataset* total). A matriz de confusão é apresentada na Figura 4.

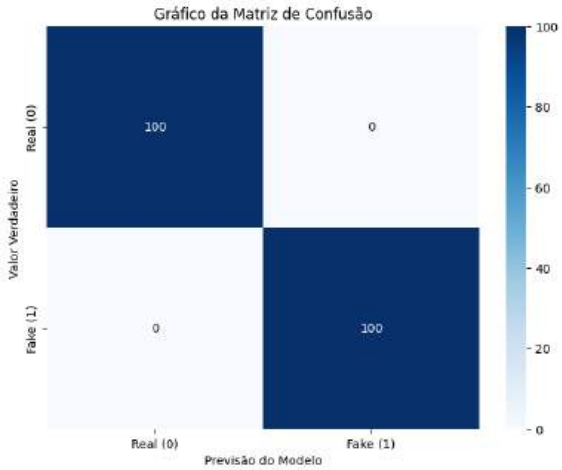


Fig. 4. Matriz de Confusão evidenciando desempenho na classificação do *dataset* de teste (ausência total de falsos positivos e falsos negativos).

O modelo atingiu acurácia de 100% no conjunto de teste. Das amostras apresentadas, tanto *Real* quanto *Fake*, a rede foi capaz de classificá-las corretamente sem registrar falsos positivos ou falsos negativos. Este resultado ratifica a eficácia da arquitetura simplificada proposta para o *dataset* em questão. Ao discutir esses resultados em face aos trabalhos relacionados, evidencia-se que a estratégia de operar sobre assinaturas

forenses pré-extraídas superou as abordagens tradicionais ao atingir desempenho máximo demandadno apenas uma fração mínima de recursos computacionais. O alto nível de acerto comprova que inconsistências na sincronização audiovisual e anomalias de compressão são características discriminativas suficientes e plenas para a identificação de mídias sintetizadas.

C. Interpretabilidade Computacional (XAI)

Para elucidar o processo de decisão da Rede Neural e garantir transparência interpretativa, aplicou-se o método de Inteligência Artificial Explicável *SHapley Additive exPlanations* (*SHAP*) [7].

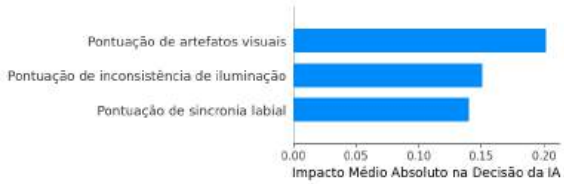


Fig. 5. Impacto médio absoluto de cada característica na decisão final do modelo (*SHAP Bar Plot*).

A Figura 5 revela que a pontuação de artefatos visuais constitui o atributo de maior importância para a classificação de mídias como *Fake*, seguida pela inconsistência de iluminação e, finalmente, pela dessincronização labial. O modelo extraiu hierarquia de importância consistente com o conhecimento forense esperado, corroborando a relevância das características selecionadas para detecção de mídias sintéticas.

IV. Conclusões e Trabalhos Futuros

A arquitetura *MLP*, após otimizações baseadas em análise de explicabilidade (*SHAP*), demonstrou desempenho robusto com 100% de acurácia no *dataset* avaliado. A classificação operando exclusivamente sobre três metadados forenses demonstrou que é viável substituir a análise massiva em nível de *pixel*. Contudo, devem-se pontuar limitações metodológicas e ameaças à validade do estudo. A obtenção de 100% de acurácia e a ausência total de erros foram viabilizadas pelo uso de métricas numéricas pré-extraídas e tabuladas, o que abstrai o elevado custo computacional que seria inevitavelmente exigido para a extração forense dessas características a partir de mídias brutas em tempo real. Além disso, tal perfeição no conjunto de teste pode indicar uma dependência do modelo às assinatuas específicas da base de dados utilizada. Portanto, como perspectiva futura, propõe-se a aplicação do modelo em dados provenientes do tráfego real de usuários em plataformas de redes sociais e serviços de compartilhamento de vídeo.

Declaração de Uso de Inteligência Artificial

Os autores declaram que utilizaram ferramentas de IA, incluindo Gemini, exclusivamente para auxiliar na melhoria da linguagem, estruturação do código das figuras e legibilidade deste manuscrito. O uso dessas ferramentas foi realizado sob supervisão humana, e os autores revisaram e editaram cuidadosamente o conteúdo, assumindo total responsabilidade pelo texto final publicado.

References

[1] R. Tolosana, R. Vera-Rodriguez, J. Fierrez, A. Morales, and J. Ortega-Garcia, "Deepfakes and beyond: A Survey of face manipulation and fake detection," *Information Fusion*, vol. 64, pp. 131–148, 2020.
[2] T. T. Nguyen *et al.*, "Deep learning for deepfakes creation and detection: A survey," *Computer Vision and Image Understanding*, vol. 196, 2020.
[3] P. Dhokane, "Deepfake and Synthetic Media Detection Dataset," Kaggle.
[4] Z. Yan *et al.*, "DF40: Toward Next-Generation Deepfake Detection," *Advances in Neural Information Processing Systems* (NeurIPS), 2024.
[5] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, MIT Press, 2016.
[6] F. Pedregosa *et al.*, "Scikit-learn: Machine Learning in Python," *Journal of Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.
[7] S. M. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions," *Advances in Neural Information Processing Systems*, vol. 30, 2017.
[8] Keras, "tf.keras.Sequential - TensorFlow API Documentation." [Online]. Disponível: https://www.tensorflow.org/api_docs/python/tf/keras/-Sequential.

Predição de Vagas de Empregos no Mercado de IA e Dados Utilizando Redes Neurais Artificiais

Guilherme Gabriel Saldanha Pereira
Engenharia de Computação
Universidade Federal Rural do Semi-Árido (UFERSA)
Pau dos Ferros, Brasil
guilherme.pereira@alunos.ufersa.edu.br

Rosana Cibely Batista Rego
Departamento de Engenharias e Tecnologia (DETEC)
Universidade Federal Rural do Semi-Árido (UFERSA)
Pau dos Ferros, Brasil
rosana.rego@ufersa.edu.br

***Resumo*—O mercado de Inteligência Artificial apresenta alta variabilidade salarial e estrutural entre regiões e empresas. Este trabalho propõe o uso de redes neurais artificiais do tipo *Perceptron* de Múltiplas Camadas (MLP) para prever indicadores de vagas: salário, modalidade de trabalho e tamanho da empresa. O modelo previu salários com erro médio absoluto de 11,49%, porém apresentou limitações significativas nas classificações multiclasse, com acurácias de 33,6% para modalidade de trabalho (equivalente a predição aleatória) e 45,8% para tamanho da empresa. As principais limitações incluem: (i) arquitetura única não otimizada para cada tarefa; (ii) ausência de tratamento de desbalanceamento de classes; (iii) falta de engenharia de *features* específica para problemas categóricos. Os resultados evidenciam a eficácia de MLPs para regressão salarial, mas indicam a necessidade de modelos especializados para classificação em mercados voláteis.**

***Index Terms*—Redes Neurais Artificiais, Aprendizado de maquina, Mercado de Trabalho, Inteligência Artificial**

I. Introdução

O mercado global de Inteligência Artificial (IA) e Ciência de Dados apresenta um crescimento acelerado e, ao mesmo tempo, fragmentado. Novas metodologias de negócios e de trabalho são desenvolvidas constantemente, acompanhadas pela criação de cargos especializados. Consequentemente, os profissionais enfrentam uma realidade complexa, na qual as remunerações variam drasticamente entre países, empresas e modalidades de trabalho, dificultando a avaliação objetiva de oportunidades.

Esse contexto ganha ainda mais ênfase ao analisar o índice de contratações em IA monitorado pelo *AI Policy Observatory* da OCDE [1], conforme ilustrado na Figura 1.

A partir da Figura 1, observa-se que os índices não representam valores brutos, mas sim o ritmo de crescimento da área de IA em relação ao mercado total de cada nação. A métrica normalizada permite comparar a aceleração do setor entre diferentes economias.

Ao analisar países que mantêm uma trajetória ascendente, como o Brasil, infere-se que tais mercados ainda não atingiram o teto de contratação. Consequentemente, fatores críticos como a modalidade de trabalho e o tamanho das companhias permanecem fluidos. Além disso, a disparidade visualizada entre as curvas evidencia que cada país atravessa um estágio distinto de maturidade, gerando discrepâncias significativas nos indicadores de emprego.

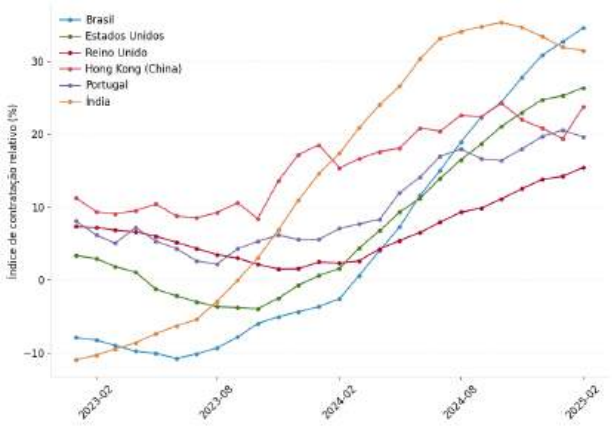


Figura 1. Índice relativo de contratação para vagas de IA ao longo do tempo (Fonte: OCDE)

Essa volatilidade reflete-se diretamente na variação salarial do setor. Tomando o cargo de Engenharia de IA como exemplo, observa-se na Figura 2 flutuações significativas. Dados extraídos do relatório da JobPikr [2] indicam que essas variações são fundamentadas na maturidade econômica e na demanda específica de mercados como o dos Estados Unidos em comparação ao Reino Unido.

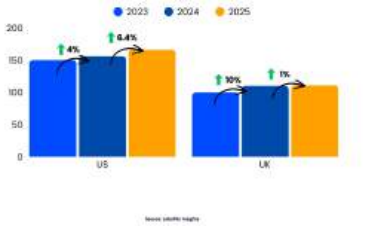


Figura 2. Variação percentual nas faixas salariais entre EUA e UK (Fonte: JobPikr)

Observa-se crescimento nos Estados Unidos e desaceleração no Reino Unido entre 2023 e 2025, evidenciando instabilidade mesmo em mercados maduros.

Este trabalho propõe uma rede neural para prever três indicadores de emprego:

- Salário (em dólares);
- Modalidade de trabalho;
- Tamanho da companhia.

O conjunto de dados utilizado para o treinamento do modelo proposto foi o *Global AI & Data Jobs Salary Dataset* [9]. Este *dataset* contém uma coleção de registros de vagas de tecnologia coletados entre os anos de 2020 e 2026, abrangendo cargos nas áreas de IA, *Machine Learning*, Engenharia de *Software*, Ciência e Análise de Dados.

Além das variáveis *target* já mencionadas, a base de dados inclui atributos que variam desde métricas de desempenho, como velocidade de promoção, horas trabalhadas por semana e anos de experiência, até indicadores de mercado, como percentual salarial, crescimento de carreira e dificuldade de contratação.

II. Trabalhos Relacionados

A literatura sobre a predição de indicadores no mercado de trabalho tem explorado diversas abordagens para lidar com a volatilidade do setor tecnológico com o passar do tempo. Kablaoui e Salman [3] demonstraram a eficácia de modelos baseados em redes neurais artificiais para estimar salários no setor de tecnologia utilizando *Python*, ressaltando que atributos como nível de experiência do profissional juntamente localização geográfica são os principais preditores de rendimento, o que corrobora a escolha das *features* utilizadas neste projeto, incluindo estas já citadas.

Kamalov et al. [4] demonstram que funções de ativação não-lineares (*ReLU*) e otimização via *Adam* facilitam a convergência em dados de alta dimensionalidade, justificando a estrutura do modelo MLP adotado.

Souza e Lima [5] mostram que, embora *Single-Task Learning* permita especialização eficiente para regressão, problemas de classificação multiclasse exigem balanceamento rigoroso de classes para superar a predição aleatória, fenômeno observado neste experimento.

A escolha pela arquitetura *Multilayer Perceptron* justifica-se pela sua capacidade superior de mapeamento de funções não-lineares. Enquanto autores como Lothe *et al.* [11] exploraram modelos de regressão linear e algoritmos de aprendizado supervisionado tradicionais em seus estudos de predição salarial, a MLP surge como uma alternativa robusta para lidar com a complexidade dos dados.

Essa abordagem permite uma modelagem que se mostra promissora para capturar a interdependência entre o salário, a modalidade de trabalho e o tamanho da companhia, especialmente em um mercado global de tecnologia marcado pela volatilidade e pela heterogeneidade, conforme discutido por Nimbalkar *et al.* [10].

III. Metodologia

O projeto foi dividido em três fases principais:

1) Pré-processamento de dados
2) Construção do modelo
3) Avaliação do modelo por meio das métricas

O pré-processamento incluiu:

- Tratamento de dados faltantes
- *Encoding* de variáveis categóricas
- Divisão *treino/teste*
- Seleção de *features*

A variável *real_salary_usd* foi criada combinando salário e bônus respectivos a vaga. O tratamento de *outliers* foi omitido para preservar amostras, conforme Figura 3.

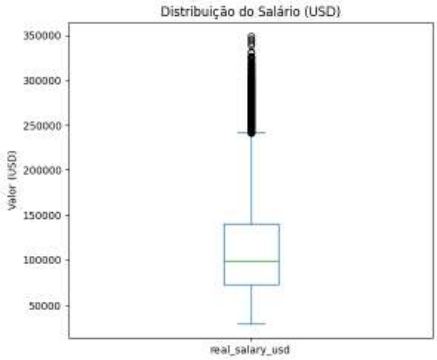


Figura 3. Boxplot da coluna referente aos salários da vaga

O algoritmo de seleção de características determina o número de entradas (*n_entradas*) para cada instância do modelo.

IV. Modelo de Rede Neural

Esta seção descreve a arquitetura da rede e os métodos utilizados em sua construção, conforme ilustrado na Figura 4.

A. Perceptron de Múltiplas Camadas

A forma como o conjunto de dados percorre a rede para gerar uma predição é definida pela propagação direta (*forward propagation*). Para um neurônio individual, essa operação é representada pelo somatório ponderado de suas entradas, seguido pela adição de um termo de ajuste:

$$Y_{pred} = \left(\sum_{i=1}^{n} X_i \cdot W_i \right) + b \tag{1}$$

Onde:

- n é o número total de características (entradas) fornecidas ao neurônio.
- X_i representa o valor da i-ésima entrada (coluna do conjunto de dados).
- W_i representa o peso sináptico associado à i-ésima entrada, indicando sua importância para o modelo.
- b representa o fator de *bias*, que permite deslocar a função de ativação para melhor ajuste aos dados.
- Y_{pred} representa o valor resultante da combinação linear antes da aplicação da função de ativação.

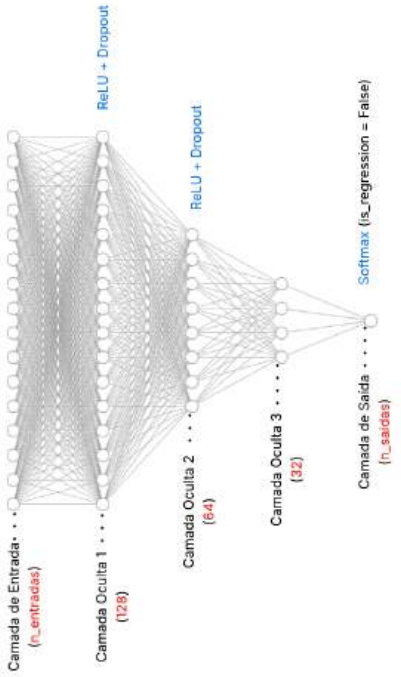


Figura 4. Arquitetura do modelo MLP

B. Aprendizagem Supervisionada

O modelo foi treinado utilizando como base o conceito de aprendizagem supervisionada, onde os rótulos representam os indicadores de interesse e a rede aprende por meio da comparação entre os valores reais oriundos da saída da rede neural e os valores ideias vindos das colunas *target* que são: *salary_usd*, *work_mode* e *company_size*.

O modelo irá aprender utilizando a técnica de retroprogação, a qual consiste na atualização dos pesos a cada nova iteração por meio do vetor de negativo do gradiente formado pela variação de cada parâmetro interno da rede (isto é, peso e *bias*). A retropropagação pode ser representada como a variação dos parâmetros internos da rede, sendo ilustrada abaixo da seguinte forma:

$$\theta_{novo} = \theta_{antigo} - \alpha \cdot \frac{\partial L}{\partial \theta} \tag{2}$$

Onde:

- θ: Representa os parâmetros internos da rede (pesos W ou *bias* b).
- α: Taxa de aprendizado (*learning rate*), que controla o tamanho do passo de ajuste.
- L: Função de custo (MSE para regressão ou Entropia Cruzada para classificação).
- $\frac{\partial L}{\partial \theta}$: Derivada parcial da perda em relação ao parâmetro, indicando a direção e magnitude do ajuste necessário para reduzir o erro.

C. Single Task Learning

Foram criados três modelos baseados na mesma estrutura. Logo, dada uma classe que define toda a arquitetura do modelo da rede neural, foram criadas três instâncias, cada uma responsável por realizar a predição de um indicador.

- Salário: regressão (1 neurônio na camada de saída, registra um único valor)
- Modalidade de trabalho: classificação (3 neurônios na camada de saída, para cada classe)
- Tamanho da empresa: classificação (5 neurônios na camada de saída, para cada classe)

As três instâncias do MLP compartilham a mesma estrutura base (Figura 4), cada modelo é adaptado ao seu problema específico, variando o número de neurônios de saída e funções de ativação.

Limitação: A utilização de uma arquitetura única para todos os problemas (regressão e classificação) impede a otimização individual de hiperparâmetros, comprometendo o desempenho nas tarefas de classificação. O atributo booleano *is_regression* apenas alterna entre configurações de saída, sem ajustes estruturais profundos.

D. Funções de Custo e Ativação

Cada problema utiliza funções de custo e de ativação diferentes pois como foi dito anteriormente, problemas de regressão e de classificação para o aprendizado supervisionado terão abordagens diferentes.

- **Função de Custo de Regressão: MSE (Erro quadrático médio)**
  O erro médio quadrado será a função de custo que irá mensurar o erro médio que o indicador de salário está tendo na saída da rede, sendo este representado por:

$$MSE = \frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2 \tag{3}$$

  Onde:
  - n representa o total de amostras que forma computadas na entrada da rede
  - y_i é o valor do rótulo para aquela amostra específica
  - $\hat{y}_i$ é o valor da predição gerado pela propagação para frente

  O MSE foi escolhido por penalizar quadraticamente desvios significativos entre salário real e predito, aumentando a sensibilidade do modelo a discrepâncias.
- **Função de Custo de Classificação: Cross-Entropy (Entropia Cruzada)**
  A Entropia Cruzada é a função de custo utilizada para os problemas de classificação (modalidade de trabalho e tamanho da empresa). Ela mensura a discrepância entre a distribuição de probabilidade prevista pelo modelo e a distribuição real dos rótulos. Sua expressão matemática é:

$$L = -\sum_{i=1}^{K} y_i \log(\hat{y}_i) \tag{4}$$

Onde:

- K: Número total de classes.
- y_i: Valor do rótulo real (0 ou 1) para a classe i, seguindo a codificação *one-hot*.
- $\hat{y}_i$: Probabilidade prevista pelo modelo para a classe i (saída da função *Softmax*).
- L: Perda (*loss*) calculada para a amostra.

Probabilidades baixas na classe correta são penalizadas exponencialmente, forçando ajustes agressivos nos pesos. É adequada para problemas com fronteiras de decisão sutis.

- **Função de Ativaçã*Engenharia de Computação, Universidade Federal Rural do Semi-Árido (UFERSA)*o: ReLU**

  A unidade linear retificada (*ReLU*) é aplicada entre a transição das camadas lineares no modelo. Ela é essencial para a arquitetura desta rede neural tendo em vista que é a partir desta função de ativação que introduz o fator de não-linearidade para o modelo. Sua expressão matemática é:

$$f(x) = \max(0, x) \tag{5}$$

  Onde:

  - x representa o valor de entrada vindo da transformação linear (soma ponderada de pesos e *bias*).
  - $f(x)$ indica o valor de saída da ativação, que será 0 para qualquer entrada negativa e o próprio valor x para entradas positivas.

- **Função de Ativação: Softmax**

  Utilizada exclusivamente na camada de saída para os problemas de classificação (modalidade de trabalho e tamanho da empresa), a função *Softmax* é definida por:

$$\sigma(\mathbf{z})_i = \frac{e^{z_i}}{\sum_{j=1}^{K} e^{z_j}} \tag{6}$$

  Onde:

  - z_i representa o valor bruto de saída (*logit*) para a classe i.
  - K indica número total de classes do problema.
  - $\sigma(\mathbf{z})_i$ trata-se da probabilidade da amostra pertencer à classe i.

A *Softmax* transforma *logits* em uma distribuição de probabilidade (soma = 1.0), indicando o nível de confiança na predição.

E. Otimizador Adam

O otimizador *Adam* é utilizado para atualização dos pesos para todos os indicadores. As equações que regem o seu funcionamento são:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \tag{7}$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \tag{8}$$

$$\theta_t = \theta_{t-1} - \alpha \frac{m_t}{\sqrt{v_t} + \epsilon} \tag{9}$$

Onde:

- g_t representa o gradiente da função de custo no instante t.
- m_t é a estimativa do primeiro momento (média móvel da direção dos gradientes).
- v_t é a estimativa do segundo momento (média móvel da magnitude dos gradientes ao quadrado).
- β_1 e β_2 são os coeficientes de decaimento para as médias móveis (*hiperparâmetros*).
- α representa a taxa de aprendizado (*learning rate*).
- ϵ é uma constante pequena para evitar a divisão por zero.
- θ_t representa os parâmetros (pesos e *bias*) atualizados da rede.

F. Dropout

O *Dropout* é uma técnica de regularização utilizada para reduzir o *overfitting* do modelo, interrompendo a adaptação excessiva entre os neurônios. A operação pode ser definida como:

$$y_i = \frac{x_i}{1 - p} \cdot m_i \tag{10}$$

Onde:

- x_i representa o sinal de entrada do neurônio i.
- p representa a taxa de *dropout*.
- m_i é um vetor binário (*mask*) aleatório.
- $1/(1 - p)$ é o fator de escala aplicado.
- y_i representa o sinal de saída do neurônio i após a regularização.

Durante a fase de teste, o *dropout* é desativado para utilizar toda a capacidade da rede.

V. Resultados

É possível extrair as métricas dos resultados gerados a partir do conjunto de dados de teste de cada indicador. Além disso, por meio do SHAP (*SHapley Additive exPlanations*), torna-se possível visualizar as variáveis selecionadas pelo algoritmo de *feature selection* mencionado na Fase 1, bem como identificar aquelas que exerceram maior impacto na predição de cada um dos indicadores.

A. Salário

- MAE (Erro Médio Absoluto): 12,597.62 USD
- RMSE (Raiz do Erro Quadrático Médio): 16,782.90 USD

O MAE indica erro médio de 12.597,62 USD. Considerando a faixa salarial de 40.000 a 200.000 dólares (Figura 3) e média de 109.574,66 USD, o erro relativo é de 11,49%. Na prática, este percentual implica uma margem de flutuação de aproximadamente 12,6 mil dólares anuais em relação ao valor real, podendo ser interpretado como uma flutuação aceitável sob o contexto de contratações e retenções de talentos, uma vez que se aproxima das faixas de variação comumente utilizadas em negociações salariais reais no setor de tecnologia.

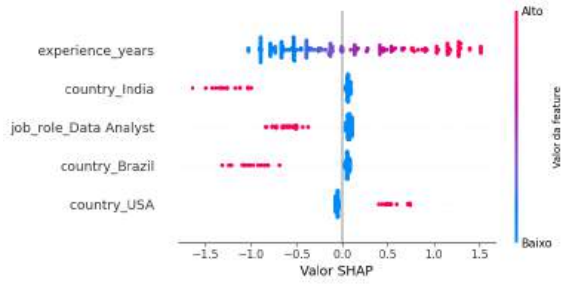


Figura 5. Gráfico de resumo SHAP para o indicador de salário

O RMSE de 16.782,90 USD é maior que o MAE devido à penalização quadrática de *outliers*. **Limitação:** O modelo não foi otimizado para salários extremos e não incorpora fatores contextuais (experiência, localização específica), limitando sua aplicabilidade prática.

O gráfico de resumo SHAP (Figura 5) indica que os anos de experiência (*experience_years*) representam o fator de maior impacto na determinação da faixa salarial. Além disso, a relevância de múltiplas variáveis ligadas à localidade reforça que a localização geográfica é um determinante crítico para a predição deste indicador. Isso explica a disparidade visualizada entre os índices de contratação para vagas de IA de cada país da OCDE e os relatórios da JobPikr mencionados anteriormente.

B. Modalidade de Trabalho

Tabela I
MÉTRICAS EXTRAÍDAS DO INDICADOR DE MODO DE TRABALHO

Métrica	Valor
Acurácia	0,3394
Precisão (macro)	0,3388
F1-Score (macro)	0,3046

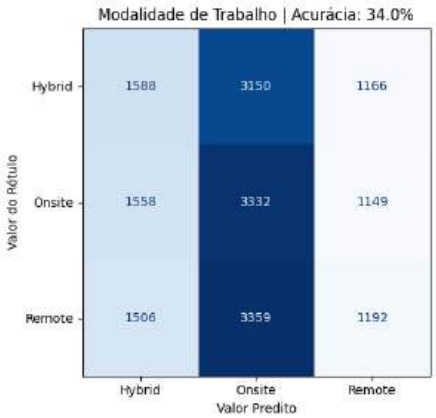


Figura 6. Matriz confusão do indicador de modalidade de trabalho

A acurácia de 33% equivale à predição aleatória para três classes. O modelo não aprendeu padrões úteis para modalidade de trabalho. A matriz de confusão evidencia um viés para a classe *"Onsite"*, indicando uma tendência do modelo em favorecer essa categoria. Entre as principais limitações identificadas, destacam-se: o desbalanceamento severo de classes que não foi tratado adequadamente, a utilização de uma arquitetura genérica que pode não ser a mais apropriada para a tarefa em questão, a ausência de *features* suficientemente discriminativas e a possível falta de correlação entre as variáveis disponíveis e o alvo a ser predito.

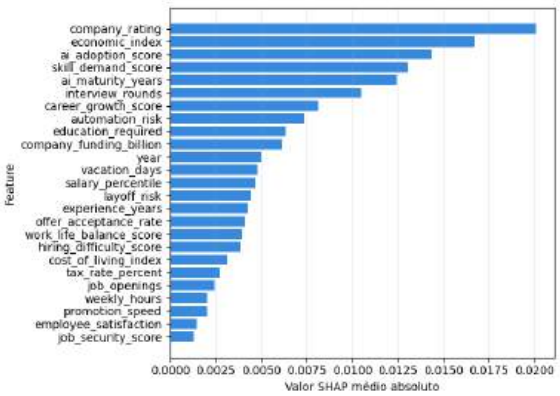


Figura 7. Gráfico de resumo SHAP para o indicador de modelo de trabalho

C. Tamanho da Companhia

Tabela II
MÉTRICAS EXTRAÍDAS DO INDICADOR DE TAMANHO DA COMPANHIA

Métrica	Valor
Acurácia	0,4584
Precisão (macro)	0,4168
F1-Score (macro)	0,4168

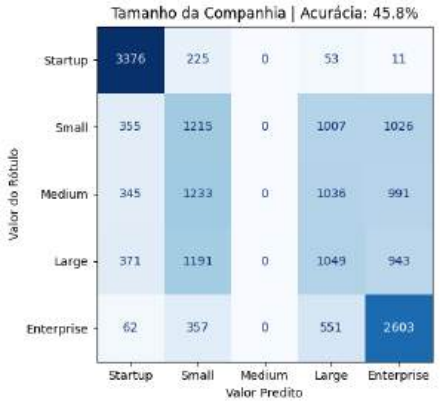


Figura 8. Matriz confusão do indicador de tamanho da companhia

Com cinco classes, predição aleatória teria 20% de acurácia. O modelo atingiu 45,8%. O *F1-Score* de 40% indica aprendizado de padrões, sem viés severo de classe. Mas a acurácia

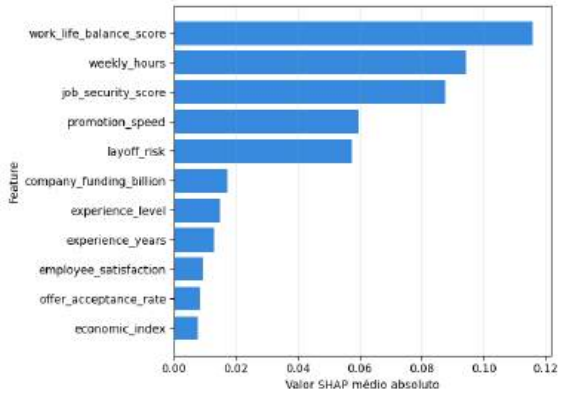


Figura 9. Gráfico de resumo SHAP para o indicador de tamanho da companhia

ainda é modesta para aplicação prática, com ambiguidade significativa entre classes intermediárias de tamanho. A ausência de otimização específica e engenharia de *features* limita o desempenho máximo.

A análise da matriz de confusão (Figura 8) revela que o modelo apresenta dificuldades em distinguir empresas de médio e grande porte. Este comportamento sugere que os atributos das vagas, como faixas salariais e exigências de experiência tornam-se homogêneos ao ponto do modelo não conseguir distinguir as classes de forma correta.

Como discutido na introdução, a fragmentação no mercado global de IA cria uma linha tênue entre diferentes tamanhos corporativos, onde muitas empresas de médio porte já adotam estruturas de contratação e de remuneração comparáveis às de grandes corporações, dificultando a classificação categórica baseada apenas em indicadores de emprego.

VI. Conclusão

O modelo MLP apresentou desempenho satisfatório para regressão salarial (erro de 11,49%), demonstrando capacidade filtrar as inconsistências globais e fornecer uma estimativa robusta. Contudo, falhou nas classificações multiclasse: modalidade de trabalho (33%, equivalente a predição aleatória) e tamanho da empresa (45,8%, modesto). As principais limitações técnicas identificadas incluem o uso de uma arquitetura genérica não otimizada para cada tarefa, o que acaba favorecendo problemas de regressão, a ausência de tratamento adequado para o desbalanceamento de classes, a falta de engenharia de *features* específica para problemas categóricos, a não incorporação de fatores contextuais relevantes e a ausência de otimização individual dos hiperparâmetros.

No que se refere às limitações do domínio, a volatilidade do mercado de IA (Figura 1) torna a predição categórica mais desafiadora, uma vez que as empresas ainda não estabeleceram padrões rígidos para tamanho da companhia e modalidade de trabalho, ao passo que salários tendem a seguir métricas mais consolidadas. Como trabalhos futuros, destacam-se o desenvolvimento de modelos especializados para cada tarefa, a aplicação de técnicas de balanceamento como SMOTE, a exploração de arquiteturas alternativas, como *Random Forest* e *XGBoost* para classificação, além da coleta de *features* adicionais mais discriminativas.

Agradecimentos

Os autores agradecem à disciplina de Redes Neurais do curso de Engenharia de Computação da Universidade Federal Rural do Semi-Árido (UFERSA), no âmbito da qual este trabalho foi desenvolvido.

Declaração de Uso de Inteligência Artificial

Os autores declaram que utilizaram ferramentas de inteligência artificial, incluindo ChatGPT, Claude e Gemini exclusivamente para auxiliar na melhoria da linguagem e legibilidade deste manuscrito. O uso dessas ferramentas foi realizado sob supervisão humana, e os autores revisaram e editaram cuidadosamente o conteúdo, assumindo total responsabilidade pelo texto final publicado.

Referências

[1] OECD.AI, "AI Policy Observatory: Relative AI hiring index," 2026. [Online]. Disponível em: https://oecd.ai. Acesso em: 14 abr. 2026.

[2] JobPikr, "AI Salary Benchmark Report 2026." Disponível em: https://www.jobspikr.com/report/ai-salary-benchmark-2026/

[3] R. Kablaoui and A. Salman, "Machine Learning Models for Salary Prediction Dataset using Python," *2022 International Conference on Electrical and Computing Technologies and Applications (ICECTA)*, pp. 1-5, 2022.

[4] F. Kamalov, A. Nazir and M. Safaraliev, "Comparative analysis of activation functions in neural networks," *2021 28th IEEE International Conference on Electronics, Circuits, and Systems (ICECS)*, pp. 1-4, 2021.

[5] R. Souza and A. Lima, "A Comparison of Multi-task Learning and Single-Task Learning Approaches," *Lecture Notes in Computer Science*, vol. 9, no. 1, pp. 22-34, 2023.

[6] S. Haykin, "Redes Neurais: Princípios e Prática," 2ª ed. Porto Alegre: Bookman, 2001.

[7] Deep Learning Book, "Como Funciona o Dropout?," 2018. [Online]. Disponível em: https://www.deeplearningbook.com.br/como-funciona-o-dropout/. Acesso em: 14 abr. 2026.

[8] IBM, "O que é backpropagation?," 2024. [Online]. Disponível em: https://www.ibm.com/br-pt/think/topics/backpropagation. Acesso em: 15 abr. 2026.

[9] M. K. Thalla, "Global AI and Data Jobs Salary Dataset," 2024. [Online]. Disponível em: https://www.kaggle.com/datasets/mohankrishnathalla/global-ai-and-data-jobs-salary-dataset. Acesso em: 05 mai. 2026.

[10] P. Nimbalkar, A. Jadhav, P. Patil, S. Chaudhari e D. Surve, "Salary Sense: A Model Pool Driven Developer Salary Prediction and Career Intelligence System," *2026 International Conference on Computing, Communication, Control and Cyber-Physical Systems (I5CPS)*, Mumbai, India, 2026. [Online]. Disponível em: IEEE Xplore.

[11] D. M. Lothe, P. Tiwari, N. Patil, S. Patil e V. Patil, "Salary Prediction Using Machine Learning," *International Journal of Advance Scientific Research and Engineering Trends*, vol. 6, no. 5, pp. 2456-0774, Maio 2021.

Previsão de Interrupções em Cadeias de Suprimento Globais Utilizando Aprendizado de máquina

Paulo H. M. Silva
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
paulo.silva23378@alunos.ufersa.edu.br

Rosana C. B. Rego
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil

***Resumo*—Este artigo apresenta um estudo comparativo de modelos de aprendizado de máquina para a previsão de interrupções em cadeias de suprimento globais. Utilizando o conjunto de dados *Global Supply Chain Risk and Logistics 2024–2026*, foram desenvolvidas e avaliadas três abordagens: uma rede neural artificial com camadas de Dropout para regularização, uma rede neural otimizada via busca manual de hiperparâmetros com validação cruzada (KFold), e um classificador Random Forest. O pré-processamento incluiu codificação de variáveis categóricas por LabelEncoder, normalização Min-Max, remoção de outliers pelo método IQR e balanceamento de classes via NearMiss. Os resultados demonstram que o Random Forest obteve o melhor desempenho geral, com 66,00% de acurácia e F1-Score de 0,63, seguido pela rede neural com Dropout (64,65%) e pela rede otimizada (62,00%). A análise de importância de variáveis revelou que atributos como risco geopolítico (*Geopolitical_Risk_Score*), confiabilidade do transportador (*Carrier_Reliability_Score*) e índice de combustível (*Fuel_Price_Index*) são os mais influentes na predição de interrupções logísticas.**

***Palavras-chave*—cadeia de suprimentos, aprendizado de máquina, redes neurais artificiais, Random Forest, previsão de interrupções, logística.**

I. Introdução

A crescente complexidade das cadeias de suprimentos globais, impulsionada pela interdependência econômica entre países e pela volatilidade geopolítica, tem tornado a previsão de interrupções logísticas um desafio estratégico para organizações ao redor do mundo. Eventos disruptivos, como pandemias, conflitos armados e fenômenos climáticos extremos, podem comprometer significativamente a continuidade operacional de empresas e governos [3].

Nesse contexto, técnicas de aprendizado de máquina (*Machine Learning*) têm se destacado como ferramentas promissoras para a modelagem preditiva de fenômenos complexos. A capacidade dessas abordagens de identificar padrões não lineares em grandes volumes de dados as torna particularmente adequadas para a análise de riscos em cadeias de suprimentos [1].

Este trabalho propõe e avalia um pipeline completo de aprendizado de máquina aplicado ao conjunto de dados *Global Supply Chain Risk and Logistics 2024–2026*, disponível publicamente na plataforma Kaggle. Três abordagens distintas são comparadas: (i) rede neural artificial com regularização por Dropout; (ii) rede neural com hiperparâmetros otimizados; e (iii) classificador Random Forest. O objetivo principal é identificar o modelo que melhor prediz a ocorrência de interrupções logísticas, representada pela variável binária Disrupção.

O restante do artigo está organizado da seguinte forma: a Seção II revisa trabalhos relacionados; a Seção III descreve os materiais e métodos empregados; a Seção IV apresenta e discute os resultados obtidos; e a Seção V conclui o trabalho com considerações finais.

II. Levantamento Bibliográfico

A aplicação de técnicas de aprendizado de máquina para a gestão de riscos em cadeias de suprimentos tem atraído crescente atenção acadêmica. Waller e Fawcett [1] destacam que a análise de dados em larga escala oferece oportunidades inéditas para a previsão de eventos disruptivos, reduzindo a dependência de modelos analíticos tradicionais.

Métodos de ensemble, como Random Forest e Gradient Boosting, também têm demonstrado robustez superior em problemas de classificação binária com dados tabulares [2].

Goodfellow et al. [5] consolidam a teoria por trás de técnicas de regularização como Dropout, demonstrando sua eficácia na redução de overfitting em redes profundas. No contexto específico de risco logístico, Ivanov e Dolgui [3] propõem o conceito de resiliência de cadeias de suprimentos e ressaltam a importância de modelos preditivos capazes de antecipar interrupções.

O uso de técnicas de balanceamento de classes, como NearMiss e SMOTE, tem sido fundamental para lidar com o desbalanceamento inerente a conjuntos de dados de eventos raros [4]. Pedregosa et al. [6] consolidam a implementação dessas técnicas no ecossistema scikit-learn. O presente trabalho diferencia-se ao realizar uma comparação sistemática entre três abordagens distintas, utilizando um dataset contemporâneo de cadeias de suprimentos globais.

III. Conjunto de Dados

O conjunto de dados utilizado é o *Global Supply Chain Risk and Logistics 2024–2026*, obtido via kagglehub da plataforma Kaggle. O dataset contém registros de embarques internacionais com 13 atributos abrangendo características logísticas, condições geopolíticas e ambientais:

- *Origin_Port* / *Destination_Port*: portos de origem e destino (categórico);
- *Transport_Mode*: modalidade de transporte — aéreo, marítimo, rodoviário ou ferroviário (categórico);
- *Product_Category*: categoria do produto transportado (categórico);
- *Distance_km* / *Weight_MT* / *Lead_Time_Days*: atributos numéricos de distância, peso e prazo de entrega;
- *Fuel_Price_Index*: índice de preço do combustível no período do embarque (numérico);
- *Geopolitical_Risk_Score*: score de risco geopolítico da rota (numérico);
- *Carrier_Reliability_Score*: índice de confiabilidade do transportador (numérico);
- *Weather_Condition*: condição climática da rota (categórico);
- *Disruption_Occurred*: variável alvo binária — 0 = sem interrupção; 1 = com interrupção.

A. Análise Exploratória e Pré-processamento

A análise exploratória revelou ausência de valores faltantes (NaN) no conjunto de dados. Contudo, boxplots aplicados aos atributos numéricos identificaram a presença de outliers na variável *Lead_Time_Days*. Esses valores discrepantes foram tratados pela regra do intervalo interquartil (IQR): os valores abaixo de $Q_1 - 1{,}5 \times IQR$ foram substituídos pelo limite inferior (0, por se tratar de tempo) e os superiores a $Q_3 + 1{,}5 \times IQR$ foram substituídos pelo limite superior.

As variáveis categóricas foram codificadas numericamente com LabelEncoder. Em seguida, *Distance_km*, *Weight_MT* e *Lead_Time_Days* foram normalizados para $[0, 1]$ via MinMaxScaler. As colunas *Shipment_ID* e *Date* foram removidas por não contribuírem com informação preditiva. As Figuras 1 a 3 apresentam análises exploratórias dos principais atributos.

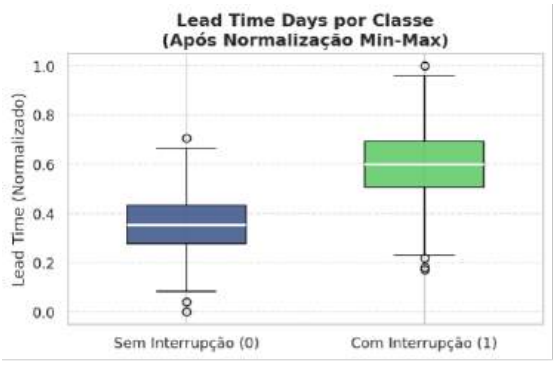


Fig. 1. Boxplot de Lead Time Days (normalizado) por classe de interrupção.

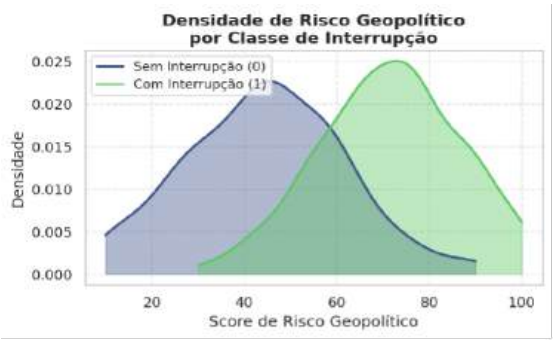


Fig. 2. Distribuição de densidade do Geopolitical Risk Score por classe.

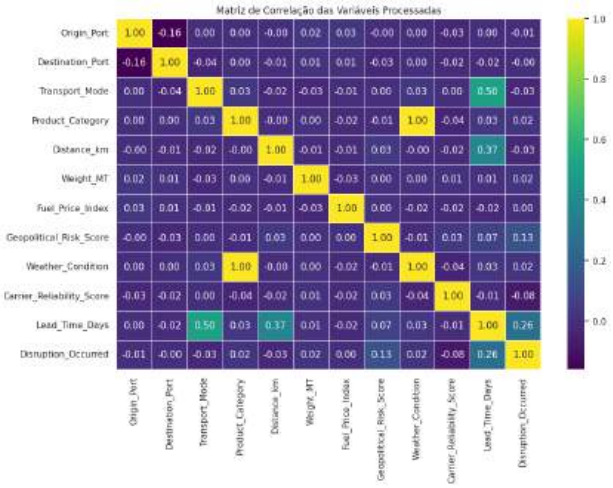


Fig. 3. Matriz de correlação de Pearson entre todas as variáveis processadas.

A matriz de correlação (Fig. 3) evidencia baixa multicolinearidade entre os atributos, favorável à estabilidade dos modelos. Destacam-se correlações moderadas entre *Geopolitical_Risk_Score* e *Disruption_Occurred*, reforçando a relevância desse atributo.

B. Balanceamento de Classes

A variável alvo apresentou desequilíbrio em sua distribuição original. Para mitigar o viés em direção à classe majoritária, aplicou-se a técnica NearMiss da biblioteca imbalanced-learn, que realiza subamostragem selecionando os exemplos mais próximos da fronteira de decisão.

IV. Modelos de Aprendizado de Máquina

Três configurações foram implementadas e comparadas. O primeiro modelo é uma rede neural sequencial com arquitetura detalhada na Tabela I.

TABELA I
ARQUITETURA DA REDE NEURAL COM DROPOUT

Camada	Neurônios / Taxa	Ativação
Entrada (Input)	11 atributos	—
Dense 1	128	ReLU
Dropout 1	30%	—
Dense 2	64	ReLU
Dropout 2	20%	—
Saída (Output)	1	Sigmoid

O modelo foi compilado com o otimizador Adam (*learning_rate* = 0,001) e função de perda *binary_crossentropy*. O treinamento ocorreu por 100 épocas com *batch_size* = 32, utilizando 20% dos dados de treino para validação interna.

O segundo modelo mantém a mesma estrutura base, mas sem camadas de Dropout, com hiperparâmetros selecionados por busca manual. Além disso, foi aplicado validação cruzada KFold ($k = 3$). A Tabela II apresenta as configurações avaliadas.

TABELA II
CONFIGURAÇÕES AVALIADAS NO GRIDSEARCH MANUAL

Neurônios	Taxa de Aprendizado	Batch Size
64	0,001	32
128	0,010	64

O terceiro modelo utiliza o classificador Random Forest da biblioteca scikit-learn, configurado com 200 estimadores e profundidade máxima de 10 níveis.

A. Protocolo de Avaliação

O conjunto de dados foi dividido em 80% para treinamento e 20% para teste (*random_state* = 42). Todos os dados foram padronizados com StandardScaler após a divisão, evitando vazamento de informação (*data leakage*). As métricas empregadas são: acurácia global, F1-Score por classe e matriz de confusão.

V. RESULTADOS E SIMULAÇÕES

A. Desempenho Comparativo dos Modelos

A Tabela III resume as métricas obtidas pelos três modelos nos dados de teste. O Random Forest alcançou o melhor desempenho global, com 66,00% de acurácia e F1-Score de 0,63.

TABELA III
COMPARAÇÃO DE DESEMPENHO DOS MODELOS NO CONJUNTO DE TESTE

Modelo	Acurácia	F1 (Cl. 1)	Observações
RNA + Dropout	64,65%	0,62	Dropout 30%/20%
RNA Otimizada	62,00%	0,62	KFold k=3, GridSearch
Random Forest	66,00%	0,63	200 árvores, depth=10

B. Previsão vs. Valores Reais

A Fig. 4 exibe a comparação entre os valores reais e as probabilidades previstas pelo modelo para as primeiras 10 amostras do conjunto de teste. O limiar de 0,5 foi adotado para converter probabilidades em rótulos binários.

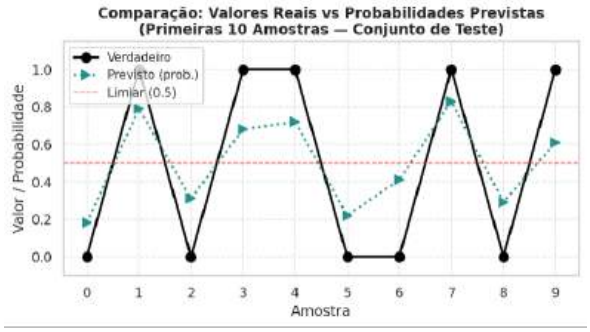
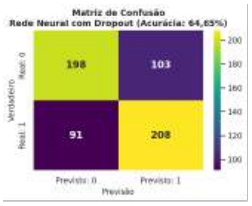


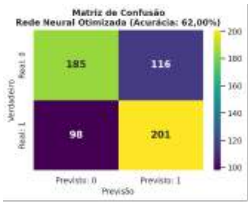
Fig. 4. Valores reais versus probabilidades previstas pelo modelo (10 primeiras amostras do teste).

C. Matrizes de Confusão

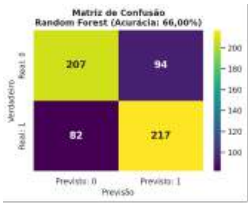
A Figura 5 apresenta as matrizes de confusão para os três modelos avaliados. Nas matrizes, os rótulos 0 e 1 referem-se às classes da variável alvo *Disruption_Occurred*: 0 indica ausência de interrupção logística e 1 indica ocorrência de interrupção. Os eixos representam os valores reais (linhas) e os valores preditos (colunas) por cada modelo. A análise permite identificar erros de Tipo I (falsos positivos) e Tipo II (falsos negativos), ambos com implicações práticas relevantes na gestão de risco logístico.



(a) Rede Neural com Dropout



(b) Rede Neural GridSearch



(c) Random Forest

Fig. 5. Comparação das matrizes de confusão dos modelos avaliados.

O Random Forest apresentou o maior número de verdadeiros positivos (217) e verdadeiros negativos (207), confirmando sua superioridade geral. A rede neural otimizada

apresentou o maior número de falsos positivos (116), indicando maior taxa de alarmes falsos, especialmente crítico em contextos onde previsões incorretas geram custos operacionais desnecessários.

D. Importância das Variáveis

A Fig. 6 apresenta a importância relativa de cada atributo segundo o Random Forest. Os resultados revelam que *Geopolitical_Risk_Score* (18,5%), *Carrier_Reliability_Score* (16,2%) e *Fuel_Price_Index* (13,8%) são os três atributos mais determinantes.



Fig. 6. Importância relativa das variáveis segundo o classificador Random Forest.

Esses resultados são coerentes pois instabilidades geopolíticas aumentam a probabilidade de atrasos nas rotas; baixa confiabilidade dos transportadores eleva o risco de falhas operacionais; e oscilações no preço do combustível impactam a pontualidade dos embarques. Variáveis como porto de origem e porto de destino apresentaram menor importância relativa, sugerindo que a identificação geográfica dos terminais tem impacto secundário frente aos índices de desempenho e risco.

VI. Conclusões

Este trabalho comparou modelos de aprendizado de máquina para predição de interrupções em cadeias de suprimentos, com pipeline completo de pré-processamento e avaliação. O Random Forest apresentou o melhor desempenho (66,00% de acurácia, F1 = 0,63), superando as redes neurais. A rede com Dropout obteve resultado intermediário (64,65%), superior à versão sem regularização (62,00%), indicando a eficácia da técnica. As curvas de perda sugerem boa convergência, sem overfitting relevante.

Como trabalhos futuros, recomenda-se explorar modelos com dependência temporal e técnicas de balanceamento, como SMOTE.

Declaração de Uso de Inteligência Artificial

Os autores declaram que utilizaram ferramentas de inteligência artificial, incluindo ChatGPT, exclusivamente para auxiliar na melhoria da linguagem e legibilidade deste manuscrito. O uso dessas ferramentas foi realizado sob supervisão humana, e os autores revisaram e editaram cuidadosamente o conteúdo, assumindo total responsabilidade pelo texto final publicado.

References

[1] M. S. Waller e S. E. Fawcett, "Data science, predictive analytics, and big data: A revolution that will transform supply chain design and management," *J. Business Logistics*, vol. 34, no. 2, pp. 77–84, 2013.

[2] L. Breiman, "Random forests," *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001.

[3] D. Ivanov e A. Dolgui, "A digital supply chain twin for managing the disruption risks and resilience in the era of Industry 4.0," *Production Planning & Control*, vol. 32, no. 9, pp. 775–788, 2021.

[4] N. V. Chawla, K. W. Bowyer, L. O. Hall e W. P. Kegelmeyer, "SMOTE: Synthetic minority over-sampling technique," *J. Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002.

[5] I. Goodfellow, Y. Bengio e A. Courville, *Deep Learning*. Cambridge, MA: MIT Press, 2016.

[6] F. Pedregosa *et al.*, "Scikit-learn: Machine learning in Python," *J. Machine Learning Research*, vol. 12, pp. 2825–2830, 2011.

Multilayer Perceptron-Based System for Behavioral Analysis and Educational Recommendation in Autism Spectrum Disorder

Ângela M. A. Souza
Bacharelado Interdisciplinar em Tecnologia da Informação
Universidade Federal Rural do Semi-Árido
Rio Grande do Norte, Brasil
angela.souza@alunos.ufersa.edu.br

Rosana C. B. Rego
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido
Rio Grande do Norte, Brasil
rosana.rego@ufersa.edu.br

***Abstract*—Autism Spectrum Disorder (ASD) requires early identification and effective educational intervention. This study presents a multilayer perceptron neural network to identify behavioral patterns associated with ASD from questionnaire responses. The model achieved 100% accuracy, precision, recall, and F1-score on the test set ($N_{\text{test}} = 211$). A rule-based interpretative layer translates model outputs into educational profiles and personalized pedagogical recommendations, enabling practical support for educators. The integration of machine learning with educational strategies demonstrates the potential of AI as a support tool for inclusive education and early intervention.**

***Index Terms*—Autism spectrum disorder, inclusive education, multilayer perceptron, behavioral analysis, neural network.**

I. Introdução

O Transtorno do Espectro Autista (TEA) é uma condição neurodesenvolvimental de base neurobiológica, cujas principais características incluem dificuldades na comunicação e interação social, bem como padrões restritos e repetitivos de comportamentos, interesses ou atividades. O termo "espectro" denota a heterogeneidade das manifestações clínicas do transtorno, indicando que os sintomas variam em intensidade, desde formas leves até graves, nas dimensões sociocomunicativa e comportamental, ao invés de representarem categorias diagnósticas isoladas. A identificação do TEA ocorre com frequência entre 12 e 24 meses de idade, podendo manifestar-se por meio de atrasos no desenvolvimento ou mesmo pela regressão de habilidades anteriormente adquiridas, evidenciando a necessidade de detecção e intervenção precoces [1]. A intervenção deve começar no ponto mais precoce possível, pois a detecção e intervenção precoces resultam em desfechos positivos para a criança, a família e a sociedade [2]. No entanto, barreiras no acesso a serviços de saúde afetam 29% das crianças com TEA, incluindo dificuldades para conseguir consultas com rapidez suficiente, longos tempos de espera no consultório e problemas para encontrar profissionais especializados [3].

Paralelamente, a inteligência artificial (IA) tem emergido como uma ferramenta promissora na área da saúde, especialmente no suporte ao diagnóstico de transtornos do neurodesenvolvimento [4]. Modelos de aprendizado de máquina, como redes neurais artificiais, podem aprender padrões complexos a partir de dados comportamentais e auxiliar profissionais na triagem inicial [5].

Este artigo propõe um modelo baseado em rede neural Perceptron Multicamada (MLP) para classificar a probabilidade de traços de TEA em crianças pequenas a partir de características individuais e respostas de um questionário comportamental. Além disso, o modelo incorpora uma camada interpretável baseada em regras que, a partir das respostas individuais, gera um perfil comportamental e recomenda estratégias pedagógicas personalizadas, alinhando-se aos princípios da educação inclusiva.

II. Trabalhos Relacionados

Diversos estudos têm explorado o uso de inteligência artificial e aprendizado de máquina para triagem e diagnóstico do TEA. Thabtah [6] propôs um sistema de triagem para TEA baseado em aprendizado de máquina, adaptado aos critérios do DSM-5, demonstrando a viabilidade do uso de questionários comportamentais para identificação precoce. O autor desenvolveu diferentes conjuntos de dados para crianças, adolescentes e adultos, incluindo o *Autism Dataset for Toddlers* utilizado no presente trabalho.

Wall et al. [7] aplicaram algoritmos de aprendizado de máquina para reduzir o tempo de diagnóstico do TEA, alcançando alta acurácia na classificação a partir de um número reduzido de questões comportamentais. O estudo demonstrou que é possível manter a precisão diagnóstica com menos itens, facilitando a triagem em larga escala.

Anagnostopoulou et al. [4] realizaram uma revisão sobre aplicações de inteligência artificial na avaliação do autismo, destacando o potencial de redes neurais e algoritmos de classificação para auxiliar profissionais da saúde no processo diagnóstico. Os autores apontam que a IA pode reduzir a subjetividade inerente aos métodos tradicionais.

Francese e Yang [5] conduziram uma revisão sistemática da literatura sobre o uso de aprendizado de máquina e dispositivos vestíveis (*wearables*) no suporte à triagem e intervenção do TEA. Os resultados indicam um crescimento significativo de

pesquisas na área, embora a maioria ainda esteja em estágio experimental.

Diferentemente dos trabalhos anteriores, que focam exclusivamente na classificação binária, o presente estudo propõe uma camada interpretável adicional que traduz as predições do modelo em perfis comportamentais e recomendações pedagógicas personalizadas, ampliando a utilidade da ferramenta para educadores e profissionais da saúde.

III. Metodologia

A. Base de Dados

Utilizou-se o *Autism Dataset for Toddlers*[1], com $N = 1054$ registros e $d = 19$ variáveis. O conjunto $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^{N}$ contém respostas binárias a 10 questões comportamentais $(A1, \ldots, A10) \in \{0,1\}^{10}$, além de variáveis demográficas, como idade em meses, sexo, etnia, icterícia neonatal, histórico familiar de TEA e o respondente. A variável alvo $y \in \{0,1\}$ indica a ausência ou presença de traços de TEA.

Aplicou-se `LabelEncoder` para codificar variáveis categóricas em representações numéricas ordinais. A Tabela I apresenta a distribuição das classes após a codificação.

TABLE I
Distribuição das variáveis categóricas após codificação

Variável	Categoria	Contagem
Class/ASD Traits	Traços presentes (1)	728
	Traços ausentes (0)	326
Jaundice	Não (0)	766
	Sim (1)	288
Sex	Masculino (1)	735
	Feminino (0)	319
Family_mem_with_ASD	Não (0)	884
	Sim (1)	170

B. Análise Exploratória

A análise exploratória revelou padrões consistentes com a literatura. Em relação à etnia (Figura 1), observaram-se diferenças significativas na prevalência entre grupos étnicos. Quanto à icterícia neonatal (Figura 2), a maioria dos casos com traços de TEA ocorreu em crianças sem histórico de icterícia. A distribuição por sexo (Figura 3) mostrou prevalência significativamente maior no sexo masculino, consistente com a literatura especializada. Por fim, analisando o histórico familiar (Figura 4), das 1054 crianças, 884 não possuíam histórico familiar e 170 apresentavam histórico positivo, com predominância de traços de TEA em ambos os grupos, sendo este achado mais expressivo no grupo com histórico familiar.

[1]https://www.kaggle.com/datasets/vaishnavisirigiri/autism-dataset-for-toddlers

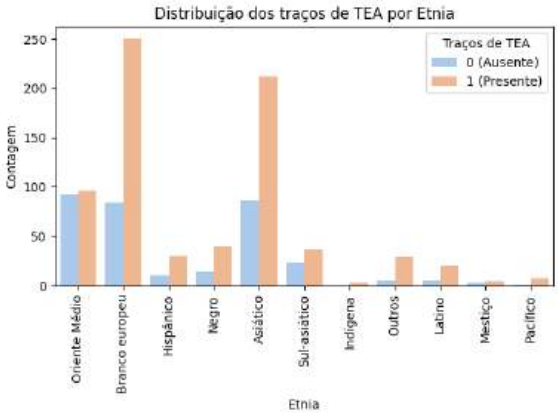


Fig. 1. Distribuição dos traços de TEA por etnia.

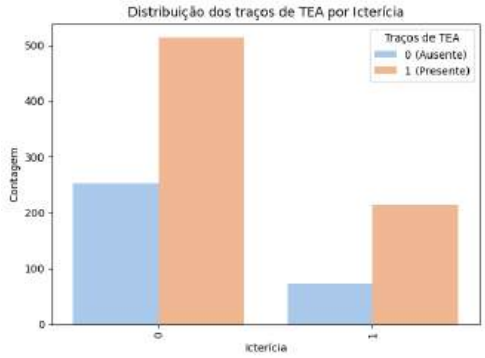


Fig. 2. Distribuição dos traços de TEA por presença de icterícia neonatal.

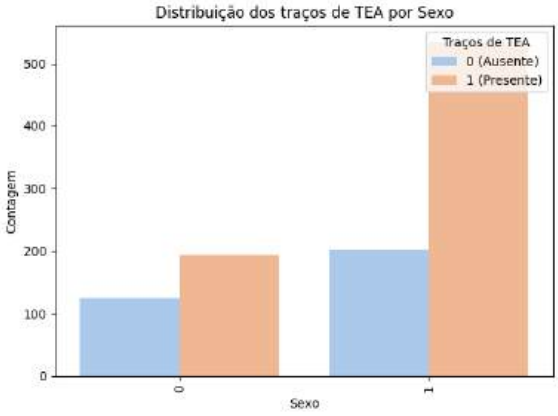


Fig. 3. Distribuição dos traços de TEA por sexo.

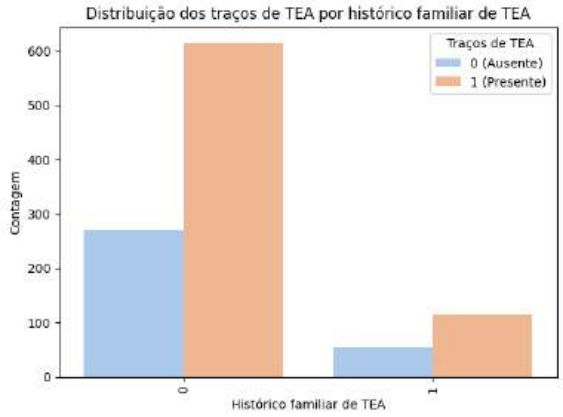


Fig. 4. Distribuição dos traços de TEA por histórico familiar de TEA.

C. Definições para Modelagem

O conjunto foi dividido estratificadamente em $\mathcal{D}_{\text{train}}$ (80%, $N_{\text{train}} = 843$) e $\mathcal{D}_{\text{test}}$ (20%, $N_{\text{test}} = 211$). Para normalização, aplicou-se `StandardScaler` para padronização Z-score:

$$\mathbf{z} = \frac{\mathbf{x} - \boldsymbol{\mu}}{\boldsymbol{\sigma}} \tag{1}$$

Devido ao desbalanceamento observado ($N_1 = 728$, $N_0 = 326$), aplicaram-se pesos às classes durante o treinamento:

$$w_0 = \frac{N}{2N_0} = 1.686, \quad w_1 = \frac{N}{2N_1} = 0.711 \tag{2}$$

D. Arquitetura da Rede Neural

O modelo feedforward totalmente conectado possui a seguinte arquitetura:

$$\begin{aligned} \mathbb{R}^{18} &\xrightarrow{\text{Dense}(128)} \mathbb{R}^{128} \\ &\xrightarrow{\text{Dropout}(0.3)} \\ &\xrightarrow{\text{Dense}(64)} \mathbb{R}^{64} \\ &\xrightarrow{\text{Dropout}(0.3)} \\ &\xrightarrow{\text{Dense}(1)} \mathbb{R}^{1} \end{aligned} \tag{3}$$

A primeira camada oculta contém 128 neurônios com ativação ReLU, onde $f(x) = \max(0, x)$. A segunda camada oculta possui 64 neurônios, também com ativação ReLU e regularização L2:

$$\mathcal{L}_{\text{reg}} = \mathcal{L}_{\text{BCE}} + \lambda \sum_i w_i^2, \quad \lambda = 0.01 \tag{4}$$

A camada de saída contém 1 neurônio com ativação sigmoide:

$$P(y = 1|\mathbf{x}) = \sigma(z) = \frac{1}{1 + e^{-z}} \tag{5}$$

O total de parâmetros treináveis do modelo é 10.753, conforme detalhado na Tabela II.

TABLE II
ARQUITETURA DA REDE NEURAL COM REGULARIZAÇÃO L2

Camada	Tipo	Parâmetros
1	Dense (128, ReLU)	2.432
2	Dropout (0.3)	0
3	Dense (64, ReLU) + L2(0.01)	8.256
4	Dropout (0.3)	0
5	Dense (1, Sigmoid)	65
Total de parâmetros		10.753

E. Treinamento

O treinamento utilizou entropia cruzada binária com pesos de classe como função de custo:

$$\mathcal{L} = -\frac{1}{N} \sum_{i=1}^{N} w_{y_i} \left[y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \right] \tag{6}$$

O otimizador Adam foi configurado com taxa de aprendizado $\alpha = 0.001$ e parâmetros $\beta_1 = 0.9$, $\beta_2 = 0.999$. Os hiperparâmetros incluíram épocas máximas de 40, batch size de 32 e validação com 20% de $\mathcal{D}_{\text{train}}$. Para regularização, implementou-se early stopping com paciência de 15 épocas, monitorando $\mathcal{L}_{\text{val}}$ e restaurando os melhores pesos ao final do treinamento. A Figura 5 mostra a convergência da função de perda durante o processo.

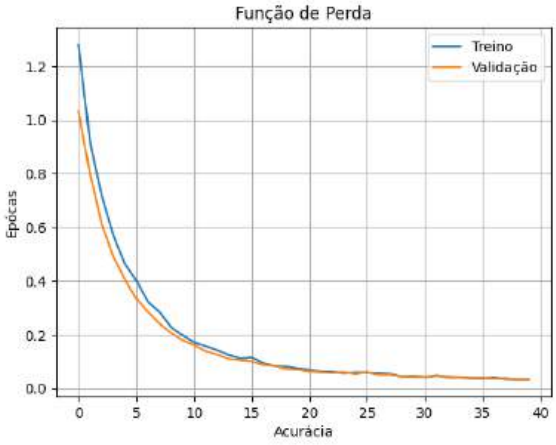


Fig. 5. Função de perda ao longo das épocas para os conjuntos de treino e validação.

F. Camada Interpretável e Recomendação de Estratégias

Implementou-se uma camada interpretável baseada em regras determinísticas. A função de mapeamento $\Phi : \{0, 1\}^{10} \to \mathcal{P}$ transforma as respostas $(A1, \ldots, A10)$ em perfis comportamentais, onde $\mathcal{P}$ representa o conjunto de perfis derivados. Subsequentemente, a função de recomendação $\Psi : \mathcal{P} \to \mathcal{S}$ mapeia cada perfil comportamental para estratégias pedagógicas personalizadas baseadas em evidências [8-16], onde $\mathcal{S}$ representa o conjunto de estratégias disponíveis.

IV. Resultados

A. Desempenho do Modelo

O modelo atingiu acurácia de 100% em $\mathcal{D}_{\text{test}}$ ($N_{\text{test}} = 211$):

$$\text{Acc} = \frac{TP + TN}{N_{\text{test}}} = \frac{135 + 76}{211} = 1.00 \tag{7}$$

Métricas por classe (Tabela III):

$$P_i = R_i = F1_i = 1.00, \quad \forall i \in \{0, 1\} \tag{8}$$

onde P (precisão), R (recall) e $F1$ (F1-score) são perfeitos para ambas as classes.

TABLE III
Relatório de Classificação no Conjunto de Teste

Classe	Precisão	Recall	F1-score	Suporte
0 (Ausente)	1,00	1,00	1,00	76
1 (Presente)	1,00	1,00	1,00	135
Acurácia	1,00 (211 amostras)			
Macro avg	1,00	1,00	1,00	211
Weighted avg	1,00	1,00	1,00	211

A matriz de confusão (Figura 6) confirma separação perfeita: $FP = FN = 0$.

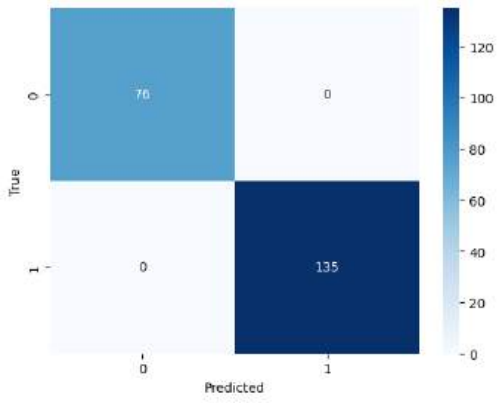


Fig. 6. Matriz de confusão para o conjunto de teste.

B. Análise das Predições

As probabilidades preditas demonstram alta confiança: $P(y = 1|\mathbf{x}) \approx 1$ para a maioria das amostras (Tabela IV).

TABLE IV
Exemplo de probabilidades previstas pelo modelo

Amostra	Probabilidade de TEA
1	0,9999986
2	0,9989839
3	0,9999999
8	0,9994163

C. Camada Interpretável e Perfil Comportamental

A camada interpretável mapeia respostas $(A1, \ldots, A10)$ em perfis comportamentais e estratégias pedagógicas baseadas em evidências. Para dificuldades de interação social (A1-A2), recomenda-se posicionamento na altura dos olhos, uso de objetos atrativos e reforço positivo [8]. Em comunicação gestual (A3), as estratégias incluem imitação, atenção compartilhada e reforço de gestos funcionais [9]. Para iniciação social (A4), sugere-se role-play, modelagem de saudações e integração às rotinas diárias [10].

Quanto à imaginação (A5), propõe-se dramaturgia com ambientes multi-sensoriais, fantoches e estruturação lúdica [11]. Para atenção conjunta (A6), utiliza-se recipiente com objetos surpresa e modelagem de foco com expressões faciais [12]. Em empatia social (A7), as abordagens envolvem cartões de emoção, histórias sociais e videomodelagem [13].

Para linguagem atípica (A8), recomenda-se aprendizado baseado em jogos, estimulação sensorial e atividades repetitivas [14]. Em comunicação não verbal (A9), as técnicas incluem modelagem, imitação, uso de espelhos e jogos [15]. Por fim, para atenção atípica (A10), sugere-se uso de interesses especiais, rotinas consistentes e promoção de estados de fluxo [16]. A implementação individualizada dessas estratégias contribui significativamente para o desenvolvimento sociocomunicativo de crianças com traços de TEA.

D. Explicabilidade do modelo

Para tornar as decisões do modelo mais transparentes e compreensíveis para profissionais da saúde e educadores, foram aplicadas técnicas de explicabilidade, incluindo SHAP (*SHapley Additive exPlanations*) e LIME (*Local Interpretable Model-agnostic Explanations*). Estas ferramentas permitem identificar quais variáveis mais influenciam as predições do modelo e como cada caso específico é classificado.

O SHAP fundamenta-se na teoria dos jogos cooperativos, onde o valor de Shapley para uma feature i é definido como:

$$\phi_i = \sum_{S \subseteq F \setminus i} \frac{|S|!(|F| - |S| - 1)!}{|F|!} [f(S \cup i) - f(S)] \tag{9}$$

onde F é o conjunto de todas as features, S é um subconjunto de features que não contém i, e $f(S)$ representa o valor esperado da predição do modelo condicionado às variáveis presentes em S.

A predição do modelo pode ser decomposta como a soma do valor base com os valores SHAP individuais:

$$f(\mathbf{x}) = \mathbb{E}[f(\mathbf{x})] + \sum_{i=1}^{M} \phi_i \tag{10}$$

onde $E[f(X)]$ corresponde ao valor esperado da saída do modelo sobre a distribuição dos dados.

A importância global de cada feature é calculada como a média dos valores absolutos de SHAP sobre todas as amostras do conjunto de teste:

$$\bar{\phi} i = \frac{1}{N\text{test}} \sum_{j=1}^{N_{\text{test}}} \left| \phi_i^{(j)} \right| \tag{11}$$

Enquanto o SHAP fornece uma visão global e consistente das contribuições das features, o LIME aproxima localmente o modelo complexo f por um modelo interpretável g na vizinhança da amostra $\mathbf{x}$:

$$\xi(\mathbf{x}) = \arg\min_{g \in G} \mathcal{L}(f, g, \pi_{\mathbf{x}}) + \Omega(g) \tag{12}$$

onde $\mathcal{L}$ é a função de perda que mede a fidelidade local de g em relação a f, $\pi_{\mathbf{x}}$ define a distribuição de vizinhança em torno de $\mathbf{x}$, e $\Omega(g)$ é um termo de regularização que penaliza a complexidade do modelo interpretável.

A Figura 7 mostra os valores SHAP individuais, onde a cor vermelha indica valores altos da feature (presença da dificuldade) e a azul valores baixos (ausência). As variáveis comportamentais com maior impacto positivo são A10 (atenção atípica), A7 (empatia social) e A5 (imaginação), indicando que valores elevados dessas dificuldades contribuem significativamente para a classificação positiva. As demais variáveis comportamentais também apresentam impacto expressivo.

Entre as características individuais, Sexo destaca-se com o maior impacto, seguido por Idade com relevância moderada. Já Etnia, Icterícia e Histórico familiar de TEA apresentam valor SHAP próximo de zero, indicando menor relevância para as decisões do modelo.

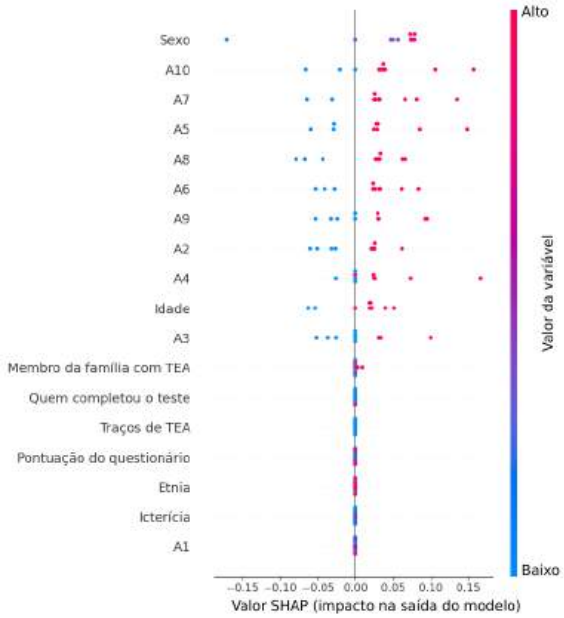


Fig. 7. Valores SHAP individuais por variável sobre o impacto de cada feature na saída do modelo.

A Figura 8 mostra os valores SHAP médios. A variável Sexo tem o maior impacto (0,07), seguida por A10 (0,05), A7 (0,05), A5 (0,045), A8 (0,04), A6 (0,035), A9 (0,03), A2 (0,025), A4 (0,02) e Idade (0,018). Variáveis demográficas como Etnia, Icterícia e Histórico familiar de TEA apresentaram impacto próximo de zero.

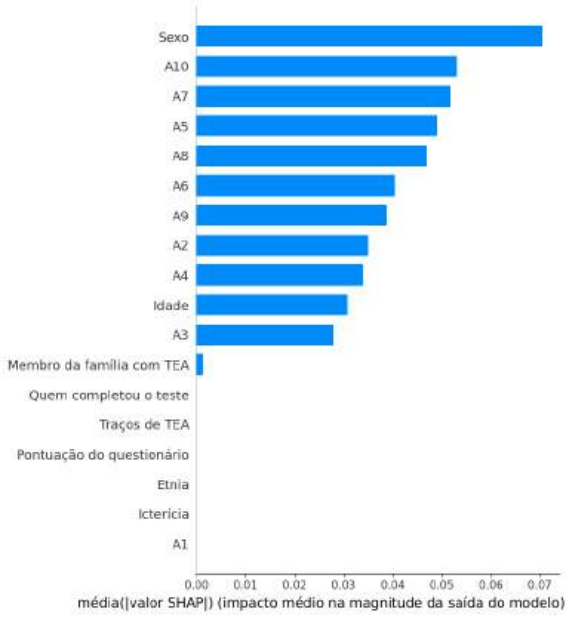


Fig. 8. Gráfico de barras da importância global das variáveis com base nos valores SHAP médios.

A Figura 9 apresenta a explicação LIME para uma amostra do teste, classificada com aproximadamente 99% de probabilidade para TEA. Variáveis como A4, A10, A6, A2 e A7 contribuíram positivamente para essa decisão, enquanto A3, A9, A8, Idade e A5 tiveram influência negativa, sendo a classificação final determinada pelo predomínio das contribuições positivas.

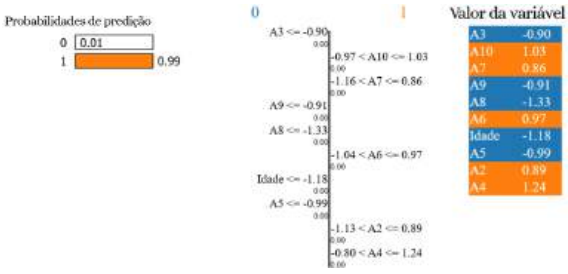


Fig. 9. Visualização LIME da explicação local para uma amostra do conjunto de teste.

A combinação de SHAP e LIME mostrou que o modelo prioriza características comportamentais, especialmente A10, A7 e A5, com impacto próximo de zero para variáveis demográficas como Etnia e Icterícia. A alta confiança do modelo (probabilidade 1,00) torna a ferramenta mais transparente para profissionais da educação e saúde.

V. Conclusão

Este estudo apresentou um sistema inteligente para triagem de TEA combinando MLP com camada interpretável para recomendações pedagógicas personalizadas, demonstrando potencial como ferramenta de suporte clínico e educacional.

No entanto, é necessário reconhecer as limitações do estudo. O desempenho alcançado (100% de acurácia, precisão, recall e F1-score), embora matematicamente correto nos dados analisados, é atípico em tarefas clínicas e deve ser interpretado com cautela. Este resultado pode estar sujeito a overfitting, vazamento de dados (*data leakage*) e desbalanceamento das classes (69,1% de casos positivos mesmo utilizando *class_weight*). Diante dessas limitações, os resultados devem ser considerados como promissores, porém preliminares, e o modelo não substitui a avaliação clínica especializada.

Como trabalhos futuros, propõe-se validação em coortes multicêntricas independentes, expansão de estratégias baseadas em diretrizes clínicas atualizadas e desenvolvimento de interface amigável para uso por profissionais da educação e saúde.

Declaração de Uso de Inteligência Artificial

Em conformidade com as diretrizes de integridade científica e boas práticas acadêmicas recomendadas pela CAPES, os autores declaram que utilizaram a ferramenta DeepSeek para auxiliar na pesquisa de estratégias educacionais baseadas em literatura, aperfeiçoamento da linguagem e criação de tabelas. Todo o conteúdo foi revisado e editado pelos autores, que assumem total responsabilidade pelo trabalho final.

Agradecimentos

Os autores agradecem à disciplina de Redes Neurais do curso de Engenharia de Software da Universidade Federal Rural do Semi-Árido (UFERSA), no âmbito da qual este trabalho foi desenvolvido.

References

[1] SILVA, C. C.; ELIAS, L. C. S. Instrumentos de avaliação no transtorno do espectro autista: uma revisão sistemática. Revista Avaliação Psicológica, v. 19, n. 2, p. 189-197, 2020.

[2] KOEGEL, Lynn Kern et al. The importance of early identification and intervention for children with or at risk for autism spectrum disorders. International Journal of Speech-Language Pathology, v. 16, n. 1, p. 50-56, 2014.

[3] LINDLY, O. J.; ZUCKERMAN, K. E.; KUHLTHAU, K. A. Healthcare access and services use among US children with autism spectrum disorder. Autism, v. 23, n. 6, p. 1419-1430, 2019.

[4] ANAGNOSTOPOULOU, Panagiota et al. Artificial intelligence in autism assessment. International Journal of Emerging Technologies in Learning (iJET), v. 15, n. 6, p. 95-107, 2020.

[5] FRANCESE, Rita; YANG, Xiaomin. Supporting autism spectrum disorder screening and intervention with machine learning and wearables: a systematic literature review. Complex & Intelligent Systems, v. 8, n. 5, p. 3659-3674, 2022.

[6] THABTAH, Fadi. Autism spectrum disorder screening: machine learning adaptation and DSM-5 fulfillment. In: Proceedings of the 1st International Conference on Medical and Health Informatics, p. 1-6, 2017.

[7] WALL, Dennis P. et al. Use of artificial intelligence to shorten the behavioral diagnosis of autism. PLoS ONE, v. 7, n. 8, p. e43855, 2012.

[8] N. Adriaenssens, "Using an elicited orienting response and respondent conditioning to increase eye contact in response to a name call in children with autism", M.S. thesis, Florida Institute of Technology, Melbourne, FL, 2019.

[9] M. G. Logrieco, L. Casula, S. Guerrera, M. Fasolo, G. Valeri, S. Vicari, and E. Annechini, "Nonverbal skills evolution in children with autism spectrum disorder one year post-diagnosis," *Children*, vol. 11, no. 12, pp. 1520, 2024.

[10] D. J. Dsouza and R. Kaur, "From core to steps: Development and validation of next-level interactive social pragmatic interventions and responsive engagement for children with autism, through trackable intervention model," *MethodsX*, pp. 103663, 2025.

[11] J. Beadle-Brown, D. Wilkinson, L. Richardson, N. Shaughnessy, M. Trimingham, J. Leigh, B. Whelton, and J. Himmerich, "Imagining autism: Feasibility of a drama-based intervention on the social, communicative and imaginative behaviour of children with autism," *Autism*, vol. 22, no. 8, pp. 915-927, 2018.

[12] G. Davies, "Attention Autism," Whittington Hospital NHS. [Online]. Available: https://www.whittington.nhs.uk/default.asp?c=44644&print=1. Accessed: Apr. 17, 2026.

[13] Advanced Autism Services, "Supporting social and emotional development in children with autism," Jun. 27, 2025. [Online]. Available: https://www.advancedautism.com/post/supporting-social-and-emotional-development-in-children-with-autism. Accessed: Apr. 17, 2026.

[14] R. Nordin, M. Marzuki, and R. Aboo Bakar, "I-M-A-N approach: A creative method to teach autistic children verbal communication," in *Melaka International Intellectual Exposition 2024 (MIIEX'24)*, Melaka, Malaysia, 2024, pp. 507-510.

[15] N. O. M. Mohammed, A. A. Hassan, "The effectiveness of a proposed training program to develop nonverbal communication skills in children with autism spectrum disorder," *Sulaimani Journal for Humanities*, vol. 2, no. 2, pp. 231-254, 2025.

[16] "Supporting monotropic thinkers: Creating environments where focus can flourish," Reframing Autism, Oct. 19, 2025. [Online]. Available: https://reframingautism.org.au/supporting-monotropic-thinkers-creating-environments-where-focus-can-flourish/. Accessed: Apr. 17, 2026.

Aplicação de Redes Perceptron Multicamadas no Diagnóstico da Doença de Alzheimer com IA Explicável

Maria A. F. Teixeira
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
maria.teixeira@alunos.ufersa.edu.br

Rosana C. B. Rego
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
rosana.rego@ufersa.edu.br

***Resumo*—Este artigo apresenta o desenvolvimento de uma rede neural do tipo Perceptron Multicamadas (MLP) para a classificação binária da doença de Alzheimer (DA) utilizando dados clínicos estruturados. O objetivo é oferecer uma alternativa de baixo custo e alta sensibilidade para triagem inicial, superando as barreiras socioeconômicas associadas aos exames de imagem. A metodologia envolveu o pré-processamento de 2.149 registros, incluindo normalização e balanceamento de classes, bem como uma arquitetura otimizada com Batch Normalization, Dropout e regularização L2. Os resultados demonstraram uma acurácia de 79,07% e um recall de 87,5%. Conclui-se que o modelo é eficaz na minimização de falsos negativos em cenários com infraestrutura limitada.**

***Palavras-chave*—Alzheimer's disease, MLP, Binary classification, Neural Network**

I. Introdução

Alzheimer é uma doença que acarreta a perda de memória e diversos distúrbios cognitivos, sendo uma doença progressiva e sem cura. Cerca de 10% dos indivíduos acima dos 65 anos e 40% acima de 80 anos são afetados pela Doença de Alzheimer (DA, do inglês: *Alzheimer disease*) [1]. A doença ocorre ao longo de 5 a 10 anos reduzindo a expectativa de vida do enfermo em 50% [2].

Historicamente, para o diagnóstico da DA baseia-se em exames de neuroimagem, como a Ressonância Magnética (RM). Embora modelos de última geração utilizando Redes Neurais Convolucionais (CNN, do inglês: *Convolutional Neural Networks*) alcancem precisões superiores a 99% em imagens [3], a aplicação prática dessas ferramentas esbarra em barreiras socioeconômicas, como o alto custo dos equipamentos e a necessidade de especialistas qualificados, o que limita sua disponibilidade em regiões com infraestrutura médica reduzida.

Nesse cenário, emerge uma transição na literatura para o uso de inteligência artificial aplicada a dados clínicos multimodais estruturados. Dados tabulares que incluem históricos médicos, escores de testes neuropsicológicos e hábitos de vida oferecem uma alternativa de baixo custo e alta escalabilidade para triagens em massa na atenção primária [4]–[6].

O presente trabalho propõe preencher a lacuna entre a eficácia diagnóstica e a simplicidade de implementação. Desenvolveu-se uma arquitetura de Perceptron Multicamadas (MLP, do inglês: *Multilayer Perceptron*) otimizada com técnicas de regularização para a classificação binária da DA a partir de dados clínicos acessíveis. O diferencial desta abordagem reside no foco técnico voltado à sensibilidade (*Recall*), visando minimizar falsos negativos em cenários de triagem inicial, e na eficiência computacional, permitindo que o modelo seja executado em infraestruturas de computação em nuvem com recursos limitados.

Este artigo está organizado da seguinte forma: a Seção II apresenta o levantamento bibliográfico; a Seção III descreve a metodologia e a arquitetura da rede neural proposta; a Seção IV discute os resultados obtidos; e a Seção V apresenta as considerações finais e sugestões para trabalhos futuros.

II. Levantamento Bibliográfico

A literatura sobre a detecção da DA demonstra uma transição representativa de diagnósticos baseados exclusivamente em neuroimagens para abordagens multimodais e clínicas estruturadas.

Empregando *Deep Learning* (DL) em imagens de ressonância magnética, [3] propuseram uma arquitetura de Rede Neural Convolucional Espaço-Temporal (STCNN, do inglês: *Spatial-Temporal Convolutional Neural Network*), que utiliza correlações espaciais em fatias cerebrais para atingir 0,993 de acurácia.

Apesar do sucesso do algoritmo, [3], [5] ressaltaram que o uso de neuroimagens enfrenta barreiras de alto custo e inacessibilidade em regiões com infraestrutura médica limitada, o que impulsiona a busca por alternativas baseadas em dados clínicos.

Utilizando dados clínicos estruturados, [4] compararam ML clássico e DL utilizando a base *Alzheimer's Disease Neuroimaging Initiative* (ADNI). O estudo testou arquiteturas híbridas, integrando *transformers* e *DigitCapsule-Net* para classificar os pacientes em quatro estágios da doença. A pesquisa demonstrou que, ao lidar estritamente com dados

clínicos estruturados modelos baseados em árvores, superam ou igualam a precisão das arquiteturas complexas de redes profundas.

Outros autores também utilizaram dados clínicos tabulares de bases abertas para triagem em massa. Similar a este trabalho, [5], [6] utilizaram a base de [7]. [5] demonstraram que a técnica de Stacking Ensemble alcança 0,97 de acurácia e 0,94 de recall, focando em métricas robustas sem a geração de dados sintéticos. Enquanto [6] aplicaram Random Forest otimizada pelo método de Colônia de Formigas, atingindo 0,95 de acurácia. [6] destaca o uso de IA Explicável para validar que variáveis como o Mini Exame do Estado Mental (MMSE, do inglês: *Mini-Mental State Examination*) e avaliações funcionais são os preditores mais determinantes.

Diferente das abordagens de [3], [6], que mitigam o desbalanceamento de classes através da geração de dados sintéticos via *Synthetic Minority Over-sampling Technique* (SMOTE) e variações, este trabalho opta pelo uso do *RandomOverSampler*. Esta escolha visa manter a fidelidade às observações clínicas reais, evitando o ruído que dados artificiais podem introduzir em diagnósticos sensíveis. A Tabela I sintetiza este cenário comparativo.

TABELA I
SÍNTESE COMPARATIVA DO ESTADO DA ARTE

Estudo	**Dados**	**Técnica Principal**	**Métrica (Acc / Rec)**
[3]	Imagem	CNN (STCNN)	0,993 / 0,992
[4]	ADNI	Transformers / Capsule Net	0,905 / –
[6]	Kaggle	Random Forest + ACO	0,95 / 0,94
[5]	Kaggle	Stacking (XGB + GB)	0,97 / 0,94
Este Trabalho	Kaggle	Rede Neural (MLP)	0,791 / 0,875

Embora a literatura aponte para a eficiência de modelos de árvores em dados tabulares, há uma oportunidade para o uso de MLP otimizadas. Este trabalho preenche essa lacuna ao integrar técnicas de *BatchNormalization* e *Dropout*, conferindo robustez à rede neural frente ao overfitting.

III. MODELO DE REDE NEURAL PROPOSTO

Nesta seção, descreve-se o fluxo de trabalho adotado par o desenvolvimento do modelo de classificação.

A. Pré-processamento

A base de dados utilizada foi extraída de [7], composta po 2.149 registros clínicos. O pré-processamento foi estruturad em três etapas fundamentais:

1) Seleção de atributos: foram mantidas as variáve clínicas e demográficas de maior relevância biológic e estatística (e.g., MMSE, Índice de Massa Corporal (IMC), Atividade Física).
2) Normalização: aplicou-se o *StandardScaler* para reescalar os atributos numéricos para uma distribuição com média 0 e desvio padrão 1. Isso garante que variáveis com diferentes ordens de magnitude contribuam equitativamente para o ajuste dos pesos da rede.
3) Divisão de dados: o conjunto foi particionado na proporção de 80% para treinamento e 20% para teste, assegurando uma avaliação imparcial do desempenho do modelo em dados não vistos [8].

Para mitigar o impacto do desbalanceamento de classes, foram calculados pesos específicos para a função de perda:

$$w_0 = 0,7736, \quad w_1 = 1,4137 \tag{1}$$

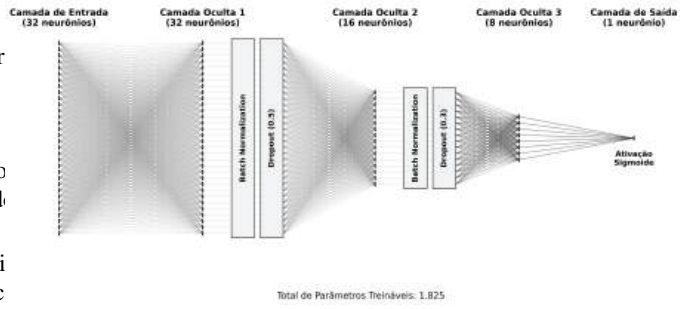
Estes valores foram obtidos através da função `compute_class_weight` da biblioteca *scikit-learn*, utilizando a estratégia `'balanced'`.

B. Arquitetura da Rede Neural MLP

A arquitetura proposta consiste em uma *Multilayer Perceptron* (MLP) estruturada em três camadas densas, projetada especificamente para capturar as correlações não lineares inerentes aos dados tabulares clínicos. A camada de entrada recebe 32 atributos, que são processados por uma primeira camada oculta contendo 32 neurônios com função de ativação ReLU [9] e regularização L2 com fator de $0,001$. Visando estabilizar o treinamento e mitigar o *overfitting*, esta camada é sucedida por técnicas de *Batch Normalization* e *Dropout* com taxa de $0,5$ [10]. O fluxo de informações segue para uma segunda camada de 16 neurônios e uma terceira de 8 neurônios, ambas mantendo a ativação ReLU e a regularização L2, sendo a segunda camada acompanhada por um novo bloco de normalização e *Dropout* com taxa reduzida para $0,3$. Por fim, a camada de saída é composta por um único neurônio com função de ativação sigmoide, configuração necessária para a geração de probabilidades em problemas de classificação binária.

A representação visual detalhada desta arquitetura, incluindo as camadas de regularização e o fluxo de dados, é apresentada na Figura 1.

Fig. 1. Diagrama da Arquitetura MLP



C. Treinamento

O modelo foi compilado utilizando o otimizador Adam [11], com taxa de aprendizado inicial de 0,001. A função de perda

adotada foi a *Binary Cross-Entropy* (BCE), calculada sobre o lote de tamanho N:

$$\text{Loss} = -\frac{1}{N}\sum_{i=1}^{N}[y_i \log(\hat{y}_i) + (1-y_i)\log(1-\hat{y}_i)] \qquad (2)$$

Para lidar com possíveis desequilíbrios no conjunto de dados, a função de perda foi aplicada com pesos de classe. Além da perda, foram monitoradas as métricas de acurácia e *recall*.

Foram utilizadas as seguintes estratégias de *early stopping* e ajuste dinâmico:

- *Early stopping*: interrupção do treinamento após 10 épocas sem melhoria na perda de validação (*val_loss*).
- *ReduceLROnPlateau*: redução da taxa de aprendizado por um fator de 0,5 caso a *val_loss* não apresente melhora por 8 épocas consecutivas.

O treinamento foi executado por 60 épocas, reservando-se 20% dos dados para validação.

IV. Resultados e Simulações

Esta seção apresenta o desempenho da MLP proposta, analisando as métricas de convergência durante o treinamento e a eficácia da classificação no conjunto de teste.

A. Desempenho no Conjunto de Teste

Após o treinamento, o modelo foi avaliado no conjunto de teste (20% dos dados). Adotou-se um limiar de decisão de 0,4 para priorizar o recall da classe positiva. Os resultados alcançados foram sintetizados na Tabela II.

TABELA II
Métricas de desempenho da MLP no conjunto de teste.

Métrica	Valor
Acurácia	0,7907
Recall (Classe Alzheimer)	0,8750
Precisão (Classe Alzheimer)	0,65
F1-score (Classe Alzheimer)	0,75

Para fins de classificação, definiu-se a classe 1 como a presença da DA e a classe 0 como indivíduos saudáveis. Na Figura 2, a Matriz de Confusão revela que o modelo demonstrou uma capacidade robusta de identificar casos positivos, minimizando a taxa de falsos negativos. Em um cenário de triagem clínica, o *Recall* de 87,5% (Tabela I) é particularmente valioso, pois prioriza a detecção de pacientes em risco em detrimento de uma acurácia global puramente estatística.

B. Evolução da Função de Perda

A Figura 3 mostra a evolução da perda durante o treinamento. Observa-se convergência estável, sem sinais de overfitting severo, graças às técnicas de regularização empregadas (Veja III-C).

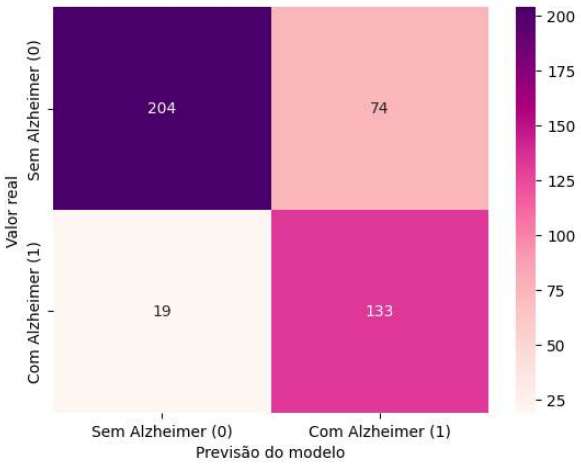
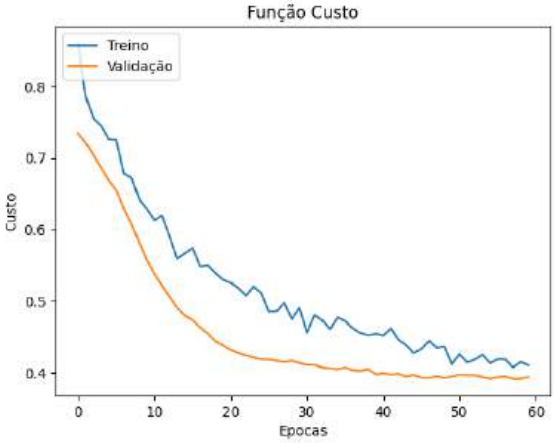


Fig. 2. Matriz de confusão no conjunto de teste, onde a classe 0 representa o grupo de controle (saudável) e a classe 1 representa o diagnóstico positivo para Alzheimer

Fig. 3. Curva de perda (treino e validação) ao longo das épocas.



C. Inteligência Artificial Explicável (XAI)

A interpretabilidade do modelo foi feita por meio das técnicas SHAP (*SHapley Additive exPlanations*) [12] e LIME (*Local Interpretable Model-agnostic Explanations*) [13]. O gráfico SHAP (Fig. 5), em um subconjunto amostral de 50 registros do conjunto de teste padronizado, indica que as variáveis Queixas de Memória, Avaliação Funcional e AVD (Pontuação de Atividades da Vida Diária) são os preditores com maior impacto global no modelo.

Complementarmente, a análise LIME (Fig. 4) permite observar a contribuição individual de cada característica para uma predição específica. Nota-se que, para o caso analisado, a presença de problemas comportamentais e um histórico familiar positivo de Alzheimer foram determinantes para a classificação da classe 1 (Diagnóstico Positivo).

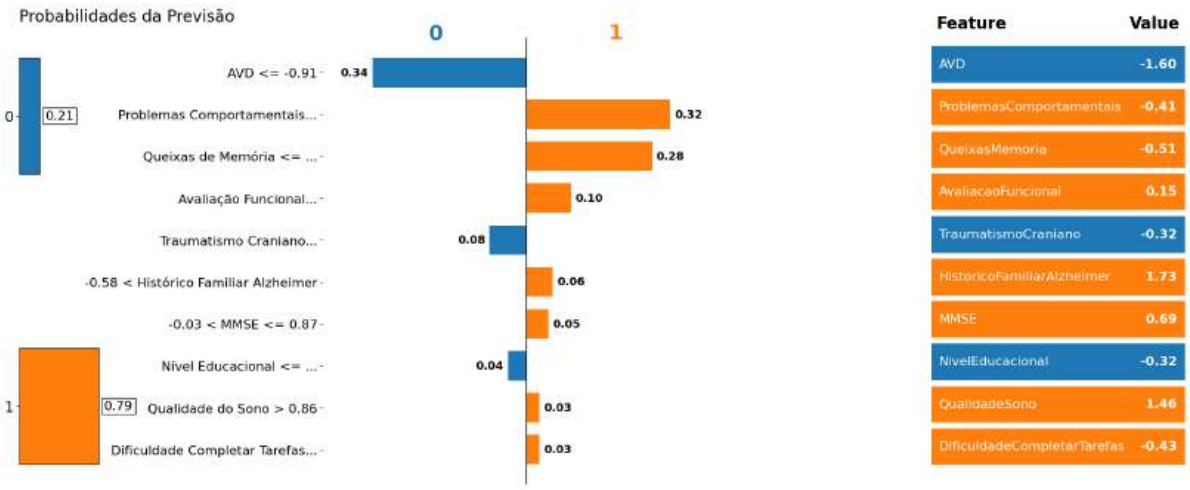


Fig. 4. Explicação local de uma instância via LIME, demonstrando o peso de cada atributo na decisão final do modelo.

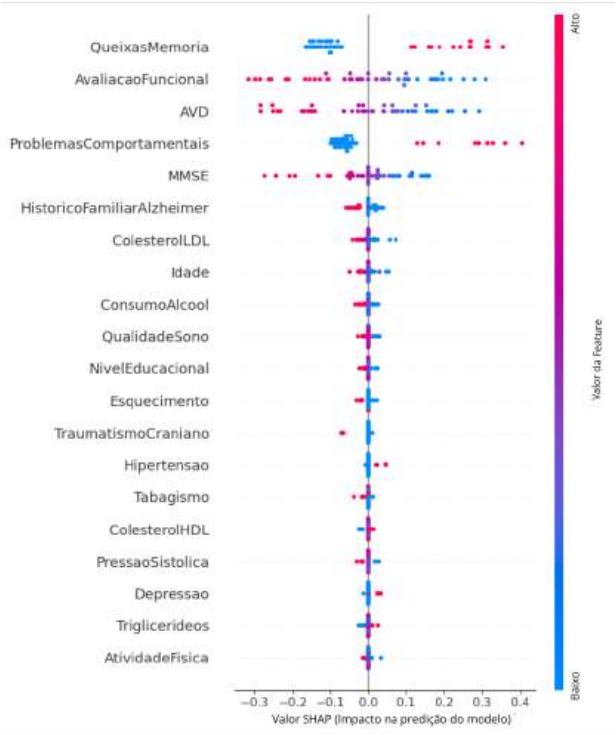


Fig. 5. Análise SHAP destacando a importância global das variáveis clínicas no modelo MLP.

D. Comparação com o Estado da Arte

Ao contrastar os resultados com os trabalhos [5] e [6], que utilizam técnicas de *Ensemble* de árvores, nota-se que a MLP proposta oferece desempenho competitivo com uma arquitetura significativamente mais leve. Enquanto modelos complexos buscam acurácias próximas a 97%, este estudo demonstra que uma rede neural densa com regularização moderna consegue equilibrar sensibilidade e baixo custo computacional.

V. Conclusão

O presente trabalho desenvolveu e avaliou uma rede neural do tipo *Multilayer Perceptron* (MLP) para a classificação da Doença de Alzheimer utilizando dados clínicos estruturados. Diante do cenário global de envelhecimento populacional e da necessidade de ferramentas de triagem acessíveis, a solução proposta demonstrou ser uma alternativa viável aos modelos de neuroimagem de alto custo e às arquiteturas de aprendizagem de máquina excessivamente complexas.

Os resultados obtidos, com uma acurácia de 79,07% e um *recall* de 87,5%, demonstraram que uma rede neural densa regularizada é capaz de capturar padrões clínicos relevantes em dados tabulares. O foco primordial no *recall* reflete o compromisso com a sensibilidade diagnóstica da ferramenta.

Para trabalhos futuros, sugere-se a exploração de abordagens multimodais, integrando dados clínicos com biomarcadores genéticos ou extração de características de exames de imagem simplificados.

Agradecimentos

Os autores agradecem à disciplina de Redes Neurais do curso de Engenharia de Software da Universidade Federal Rural do Semi-Árido (UFERSA), no âmbito da qual este trabalho foi desenvolvido.

Declaração de Uso de Inteligência Artificial

Os autores declaram que utilizaram ferramentas de inteligência artificial, incluindo o Gemini, exclusivamente para auxiliar na melhoria da linguagem e legibilidade deste manuscrito. Após a utilização desta ferramenta, os autores revisaram e editaram o conteúdo conforme necessário e assumem total responsabilidade pelo conteúdo final do trabalho.

Referências

[1] A. Sereniki and M. A. B. F. Vital, "A doença de alzheimer: aspectos fisiopatológicos e farmacológicos," *Revista de psiquiatria do Rio Grande do Sul*, vol. 30, 2008. [Online]. Available: https://www.scielo.br/j/rprs/a/LNQzKPVKxLSsjbTnBCps4XM/?lang=pt

[2] M. d. A. C. Smith, "Doença de alzheimer," *Brazilian Journal of Psychiatry*, vol. 21, pp. 03–07, 1999. [Online]. Available: https://www.scielo.br/j/rbp/a/DbpBDqKVTnsfyF3HHTDCkNN/?lang=pt

[3] Anjali, D. Singh, O. J. Pandey, and H.-N. Dai, "Stcnn: Combining smote-tomek with cnn for imbalanced classification of alzheimer's disease," *IEEE SENSORS LETTERS*, vol. 8, no. 3, MAR 2024. [Online]. Available: https://ieeexplore.ieee.org/document/10413497

[4] M. A. Bravo-Ortiz, S. A. Holguin-Garcia, E. Guevara-Navarro, E. Ceron-Cabrera, A. Mora-Rubio, H. B. Arteaga-Arteaga, G. A. Ruz, and R. Tabares-Soto, "Transformers and capsule networks vs classical ml on clinical data for alzheimer classification," *PEERJ COMPUTER SCIENCE*, vol. 11, SEP 29 2025. [Online]. Available: https://peerj.com/articles/cs-3208/

[5] M. K. Hossain, A. Ashraf, M. M. Islam, S. H. Sourav, and M. M. H. Shimul, "Optimizing alzheimer's disease prediction through ensemble learning and feature interpretability with shap-based feature analysis," *ALZHEIMER'S & DEMENTIA: DIAGNOSIS, ASSESSMENT & DISEASE MONITORING*, vol. 17, no. 3, AUG 8 2025. [Online]. Available: https://pubmed.ncbi.nlm.nih.gov/40787633/

[6] A. A. Soladoye, N. Aderinto, D. Osho, and D. B. Olawade, "Explainable machine learning models for early alzheimer's disease detection using multimodal clinical data," *INTERNATIONAL JOURNAL OF MEDICAL INFORMATICS*, vol. 204, DEC 2025. [Online]. Available: https://pubmed.ncbi.nlm.nih.gov/40882599/

[7] R. E. Kharoua, "Alzheimer's disease dataset," 2024. [Online]. Available: https://www.kaggle.com/dsv/8668279

[8] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg, J. Vanderplas, A. Passos, D. Cournapeau, M. Brucher, M. Perrot, and Duchesnay, "Scikit-learn: Machine learning in python," *Journal of Machine Learning Research*, vol. 12, p. 2825 – 2830, 2011, cited by: 79647. [Online]. Available: https://www.scopus.com/inward/record.uri?eid=2-s2.0-80555140075partnerID=40md5=63e53cee7a9711760872d4d103e5453a

[9] V. Nair and G. E. Hinton, "Rectified linear units improve restricted boltzmann machines," 2010, Conference paper, p. 807 – 814, cited by: 17248. [Online]. Available: https://www.scopus.com/inward/record.uri?eid=2-s2.0-77956509090partnerID=40md5=70e2e88c9faa609cc4bd7221fc47e5ca

[10] S. Ioffe and C. Szegedy, "Batch normalization: Accelerating deep network training by reducing internal covariate shift," vol. 1, 2015, Conference paper, p. 448 – 456, cited by: 28538. [Online]. Available: https://www.scopus.com/inward/record.uri?eid=2-s2.0-84969584486partnerID=40md5=bf7e146fe4da2c48a38050108068d697

[11] D. P. Kingma and J. L. Ba, "Adam: A method for stochastic optimization," 2015, Conference paper, cited by: 56477. [Online]. Available: https://www.scopus.com/inward/record.uri?eid=2-s2.0-85083951076partnerID=40md5=1512fe7d6538ffc6686cf01cba3c3460

[12] S. M. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions," in *Advances in Neural Information Processing Systems*, vol. 30. Curran Associates, Inc., 2017.

[13] M. T. Ribeiro, S. Singh, and C. Guestrin, ""why should i trust you?": Explaining the predictions of any classifier," in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, ser. KDD '16. New York, NY, USA: Association for Computing Machinery, 2016, p. 1135–1144. [Online]. Available: https://doi.org/10.1145/2939672.2939778

Include: Repositório de Materiais Adaptados para Pessoas com Necessidades Educacionais Especiais no Ensino Técnico

Rafaella Dias Gurgel
Curso Técnico Integrado em Informática
Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
Apodi, Brasil
rafaell4.dias.g@gmail.com

Lucia Haylline Moreira Lima
Curso Técnico Integrado em Informática
Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte
Apodi, Brasil
luciahayllinemoreira@gmail.com

***Resumo* – A Educação Inclusiva é essencial para a equidade educacional, porém ainda é limitada no ensino técnico, especialmente quanto à disponibilidade de materiais adaptados. Este trabalho apresenta o projeto Include, que propõe um ambiente que permita o armazenamento, a organização e a disponibilização de recursos educacionais adaptados. Para isso, foi desenvolvido o protótipo de um repositório digital para a *web* utilizando Python e Flask. Como resultado parcial, obteve-se um protótipo funcional com potencial de aplicação institucional. Conclui-se que a solução pode contribuir para o fortalecimento da Educação Inclusiva no ensino técnico, embora ainda existam desafios técnicos.**

Palavras-chave—Educação Inclusiva, Tecnologia, Educação Técnica, Repositórios Educacionais Digitais

***Abstract* – Inclusive Education is essential for educational equity; however, it remains limited in technical education, particularly regarding the availability of adapted materials. This paper presents the Include project, which proposes an environment for the storage, organization, and distribution of adapted educational resources. To this end, a prototype of a web-based digital repository was developed using Python and Flask. As a partial result, a functional prototype with potential for institutional application was obtained. The proposed solution may contribute to strengthening inclusive education in technical education, although technical challenges remain.**

Keywords—Inclusive Education, Technology, Technical Education, Digital Educational Repositories

I. INTRODUÇÃO

A Educação Inclusiva pode ser entendida como uma forma de transmitir conhecimento de forma plena e livre de preconceitos, que reconheça e valorize as diferenças [1], impactando diretamente no processo de aprendizagem das Pessoas com Necessidades Educacionais Especiais (NEE).

Grande parte das pesquisas relacionadas à acessibilidade se concentra no público infantil, possibilitando uma vasta disponibilidade de materiais didáticos adaptados voltados a esse público. No entanto, a inclusão no ensino médio integrado e na Educação Profissional e Tecnológica ainda enfrenta desafios relacionados à adaptação pedagógica, acessibilidade e disponibilização de recursos adequados às necessidades dos estudantes [2]. Nesse contexto, observa-se uma deficiência significativa de recursos adaptados no ensino médio, e especialmente para o ensino técnico, em que os conteúdos são mais complexos e específicos.

No campo do autismo, dados recentes apontam que a maioria das pesquisas está direcionada à infância, enquanto uma parcela significativamente menor aborda a fase adulta, reforçando a existência de uma lacuna epistemológica na área [3].

Nesse contexto, professores do ensino técnico enfrentam constantes desafios na adaptação metodológica, ao elaborar materiais didáticos que atendem a necessidades específicas e pontuais, processo que é dificultado pelo acesso limitado a materiais já existentes para serem utilizados como referência. Isso evidencia uma descentralização institucional na gestão desses materiais e a ausência de um sistema dedicado à sua organização e reutilização, o que contribui para a perda dos recursos produzidos, além da busca e trabalho repetitivo constante.

O potencial interativo, a flexibilização de tempos, espaços e acessos universais são justamente as características que apontam possibilidades na utilização das tecnologias na inclusão dos alunos [4].. Nesse contexto, destacam-se os Recursos Educacionais Digitais (RED), que consistem em materiais de apoio disponibilizados em formato digital, favorecendo práticas mais dinâmicas e acessíveis.

Diante das dificuldades no processo de garantia da Educação Inclusiva no ensino técnico, o presente projeto propõe o desenvolvimento do repositório Include, um sistema para a *web* voltado à estruturação de um ambiente educacional digital no contexto do ensino técnico. Esse deve permitir o armazenamento de arquivos, a organização por meio de classificações e *tags* (etiquetas), além da disponibilização dos recursos pedagógicos adaptados que foram publicados pelos usuários, que são justamente os professores e psicopedagogos das instituições de ensino.

II. FUNDAMENTAÇÃO TEÓRICA

Os Recursos Educacionais Digitais (RED) são recursos digitais voltados ao ensino, estruturados a partir de elementos multimidiáticos como textos, imagens, elementos audiovisuais, entre outros. No entanto, na perspectiva docente, desafios são enfrentados na tentativa de acessar, organizar e utilizar esses recursos. Como alternativa a esse cenário, existem sistemas como repositórios educacionais digitais, os quais se configuram como sistemas de informação que permitem o aproveitamento e a reutilização dos RED, possibilitando a construção de um acervo dinâmico que pode subsidiar práticas pedagógicas [5]. Portanto, os RED ampliam o acesso a recursos educacionais, ao contribuir para formas de aprendizagem mais dinâmicas e interativas.

Como exemplificação, no intuito de garantir a conectividade escolar e a acessibilidade de materiais de qualidade foram tomadas iniciativas de fomento governamental como o MEC RED, uma plataforma aberta no formato de repositório educacional digital que disponibiliza um banco de RED. O sistema apresenta uma organização clara dos recursos, baseando-se na categorização de recursos por área do conhecimento, os quais podem ser acessados através de mecanismos de busca e um sistema de *tags*, facilitando o acesso entre os usuários [6]. Entretanto, na perspectiva da Inclusão Escolar, plataformas semelhantes e específicas para a adaptação são essenciais, uma vez que possibilitam o armazenamento, organização e disponibilização dos materiais produzidos, além de favorecer sua reutilização por docentes.

A adaptação de materiais pedagógicos também se configura como um desafio relevante no contexto da Educação Inclusiva, especialmente diante da necessidade de construção de estratégias que considerem as especificidades dos estudantes e favoreçam sua autonomia no processo de aprendizagem. Nesse sentido, a utilização de recursos diferenciados e tecnologias digitais pode contribuir para práticas pedagógicas mais acessíveis e inclusivas, auxiliando docentes na mediação do conhecimento e na adaptação de conteúdos [7].

III. METODOLOGIA

Adotou-se uma metodologia baseada no ciclo de vida tradicional de software, que estrutura o desenvolvimento em etapas como análise e desenvolvimento de requisitos, projeto e implementação [8], além da incorporação de metodologias ágeis como *Scrum* e *Kanban*, que priorizam a adaptação contínua no decorrer do processo de produção [9]. Desse modo, foram definidas etapas de análise, implementação, testes e implantação.

A etapa de análise para o levantamento de requisitos baseou-se na observação de plataformas com propostas semelhantes (repositórios educacionais digitais e plataformas inclusivas) e de consultas informais a docentes, visando identificar as principais necessidades. A partir disso, foi elaborado o diagrama de casos de uso (Figura 1), bem como o levantamento dos requisitos funcionais (Tabela I) e não funcionais (Tabela II).

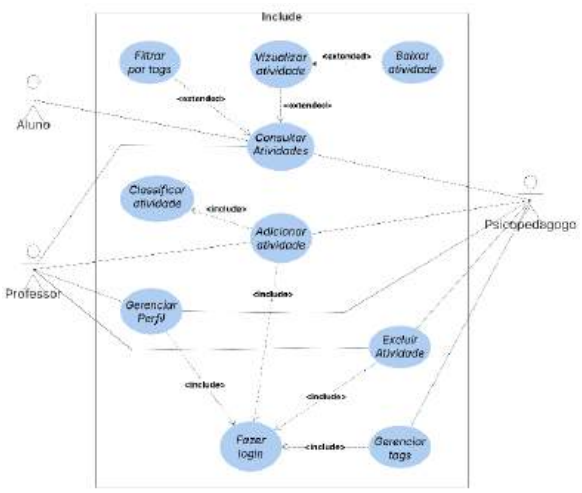


Figura 1. Diagrama de casos de uso

TABELA I. REQUISITOS FUNCIONAIS

ID	***Nome***	***Descrição***
RF01	Realizar login	Permite autenticação de usuários
RF02	Gerenciar perfil	Permite editar dados do perfil
RF03	Publicar atividade	Permite publicar atividades
RF04	Classificar atividade	Permite associar categorias e tags às atividades
RF05	Consultar atividades	Permite buscar atividades
RF06	Filtrar atividades	Permite filtrar buscas por tags
RF07	Visualizar atividades	Permite acessar detalhes da atividade
RF08	Baixar atividades	Permite download de atividades
RF09	Excluir atividades	Permite remover atividades próprias
RF10	Gerenciar Tags	Permite gerenciar tags

TABELA II. REQUISITOS NÃO-FUNCIONAIS

ID	***Nome***	***Descrição***
RNF01	Acessibilidade	Atende princípios de acessibilidade digital
RNF02	Usabilidade	Garante facilidade de uso da plataforma
RNF03	Segurança	Assegura proteção dos dados do usuário
RNF04	Plataforma para a web	Implementado como aplicação web

Com base nos requisitos levantados, foi iniciada a etapa de projeto de software, que foi desenvolvida através do planejamento de telas a serem implementadas. Inicialmente, definiu-se uma identidade visual alinhada aos fundamentos da Educação Inclusiva. Com base na Psicologia das Cores, foi elaborada uma paleta (Figura 2), utilizando azul escuro como cor base — associado à confiabilidade e profissionalismo — e amarelo ouro para destaque — associado ao acolhimento e estímulo cognitivo [10].



Figura 2. Paleta de cores

Também foram desenvolvidos um logotipo (Figura 3), contendo elementos que representam a neurodiversidade, e um mascote (Figura 4), um cão da raça labrador, associado ao conceito de cão-guia, reforçando a proposta de inclusão.



Figura 3. Logotipo



Figura 4. Mascote

Após isso, as telas foram prototipadas por meio da plataforma Canva[1], objetivando a clareza visual, organização das informações e a intuitividade, com aplicação de princípios de UX/UI.

Paralelamente, foi realizada a modelagem de dados por meio de um Diagrama Entidade-Relacionamento (DER) (Figura 5), utilizado como base para a estruturação do sistema.

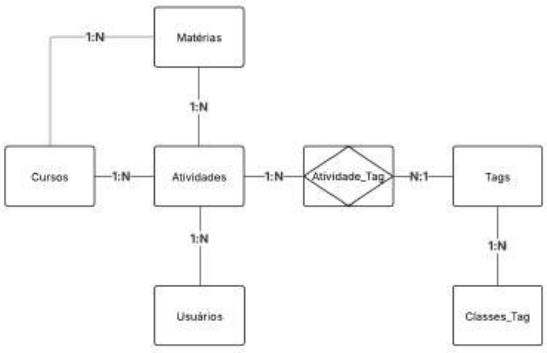


Figura 5. Diagrama Entidade-Relacionamento

A etapa de implementação consistiu na construção da lógica do repositório por meio da codificação, utilizando uma arquitetura modular baseada no padrão *Application Factory*, que favorece a organização e escalabilidade do sistema. A linguagem de programação utilizada foi Python, com o uso do framework Flask e suas extensões, ademais o *front-end* (interface) foi estruturado em HTML, CSS e renderização dinâmica por meio do Jinja2. Como banco de dados utilizou-se SQLite, por ser simples e leve – ideal para a prototipação – e o uso de serviços de armazenamento em nuvem como as *APIs* Cloudinary[2] e Supabase[3]. Ademais, foram utilizadas ferramentas como o Visual Studio Code [4] para o desenvolvimento e Git/GitHub [5] para o controle de versionamento.

A modelagem de dados foi baseada no DER elaborado anteriormente (Figura 5) e implementada com Flask-SQLAlchemy. O sistema de autenticação – cadastro, *login* e *logout* – foi desenvolvido com Flask-Login, garantindo controle de sessões e segurança por meio de armazenamento de senhas com *hash*, além de possibilitar a visualização das informações de perfil e edição das mesmas. A interface da plataforma foi desenvolvida com foco na simplicidade, clareza visual e facilidade de navegação, onde foram codificadas as telas planejadas na etapa de design.

A etapa de testes foi realizada de forma contínua durante a implementação, incluindo testes de usabilidade e ajustes para garantir o funcionamento adequado do sistema. Ao longo do desenvolvimento, também foram incorporados princípios de metodologias ágeis, como *Scrum* e *Kanban*, visando maior organização e flexibilidade no processo.

IV. Resultados e Discussões

O resultado obtido consiste em um protótipo funcional de um repositório educacional digital, alinhado aos princípios da Educação Inclusiva. O sistema incorpora elementos de humanização, como a utilização de um mascote associado ao conceito de cão-guia, e evita abordagens infantilizadas.

O sistema contempla funcionalidades essenciais de gerenciamento, busca e categorização de atividades, em conformidade com os requisitos levantados na fase de análise. A tela inicial apresenta as atividades organizadas por cursos técnicos, seguindo uma hierarquia visual que facilita a navegação e o acesso às informações (Figura 6). A publicação de atividades permite sua classificação por meio de etiquetas (Figura 7), contribuindo para a organização dos materiais. Entretanto, a busca é realizada de forma simples, não contemplando ainda mecanismos de filtragem avançada, conforme previsto no requisito RF06.

[1] Canva. Disponível em: https://www.canva.com/
[2] Cloudinary. Disponível em: https://cloudinary.com/
[3] Supabase. Disponível em: https://supabase.com/
[4] Visual Studio Code. Disponível em: https://code.visualstudio.com/
[5] GitHub. Disponível em: https://github.com/

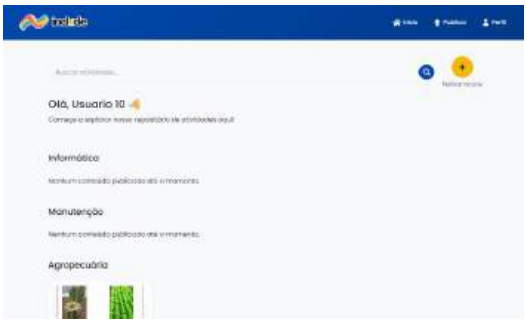


Figura 6. Tela inicial de Include

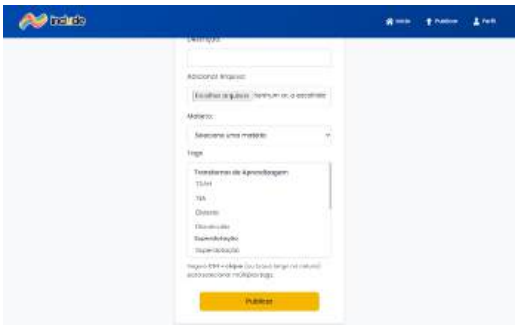


Figura 7. Tela de publicação de Include

O sistema permite publicação, categorização, visualização, download e exclusão de atividades. As telas seguem um padrão visual consistente, com barra de navegação superior contendo o logotipo da plataforma e links para as principais funcionalidades, como *login* e cadastro ou perfil, tela inicial e publicar, além de apresentar uma interface responsiva, compatível para celular (Figura 8).



Figura 8. Tela inicial de Include em celular

De modo geral, a plataforma apresenta uma estrutura organizada que favorece o acesso aos materiais adaptados. A interface contribui para uma navegação clara e eficiente. Adicionalmente, a proposta incorpora princípios de Educação Inclusiva tanto na identidade visual quanto nas funcionalidades, tornando a plataforma mais adequada ao público-alvo.

Contudo, a versão atual ainda se encontra em desenvolvimento, apresentando limitações que necessitam aprimoramento para viabilizar sua aplicação em contexto institucional. Entre essas limitações, destacam-se a não implementação de alguns requisitos previstos, como o RF06 (filtrar atividades) e o RF10 (gerenciar *tags*), além da ausência de uma hierarquia de permissões de usuários entre alunos, docentes e administradores.

Apesar dessas limitações, o sistema já evidencia potencial como ferramenta de apoio à prática docente na adaptação, reforçando o papel das tecnologias digitais como suporte institucional, ao oferecer um ambiente estruturado para armazenamento, categorização e acesso a recursos adaptados.

V. Conclusão

Conclui-se que o sistema desenvolvido atende parcialmente aos objetivos propostos, resultando em um protótipo funcional de repositório educacional digital para a *web* com potencial de aplicação no contexto institucional. A plataforma contempla funcionalidades essenciais, como publicação e gerenciamento de atividades, autenticação de usuários e organização de materiais.

Entretanto, o sistema ainda apresenta limitações que impedem sua implantação imediata, como a ausência de mecanismos de busca avançada e de uma estrutura completa de permissões de usuários. Assim, são necessárias melhorias relacionadas à usabilidade, escalabilidade e evolução das funcionalidades. Ainda assim, a proposta se mostra promissora como ferramenta de apoio à Educação Inclusiva, com potencial de expansão e aprimoramento futuro.

Referências

[1] M. T. E. Mantoan, Inclusão escolar: o que é? por quê? como fazer? São Paulo: Summus, 2015.

[2] R. A. Nocêra e S. O. G. Papi, “Inclusão escolar de pessoas com deficiência na Educação Profissional Técnica de nível médio: uma análise das pesquisas brasileiras,” *Momento - Diálogos em Educação*, vol. 33, nº 2, 2024, doi: 10.14295/momento.v33i2.17269.

[3] A. L. A. de Souza e S. I. Massuda, “Entre o reconhecimento e a invisibilidade institucionalizada: os direitos dos autistas adultos nas leis brasileiras,” *Revista Foco*, vol. 18, nº 8, p. e9429, 2025, doi: 10.54751/revistafoco.v18n8-040.

[4] S. R. Oliveira *et al*., “A integração das tecnologias digitais no ensino inclusivo: desafios e perspectivas pedagógicas para a educação e a linguagem,” *Caderno Pedagógico*, vol. 21, nº 12, p. e10805, 2024, doi: 10.54033/cadpedv21n12-166.

[5] R. Hitzschky *et al*., “Formação docente e artefatos digitais: análise de recursos educacionais digitais (RED) e a exploração de um repositório educacional digital,” em *Anais do XXVI Workshop de Informática na Escola (WIE)*, 2020, pp. 369–378, doi: 10.5753/cbie.wie.2020.369.

[6] Brasil, Ministério da Educação, “Repositório de Recursos Educacionais Digitais (MEC RED),” Brasília, s.d. Disponível em: https://www.gov.br/mec/pt-br/mec-red

[7] B. S. Peres and M. L. Bissoto, “O material pedagógico adaptado na educação inclusiva: alternativas de inclusão para o aluno autista numa perspectiva sociocomunitária,” in *Anais do XI ANPED Sul*, Curitiba, Brasil, 2014. Disponível em: https://anpedsudeste2014.wordpress.com/wp-content/uploads/2015/07/maria-luisa-bissoto-bianca-scalon-peres-de-paula.pdf. Acesso em: 5 mar. 2026.

[8] R. S. Pressman e B. R. Maxim, *Engenharia de software: uma abordagem profissional*, 9ª ed. Porto Alegre: AMGH, 2021.

[9] K. Beck *et al*., “Manifesto para o desenvolvimento ágil de software,” 2001. Disponível em: https://agilemanifesto.org.

[10] E. Heller, *A psicologia das cores: como as cores afetam a emoção e a razão*. São Paulo: Gustavo Gili, 2013.

Base de Lançamento de Foguetes de Garrafa PET com Controle e Monitoramento Remoto

Arthur de Oliveira Costa, Carlos André Lima Queiroz, Clarissa Vitória Alves Gonçalves
Luís Eduardo Pinto Tôrres Viana, Jackson da Cruz Costa
Instituto Federal do Rio Grande do Norte - IFRN
Campus Apodi, RN, Brasil
reservaarthur97@gmail.com, carlosandre2009lima@gmail.com,
clarissagncvs@gmail.com, luiseduardoptviana@gmail.com,
jackson.costa@ifrn.edu.br

***Abstract*—This work presents the development and improvement of an automated PET bottle rocket launch base with remote control and monitoring. Initially created in 2023 to ensure greater safety in OBAFOG launches, the base was redesigned in 2024 after identifying flaws. The new version incorporates a mobile application developed in Flutter, Bluetooth communication, and sensor integration. The research followed an approach with practical tests and usability evaluations that confirmed the system's effectiveness and safety.**

***Index Terms*—Automação, ESP32, Bluetooth, Flutter, IoT**

I. Introdução

No cenário educacional brasileiro, o interesse de estudantes pelas chamadas "Olimpíadas do Saber", tanto nacionais quanto regionais, cresce a cada ano e incentiva a participação de jovens nos mais diversos campos do conhecimento. Entre elas, destaca-se a OBAFOG, Olimpíada Brasileira de Foguetes. Ela é totalmente experimental e visa despertar o interesse dos alunos pela construção e lançamento de foguetes de diferentes tipos. Entre eles, o nível 4, destinado ao Ensino Médio, que utiliza reação química (como vinagre e bicarbonato de sódio) para a propulsão, ganhou bastante popularidade nos últimos anos.

Com o crescimento no número de participantes, surgiu uma preocupação com a segurança dos envolvidos, especialmente durante as etapas de montagem e, sobretudo, no momento dos lançamentos dos foguetes. Atualmente, é comum que os foguetes operem sob pressões superiores a 200 PSI, podendo alcançar até 300 PSI, conforme estudo de Coelho (2020). Para efeito de comparação, a pressão média de operação de um pneu de automóvel gira em torno de 30 a 35 PSI, evidenciando o elevado nível de periculosidade envolvido nesse tipo de atividade. Essa constatação levou ao reconhecimento da necessidade de aprimorar a infraestrutura utilizada, a fim de garantir um ambiente mais seguro para os participantes. Em 2023, foi desenvolvida a primeira versão da base de lançamentos automatizada, com o objetivo de aumentar a segurança durante os disparos.

Essa inovação permitiu que o operador controlasse as operações a uma distância segura, minimizando riscos pessoais e evitando interferências no procedimento. A Figura 1 ilustra o modelo inicial da base.



Fig. 1. Base de lançamentos 2023

II. Referencial teórico

Os principais elementos teóricos relacionados à construção e ao lançamento de foguetes na OBAFOG dizem respeito a conceitos da Física. Segundo os Trabalhos do físico Marco Antonio Sodré (OLIVEIRA, 2008) indicam que a física por trás do voo do foguete se dá pela terceira lei de Newton, conhecida como lei de ação e reação, na qual o foguete carrega um combustível em seu interior e, utilizando algum tipo de combustão, reação química ou somente pelo nível alto de pressão, expele combustível continuamente na direção contrária à da sua ponta gerando força o suficiente para decolar. O modelo de foguete utilizado necessita somente de bicarbonato de sódio e vinagre, pois a mistura do vinagre com o bicarbonato de sódio gera o ácido carbônico, que se converte em dióxido de carbono e, em ambiente selado, como a garrafa, eleva continuamente a pressão e consegue gerar força suficiente para lançar o foguete em centenas de metros.

Conforme estudo realizado diante da pressão em recipientes de plástico (COELHO, 2020), especificamente na reação do ácido acético com bicarbonato de sódio, a pressão máxima suportada por uma garrafa convencional é em torno de 160 PSI, unidade de medida de pressão no sistema imperial. Entretanto, devido ao uso das garrafas PET retornáveis, que possuem espessura maior, o limite é aumentado para mais de 200 PSI, baseando-se em lançamentos anteriores das Olimpíadas nacionais.

Quanto aos mecanismos de controle e monitoramento remoto utilizados na base, pode ser destacado o SoC (System

on Chip) ESP32. O artigo "Connectivity Evaluation of ESP32 in Outdoor Scenario" (RENDEIRO, 2023), publicado por pesquisadores da Universidade Federal do Pará, fornece uma base teórica sólida para o projeto. Por meio da avaliação do desempenho do módulo em ambientes externos, observou-se que o módulo oferece vantagens para o processamento de dados e comandos para os relés, principalmente pela conectividade Bluetooth e Wi-Fi integradas, bem como a possibilidade de aprimoramento da qualidade de uplink e downlink por meio de antenas externas. Além disso, a abordagem de implementação em estado finito (FSM) descrita no artigo pode ser adaptada para coordenar as operações de lançamento, monitoramento e coleta de dados do foguete de garrafas PET, garantindo execução eficiente e sincronizada da base.

III. Metodologia

A. Caracterização do objeto de estudo

O objeto de estudo deste trabalho é a base de lançamento automática desenvolvida para foguetes de garrafa PET. Trata-se de uma estrutura metálica equipada com sensores de pressão e inclinação, além de mecanismos controlados por SoC's ESP32, responsáveis pela automação remota do processo de lançamento. Sua principal finalidade é eliminar a interferência humana direta durante o disparo, permitindo monitoramento remoto e maior segurança operacional.

A base de lançamento é utilizada na Olimpíada Brasileira de Foguetes (OBAFOG) e outros eventos de lançamentos de foguetes de garrafa PET.O projeto surgiu em 2023, a partir da identificação de falhas de segurança durante lançamentos, resultando no desenvolvimento de um protótipo automatizado com sensores, motores e SoC's para controle do sistema. A pesquisa é, portanto, de natureza aplicada, pois visa desenvolver e aprimorar essa solução tecnológica prática para o problema real de garantir lançamentos mais seguros e eficientes nas competições e atividades experimentais futuras.

B. Método de pesquisa

Para o desenvolvimento do projeto, adotou-se a metodologia de engenharia (FEBRACE, 2021). Essa etapa permitiu mapear todos os problemas críticos, como falhas de comunicação, imprecisão na medição de ângulo e travamento de componentes eletrônicos.

1. Compreensão do problema : realiza-se inicialmente um estudo detalhado de problemas relacionados às bases comuns utilizadas na OBAFOG e do protótipo de base de lançamento construído em 2023, levantando-se precisamente as falhas observadas durante os testes e os novos pontos de melhoria a serem implementados. Essa etapa permitiu mapear todos os problemas críticos, como falhas de comunicação, falhas de segurança, imprecisão na medição de ângulo e travamento de componentes eletrônicos.

2. Proposição de soluções: com base nas falhas identificadas, propõem-se soluções específicas para cada problema detectado, com justificativas técnicas para sua adoção. As propostas contemplam alterações no hardware (mecânica e elétrica) e no software de controle, visando corrigir as deficiências do protótipo inicial e melhorar a usabilidade da base.

3. Implementação: implementam-se as soluções propostas na etapa anterior, integrando modificações nas partes mecânica, elétrica e de programação da base. Nessa fase, corrigem-se as falhas previamente levantadas no protótipo inicial e incorporam-se aperfeiçoamentos projetados, como ajustes nos atuadores e otimizações nos sensores e controles eletrônicos.

4. Testes e validação: Após a implementação das melhorias, conduzem-se testes operacionais para verificar se os problemas foram efetivamente solucionados e se a operação da base de lançamento foi aprimorada. Essa etapa final envolve validar todos os sistemas com a participação dos usuários da base (alunos e professores), garantindo a funcionalidade plena e a segurança da base automatizada antes de sua aplicação definitiva.

O teste foi aplicado em um protocolo estruturado em seis etapas: inspeção visual, testes de alimentação, configuração de comunicação, testes funcionais, validação de precisão e estresse. Somado a isso, o sistema foi submetido a uma avaliação de usabilidade baseada em três pilares fundamentais para interfaces de controle crítico:

Eficácia e eficiência: medição do tempo necessário para completar o ciclo de lançamento e a taxa de sucesso nas operações sem intervenção manual.

Visibilidade e Feedback: Verificação da clareza das informações de telemetria (pressão e ângulo) em tempo real sob condições de alta luminosidade solar, garantindo que o usuário tenha consciência situacional plena.

Prevenção de Erros e Segurança: Avaliação da facilidade de acesso ao comando de aborto e da eficácia dos alertas sonoros e visuais antes do disparo.

Por meio dessas etapas, é possível diagnosticar com precisão o estado de funcionamento de cada sensor e a qualidade da interação humano-computador, documentar os resultados obtidos e tomar decisões informadas sobre sua reutilização ou substituição. A adoção deste protocolo promove não apenas a melhoria da qualidade técnica, mas também a economia de recursos, o aumento da satisfação do usuário e a segurança nas aplicações. Com essa metodologia estruturada, é esperado que o projeto entregue uma base de lançamento totalmente funcional, confiável e intuitiva, que cumpra as exigências de segurança das competições de foguetes.

No que tange à segurança operacional, o sistema foi projetado para permitir um distanciamento de até 20 metros entre o operador e a base. Enquanto no modelo manual a proximidade é inferior a 2 metros, a automação via BLE elimina o risco de ferimentos por eventuais falhas estruturais da garrafa sob alta pressão. Sob a ótica da acessibilidade, a interface móvel substitui o esforço físico de agitação e disparo mecânico por comandos digitais, permitindo que estudantes com limitações motoras operem o sistema com autonomia.

IV. Desenvolvimento

A. Planejamento do aplicativo

A construção do aplicativo móvel iniciou-se pela representação gráfica das funções e telas necessárias, de acordo com as necessidades do hardware previamente montado, conforme observado na Figura 2. A partir do modelo, foram definidas a linguagem de programação e as tecnologias ideais para o êxito do projeto.

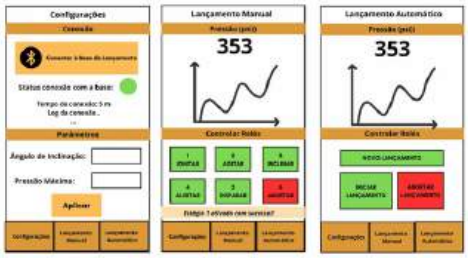


Fig. 2. Representação gráfica do Aplicativo da base de lançamentos.

B. Desenvolvimento do aplicativo e o uso do framework flutter

A construção do aplicativo móvel iniciou-se pela representação gráfica das funções e telas necessárias, de acordo com as necessidades do hardware previamente montado. A partir do modelo, foram definidas a linguagem de programação e as tecnologias ideais para o êxito do projeto.

O aplicativo é desenvolvido utilizando Flutter como framework e a linguagem Dart. A escolha do Flutter como plataforma de desenvolvimento se deve à sua natureza multiplataforma, permitindo a criação de aplicações de alta qualidade para diversos sistemas operacionais, como Android e iOS, a partir de um único código-fonte. Isso possibilita que variados dispositivos, como smartphones ou tablets, independente do modelo, sejam utilizados como controladores, eliminando a dependência de um único hardware físico e complexo.

C. Uso da tecnologia Bluetooth Low Energy (BLE)

A substituição do protocolo ESP-NOW pela tecnologia Bluetooth Low Energy (BLE) trouxe vantagens significativas para o sistema de comunicação entre o aplicativo e a central de controle. O ESP-NOW, embora eficiente em alguns casos, pode apresentar instabilidade em ambientes com alta densidade de redes Wi-Fi, que interferem na frequência de operação. O BLE, por outro lado, é uma tecnologia ideal para comunicação de curta distância, Conforme destacado por Pires e Cristo (2024), a utilização do BLE em SoC's como o ESP32 permite uma validação estável e uma latência de resposta reduzida, garantindo o acionamento imediato de mecanismos de hardware por controle remoto. O BLE foi projetado para operações que exigem pouca energia, aumentando a duração da bateria dos dispositivos móveis utilizados no controle da base. Em comparação ao ESP-NOW, o BLE oferece uma conexão mais robusta e menos sujeita a interferências externas, o que é crucial em um ambiente controlado como o de lançamentos de foguetes. O Bluetooth é amplamente suportado pelos dispositivos modernos, tornando sua implementação simples. O serviço BLE implementado no ESP32 expõe três características: uma de escrita (WRITE), responsável por receber os comandos do aplicativo, e duas de notificação (NOTIFY), destinadas à transmissão contínua dos valores de pressão e ângulo. Após eventual desconexão, o dispositivo retoma automaticamente o modo de anúncio, garantindo a reestabilização da comunicação sem intervenção manual. Além disso, o ESP32 já possui suporte integrado para BLE, facilitando a transição entre os protocolos. Para implementar essa funcionalidade, o projeto utiliza as seguintes bibliotecas principais:

Flutter (SDK):O SDK essencial para o desenvolvimento da aplicação em Dart. B.

Flutter blue plus: Facilita a comunicação com dispositivos BLE, gerenciando a conexão e a troca de dados em tempo real com o ESP32.

D. Controle de relés

Os seis motores são controlados por relés, que atuam como interruptores eletrônicos. Cada relé é responsável por ligar e desligar o circuito de um dos motores, acionando as fases de ignição, agitação, inclinação, alerta, disparo e aborto, conforme observado na Figura 3. Os comandos são transmitidos como strings de 3 caracteres no formato LXY, onde X identifica o mecanismo (1 a 6) e Y define o estado (1 = ativado, 0 = desativado). O comando de aborto, além de acionar a válvula solenóide, desativa simultaneamente todos os demais relés, implementando um mecanismo de parada de emergência completa (fail-safe) por software. A utilização de relés permite um controle preciso e seguro, essencial para o sucesso do processo automatizado.

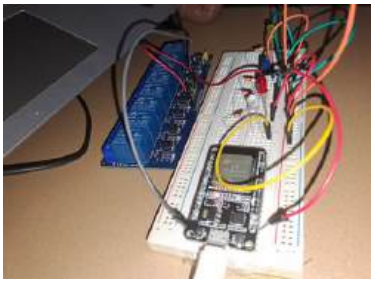


Fig. 3. Módulo relés no protótipo da base de lançamentos.

E. Sensor de inclinação ADXL345

A instalação de um sensor de inclinação, como o ADXL345, foi essencial para garantir que a base esteja posicionada no ângulo ideal de 45° antes do lançamento. Este sensor de aceleração pode medir a inclinação em três eixos, permitindo um controle preciso do ângulo de inclinação da base. Devido ao seu formato, conforme ilustrado na Figura 4, o sensor



Fig. 4. Sensor ADXL345.

teve facilidade em ser integrado à estrutura da base, sendo encaixado na parte superior.

O ADXL345 oferece medições precisas de inclinação, garantindo que a base esteja no ângulo correto para o lançamento. Isso melhora significativamente o desempenho do foguete, já que o ângulo de 45° é considerado ideal para maximizar a distância, conforme estabelecido pelo próprio regulamento da competição (CANALLE, 2026). Assim como o BLE, o ADXL345 consome pouca energia, o que o torna ideal para sistemas que precisam operar por longos períodos. O sensor pode ser facilmente integrado ao ESP32 e controlado através da IDE do Arduino, facilitando sua implementação no sistema.

O sensor de inclinação ADXL345 foi calibrado experimentalmente utilizando dois pontos de referência mecânica previamente conhecidos. As leituras brutas de 3,72° e 17,4° foram utilizadas como limites de interpolação linear, permitindo a conversão para o ângulo real de operação da base, conforme o modelo:

$$\theta_{\text{real}} = (\theta_y - 3.72) \cdot (17.4 - 3.72) \times 47$$

O ângulo θ_y é obtido a partir das leituras dos três eixos de aceleração (a_x, a_y, a_z) pela equação:

$$\theta_y = \arctan\left(\frac{a_y}{\sqrt{a_x^2 + a_z^2}}\right) \times \frac{180}{\pi}$$

Sobre esse valor intermediário aplica-se a interpolação linear de calibração, resultando no ângulo real de operação da base.

F. Sensor de pressão

O sensor de pressão mede a pressão interna do foguete, essencial para garantir que ela esteja dentro dos limites seguros durante a preparação e o lançamento. A leitura do sensor é crucial para monitorar a pressão em tempo real e evitar sobrepressurização, que poderia resultar em falhas no lançamento ou danos ao equipamento. O sensor está conectado à estrutura interna da base pela válvula com conector, onde então é acoplado, conforme observado na Figura 5. Assim, a pressão exercida no foguete e no sensor é igual, possibilitando uma leitura precisa e eficiente. O sensor de pressão está conectado ao pino sensorPressaoPin do ESP32. Ele gera um sinal analógico proporcional à pressão interna, que é lido e convertido em uma tensão no ESP32 ,a tensão é convertida em um valor de pressão em PSI utilizando a fórmula específica do sensor:

1. Conversão ADC → tensão

$$V = \frac{\text{ADC} \times 3.3}{4095} + 0.09$$

ESP32 12 bits: 4095 níveis.

2. Conversão de tensão → pressão

$$P = (V - 0.5) \times 75$$

A pressão é então monitorada continuamente e os dados são enviados via BLE.



Fig. 5. Sensor de Pressão.

G. Mecânica da Base de Lançamentos

A base de lançamentos possui uma estrutura de aço que conta com 3 motores, um sensor de pressão e um acelerômetro. Os motores atuam nos botões de ignitar, agitar, inclinar e lançar, há também uma válvula solenóide que serve para o botão de abortar lançamento e um manômetro para visualização da pressão enquanto próximo à base, conforme ilustrado na Figura 6.



Fig. 6. Estrutura Física da Base de Lançamentos.

H. Funcionamento da Base de Lançamentos

O sistema opera por meio de seis mecanismos integrados no módulo físico, cada um desempenhando uma função crítica no ciclo de lançamento, conforme ilustrado na representação esquemática (Figura 7), e para melhor detalhamento temos o Modelo de controle e tomada de decisão(Figura 8). O acionamento remoto desses motores garante a segurança do operador:

Ignitar: Rompe o reservatório de reagentes para iniciar a reação química.

Agitar: Promove a mistura eficiente do vinagre e bicarbonato para otimizar a pressurização.

Inclinar: Ajusta a base ao ângulo de 45°, ideal para alcance máximo.

Alertar: Emite sinal sonoro de segurança antes do disparo.

Disparar: Libera a trava mecânica, efetuando o lançamento.

Abortar: Aciona uma válvula solenóide para a despressurização controlada e remota do foguete. Este é o principal mecanismo de segurança, pois permite neutralizar o risco de explosão sem a necessidade de aproximação física do equipamento em caso de falha no disparo.

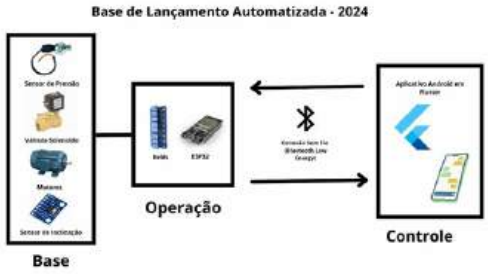


Fig. 7. Representação esquemática da base de lançamentos.



Fig. 8. Modelo de controle e tomada de decisão.

O algoritmo embarcado foi implementado no ESP32 com aquisição periódica dos sensores em intervalos de 1 segundo. Após a conexão via Bluetooth Low Energy (BLE), o sistema realiza a leitura dos sensores de pressão e inclinação, aplica os modelos de calibração e transmite os dados ao aplicativo móvel. Com base nessas informações, o operador pode validar os parâmetros e executar os comandos de ignição, agitação, inclinação, alerta, disparo ou aborto.

O fluxo operacional, apresentado na Figura 8, compreende as etapas de inicialização, conexão, aquisição, calibração, transmissão, validação e tomada de decisão.

V. Apresentação e Análise dos Resultados

A. Aplicativo móvel

O aplicativo de controle remoto da base, em sua versão final, conta com 3 telas,a primeira tela para efetuar a conexão Bluetooth, a segunda para o controle do lançamento e uma terceira tela que está em desuso, possuindo a finalidade de automatizar o processo completamente.

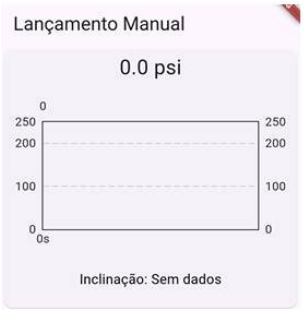


Fig. 9. Gráfico e valores do sensor de inclinação no aplicativo.

A interface principal apresenta um gráfico de pressão em tempo real e a indicação do ângulo de inclinação atual da base (Figura 9). Abaixo dessas informações, encontram-se os comandos de acionamento dos mecanismos (Figura 10). A arquitetura do aplicativo permitiu uma comunicação estável com o SoC ESP32, possibilitando o monitoramento detalhado e o controle seguro das etapas de pressurização e disparo.



Fig. 10. Interface do Aplicativo.

VI. Avaliação de Resultados

Diante da conclusão das etapas de implementação das melhorias na base de lançamento automática, foram realizados diversos testes práticos e coleta de feedback com usuários do projeto (estudantes e professores). Os resultados obtidos foram comparados com os dados coletados durante os testes do protótipo desenvolvido anteriormente, em 2023. Os testes se deram por meio de repetidamente realizar ciclos de ativação de cada um dos botões do aplicativo, variando também para testes de pressionar um mesmo botão várias vezes, a fim de garantir que os botões não falham em situações diversas. A ocorrência frequente de travamentos do sensor de pressão, que comprometia a confiabilidade da operação na base anterior, foi completamente eliminado na nova versão, com todos os testes demonstrando pleno funcionamento do sistema. Outro aspecto analisado foi o tempo médio de preparação para lançamento, que passou de 220 segundos para 90 segundos, representando uma redução de aproximadamente 60 por cento

(figura 11). Essa melhoria está diretamente relacionada à automação das etapas que antes exigiam intervenção e uso manual dos docentes e participantes.

Por fim, visualizando o feedback coletado, a avaliação dos usuários foi amplamente positiva. Alunos e professores atribuíram notas entre 4 e 5 nos quesitos segurança, praticidade e inovação, destacando a diferença e melhoria da nova base, conforme mostra a figura 12. Além da segurança operacional, os sensores permitiram correlacionar parâmetros físicos com o desempenho do lançamento. Observou-se que lançamentos realizados com inclinação entre 44° e 46° e pressão entre 190 e 230 PSI apresentaram alcance médio de 240 metros, com desvio padrão de 20 metros, em aproximadamente 55 lançamentos realizados durante a OBAFOG, contribuindo para melhor previsibilidade e repetibilidade operacional.

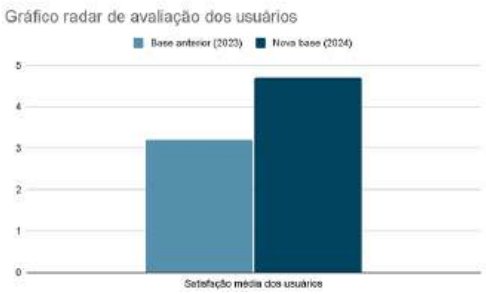


Fig. 11. Radar de avaliação dos usuários.

Os resultados do Gráfico na figura 11 confirmam que os objetivos de segurança e acessibilidade foram atingidos. A nota elevada reflete a confiança dos utilizadores no sistema de monitorização remota. A praticidade da interface Flutter foi validada como um fator de inclusão, permitindo uma operação inclusiva e intuitiva, independentemente da experiência técnica prévia ou força física do operador.

Visando observar resultados em competições, a base foi testada em situações reais e obteve resultados satisfatórios, garantindo a segurança de nossas equipes, e recebendo premiações pelos lançamentos, comprovando a sua efetividade. Os resultados evidenciam que as melhorias implementadas atingiram os objetivos propostos, tornando a base mais eficiente, segura e funcional para uso em competições e projetos educacionais.

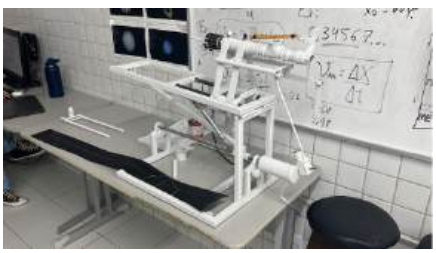


Fig. 12. Base de lançamentos automática.

VII. Conclusão

O trabalho apresentou o desenvolvimento e a reestruturação de uma base de lançamento automática para foguetes de garrafa PET, com controle remoto via aplicativo Flutter e sensores integrados. O projeto atingiu seu propósito ao corrigir deficiências e otimizar a estrutura de lançamento automatizada, tornando-a completamente operacional e segura para a OBAFOG e pesquisas acadêmicas. A implementação das melhorias diminuiu consideravelmente os riscos durante os lançamentos, assegurando maior precisão e confiabilidade. Além disso, a iniciativa proporcionou uma experiência enriquecedora para os estudantes envolvidos, viabilizando a aplicação prática de conhecimentos em tecnologia e engenharia, fortalecendo o uso da automação na educação científica. A conectividade de SoC's, como o ESP32, foi fundamental para a eficiência do monitoramento remoto. Diferente dos modelos tradicionais que focam apenas na funcionalidade de lançar o foguete, este projeto demonstrou que a priorização da segurança e da acessibilidade através da automação não só reduz riscos de acidentes, como também torna a prática científica da OBAFOG mais inclusiva e pedagógica.

Entre as principais dificuldades enfrentadas, destacam-se a integração dos módulos eletrônicos e a estabilização da comunicação entre a base e o controle remoto. Ainda assim, os resultados superaram as expectativas iniciais e abriram caminhos para novas pesquisas, como a adição de telemetria em tempo real e integração com plataformas IoT baseadas em nuvem.

References

[1] OLIVEIRA, Marco Antonio Sodré. OS ASPECTOS FÍSICOS E MATEMÁTICOS DO LANÇAMENTO DO FOGUETE DE GARRAFA PET. 2008. Trabalho de conclusão de curso (Licenciatura em Física) - Universidade Católica de Brasília, Brasília, 2008.

[2] COELHO, Sara E. Análise da pressão em recipientes de plástico devido à reação do ácido acético com bicarbonato de sódio. Revista Brasileira de Ensino de Física, Abelardo Luz, SC - Brasil, 31 ago. 2020. Disponível em: https://www.scielo.br/j/rbef/a/Gjbm3HcXdrjgnN3Wb9Pvbhr/?lang=pt. Acesso em: 12 mar. 2024.

[3] RENDEIRO, Pedro et al. Connectivity Evaluation of ESP32 in Outdoor Scenarios. XIV Computer on the Beach, Florianópolis, SC - Brasil, 1 abr. 2023. Disponível em: https://periodicos.univali.br/index.php/acotb/article/view/19458/11273. Acesso em: 12 mar. 2024.

[4] WU, Wenhao. React Native vs Flutter, cross-platform mobile application frameworks. 2018. Disponível em: . Acesso em: 20 jul. 2024.

[5] METODOLOGIA de engenharia. In: Requisitos - FEBRACE. [S. l.], 2021. Disponível em: https://febrace.org.br/participe/planeje-seu-projeto/requisitos/. Acesso em: 12 mar. 2024.

[6] PIRES, Luiz Felipe Lazarotto; CRISTO, Fernando de. Controle de Acesso por Proximidade com ESP32 e BLE: Validação Local e Interface Web de Gerenciamento. Frederico Westphalen: IFFar, 2024. Disponível em: https://arandu.iffarroupilha.edu.br/handle/itemid/854. Acesso em: 07 mai. 2026.

[7] CANALLE, João Batista Garcia. Regulamento da 20ª Olimpíada Brasileira de Foguetes — Modelo 2: Foguete de Canudo de Papel. Rio de Janeiro: OBA/OBAFOG, Acesso em: 07 mai. 2026.

Rede Neural Perceptron Multicamadas para Classificação Multiclasse de Câncer de Pele

1º Rubens Alexandre de Sousa Ferreira
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
rubens.ferreira@alunos.ufersa.edu.br

2º Rosana C. B. Rego
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
rosana.rego@ufersa.edu.br

***Resumo*—O câncer de pele é um problema relevante de saúde pública, e seu diagnóstico por computador tem sido amplamente explorado com aprendizado de máquina. Este trabalho investigou o uso de uma rede Perceptron Multicamadas (MLP) na classificação multiclasse de lesões do *dataset* HAM10000, destacando suas limitações para imagens, especialmente em cenários desbalanceados. As imagens foram redimensionadas para 64×64, vetorizadas ($d = 12288$) e padronizadas. O modelo utilizou duas camadas densas com ReLU e saída *softmax* para 7 classes. Sete configurações foram avaliadas, variando taxa de aprendizado e número de neurônios. O melhor resultado utilizou balanceamento com SMOTE ($\alpha = 0.0001$, arquitetura 128–64) obtendo acurácia de 70,84% e F1-score ponderado de 70,32%. Apesar de capturar padrões relevantes, houve baixo desempenho em classes minoritárias e indícios de *overfitting*. Comparada a abordagens como CNNs e *Transformers*, a MLP mostrou-se limitada por ignorar a estrutura espacial, sendo adequada apenas como linha de base.**

***Index Terms*—perceptron multicamadas, HAM10000, câncer de pele, classificação multiclasse, redes neurais artificiais**

I. Introdução

O câncer de pele está entre as neoplasias de maior incidência em escala mundial, e sua detecção em estágios iniciais pode contribuir para a redução de atrasos no diagnóstico e para o suporte à decisão clínica [1]. Nesse cenário, a aplicação de técnicas de inteligência artificial à análise de imagens dermatoscópicas tem se consolidado como uma abordagem relevante, sobretudo com a disponibilização de bases públicas padronizadas, como o *dataset* HAM10000, formado por $N = 10015$ imagens distribuídas em $K = 7$ classes diagnósticas [2].

A classificação automática dessas imagens constitui uma tarefa complexa em razão de fatores como a semelhança entre diferentes tipos de lesões, o desbalanceamento entre as classes do conjunto de dados e a elevada variabilidade de atributos visuais, como textura, coloração, formato e bordas. Abordagens clássicas de detecção de melanoma já exploravam atributos cromáticos e características visuais como apoio ao diagnóstico, indicando a relevância da informação de cor e aparência no problema [3], [4].

Mais recentemente, arquiteturas convolucionais, estratégias de *transfer learning* e modelos baseados em *self-attention* vêm apresentando desempenho superior por conseguirem explorar relações espaciais, padrões hierárquicos e dependências globais das imagens dermatoscópicas [4], [5], [7]. Embora arquiteturas mais recentes apresentem melhor desempenho, a MLP ainda possui importância no contexto didático das Redes Neurais Artificiais, pois sua formulação torna explícitos mecanismos como *forward propagation* (propagação direta), *backpropagation* (retropropagação do erro), uso de funções de ativação, ajuste de pesos por descida de gradiente e classificação multiclasse com *softmax* [5].

Além disso, a MLP pode ser adotada como linha de base experimental, permitindo comparar seus resultados com os de arquiteturas mais adequadas ao processamento de imagens. Nesse sentido, este artigo tem como objetivo aplicar uma rede *Multilayer Perceptron* para a classificação multiclasse de câncer de pele no *dataset* HAM10000 e, principalmente, demonstrar experimentalmente por que esse tipo de arquitetura não constitui a escolha mais adequada para esse problema. A hipótese central é que, embora a MLP seja capaz de aprender parte dos padrões discriminativos presentes nos dados, seu desempenho tende a ser inferior ao de arquiteturas que preservam as relações espaciais da imagem.

O restante deste artigo está organizado da seguinte forma: a Seção II apresenta os trabalhos relacionados; a Seção III descreve a metodologia adotada; a Seção IV discute os resultados e simulações; e, por fim, a Seção V apresenta as conclusões.

II. Trabalhos Relacionados

A literatura recente sobre classificação automática de lesões cutâneas no *dataset* HAM10000 evidencia que os melhores resultados têm sido obtidos por arquiteturas capazes de preservar e explorar a estrutura espacial das imagens, combinando pré-processamento, balanceamento, segmentação, extração de características e classificadores profundos.

Em [1], os autores apresentam uma abordagem híbrida com filtro de mediana adaptativo, segmentação por U-Net, extração de características com otimização dual e classificação com *Deep CNN*. O estudo reporta 98,76% de acurácia, 96,02% de precisão, 95,37% de *recall* e 95,32% de F1-score no HAM10000, indicando que estratégias complementares de segmentação e seleção de atributos podem ampliar significativamente a capacidade discriminativa do modelo.

Em [3], foi proposta uma arquitetura convolucional própria, utilizando imagens redimensionadas, *data augmentation*, camadas convolucionais, *max-pooling*, *dropout* e saída *softmax*. O estudo também compara a proposta com arquiteturas

consolidadas, como ResNet50 e VGG16, além de avaliá-la em diferentes bases de dados. No HAM10000, a abordagem alcança 90,00% de acurácia, 87,00% de *recall* e 85,00% de F1-score, reforçando a importância das CNNs na extração automática de padrões espaciais em imagens dermatoscópicas.

Em [5], os autores abordam um *pipeline* baseado em pré-processamento, balanceamento de classes, segmentação e classificação por *transfer learning*, avaliando arquiteturas como DenseNet169 e ResNet50. Os melhores resultados foram obtidos com DenseNet169 associada a *undersampling*, alcançando 91,20% de acurácia e 91,70% de F1-score. Esse resultado evidencia que o tratamento do desbalanceamento e a preservação das características visuais da lesão exercem influência direta sobre o desempenho final do classificador.

Além das abordagens convolucionais, modelos baseados em mecanismos de atenção também têm sido explorados na classificação de lesões cutâneas. Em [6], os autores avaliam um *Vision Transformer* (ViT) aplicado ao HAM10000 e o comparam com VGG16, ResNet50, MobileNetV2 e uma CNN customizada. Diferentemente das CNNs tradicionais, o ViT divide a imagem em *patches* (blocos), utiliza codificação posicional e mecanismos de *self-attention* para capturar relações locais e dependências globais. Segundo os resultados apresentados, o modelo atingiu 98,00% de acurácia, 98,30% de precisão, 97,80% de *recall* e 98,00% de F1-score.

Outro aspecto recorrente é o impacto do desbalanceamento entre classes. Em [8], os autores mostram que o uso de *data augmentation* melhorou o desempenho de classificadores profundos no HAM10000, com o RegNetY-320 alcançando 91,00% de acurácia, 88,10% de F1-score e ROC de 0,95 após balanceamento artificial.

Em conjunto, esses estudos indicam que o bom desempenho na classificação de lesões cutâneas depende da preservação de informações espaciais, da extração de padrões hierárquicos e do tratamento do desbalanceamento. Isso contrasta com a MLP, na qual a imagem é achatada em um vetor unidimensional, reduzindo a capacidade de explorar sua organização espacial. Assim, este trabalho adota a MLP como linha de base experimental para evidenciar suas limitações estruturais na classificação multiclasse de imagens dermatoscópicas.

III. Metodologia

A. Base de dados

Neste trabalho, foi utilizado o *dataset* HAM10000, amplamente empregado em pesquisas sobre classificação automática de lesões cutâneas [2]. Esse conjunto de dados é composto por $N = 10015$ imagens dermatoscópicas de lesões pigmentadas distribuídas em $K = 7$ classes diagnósticas: melanoma (MEL - 1.113 imagens), nevos melanocíticos (NV - 6.705 imagens), carcinoma basocelular (BCC - 514 imagens) queratose benigna (BKL - 1.099 imagens), queratose actínica (AKIEC - 327 imagens), dermatofibroma (DF - 115 imagens) e lesão vascular (VASC - 142 imagens).

Seja $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^{N}$ o conjunto de dados, onde $\mathbf{x}_i \in \mathbb{R}^{h \times w \times c}$ representa a i-ésima imagem RGB com altura h, largura w e $c = 3$ canais de cor, e $y_i \in \mathcal{Y} = \{0, 1, 2, 3, 4, 5, 6\}$ representa a classe diagnóstica correspondente. O objetivo é aprender uma função $f : \mathbb{R}^d \to \Delta^{K-1}$ que mapeia imagens para uma distribuição de probabilidade sobre as K classes, onde Δ^{K-1} denota o simplex de probabilidade $(K-1)$-dimensional.

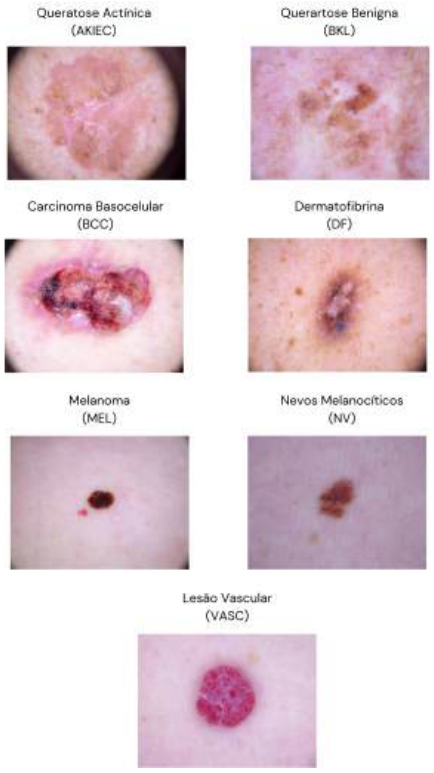


Figura 1. Exemplos ilustrativos de imagens do dataset HAM10000, com uma amostra para cada classe diagnóstica.

A utilização desse *dataset* é adequada ao problema abordado, uma vez que contempla um cenário de classificação multiclasse em imagens médicas reais. No entanto, trata-se de uma base fortemente desbalanceada [8], com predominância da classe NV (aproximadamente 67% do dataset), o que torna mais complexo o processo de treinamento e avaliação dos modelos. A Fig. 1 apresenta um exemplo ilustrativo de imagem para cada uma das sete classes presentes no HAM10000.

Observa-se que as categorias exibem diferenças visuais relacionadas à coloração, textura, formato e delimitação das bordas, embora algumas delas também apresentem semelhanças relevantes. Essa variabilidade contribui para a complexidade do problema e reforça a necessidade de modelos capazes de explorar adequadamente a estrutura espacial das imagens.

B. Pré-processamento dos dados

Trata-se de um problema de classificação multiclasse supervisionada [9] [10] [11]. Seja $\mathbf{X} \in \mathbb{R}^{N \times h \times w \times c}$ o tensor completo de imagens originais. O *pipeline* de pré-processamento consiste em uma sequência de transformações $\mathcal{T} = T_4 \circ T_3 \circ T_2 \circ T_1$, onde:

Redimensionamento (T_1): Cada imagem $\mathbf{x}_i$ de tamanho arbitrário é redimensionada para dimensões fixas $h' = w' = 64$ pixels, resultando em $\mathbf{x}'_i \in \mathbb{R}^{64\times64\times3}$. Esta operação garante uniformidade dimensional e reduz o custo computacional.

Normalização (T_2): Os valores de intensidade dos pixels são normalizados para o intervalo $[0, 1]$ por meio da transformação $\mathbf{x}''_i = \mathbf{x}'_i/255.0$, onde a divisão é aplicada elemento a elemento.

Achatamento (T_3): A imagem tridimensional $\mathbf{x}''_i \in \mathbb{R}^{64\times64\times3}$ é achatada (*flatten*) em um vetor unidimensional $\mathbf{v}_i \in \mathbb{R}^d$, onde $d = 64 \times 64 \times 3 = 12288$. Formalmente:

$$\mathbf{v}_i = \textit{flatten}(\mathbf{x}''_i) \in \mathbb{R}^{12288} \tag{1}$$

Padronização (T_4): Aplicou-se o *StandardScaler* para centralizar e escalar os dados. Para cada dimensão $j \in \{1, \ldots, d\}$, a transformação é dada por:

$$z_{ij} = \frac{v_{ij} - \mu_j}{\sigma_j} \tag{2}$$

onde $\mu_j = \frac{1}{N_{\text{train}}} \sum_{i\in\mathcal{D}_{\text{train}}} v_{ij}$ e $\sigma_j = \sqrt{\frac{1}{N_{\text{train}}} \sum_{i\in\mathcal{D}_{\text{train}}} (v_{ij} - \mu_j)^2}$ são a média e o desvio padrão calculados apenas sobre o conjunto de treinamento.

A divisão entre os conjuntos de treino e teste foi realizada na proporção de 80% para treino ($|\mathcal{D}_{\text{train}}| = 8012$) e 20% para teste ($|\mathcal{D}_{\text{test}}| = 2003$), com *random state* fixado em 42 e estratificação pelas classes, preservando a distribuição original do problema em ambas as partições.

Embora esse fluxo permita o treinamento de uma MLP convencional, ele também introduz uma limitação importante: o achatamento da imagem elimina as relações de vizinhança entre pixels, convertendo padrões bidimensionais em sequências lineares de atributos. Em arquiteturas mais adequadas à análise de imagens, como as redes neurais convolucionais (CNNs), essa organização espacial é preservada e explorada diretamente por filtros convolucionais. Já na MLP, tais relações precisam ser inferidas de forma indireta, o que tende a comprometer a eficiência da representação.

C. Arquitetura da rede

A arquitetura adotada neste estudo foi um *Perceptron* Multicamadas totalmente conectado (*fully-connected feedforward neural network*) [7] composto por $L = 4$ camadas sequenciais. A topologia pode ser expressa formalmente como:

$$\mathbb{R}^{12288} \xrightarrow{\text{Dense}(128)} \mathbb{R}^{128} \xrightarrow{\text{Dense}(64)} \mathbb{R}^{64} \xrightarrow{\text{Dense}(7)} \mathbb{R}^{7} \tag{3}$$

onde a camada de entrada recebe vetores $\mathbf{z} \in \mathbb{R}^{12288}$, a primeira camada oculta possui $n_1 = 128$ neurônios com ativação ReLU, a segunda camada oculta contém $n_2 = 64$ neurônios com ativação ReLU, e a camada de saída apresenta $n_{\text{out}} = 7$ neurônios com ativação *Softmax* para as $K = 7$ classes diagnósticas.

Para uma camada arbitrária $l \in \{1, 2, 3\}$, a saída $\mathbf{h}^{(l)}$ é computada por:

$$\mathbf{h}^{(l)} = f^{(l)}\left(\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}\right) \tag{4}$$

onde $\mathbf{W}^{(l)} \in \mathbb{R}^{n_l\times n_{l-1}}$ é a matriz de pesos, $\mathbf{b}^{(l)} \in \mathbb{R}^{n_l}$ é o vetor de viés, $f^{(l)}$ é a função de ativação da camada l, e $\mathbf{h}^{(0)} = \mathbf{z}$ representa o vetor de entrada.

Nas camadas ocultas ($l = 1, 2$), utiliza-se a função ReLU (*Rectified Linear Unit*):

$$f_{\text{ReLU}}(x) = \max(0, x) = \begin{cases} x, & \text{se } x > 0 \\ 0, & \text{caso contrário} \end{cases} \tag{5}$$

Na camada de saída ($l = 3$), aplica-se a função *Softmax* para converter os *logits* em uma distribuição de probabilidade:

$$P(y = k|\mathbf{z}) = \sigma_k(\mathbf{h}^{(3)}) = \frac{e^{h_k^{(3)}}}{\sum_{j=1}^{K} e^{h_j^{(3)}}}, \quad k \in \{1, \ldots, 7\} \tag{6}$$

com $\sum_{k=1}^{K} P(y = k|\mathbf{z}) = 1$.

A função objetivo utilizada foi a entropia cruzada categórica (*categorical cross-entropy*), apropriada para classificação multiclasse:

$$\mathcal{L}(\theta) = -\frac{1}{|\mathcal{B}|} \sum_{i\in\mathcal{B}} \sum_{k=1}^{K} y_{ik} \log P(y = k|\mathbf{z}_i; \theta) \tag{7}$$

onde $\mathcal{B}$ denota um *mini-batch* de treinamento, $y_{ik} \in \{0, 1\}$ é a codificação *one-hot* da classe verdadeira, e $\theta = \{\mathbf{W}^{(l)}, \mathbf{b}^{(l)}\}_{l=1}^{3}$ representa o conjunto completo de parâmetros treináveis.

O processo de otimização foi realizado com o algoritmo Adam (*Adaptive Moment Estimation*), que utiliza estimativas dos momentos de primeira e segunda ordem dos gradientes, combinadas com taxas de aprendizado adaptativas. Além disso, foram utilizados pesos de classe balanceados w_k, calculados inversamente proporcionais à frequência de cada classe k no conjunto de treinamento:

$$w_k = \frac{N_{\text{train}}}{K \cdot n_k} \tag{8}$$

onde n_k é o número de amostras da classe k em $\mathcal{D}_{\text{train}}$. Esta estratégia visa reduzir os efeitos do desbalanceamento do *dataset* durante o treinamento.

De forma geral, uma rede *feedforward* pode ser representada por $\mathbf{y} = f(\mathbf{x}; \theta)$, onde $\mathbf{x}$ representa o vetor de entrada, θ representa o conjunto de parâmetros ajustáveis da rede, e $\mathbf{y}$ corresponde à saída produzida pelo modelo. Redes do tipo *Multilayer Perceptron* são capazes de modelar relações não lineares por meio da combinação de camadas ocultas, funções de ativação e retropropagação do erro [6]. Entretanto, sua eficácia depende fortemente da natureza dos atributos de entrada e da preservação de informações espaciais relevantes.

D. Configuração experimental e métricas de avaliação

Foram avaliadas sete configurações experimentais, com variação sistemática da taxa de aprendizado α e da quantidade de neurônios nas camadas ocultas (n_1, n_2), a fim de analisar

o comportamento da MLP sob diferentes ajustes de hiperparâmetros. O espaço explorado foi:

$$\begin{gathered}\alpha \in \{0.0001, 0.001, 0.01\}, \\ (n_1, n_2) \in \{(64, 32), (64, 64), (128, 64), \\ (256, 32), (256, 64)\}\end{gathered} \tag{9}$$

Em todos os experimentos, foram mantidos fixos os seguintes hiperparâmetros: número de épocas $E = 50$, tamanho do *mini-batch* $|\mathcal{B}| = 32$, *validation split* de 20% sobre o conjunto de treino, parâmetros do otimizador Adam ($\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 10^{-7}$), e função de perda *categorical cross-entropy* com pesos de classe balanceados. A Tabela I apresenta o resumo das configurações testadas e das métricas ponderadas obtidas. Após essa etapa inicial, foi realizado um experimento adicional com balanceamento do conjunto de treinamento por meio de SMOTE, utilizando a configuração de referência com taxa de aprendizado $\alpha = 0.0001$ e arquitetura $(128, 64)$, sem uso adicional de pesos de classe, a fim de avaliar isoladamente o impacto do balanceamento sintético no desempenho do modelo.

Para a avaliação de desempenho, foram consideradas as métricas de acurácia, precisão ponderada, *recall* ponderado e F1-score ponderado. Para um problema de classificação multiclasse com K classes, seja $C \in \mathbb{N}^{K \times K}$ a matriz de confusão, onde C_{ij} representa o número de amostras da classe verdadeira i classificadas como classe j.

As métricas ponderadas são calculadas levando em consideração o suporte de cada classe no conjunto de teste. Seja n_k o número de amostras pertencentes à classe k em D_{test}, com $|D_{test}| = \sum_{k=1}^{K} n_k$. A acurácia global é definida como a proporção de previsões corretas.

A adoção de métricas ponderadas mostra-se apropriada neste contexto, pois considera a contribuição de cada classe de acordo com sua frequência no conjunto de teste. Em problemas desbalanceados como o HAM10000, a acurácia isoladamente pode ser insuficiente para caracterizar o desempenho do modelo, tornando relevante a análise conjunta de métricas que incorporem a distribuição real das classes na avaliação final.

E. Balanceamento com SMOTE

Após a etapa inicial de estudo de casos, foi realizado um experimento adicional de balanceamento do conjunto de treinamento por meio da técnica SMOTE (*Synthetic Minority Over-sampling Technique*). Essa etapa teve como objetivo investigar se a geração sintética de amostras para as classes minoritárias poderia reduzir os efeitos do desbalanceamento do dataset HAM10000 e melhorar o desempenho global da MLP [9].

Esse procedimento foi aplicado após a divisão estratificada entre treino e teste, preservando o conjunto de teste original para avaliação final. Após as etapas de redimensionamento, normalização, achatamento das imagens e padronização dos atributos, foi utilizado SMOTE exclusivamente sobre o conjunto de treinamento, como essa técnica atua em espaço vetorial, sua aplicação ocorreu sobre os vetores padronizados obtidos a partir das imagens achatadas.

Para essa etapa, foi adotado como configuração de referência a arquitetura com taxa de aprendizado de 0,0001 e duas camadas ocultas com 128 e 64 neurônios, por ter apresentado o melhor equilíbrio entre as métricas ponderadas na fase inicial de testes. Após o balanceamento, os rótulos foram novamente convertidos para o formato *one-hot*, e o modelo foi treinado com os mesmos hiperparâmetros gerais já definidos anteriormente, porém sem o uso adicional de pesos de classe, a fim de isolar o balanceamento sintético sobre o processo de aprendizagem.

IV. Resultados e Simulações

A análise dos resultados mostra que a MLP foi sensível às alterações de hiperparâmetros, especialmente à taxa de aprendizado (*learning rate*). Na etapa inicial, considerando os sete casos sem balanceamento sintético, o melhor equilibrio entre as métricas ponderadas ocorreu no caso C2, com taxa de aprendizado $\alpha = 0.0001$ e configuração topológica $(n_1, n_2) = (128, 64)$, atingindo acurácia de Acc $= 0.6944$ e F1-score ponderado de $\text{F1}_{\text{ponderado}} = 0.6953$. Contudo, após a etapa adicional de balanceamento do conjunto de treinamento com SMOTE, o melhor desempenho global do estudo ocorreu no caso 8, que manteve a mesma configuração arquitetural e alcançou acurácia de Acc $= 0.7084$ e F1-score ponderado de $\text{F1}_{\text{ponderado}} = 0.7032$. Esses valores indicam que a rede conseguiu aprender parte dos padrões discriminativos do problema e que o balanceamento sintético contribuiu positivamente para o desempenho global, embora os resultados ainda permaneçam distantes do desempenho observado em arquiteturas específicas para visão computacional.

O caso C3 foi o pior cenário experimental. Com taxa de aprendizado $\alpha = 0.01$, excessivamente alta para a escala do problema, a rede praticamente colapsou, alcançando apenas Acc $= 0.0124$ (acurácia de 1.24%) e F1-score ponderado de 0.0022. Esse comportamento indica instabilidade severa no processo de otimização, sugerindo que a magnitude dos gradientes causou oscilações excessivas nos parâmetros durante a descida de gradiente, impedindo convergência adequada para um mínimo local razoável.

Entre as configurações com taxa de aprendizado fixa em $\alpha = 0.0001$ (casos C2, C4, C5, C6 e C7), observou-se que o aumento do número de neurônios não resultou em melhoria consistente. Embora o caso C6, com arquitetura $(256, 32)$, tenha apresentado acurácia ligeiramente superior à do caso C2 (0.6984 contra 0.6944), suas métricas de precisão ponderada e F1-score ponderado foram inferiores. Já o caso C7, com arquitetura $(256, 64)$, também não superou o desempenho global do C2. Esses resultados indicam que ampliar a capacidade paramétrica da MLP não é suficiente para superar suas limitações em imagens, pois a arquitetura não preserva explicitamente relações espaciais locais nem explora padrões hierárquicos como ocorre em redes convolucionais.

A etapa adicional com balanceamento por SMOTE mostrou, entretanto, que o tratamento do desbalanceamento pode gerar ganhos relevantes quando combinado à configuração de referência escolhida. Mantida a arquitetura $(128 - 64)$ e taxa

Tabela I
CONFIGURAÇÕES TESTADAS E MÉTRICAS PONDERADAS OBTIDAS

Caso	Taxa de aprendizado	Oculta 1	Oculta 2	Acurácia	Precisão ponderada	*Recall* ponderado	F1-score ponderado
C1	0,0010	128	64	0,5501	0,7233	0,5501	0,5968
C2	0,0001	128	64	0,6944	0,6970	0,6944	0,6953
C3	0,0100	128	64	0,0124	0,1114	0,0124	0,0022
C4	0,0001	64	64	0,6834	0,6889	0,6834	0,6859
C5	0,0001	64	32	0,6585	0,6852	0,6585	0,6700
C6	0,0001	256	32	0,6984	0,6901	0,6984	0,6940
C7	0,0001	256	64	0,6894	0,6949	0,6894	0,6916
C8 (SMOTE)	0,0001	128	64	0,7084	0,7009	0,7084	0,7032

Tabela II
DESEMPENHO POR CLASSE NO MELHOR CASO EXPERIMENTAL (C8)

Classe	Precisão	*Recall*	F1-score	Suporte
MEL	0,36	0,39	0,37	223
NV	0,84	0,87	0,85	1341
BCC	0,48	0,43	0,45	103
AKIEC	0,48	0,35	0,41	65
BKL	0,45	0,42	0,43	220
DF	0,38	0,26	0,31	23
VASC	0,57	0,29	0,38	28

de aprendizado $\alpha = 0.0001$, o caso C8 superou o caso C2 em todas as métricas globais ponderadas, elevando a acurácia de 0.6944 para 0.7084. Esse resultado sugere que a superamostragem sintética contribuiu para reduzir parcialmente os efeitos da predominância da classe majoritária no processo de treinamento.

A análise por classe do melhor caso experimental (caso 8, com SMOTE) também reforça essa interpretação. A classe NV obteve desempenho muito superior às demais, com precisão $P_{\text{NV}} = 0.84$ e *recall* $R_{\text{NV}} = 0.87$, resultando em F1-score de 0.85. Em contraste, classes menos representadas, como DF (F1 $= 0.31$, suporte de 23 amostras) e VASC (F1 $= 0.38$, suporte 28 amostras), apresentaram métricas significativamente menores. A classe BKL também permaneceu em patamar intermediário, com F1-score de 0.43 e suporte de 220 amostras.

Esse comportamento sugere que, mesmo com o balanceamento sintético do conjunto de treinamento, o modelo ainda foi influenciado pelo forte desbalanceamento do conjunto (NV representa $\approx 67\%$ dos dados) e pela dificuldade de separar categorias com aparência visual semelhante sem preservação de informação espacial. A Tabela II detalha as métricas por classe no melhor cenário experimental.

Outro aspecto relevante é o indício de *overfitting*. Nas configurações mais promissoras, as curvas de treinamento apresentaram crescimento acentuado da acurácia de treino, enquanto a acurácia de validação permaneceu em patamar consideravelmente inferior. Formalmente, observou-se uma divergência crescente entre o erro de treino $\mathcal{L}_{\text{train}}$ e o erro de validação $\mathcal{L}_{\text{val}}$ ao longo das épocas, com $\mathcal{L}_{\text{val}} - \mathcal{L}_{\text{train}} > \delta$ para algum limiar $\delta > 0$ significativo.

Em outras palavras, a rede passou a memorizar padrões específicos do conjunto de treino com mais facilidade do que generalizá-los para exemplos não vistos. Esse efeito é coerente com o uso de um vetor de entrada de alta dimensionalidade ($d = 12288$ atributos) em uma arquitetura totalmente conectada. Com 12288 parâmetros de entrada e duas camadas densas, o número total de parâmetros treináveis da configuração 128-64 é aproximadamente:

$$\begin{aligned} |\theta| &= (12288 \times 128 + 128) \\ &\quad + (128 \times 64 + 64) \\ &\quad + (64 \times 7 + 7) \\ &= 1{,}581{,}703 \text{ parâmetros} \end{aligned} \tag{10}$$

Com $|\mathcal{D}_{\text{train}}| = 8012$ amostras, a razão parâmetros/amostras é ≈ 197.5, indicando alta capacidade de memorização. Em comparação, arquiteturas convolucionais conseguem extrair representações mais compactas explorando compartilhamento de pesos e hierarquias espaciais, reduzindo essa razão significativamente.

Do ponto de vista conceitual e quantitativo, os resultados obtidos confirmam a hipótese proposta no início do artigo. A MLP pode funcionar como um classificador de base para o HAM10000, sobretudo quando se deseja enfatizar fundamentos de redes neurais artificiais. Contudo, quando o objetivo é maximizar desempenho em classificação de imagens, a arquitetura mostra limitações claras.

Em comparação quantitativa com os trabalhos da Seção II, o melhor resultado desta pesquisa ($\text{Acc}_{\text{C8}} = 70.84\%$, $\text{F1}_{\text{C8}} = 70.32\%$) apresentou as seguintes lacunas de desempenho (*performance gaps*): em relação ao *Deep Skin* [5], observa-se $\Delta_{\text{Acc}} = 91.2\% - 70.84\% = 20.36$ pontos percentuais e $\Delta_{\text{F1}} = 91.7\% - 70.32\% = 21.38$ p.p.; em relação ao *Vision Transformer* [6], tem-se $\Delta_{\text{Acc}} = 98.0\% - 70.84\% = 27.16$ p.p. e $\Delta_{\text{F1}} = 98.0\% - 70.32\% = 27.68$ p.p.; e em relação ao *Pipeline* Híbrido [1], obtém-se $\Delta_{\text{Acc}} = 98.76\% - 70.84\% = 27.92$ p.p. e $\Delta_{\text{F1}} = 95.32\% - 70.32\% = 25.00$ p.p.

Essas diferenças sustentam a afirmação de que a MLP não é a arquitetura ideal para esse problema. Os modelos de melhor desempenho exploram informação espacial por

meio de convoluções, mecanismos de atenção ou *pipelines* de extração de características, recursos ausentes na MLP padrão.

Além das limitações da própria arquitetura, este estudo apresenta restrições metodológicas que devem ser consideradas na interpretação dos resultados. Não foram aplicadas técnicas de *data augmentation*, as quais poderiam ampliar artificialmente o conjunto de treinamento e melhorar a generalização. Também não foram realizadas etapas específicas de remoção de artefatos visuais, como pelos, bolhas ou marcações médicas, nem procedimentos de segmentação da lesão para isolamento da região de interesse ou extração prévia de características, como textura, bordas e descritores de cor. Tais estratégias são frequentemente empregadas em trabalhos de maior desempenho na classificação de lesões cutâneas.

Outra limitação metodológica refere-se à ausência de validação cruzada *k-fold*, o que impede estimar a variabilidade do desempenho da MLP em diferentes partições de dados. Ainda assim, a divisão estratificada entre treino e teste, associada ao *validation split* interno, permitiu uma análise inicial controlada do comportamento da arquitetura. Além disso, este estudo não incluiu um experimento próprio com redes neurais convolucionais. Assim, a comparação com CNNs foi realizada apenas a partir da literatura, e não por meio de um modelo treinado e avaliado nas mesmas condições da MLP. Essa comparação direta está sendo desenvolvida como continuidade da pesquisa e será incorporada em trabalhos futuros.

Dessa forma, os resultados devem ser interpretados como uma avaliação exploratória da MLP enquanto linha de base para classificação multiclasse no HAM10000. O objetivo principal não foi obter o melhor desempenho possível para o conjunto de dados, mas demonstrar as limitações estruturais de uma arquitetura totalmente conectada quando aplicada diretamente a imagens achatadas em vetores unidimensionais, reforçando a importância de modelos capazes de preservar relações espaciais, como as redes neurais convolucionais.

V. Conclusões

Este trabalho apresentou a aplicação de uma rede neural *Perceptron* Multicamadas para classificação multiclasse de câncer de pele no *dataset* HAM10000, com o objetivo de estabelecer uma linha de base experimental e demonstrar empiricamente as limitações estruturais da arquitetura para processamento de imagens. O experimento mostrou que a MLP consegue aprender padrões relevantes e produzir uma linha de base funcional, especialmente quando configurada com taxa de aprendizado baixa ($\alpha = 0.0001$) e número moderado de neurônios nas camadas ocultas (configuração 128-64). Após a etapa inicial de testes, a aplicação do balanceamento do conjunto de treinamento por meio de SMOTE permitiu obter o melhor desempenho global do estudo, com acurácia de 70.84% e F1-score ponderado de 70.32%.

Entretanto, os resultados também evidenciaram as limitações fundamentais do modelo. O achatamento da imagem em vetores unidimensionais elimina relações espaciais essenciais entre pixels adjacentes, o forte desbalanceamento das classes continua impactando o desempenho nas classes minoritárias (apesar do uso de pesos balanceados), e o *overfitting* surge com facilidade devido ao elevado número de parâmetros (≈ 1.58 milhões) em relação ao tamanho do conjunto de treinamento. Embora o uso de SMOTE tenha contribuído para melhorar as métricas globais ponderadas, essa estratégia não foi suficiente para superar a principal limitação da MLP: a incapacidade de explorar explicitamente a organização espacial das imagens.

Como trabalhos futuros, pretende-se dar continuidade à pesquisa com a avaliação de arquiteturas convolucionais sob protocolo experimental equivalente, incorporando técnicas de *data augmentation*, regularização, validação cruzada *k-fold* e comparação entre diferentes estratégias de tratamento do desbalanceamento. Essa etapa permitirá comparar de forma mais robusta o desempenho da MLP com modelos que preservam a estrutura espacial das imagens dermatoscópicas.

Uso de Inteligência Artificial

Em conformidade com as diretrizes de integridade científica e boas práticas acadêmicas recomendadas pela CAPES, os autores declaram que utilizaram ferramentas de inteligência artificial, incluindo ChatGPT, exclusivamente para auxiliar na melhoria da linguagem e legibilidade deste manuscrito. O uso dessas ferramentas foi realizado sob supervisão humana, e os autores revisaram e editaram cuidadosamente o conteúdo, assumindo total responsabilidade pelo texto final publicado.

Referências

[1] E. Gomathi, M. Jayasheela, M. Thamarai, and M. Geetha, "Skin Cancer Detection Using Dual Optimization Based Deep Learning Network," *Biomedical Signal Processing and Control*, vol. 84, art. no. 104968, 2023, doi: 10.1016/j.bspc.2023.104968.

[2] P. Tschandl, C. Rosendahl, and H. Kittler, "The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions," *Scientific Data*, vol. 5, art. no. 180161, 2018.

[3] M. Azeem, K. Kiani, T. Mansouri and N. Topping, "SkinLesNet: Classification of Skin Lesions and Detection of Melanoma Cancer Using a Novel Multi-Layer Deep Convolutional Neural Network," *Cancers*, vol. 16, no. 1, art. no. 108, 2024.

[4] A. Kamboj, "A color-based approach for melanoma skin cancer detection," in *Proc. 2018 First Int. Conf. on Secure Cyber Computing and Communication (ICSCCC)*, IEEE, 2018, pp. 508–513, doi: 10.1109/ICSCCC.2018.8703309.

[5] H. L. Gururaj, N. Manju, A. Nagarjun, V. N. M. Aradhya, and F. Flammini, "Deep Skin: A Deep Learning Approach for Skin Cancer Classification," *IEEE Access*, vol. 11, pp. 50205–50214, 2023, doi: 10.1109/ACCESS.2023.3274848.

[6] K. Naveen and M. H. Khanam, "Leveraging Vision Transformers for Automated Skin Lesion Diagnosis: A Case Study on Skin Cancer MNIST: HAM10000," in *Proc. 2025 IEEE Int. Conf. on Advanced Computing Technologies (ICACT)*, 2025, doi: 10.1109/ICACT67549.2025.11351464.

[7] R. C. Rego, "Redes Neurais Artificiais Feedforward," material da disciplina de Redes Neurais Artificiais, UFERSA, 2026. [Online]. Available: https://roscibely.github.io/lectures/neuralnetwork/main.html

[8] T. M. Alam, K. Shaukat, W. A. Khan, I. A. Hameed, L. A. Almuqren, M. A. Raza, M. Aslam, and S. Luo, "An Efficient Deep Learning-Based Skin Cancer Classifier for an Imbalanced Dataset," *Diagnostics*, vol. 12, no. 9, art. no. 2115, 2022, doi: 10.3390/diagnostics12092115.

[9] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "SMOTE: Synthetic Minority Over-sampling Technique," *Journal of Artificial Intelligence Research*, vol. 16, pp. 321–357, 2002.

[10] M. Harrison, *Machine Learning – Guia de Referência Rápida: Trabalhando com Dados Estruturados em Python*. São Paulo: Novatec Editora, 2019.

[11] S. Haykin, *Neural Networks and Learning Machines*, 3rd ed. Upper Saddle River, NJ, USA: Prentice Hall, 2009.

Classificação de Níveis de Obesidade através de Redes Neurais Multicamadas: Uma Abordagem Baseada em Hábitos de Vida e Dados Antropométricos

1º Miqueias Nilton de Araujo
Curso de Engenharia de Computação
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
miqueias.araujo@alunos.ufersa.edu.br

2º Rosana C. B. Rego
Departamento de Engenharias e Tecnologia
Universidade Federal Rural do Semi-Árido (UFERSA)
Rio Grande do Norte, Brasil
rosana.rego@ufersa.edu.br

***Abstract*—Obesity and the risk of cardiovascular disease represent growing challenges for global public health. Preventive diagnosis and accurate classification of risk levels are fundamental for effective medical interventions. This study presents an artificial intelligence-based approach, using a multilayer perceptron neural network to classify the obesity level of individuals based on their eating habits and physical condition. The proposed model, structured with dense layers, ReLU activation function, dropout regularization, and Adam optimizer, achieved an overall accuracy of 94% on the test data with consistent generalization. Metric analysis demonstrated remarkable robustness, achieving an F1-Score of 1.00 for the Grade III Obesity class, with zero false negatives in the highest risk category.**

***Index Terms*—Artificial Intelligence, Artificial Neural Networks, Multilayer Perceptron, Obesity, Public Health, Decision Support Systems.**

I. Introdução

A transição nutricional global resultou em um aumento alarmante da prevalência da obesidade, fator de risco central para patologias como diabetes mellitus e apneia do sono [10] [12]. A complexidade dos fatores que determinam o índice de massa corporal, incluindo genética, comportamento alimentar e atividade física, torna a classificação manual uma tarefa suscetível a erros [12] [15]. A prevalência global da obesidade mais do que dobrou nas últimas quatro décadas, e hoje afeta mais de um bilhão de pessoas em todo o mundo. Reconhecida como uma condição ligada a muitas doenças crônicas, a obesidade impacta diretamente na qualidade de vida e na redução da expectativa de vida [16].

Em 2021, a prevalência global da doença cardiovascular (DCV) atingiu 612 milhões de pessoas, representando 26,8% de todas as mortes mundiais, com um crescimento de 0,88% ao longo das últimas três décadas [14]. Notavelmente, 79,5% de todos os anos de vida saudável perdidos ajustados às incapacidades foram atribuídos a 11 fatores de risco, sendo o índice de massa corporal (IMC) o que apresentou a maior associação [14]. Não obstante, estudos de prevalência mostram que dois terços das mortes relacionadas à obesidade são atribuíveis à DCV [6], [14]. Particularmente no Brasil, dados de 2025 sugerem que 68% dos adultos possuem IMC $\geq$ 25 kg/m², e que 31% dessa população esteja vivendo com a obesidade. Em 2021, houve 60.913 mortes prematuras associadas ao IMC elevado no país [16].

A obesidade também é um dos principais determinantes da DCV. Estudos epidemiológicos prospectivos demonstram que a obesidade está associada a um risco elevado de eventos de doença arterial coronariana (DAC) e de mortalidade cardiovascular (CV) [9]. Sua influência ocorre de forma indireta, por meio do aumento de fatores de risco CV tradicionais como diabetes tipo 2 (DM2), dislipidemia (DLP) e hipertensão arterial sistêmica (HAS), mas também por efeito direto do estado inflamatório induzido pela adiposidade na estrutura e função cardíacas [2], [3].

Historicamente, a abordagem terapêutica para a obesidade tem se centrado em intervenções relacionadas ao estilo de vida e opções farmacológicas com eficácia limitada. Contudo, a introdução da nova geração de medicações antiobesidade possibilitou a obtenção de perdas de peso mais significativas e sustentáveis. Ademais, com a complexidade crescente das opções terapêuticas disponíveis e os benefícios observados em desfechos ligados à síndrome cardiorrenal metabólica; tornou-se evidente a necessidade de novas ferramentas de estratificação que orientem a seleção do tratamento para cada situação clínica [4], [5].

Este artigo apresenta a aplicação de uma rede neural para a classificação de níveis de obesidade, detalhando as etapas de engenharia de atributos e a análise de desempenho por meio de matrizes de confusão e métricas de precisão e revocação.

II. Levantamento Bibliográfico

Com a disseminação da Internet, as tecnologias da informação e comunicação (TICs) impulsionaram o avanço de produtos e serviços, sobretudo aqueles que funcionam de forma integrada. No setor da saúde, isso se refletiu em serviços mais eficientes e aprimorados, conforme destacado

por Rocha et al. (2016) [11]. Essa área de estudo é conhecida como mobileHealth (ou mHealth), sendo que a World Health Organization (WHO, 2011) a definiu como "as práticas médicas e de saúde pública suportadas por dispositivos móveis, como telefones celulares, dispositivos de monitoramento de pacientes, assistentes digitais e outros dispositivos sem fio". Syed et al. (2019) [13] indicam que a Internet das Coisas Médicas, ou Internet of Medical Things (IoMT), representa uma inovação significativa na indústria da saúde, pois tem a capacidade de conectar profissionais de saúde, cuidadores, pacientes, dados e sistemas, visando oferecer serviços de saúde mais inteligentes. Cada vez mais, métodos de inteligência artificial estão sendo explorados e implementados no âmbito da saúde. Olivera et al. (2017) [7] aplicaram algoritmos de aprendizado de máquina para identificar diabetes não diagnosticada. Bejnordi et al. (2017) [1] demonstraram que algoritmos podem interpretar imagens de câncer de mama, alcançando desempenhos comparáveis aos de profissionais humanos na análise.

Safaei et al. (2021) [12] publicaram uma revisão de literatura bastante completa, citando as causas e consequências da obesidade e ainda fizeram um levantamento entre vários estudos, sobre as técnicas de machine learning (ML) para a predição da obesidade. Dentre os artigos analisados, Multilayer Perceptron Feed Forward Artificial Neural Networks (MLFFNN), K-Nearest Neighbors (K-NN) e Support Vector Machines (SVM) foram os algoritmos mais utilizados, sendo o MLFFNN o que apresentou melhores resultados. Este trabalho mostrou que as causas são diversas, e incluem fatores que, normalmente, não são analisados, como por exemplo, a situação socioeconômica, fatores demográficos ou fatores psicológicos.

Rezende et al. (2021) [10] publicaram um artigo mostrando como o excesso de peso e a obesidade estão diretamente relacionadas com o aumento das Doenças Crônicas não Transmissíveis (DCNT) e os impactos gerados no Sistema Único de Saúde (SUS). Em 2019, 56,1% das mortes causadas por estas doenças foram em adultos de 30 a 69 anos, sendo consideradas mortes prematuras. Ainda neste estudo, dados apontam que em 2030, 68% da população brasileira estará acima do peso e destacam como a obesidade necessita de um olhar crítico e que políticas públicas precisam ser criadas para combater essa epidemia. Não basta acreditar que somente fatores individuais, como a genética, são os responsáveis por esse aumento. Citam ainda o crescimento acelerado de pessoas acima do peso nos EUA após a década de 70 e listam as mudanças nas leis agrícolas no país, o marketing acelerado, a disponibilidade e acesso a alimentos com alto teor calórico, e a introdução no sistema alimentar de adoçantes como xarope de milho e com alto teor de frutose como fatores que alteraram o padrão alimentar de toda a população. Além da preocupação com a saúde da população, os gastos com internações ou complicações médicas decorrentes do sobrepeso são alarmantes. Em 2019, houve um gasto de 6,8 bilhões de reais com as DCNTs somente no Brasil, sendo que 22% desse valor foi por fatores de sobrepeso e obesidade, de acordo com a pesquisa de Rezende. Assim sendo, se for possível fazer um levantamento da porcentagem da população que está em risco de ficar obesa, e consequentemente, desenvolver as DCNTs, ações mais eficazes poderão ser tomadas.

III. Modelo de Rede Neural Proposto

A. Detalhamento do Problema

A obesidade e o sobrepeso são fatores de risco primários para o desenvolvimento de Doenças Cardiovasculares (DCV), diabetes e outras síndromes metabólicas. O diagnóstico clínico tradicional baseia-se frequentemente apenas no Índice de Massa Corporal (IMC), que pode ser redutivo por não considerar a complexidade dos hábitos de vida do paciente.

Do ponto de vista computacional, o problema formula-se como uma tarefa de classificação supervisionada multiclasse. Seja $\mathcal{D} = \{(\mathbf{x}_i, y_i)\}_{i=1}^{N}$ o conjunto de dados com $N = 2111$ amostras, onde $\mathbf{x}_i \in \mathbb{R}^d$ é o vetor de características de entrada, com $d = 17$ atributos iniciais (após pré-processamento, a dimensionalidade aumenta para $d' = 26$ devido à codificação one-hot), e $y_i \in \mathcal{Y} = \{0, 1, 2, 3, 4, 5, 6\}$ representa a classe alvo correspondente ao nível de obesidade.

O objetivo é aprender uma função $f : \mathbb{R}^{d'} \to \mathcal{Y}$ que minimize o erro de classificação esperado:

$$f^* = \arg\min_{f \in \mathcal{F}} \mathbb{E}_{(\mathbf{x},y)\sim\mathcal{D}}[\mathcal{L}(f(\mathbf{x}), y)] \tag{1}$$

onde $\mathcal{F}$ é o espaço de hipóteses (arquiteturas MLP) e $\mathcal{L}$ é a função de perda (entropia cruzada).

O desafio consiste em desenvolver um modelo capaz de capturar padrões não lineares complexos que mapeiem o vetor de características multidimensional $\mathbf{x}$ para a variável alvo y, mitigando erros de classificação, especialmente nas categorias de maior severidade.

B. Dados Utilizados

Os dados consistem na estimação dos níveis de obesidade em pessoas do México, Peru e Colômbia, com idades entre 14 e 61 anos e diversos hábitos alimentares e condições físicas. Os dados foram coletados por meio de uma plataforma online com um questionário onde usuários anônimos responderam a cada pergunta. As informações foram então processadas, obtendo-se 17 atributos e 2111 registros [8].

O conjunto de dados possui tamanho total de $N = 2111$ amostras, com dimensão inicial de $d = 17$ atributos (16 preditores e 1 variável alvo). Após o pré-processamento, a dimensionalidade aumenta para $d' = 26$ características devido à codificação one-hot encoding de variáveis categóricas. O problema envolve $K = 7$ classes distintas. A divisão dos dados seguiu a proporção padrão $\mathcal{D}_{\text{train}} \cup \mathcal{D}_{\text{test}} = \mathcal{D}$, com $|\mathcal{D}_{\text{train}}| = 0.8N = 1689$ amostras para treinamento e $|\mathcal{D}_{\text{test}}| = 0.2N = 422$ amostras para teste.

Os atributos estão estabelecidos nas seguintes categorias: Variáveis Antropométricas e Pessoais: Gênero, Idade, Altura, Peso e Histórico familiar de sobrepeso. Hábitos Alimentares: Consumo frequente de alimentos altamente calóricos (FAVC), Frequência de consumo de vegetais (FCVC), Número de refeições principais (NCP), Consumo de alimentos entre as

refeições (CAEC), Consumo diário de água (CH2O) e Monitoramento de calorias ingeridas (SCC). Hábitos de Estilo de Vida: Fumo (SMOKE), Frequência de atividade física (FAF), Tempo de uso de dispositivos tecnológicos (TUE), Consumo de álcool (CALC) e Meio de transporte principal (MTRANS). Variável Alvo (Target): NObeyesdad, dividida em 7 classes clínicas: Insufficient Weight (Abaixo do peso), Normal Weight (Peso normal), Overweight Level I (Sobrepeso Grau I), Overweight Level II (Sobrepeso Grau II), Obesity Type I (Obesidade Grau I), Obesity Type II (Obesidade Grau II), Obesity Type III (Obesidade Grau III) [8].

C. Pré-processamento dos Dados

O pipeline de pré-processamento estruturou-se em três etapas:

Codificação da Variável Alvo (Label Encoding): As sete categorias textuais da saída y foram mapeadas para um vetor de inteiros por meio de uma função bijetora $\phi : \mathcal{Y}_{\text{text}} \to \mathcal{Y} = \{0, 1, 2, 3, 4, 5, 6\}$:

$$\phi(\text{classe}) = \begin{cases} 0, & \text{Peso Insuficiente} \\ 1, & \text{Peso Normal} \\ 2, & \text{Sobrepeso Grau I} \\ 3, & \text{Sobrepeso Grau II} \\ 4, & \text{Obesidade Tipo I} \\ 5, & \text{Obesidade Tipo II} \\ 6, & \text{Obesidade Tipo III} \end{cases} \tag{2}$$

Transformação de Variáveis Categóricas (One-Hot Encoding): Atributos categóricos de entrada foram transformados em matrizes binárias ortogonais (ausentes de hierarquia). Uma variável categórica x_j com k categorias distintas $\{c_1, c_2, ..., c_k\}$ foi transformada em k variáveis binárias (dummy variables) $\{x_j^{(1)}, x_j^{(2)}, ..., x_j^{(k)}\}$, onde:

$$x_j^{(i)} = \begin{cases} 1, & \text{se } x_j = c_i \\ 0, & \text{caso contrário} \end{cases} \tag{3}$$

Padronização Estatística (Z-Score Normalization): Para evitar que atributos com grandes amplitudes dominem o processo de otimização, aplicou-se o método de escalonamento padrão (Standard Scaler). Seja $\mathbf{x}_j = (x_{1j}, x_{2j}, ..., x_{Nj})^T$ o vetor contendo todos os valores da característica j. A transformação Z-score é dada por:

$$z_{ij} = \frac{x_{ij} - \mu_j}{\sigma_j} \tag{4}$$

onde:

$$\mu_j = \frac{1}{N}\sum_{i=1}^{N} x_{ij}, \quad \sigma_j = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(x_{ij} - \mu_j)^2} \tag{5}$$

Após a transformação, cada característica numérica possui média $\mu = 0$ e desvio padrão $\sigma = 1$, garantindo que todas as features contribuam equitativamente para a atualização dos pesos durante o treinamento via gradiente descendente.

D. Formulação Matemática do Modelo

A arquitetura selecionada para resolver este problema foi um MLP do tipo Feedforward totalmente conectado. A topologia da rede é especificada formalmente como:

$$\begin{aligned} \mathbb{R}^{26} &\to \text{Dense}(64) \to \text{Dropout}(0.2) \\ &\to \text{Dense}(32) \to \text{Dropout}(0.2) \\ &\to \text{Dense}(7) \to \mathbb{R}^7. \end{aligned} \tag{6}$$

onde a camada de entrada recebe vetores $\mathbf{x} \in \mathbb{R}^{26}$, a primeira camada oculta possui 64 neurônios com ativação ReLU seguida de Dropout ($p = 0.2$), a segunda camada oculta contém 32 neurônios com ativação ReLU seguida de Dropout ($p = 0.2$), e a camada de saída apresenta 7 neurônios com ativação Softmax. O modelo possui um total de $(26 \times 64 + 64) + (64 \times 32 + 32) + (32 \times 7 + 7) = 3943$ parâmetros treináveis.

O mapeamento do vetor de entrada $\mathbf{x}$ para a predição de saída $\hat{\mathbf{y}}$ ocorre por meio de sucessivas transformações lineares seguidas de ativações não-lineares. Para uma camada oculta arbitrária l, a saída dos neurônios $\mathbf{h}^{(l)}$ é computada por:

$$\mathbf{h}^{(l)} = f\left(\mathbf{W}^{(l)}\mathbf{h}^{(l-1)} + \mathbf{b}^{(l)}\right) \tag{7}$$

Onde $\mathbf{W}^{(l)} \in \mathbb{R}^{n_l \times n_{l-1}}$ é a matriz de pesos que conecta a camada $l-1$ à camada l, $\mathbf{b}^{(l)} \in \mathbb{R}^{n_l}$ é o vetor de viés (bias), $f(\cdot)$ é a função de ativação não-linear, e $\mathbf{h}^{(0)} = \mathbf{x}$ representa a entrada da rede.

Nas duas camadas ocultas do modelo (com 64 e 32 neurônios), adotou-se a função ReLU (Rectified Linear Unit), que mitiga o problema do desvanecimento do gradiente e introduz esparsidade nas representações:

$$f_{\text{ReLU}}(x) = \max(0, x) = \begin{cases} x, & \text{se } x > 0 \\ 0, & \text{caso contrário} \end{cases} \tag{8}$$

Na camada de saída (com 7 neurônios, correspondentes às classes $\mathcal{Y} = \{0, 1, 2, 3, 4, 5, 6\}$), aplicou-se a função Softmax, que converte os valores brutos da rede ($\mathbf{z}$) em uma distribuição de probabilidade condicional para cada classe i:

$$P(y = i|\mathbf{x}) = \sigma_i(\mathbf{z}) = \frac{e^{z_i}}{\sum_{j=0}^{6} e^{z_j}}, \quad \text{com} \quad \sum_{i=0}^{6} P(y = i|\mathbf{x}) = 1 \tag{9}$$

O ajuste da matriz de pesos $\mathbf{W}$ foi realizado iterativamente pelo otimizador Adam (Adaptive Moment Estimation) [17], que combina momentão com taxa de aprendizado adaptativa. O algoritmo buscou minimizar o erro do modelo em relação aos dados reais. O erro foi quantificado matematicamente pela função de Entropia Cruzada Categórica Esparsa (Sparse Categorical Crossentropy):

$$\mathcal{L}(\theta) = -\frac{1}{|\mathcal{B}|}\sum_{n \in \mathcal{B}} \log P(y_n|\mathbf{x}_n; \theta) \tag{10}$$

Onde $\mathcal{B}$ é um mini-batch de treinamento, $|\mathcal{B}|$ é o tamanho do batch, e $\theta = \{\mathbf{W}^{(l)}, \mathbf{b}^{(l)}\}_{l=1}^{L}$ representa todos os parâmetros treináveis da rede.

Para prevenir overfitting e melhorar a capacidade de generalização, aplicou-se a técnica de Dropout com taxa $p = 0.2$ após cada camada oculta. Durante o treinamento, cada neurônio é desativado com probabilidade p:

$$\mathbf{h}_{\text{dropout}}^{(l)} = \mathbf{m} \odot \mathbf{h}^{(l)}, \quad \text{onde} \quad m_j \sim \text{Bernoulli}(1-p) \tag{11}$$

onde $\odot$ denota multiplicação elemento a elemento e $\mathbf{m}$ é uma máscara binária.

A configuração completa dos hiperparâmetros utilizados no treinamento incluiu o otimizador Adam com taxa de aprendizado inicial $\alpha = 0.001$ e parâmetros $\beta_1 = 0.9$, $\beta_2 = 0.999$, $\epsilon = 10^{-7}$. O treinamento utilizou mini-batches de tamanho $|\mathcal{B}| = 32$ amostras por um total de $E = 100$ épocas. A taxa de Dropout foi configurada em $p = 0.2$ para regularização, e os pesos foram inicializados usando o método Glorot Uniform. A função de perda empregada foi a Sparse Categorical Crossentropy, e a métrica de avaliação durante o treinamento foi a acurácia.

IV. Resultados e Simulações

A. Avaliação e Métricas de Desempenho

O modelo MLP desenvolvido foi avaliado utilizando um conjunto de dados de teste $\mathcal{D}_{\text{test}}$, correspondente a 20% da amostra original ($|\mathcal{D}_{\text{test}}| = 422$ amostras), garantindo que a rede fosse testada com instâncias não vistas durante o treinamento.

Para avaliar o desempenho do modelo, utilizaram-se as métricas padrão de classificação: precisão (precision), revocação (recall) e F1-Score. Para uma classe i, estas métricas são definidas como:

$$\text{Precisão}_i = \frac{TP_i}{TP_i + FP_i}, \quad \text{Revocação}_i = \frac{TP_i}{TP_i + FN_i} \tag{12}$$

$$\text{F1-Score}_i = 2 \cdot \frac{\text{Precisão}_i \times \text{Revocação}_i}{\text{Precisão}_i + \text{Revocação}_i} = \frac{2 \cdot TP_i}{2 \cdot TP_i + FP_i + FN} \tag{13}$$

onde TP_i (verdadeiros positivos), FP_i (falsos positivos) e FN_i (falsos negativos) são computados a partir da matriz de confusão.

A acurácia global do classificador foi:

$$\text{Acurácia} = \frac{1}{|\mathcal{D}_{\text{test}}|} \sum_{i=1}^{|\mathcal{D}_{\text{test}}|} \mathbb{1}[\hat{y}_i = y_i] = 0.94 \tag{14}$$

evidenciando a capacidade da arquitetura de mapear os hábitos de vida e dados antropométricos para o nível de risco adequado em 94% dos casos.

Para uma análise mais granular do comportamento do modelo em um cenário multiclasse, extraiu-se o Relatório de Classificação (Tabela 1), que detalha as métricas de Precisão, Revocação e F1-Score para cada categoria.

Tabela I
Relatório de Métricas por Classe

Classe de Risco	Precisão	Revocação	F1-Score
Peso Insuficiente	0.95	0.98	0.96
Peso Normal	0.92	0.89	0.90
Sobrepeso Grau I	0.86	0.89	0.88
Sobrepeso Grau II	0.94	0.92	0.93
Obesidade Tipo I	0.97	0.97	0.97
Obesidade Tipo II	0.98	0.97	0.97
Obesidade Tipo III	1.00	1.00	1.00

B. Análise dos Resultados via Matriz de Confusão

Gerou-se a Matriz de Confusão $\mathbf{C} \in \mathbb{N}^{7\times7}$, onde o elemento C_{ij} representa o número de instâncias da classe real i que foram classificadas como classe j. Formalmente:

$$C_{ij} = \sum_{k=1}^{|\mathcal{D}_{\text{test}}|} \mathbb{1}[y_k = i \wedge \hat{y}_k = j] \tag{15}$$

Os acertos correspondem à diagonal principal ($i = j$), enquanto os erros de classificação estão nos elementos fora da diagonal ($i \neq j$).

A Fig. 1 mostra a matriz de confusão obtida. Para a classe 6 de risco extremo (Obesidade Tipo III), o modelo atingiu uma precisão e revocação de $P_6 = R_6 = 1.00$, não registrando nenhum falso negativo ($FN_6 = 0$).

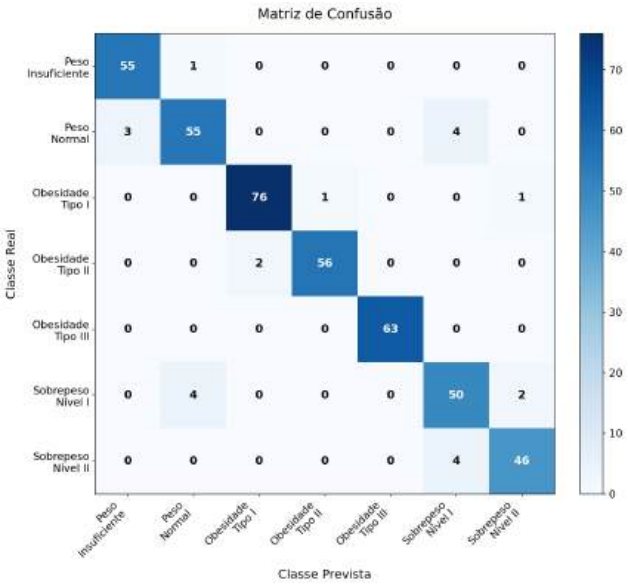


Fig. 1. Matriz de Confusão

Do ponto de vista clínico, a eliminação de falsos negativos nesta categoria é fundamental, pois garante que pacientes com necessidade de intervenção médica imediata não sejam subdiagnosticados. Um falso negativo nesta classe poderia resultar em ausência de tratamento adequado para indivíduos em alto risco cardiovascular.

Os desvios de predição (erros) concentraram-se majoritariamente entre classes adjacentes, particularmente na fronteira entre Peso Normal (classe 1) e Sobrepeso Grau I (classe 2). Esta sobreposição é compreensível dada a natureza contínua da biologia humana. Indivíduos próximos aos limiares de IMC frequentemente compartilham padrões comportamentais similares, tornando a separação matemática mais difícil para o algoritmo. Importante ressaltar que não foram observados erros de classificação entre classes distantes (por exemplo, Peso Normal classificado como Obesidade Tipo III), o que demonstra a capacidade do modelo de capturar a ordenação natural das classes.

V. Conclusões

O presente estudo demonstrou a aplicação de um MLP na classificação dos níveis de obesidade. A partir da análise de dados antropométricos e comportamentais, o modelo desenvolvido atingiu uma acurácia global de 94% no conjunto de teste, com F1-Score médio ponderado de 0.94, comprovando a correlação matemática não linear entre hábitos de vida diários e o estado nutricional dos indivíduos. O desempenho na detecção da classe de risco extremo (Obesidade Tipo III), com precisão e revocação de $P = R = 1.00$ e zero falsos negativos, reforça o potencial desta arquitetura como ferramenta de triagem para a prática clínica preventiva.

Parte significativa das variáveis do conjunto de dados do Kaggle provém de questionários preenchidos pelos próprios usuários. Dados autorrelatados sobre consumo de álcool, calorias e atividade física estão sujeitos ao viés de percepção e à subestimação comportamental. Os dados concentram-se nas populações do México, Peru e Colômbia. Consequentemente, o modelo pode apresentar uma queda de precisão se aplicado a populações de outros continentes com matrizes genéticas e dietas culturais diferentes.

Declaração de Uso de Inteligência Artificial

Os autores declaram que utilizaram ferramentas de inteligência artificial, incluindo Google Gemini, exclusivamente para auxiliar na melhoria da linguagem e legibilidade deste manuscrito. O uso dessa ferramenta foi realizado sob supervisão humana, e os autores revisaram e editaram cuidadosamente o conteúdo, assumindo total responsabilidade pelo texto final publicado.

References

[1] BEJNORDI, B. E. et al. Diagnostic Assessment of Deep Learning Algorithms for Detection of Lymph Node Metastases in Women With Breast Cancer. JAMA, v. 318, n. 22, p. 2199–2210, 12 2017. ISSN 0098-7484. Disponível em: ¡https://doi.org/10.1001/jama.2017.14585¿.

[2] Carmienke S, Freitag MH, Pischon T, Schlattmann P, Fankhaenel T, Goebel H, et al. General and abdominal obesity parameters and their combination in relation to mortality: a systematic review and meta-regression analysis. Eur J Clin Nutr. 2013;67(6):573–85.

[3] Cerhan JR, Moore SC, Jacobs EJ, Kitahara CM, Rosenberg PS, Adami HO, et al. A pooled analysis of waist circumference and mortality in 650,000 adults. Mayo Clin Proc. 2014;89(3):335–45.

[4] Godoy-Matos AF, Valério CM, Júnior WSS, de Araujo-Neto JM, Sposito AC, Suassuna JHR. CARDIAL-MS (CArdio-Renal-DIAbetes-Liver-Metabolic Syndrome): a new proposition for an integrated multisystem metabolic disease. Diabetol Metab Syndr. 2025 Jun 16;17(1):218. doi: 10.1186/s13098-025-01796-4. PMID: 40524210; PMCID: PMC12168269.

[5] Khan SS, Matsushita K, Sang Y, et al. Development and Validation of the American Heart Association Predicting Risk of Cardiovascular Disease EVENTs (PREVENTTM) Equations. Circulation 2023.

[6] Koskinas KC, Van Craenenbroeck EM, Antoniades C, Blüher M, Gorter TM, Hanssen H, Marx N, McDonagh TA, Mingrone G, Rosengren A, Prescott EB; ESC Scientific Document Group. Obesity and cardiovascular disease: an ESC clinical consensus statement. Eur Heart J. 2024 Oct 7;45(38):4063-4098. doi:10.1093/eurheartj/ehae508. Erratum in: Eur Heart J. 2025 Mar 3;46(9):876. doi: 10.1093/eurheartj/ehae915. PMID: 39210706.

[7] OLIVERA, A. R. et al. Comparison of machine-learning algorithms to build a predictive model for detecting undiagnosed diabetes-elsa-brasil: accuracy study. Sao Paulo Medical Journal, SciELO Brasil, v. 135, n. 3, p. 234–246, 2017.

[8] Palechor, F. M., & de la Hoz Manotas, A. (2019). Dataset for estimation of obesity levels based on eating habits and physical condition in individuals from Colombia, Peru and Mexico. Data in Brief, 25, 104344. Kaggle Repository.

[9] Powell-Wiley TM, Poirier P, Burke LE, Després JP, Gordon-Larsen P, Lavie CJ, Lear SA, Ndumele CE, Neeland IJ, Sanders P, St-Onge MP; American Heart Association Council on Lifestyle and Cardiometabolic Health; Council on Cardiovascular and Stroke Nursing; Council on Clinical Cardiology; Council on Epidemiology and Prevention; and Stroke Council. Obesity and Cardiovascular Disease: A Scientific Statement From the American Heart Association. Circulation. 2021 May 25;143(21):e984-e1010. doi: 10.1161/CIR.0000000000000973. Epub 2021 Apr 22. PMID: 33882682.

[10] REZENDE, L. F. M. et al. A EPIDEMIA DE OBESIDADE E AS DCNT. 2021. Disponível em: https://rezendelfm.github.io/obesidade-e-as-dcnt/. Acesso em: 03 abril 2026.

[11] ROCHA, T. A. H. et al. Saúde móvel: novas perspectivas para a oferta de serviços em saúde. Epidemiologia e Serviços de Saúde, SciELO Public Health, v. 25, p. 159–170, 2016.

[12] SAFAEI, M. et al. A systematic literature review on obesity: Understanding the causes & consequences of obesity and reviewing various machine learning approaches used to predict obesity. Computers in biology and medicine, Elsevier, v. 136, p. 104754, 2021.

[13] SYED, L. et al. Smart healthcare framework for ambient assisted living using iomt and big data analytics techniques. Future Generation Computer Systems, Elsevier, 2019.

[14] Tan SCW, Zheng BB, Tang ML, Chu H, Zhao YT, Weng C. Global Burden of Cardiovascular Diseases and its Risk Factors, 1990-2021: A Systematic Analysis for the Global Burden of Disease Study 2021. QJM. 2025 Jan 23: hcaf022. doi:10.1093/qjmed/hcaf022. Epub ahead of print. PMID: 39847534.

[15] WILBORN, C. et al. Obesity: Prevalence, Theories, Medical Consequences, Management, and Research Directions. Journal of the International Society of Sports Nutrition, v. 2, n. 2, p. 4–31, 2005. doi: 10.1186/1550-2783-2-2-4. Disponível em: ¡https://pmc.ncbi.nlm.nih.gov/articles/PMC2129146/¿.

[16] World Obesity Federation. World Obesity Atlas 2025. London: World Obesity Federation. 2025. Disponível em: https://data.worldobesity.org/publications/?cat=23

[17] D. P. Kingma and J. Ba, "Adam: A Method for Stochastic Optimization," arXiv preprint arXiv:1412.6980, 2014.

ReCiclo: Sistema Inteligente para Gestão e Incentivo da Reciclagem

Maria Luíza da Costa Nóbrega
Pau dos Ferros, RN, Brasil
malucosstaah@gmail.com

Caio Vinícius Feitoza da Oliveira
Pau dos Ferros, RN, Brasil
Caio13feitosa@gmail.com

Pryscila Rayane Souza Oliveira
Pau dos Ferros, RN, Brasil
Pryscilarayane@gmail.com

Resumo— O aumento da geração de resíduos sólidos urbanos e a baixa adesão à coleta seletiva evidenciam a necessidade de soluções tecnológicas sustentáveis. Este trabalho tem como objetivo desenvolver e avaliar um sistema inteligente para otimizar a coleta de resíduos recicláveis no município de Pau dos Ferros/RN. O sistema é composto por uma plataforma digital interativa e uma lixeira eletrônica automatizada, equipada com sensores e tecnologia RFID para identificação e registro dos resíduos. Foram realizadas etapas de mapeamento dos pontos de coleta, desenvolvimento da plataforma com integração a APIs de localização e testes experimentais com usuários. Os resultados evidenciaram aumento no engajamento e na conscientização ambiental, com registro de 386 resíduos coletados durante os testes. Conclui-se que o sistema contribui para o monitoramento da coleta seletiva e para a promoção de práticas sustentáveis, apresentando-se como uma solução inovadora e de baixo custo.

Palavras-chave—coleta seletiva, reciclagem, sustentabilidade, educação ambiental, resíduos sólidos.

Abstract**—** The increase in urban solid waste generation and the low adherence to selective waste collection highlight the need for sustainable technological solutions. This study aims to develop and evaluate an intelligent system to optimize the collection of recyclable waste in the municipality of Pau dos Ferros/RN. The system consists of an interactive digital platform and an automated electronic bin, equipped with sensors and RFID technology for the identification and recording of disposed waste. The methodology included mapping collection points, developing the platform with integration of location-based APIs, and conducting experimental tests with users. The results showed an increase in user engagement and environmental awareness, with a total of 386 recyclable items collected during the tests. It is concluded that the system contributes to the monitoring of selective waste collection and the promotion of sustainable practices, presenting itself as an innovative and low-cost solution**.**

Keywords—selective collection, recycling, sustainability, environmental education, solid waste.

I. INTRODUÇÃO

A crescente geração de resíduos sólidos urbanos tem se consolidado como um dos principais desafios ambientais enfrentados pelas cidades contemporâneas. O descarte inadequado desses materiais não apenas intensifica a poluição do solo e dos recursos hídricos, mas também compromete diretamente a saúde pública, a qualidade de vida da população e o equilíbrio ambiental das áreas urbanas. Diante desse cenário, a coleta seletiva surge como uma importante alternativa para reduzir os impactos causados pelo acúmulo de resíduos, permitindo o reaproveitamento de materiais recicláveis e incentivando práticas mais sustentáveis. Entretanto, apesar de sua relevância, ainda é comum a dificuldade da população em encontrar informações claras e acessíveis sobre a separação correta dos resíduos e os locais apropriados para descarte. Muitas pessoas desconhecem os pontos de coleta disponíveis em suas comunidades ou não sabem como diferenciar adequadamente os materiais recicláveis dos resíduos comuns, o que acaba limitando a participação da sociedade nesse processo.

No município de Pau dos Ferros/RN, essa problemática torna-se cada vez mais evidente. De acordo com dados da Secretaria Municipal de Meio Ambiente (SEMA, 2024), são produzidas aproximadamente 2.246 toneladas de resíduos sólidos urbanos por ano nos 29 bairros atendidos pela coleta regular. No entanto, desse total, apenas cerca de 33,5 toneladas são efetivamente destinadas à reciclagem, revelando um índice ainda bastante reduzido de reaproveitamento. Essa realidade está associada, entre outros fatores, à escassez de informações acessíveis sobre os pontos de coleta seletiva, à limitada conscientização da população quanto à separação adequada dos resíduos e à ausência de tecnologias acessíveis que incentivem práticas sustentáveis de descarte. Como consequência, observa-se um enfraquecimento da eficiência dos processos de reciclagem e um agravamento dos impactos ambientais provocados pelo descarte inadequado no espaço urbano.

Diante dessa realidade, torna-se fundamental desenvolver soluções inovadoras que aproximem a população das práticas sustentáveis e facilitem o acesso a informações confiáveis sobre a coleta seletiva. Com esse propósito, o presente projeto propõe uma solução tecnológica de baixo custo e potencial impacto social e ambiental: um sistema integrado composto por um site interativo e uma lixeira eletrônica inteligente. O site foi idealizado para disponibilizar, de forma simples e acessível, informações sobre pontos de coleta, tipos de resíduos aceitos e rotas de acesso, auxiliando os cidadãos no descarte adequado. Complementando essa proposta, a lixeira inteligente, equipada com sensores, é capaz de reconhecer e contabilizar a quantidade de resíduos recicláveis descartados por cada usuário, registrando dados que possibilitam monitorar o volume coletado e estimular maior engajamento da população. Além disso, futuramente, o sistema poderá incorporar mecanismos de recompensas, incentivando ainda mais a participação dos cidadãos. Assim, a iniciativa busca não apenas informar, mas também conscientizar e envolver a comunidade em práticas ambientalmente responsáveis, tornando o descarte de resíduos mais acessível, interativo e eficiente, contribuindo para a construção de uma cidade mais limpa, sustentável e comprometida com o meio ambiente.

II. METODOLOGIA

A. Aplicação do questionário

Inicialmente, foi aplicado um questionário composto por seis perguntas, por meio da plataforma Google Forms, direcionado aos estudantes da Escola Estadual em Tempo Integral Dr. José Fernandes de Melo, com o objetivo de avaliar o nível de conhecimento dos participantes acerca da coleta seletiva e das práticas relacionadas ao descarte de resíduos sólidos. O formulário permaneceu disponível por um período de três dias, obtendo a participação de 48 alunos. A análise das respostas permitiu identificar lacunas no conhecimento dos estudantes, especialmente em temas relacionados à separação

correta dos resíduos, aos pontos de coleta seletiva e às formas adequadas de descarte. Com base nessas dificuldades evidenciadas, foram iniciadas pesquisas direcionadas aos aspectos que apresentaram maior desconhecimento, visando o desenvolvimento de uma plataforma capaz de suprir essas necessidades informacionais de forma acessível e educativa.

B. Desenvolvimento do site

O desenvolvimento do site de suporte à lixeira inteligente ocorreu em quatro etapas principais. Na primeira etapa, foi realizado o levantamento de dados secundários relacionados à política municipal de resíduos sólidos e ao mapeamento dos pontos de coleta seletiva existentes no município, utilizando informações obtidas por meio do site da Secretaria Municipal de Meio Ambiente (SEMA) e da Associação dos Catadores de Pau dos Ferros. Essa fase teve como objetivo reunir informações relevantes capazes de auxiliar a população no descarte correto dos resíduos, além de incentivar práticas ambientalmente responsáveis e fortalecer a conscientização sobre a importância da coleta seletiva.

Na segunda etapa, foi definida a estrutura de navegação da plataforma, tomando como referência modelos de interface disponibilizados pela plataforma Figma. Essa etapa buscou organizar a disposição dos conteúdos e funcionalidades do sistema, visando proporcionar uma experiência de navegação mais intuitiva, acessível e funcional para os usuários.

Na terceira etapa, iniciou-se o desenvolvimento do site por meio da biblioteca React, baseada nas linguagens HTML, CSS e JavaScript. A escolha do React ocorreu devido à sua capacidade de proporcionar uma interface dinâmica, responsiva e organizada em componentes reutilizáveis, facilitando tanto o desenvolvimento quanto a manutenção da plataforma. Além disso, essa tecnologia permite maior eficiência na atualização de conteúdos e melhor desempenho na construção de interfaces interativas.

Na quarta etapa, foi realizada a integração do sistema com APIs de mapas, como o Google Maps, ampliando as funcionalidades da plataforma por meio de recursos de geolocalização. Essa integração possibilitou a identificação e exibição dos pontos de coleta seletiva mais próximos ao usuário, bem como a criação de rotas personalizadas com base na localização de cada pessoa, facilitando o acesso aos locais adequados de descarte. A Figura 1 apresenta a página inicial do site, enquanto a Figura 2 ilustra o mapeamento de alguns dos pontos de descarte existentes no município, e a Figura 3 apresenta a seção informacional da plataforma, destinada à orientação dos usuários sobre o descarte adequado de resíduos e práticas de coleta seletiva.



Fig. 1. Página inicial do site.



Fig. 2. Página de mapeamento de alguns dos pontos de descarte no município de Pau dos Ferros.



Fig. 3. Página informacional do site, contendo orientações sobre separação de resíduos, descarte correto e coleta seletiva.

C. Construção do protótipo da lixeira

Paralelamente ao desenvolvimento da plataforma digital, iniciou-se a confecção da lixeira eletrônica inteligente, idealizada com o objetivo de auxiliar na organização, monitoramento e descarte adequado dos resíduos recicláveis. Seu desenvolvimento ocorreu em quatro etapas principais. Na primeira etapa, foi definido o modelo estrutural do protótipo, considerando aspectos como praticidade, acessibilidade e facilidade de identificação dos resíduos descartados. Em seguida, realizou-se a escolha dos materiais necessários para sua construção, priorizando componentes de baixo custo e fácil acesso, visando à viabilidade econômica do projeto e à possibilidade de reprodução futura em outros contextos. A estrutura da lixeira foi desenvolvida utilizando quatro tábuas de madeira, medindo aproximadamente 1,5 m de comprimento por 50 cm de largura, além de canos de PVC com diâmetros de 20 mm, 30 mm e 50 mm, todos com cerca de 30 cm de comprimento, conectados à tampa da estrutura para permitir a entrada dos resíduos recicláveis. O processo de construção da lixeira eletrônica inteligente pode ser observado na Figura 4, que apresenta a montagem do protótipo.



Fig. 4. Processo de construção da lixeira eletrônica inteligente.

Na terceira etapa, foi realizada a programação da placa microcontroladora ESP32, responsável pelo processamento dos dados coletados pelos sensores e pelo gerenciamento das funções do sistema. Essa etapa possibilitou a integração entre os componentes eletrônicos, permitindo o reconhecimento e o registro automático dos resíduos descartados.

Por fim, na quarta etapa, foram integrados os componentes eletrônicos responsáveis pelo funcionamento da lixeira. O sistema foi equipado com sensores infravermelhos para identificação e contabilização dos resíduos recicláveis, conforme apresentado na Figura 5. Além disso, foi incorporado um leitor RFID, mostrado na Figura 6, destinado à identificação individual dos usuários, possibilitando o registro da quantidade de resíduos descartados por cada pessoa. O sistema também passou a contar com um display interativo, ilustrado na Figura 7, desenvolvido para facilitar a compreensão do funcionamento da lixeira e fornecer informações ao usuário durante sua utilização.



Fig. 5. Sensores de infravermelho utilizados na identificação dos resíduos recicláveis.

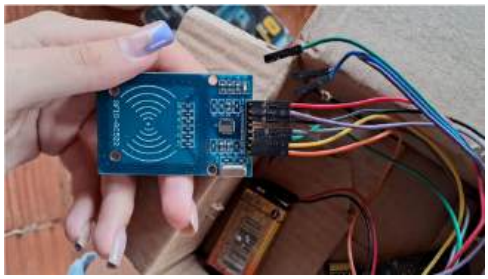


Fig. 6. Leitor de RFID utilizado para identificação dos usuários.



Fig. 7. Display interativo da lixeira inteligente.

D. Funcionamento da lixeira inteligente

A lixeira inteligente funciona por meio de um sistema automatizado composto por sensores infravermelhos integrados a uma placa microcontroladora ESP32, responsável pelo processamento e gerenciamento das informações coletadas. O código responsável por seu funcionamento foi desenvolvido utilizando C++, permitindo que ela receba, interprete e registre os sinais enviados pelos sensores durante o descarte dos resíduos. Os sensores infravermelhos foram posicionados estrategicamente nas três entradas da lixeira, organizadas de acordo com o tipo de resíduo aceito em cada compartimento, como apresentado na Figura 8. Cada entrada possui identificação específica, orientando os usuários sobre o descarte correto do material correspondente. Quando um objeto é inserido em uma das entradas, o sensor detecta sua passagem e envia automaticamente um sinal eletrônico à placa ESP32, registrando a ocorrência do descarte.



Fig. 8. Posicionamento dos sensores infravermelhos nas entradas da lixeira

A diferenciação dos resíduos ocorre porque cada sensor está associado a uma entrada específica da lixeira, permitindo ao sistema identificar em qual compartimento o material foi depositado. Dessa forma, o descarte é contabilizado automaticamente. Por exemplo, caso um objeto seja inserido na entrada destinada exclusivamente às baterias, o sensor correspondente envia um sinal à placa, que registra automaticamente aquele descarte como bateria. Além disso, o sistema incorpora um leitor RFID para identificação individual dos usuários, possibilitando registrar a quantidade de resíduos descartados por cada pessoa.

E. Teste do sistema integrado

Com o objetivo de avaliar a funcionalidade e a aceitação do sistema desenvolvido, foi realizado um teste integrado envolvendo a plataforma digital e a lixeira eletrônica inteligente com um grupo de 14 estudantes da Escola Estadual em Tempo Integral Doutor José Fernandes de Melo. A atividade ocorreu em caráter experimental, permitindo observar a interação dos participantes com as funcionalidades propostas pelo sistema, bem como sua compreensão acerca do descarte correto dos resíduos recicláveis.

Durante os testes, foi implementado um sistema de pontuação e ranking baseado na quantidade de descartes realizados corretamente pelos participantes, incluindo uma premiação para os estudantes com melhor desempenho, como forma de incentivar a participação e estimular maior engajamento com a coleta seletiva. A dinâmica gamificada mostrou-se relevante para aumentar o interesse dos alunos, favorecendo a participação ativa e tornando o processo de descarte mais interativo e educativo.

III. Resultados e Discussões

Nas Figuras 9, 10 e 11 são apresentados alguns dos resultados do questionário aplicado aos estudantes da Escola Estadual em Tempo Integral Dr. José Fernandes de Melo. O questionário foi respondido por 48 alunos e permitiu avaliar o nível de conhecimento e as práticas relacionadas à coleta seletiva e ao descarte de resíduos recicláveis.

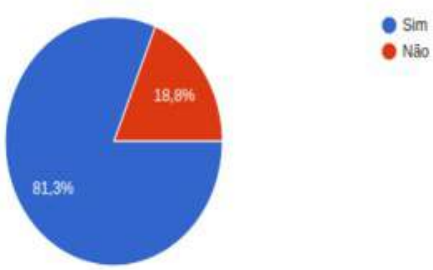


Fig. 9. Gráfico 1: você sabe o que é coleta seletiva?

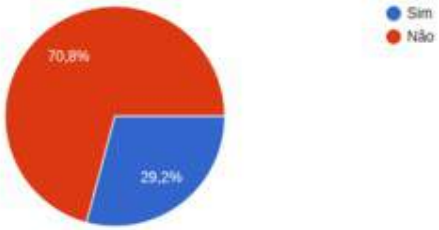


Fig. 10. Gráfico 2: você conhece os pontos de descarte próximos à sua residência?

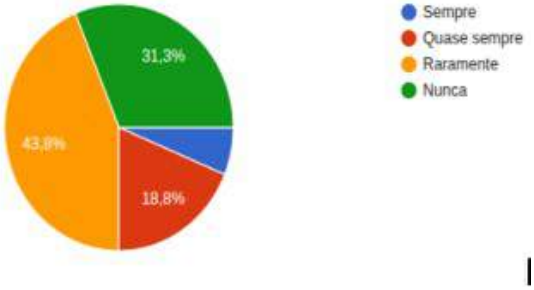


Fig. 11. Gráfico 3: com que frequência você separa o lixo reciclável do lixo comum na sua casa?

A análise das respostas revelou que, embora uma parcela significativa dos participantes já possua conhecimentos básicos sobre coleta seletiva, muitos ainda demonstram dificuldades relacionadas à prática regular da separação dos resíduos em suas residências. Além disso, observou-se que parte dos estudantes desconhece os pontos de coleta seletiva disponíveis no município, evidenciando uma lacuna informacional que pode dificultar a adoção de práticas sustentáveis no cotidiano. As respostas também indicaram elevado interesse dos estudantes em utilizar uma plataforma digital voltada à orientação sobre descarte adequado de resíduos, reconhecendo-a como uma ferramenta capaz de fornecer informações, dicas práticas e localização dos pontos de coleta seletiva. Esses resultados reforçam a relevância da proposta desenvolvida, demonstrando que a tecnologia pode atuar como importante instrumento de conscientização ambiental e incentivo à mudança de comportamento, tanto no ambiente escolar quanto fora dele.

Ainda como desdobramento da pesquisa e das reflexões geradas a partir do questionário, foi realizado um teste integrado envolvendo a plataforma digital e a lixeira eletrônica inteligente com estudantes da instituição. Durante o período experimental, registrou-se a coleta de 386 resíduos recicláveis, evidenciando a funcionalidade do sistema e a participação ativa dos usuários. Para incentivar a adesão dos participantes, foi implementado um sistema de pontuação com ranking e premiação, conforme ilustrado nas Figuras 12 e 13, estratégia que se mostrou eficaz no estímulo à participação dos estudantes.

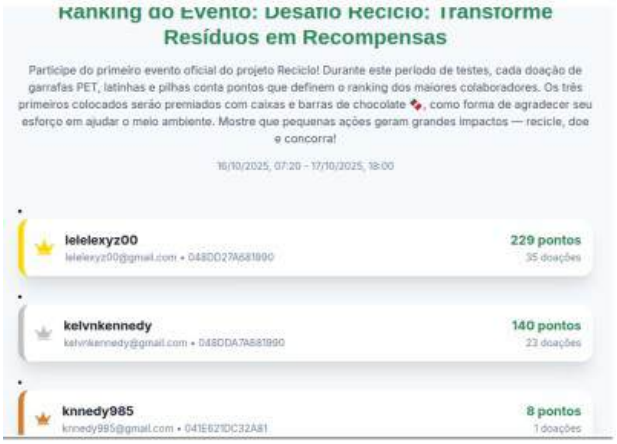


Fig. 12. Ranking dos três primeiros colocados durante o teste



Fig. 13. Premiação dos três primeiros colocados

Observou-se que a dinâmica competitiva despertou não apenas o interesse pela atividade, mas também maior engajamento com questões ambientais e práticas relacionadas à coleta seletiva, Os resultados obtidos reforçam o potencial do sistema como ferramenta educativa e de incentivo à reciclagem, contribuindo para a conscientização ambiental e validando a hipótese inicial proposta pelo projeto.

Além do impacto educativo observado, os materiais coletados durante os testes totalizaram seis sacos de 100 litros de resíduos recicláveis, mostrado na Figura 14, demonstrando o potencial prático da iniciativa na redução do descarte inadequado.



Fig. 14. Materiais recicláveis coletados durante os testes do sistema.

Parte dos materiais foi destinada à reutilização por produtores locais: um dos sacos foi entregue a um agricultor do município para armazenamento de grãos, enquanto outros dois foram destinados a um produtor local que reutilizará os recipientes no acondicionamento de seus produtos. Os três sacos restantes foram encaminhados ao órgão municipal responsável pela coleta seletiva, fortalecendo a integração do projeto com práticas sustentáveis já existentes no município e ampliando seu impacto socioambiental.

IV. Conclusão

O desenvolvimento do sistema inteligente voltado à coleta seletiva no município de Pau dos Ferros/RN evidenciou o potencial da integração entre tecnologia e educação ambiental como estratégia para enfrentar desafios relacionados à gestão de resíduos sólidos urbanos. A combinação entre uma plataforma digital interativa e uma lixeira eletrônica automatizada mostrou-se eficiente não apenas para ampliar o acesso da população a informações sobre descarte adequado, mas também para incentivar maior participação dos usuários nas práticas de coleta seletiva.

Os resultados obtidos durante o teste experimental demonstraram a funcionalidade e a viabilidade da proposta, evidenciadas pelo engajamento dos participantes, pela coleta

de 386 resíduos recicláveis e pela adesão dos estudantes às dinâmicas de pontuação e ranking implementadas durante a atividade. Além disso, observou-se maior compreensão acerca da separação correta dos resíduos e maior interesse dos participantes por práticas sustentáveis, reforçando o potencial educativo do sistema.

Outro aspecto relevante refere-se ao impacto social e ambiental da iniciativa, considerando que os materiais coletados puderam ser reutilizados ou destinados adequadamente, fortalecendo a integração do projeto com práticas sustentáveis já existentes no município. Dessa forma, o sistema contribui tanto para a conscientização ambiental quanto para o fortalecimento da coleta seletiva local.

Conclui-se, portanto, que o projeto apresenta-se como uma solução tecnológica inovadora, acessível e de baixo custo, com potencial de aplicação em outros contextos escolares e comunitários. Além de contribuir para a promoção da sustentabilidade, a proposta poderá futuramente incorporar novas funcionalidades, como sistemas de recompensas e ampliação do monitoramento dos resíduos, ampliando ainda mais seu alcance e impacto socioambiental.

References

[1] *ASSOCIAÇÃO DOS CATADORES DE PAU DOS FERROS. Informações sobre coleta seletiva e pontos de descarte no município de Pau dos Ferros/RN. Pau dos Ferros, 2024.*

[2] ALMEIDA, João Victor; SANTOS, Lucas Pereira. Desenvolvimento de uma lixeira inteligente para monitoramento de resíduos utilizando sensores e microcontroladores. *Revista Brasileira de Tecnologia Aplicada*, v. 8, n. 2, p. 45–58, 2022.

[3] *BRASIL. Lei nº 12.305, de 2 de agosto de 2010. Institui a Política Nacional de Resíduos Sólidos; altera a Lei nº 9.605, de 12 de fevereiro de 1998; e dá outras providências. Brasília, DF: Presidência da República, 2010. Disponível em: Planalto – Lei nº 12.305/2010. Acesso em: 10 maio 2026.*

[4] *BRASIL. Ministério do Meio Ambiente e Mudança do Clima. Resíduos sólidos urbanos. Brasília, DF: MMA, [s.d.]. Disponível em: Ministério do Meio Ambiente – Resíduos Sólidos Urbanos. Acesso em: 10 maio 2026.*

[5] *SECRETARIA MUNICIPAL DE MEIO AMBIENTE DE PAU DOS FERROS (SEMA). Dados sobre resíduos sólidos urbanos e coleta seletiva do município de Pau dos Ferros/RN. Pau dos Ferros: SEMA, 2024.*

[6] *SILVIA, Aparecida Soares; ALENCAR,Juheina Lacerda Ribeiro Viana. A relevância da reciclagem de resíduos sólidos para a sustentabilidade. Disponível em: https://encurtador.com.br/NQAme. Acesso em 25 jul. 2025.*

[7] COSTA, Isis dos Santos; Implementação da coleta seletiva em Pau dos Ferros-RN: Concepções baseadas a partir do Bairro Nações Unidas. Disponível em:https://xviiienanpur.anpur.org.br/anaisadmin/capapdf.php?reqid=424 Acesso em 01 ago.2025.

[8] PORTAL SUSTENTABILIDADE. Brasileiro cria sistema de coleta de lixo reciclável inteligente para remunerar cidadãos. Disponível em: https://portalsustentabilidade.com/2021/07/15/brasileiro-cria-sistema-de-coleta-de-lixo-reciclavel-inteligente-para-remunerar-cidadaos/. Acesso em: 13 set. 2025.

[9] SILVA, M. R.; SOUZA, T. P.; LIMA, R. A. Uso de sensores IoT na gestão de resíduos sólidos urbanos. Revista Brasileira de Engenharia Ambiental, São Paulo, v. 28, n. 4, p. 122–134, jul./ago. 2023. Disponível em: https://www.revbea.org.br/artigo/uso-de-sensores-iot-na-gestao-de-residuos-solidos. Acesso em: 11 out. 2025.

[10] *SOUZA, T. P.; LIMA, R. A. Educação ambiental e tecnologias digitais no ensino médio. Ciência e Educação Ambiental, Brasília, v. 15, n. 2, p. 45–59, abr./jun. 2022. Disponível em: https://www.cienciaeducacaoambiental.org.br/artigo/educacao-ambiental-e-tecnologias-digitais. Acesso em: 11 out. 2025.*

Uma arquitetura de sistema Web de apoio ao ensino gamificado dos Objetivos de Desenvolvimento Sustentável

1st Thyago Fabricio Melo Costa
DETEC/UFERSA
UFERSA
Pau dos Ferros, Brasil
thyago.costa@alunos.ufersa.edu.br

2nd Johan Pedro de Queiroz
DETEC/UFERSA
UFERSA
Pau dos Ferros, Brasil
johan.queiroz@alunos.ufersa.edu.br

3rd Nattan Ferreira Lopes
DETEC/UFERSA
UFERSA
Pau dos Ferros, Brasil
nattan.lopes@alunos.ufersa.edu.br

4th Daniela de Freitas Lima
DETEC/UFERSA
UFERSA
Pau dos Ferros, Brasil
daniela.freitas@ufersa.edu.br

5th Walber José Adriano Silva
DETEC/UFERSA
UFERSA
Pau dos Ferros, Brasil
walber.silva@ufersa.edu.br

***Resumo*—A urgência em promover a conscientização global sobre o desenvolvimento sustentável exige estratégias educacionais que transcendam os métodos tradicionais, integrando tecnologia e interatividade. Este trabalho apresenta o desenvolvimento e a arquitetura do sistema Web Extensão ODS UFERSA, uma plataforma voltada ao ensino gamificado dos Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas (ONU). A solução foi construída utilizando o *framework Next.js* e a biblioteca *React*, adotando uma arquitetura centrada no *front-end* com geração de site estático, *Static Site Generation* (SSG), para garantir alta performance, baixo custo de infraestrutura e escalabilidade via AWS (*Amazon Web Services*) *Amplify*. A interface foi estruturada sob a metodologia *Atomic Design*, proporcionando um ambiente responsivo e modular que facilita a navegação e o engajamento lúdico por meio de jogos educativos. Os resultados iniciais demonstram que a combinação de práticas de engenharia de software com estratégias de gamificação favorece a assimilação de temas complexos, consolidando o sistema como uma ferramenta viável para a educação básica e projetos de extensão universitária.**

***Palavras-chaves*—Objetivos de Desenvolvimento Sustentável; Arquitetura de Sistemas; Gamificação; Desenvolvimento de Software; *Next.js*.**

I. Introdução

A crescente urgência em promover a conscientização sobre sustentabilidade tem impulsionado diversas iniciativas voltadas à divulgação dos ODS, estabelecidos pela ONU. Mais do que um conjunto de metas, os ODS configuram uma agenda global abrangente e desafiadora, que propõe conciliar crescimento econômico, inclusão social e preservação ambiental até 2030 [1]. Nesse cenário, a educação assume um papel central na disseminação desses princípios, sobretudo quando integrada às tecnologias digitais. O uso de aplicações Web e recursos interativos não só amplia o alcance do conteúdo, como também transforma o processo de ensino-aprendizagem em uma experiência mais dinâmica, acessível e significativa, favorecendo práticas ativas e construtivas [2]. É nesse contexto que se insere este trabalho, que apresenta o desenvolvimento do sistema Web Extensão ODS UFERSA, vinculado ao Projeto de Extensão ODS da Universidade Federal Rural do Semi-Árido (UFERSA)[1]. O sistema foi concebido com o objetivo de disponibilizar aplicações Web gratuitas voltadas ao ensino dos ODS, além de servir como base para integrações com aplicações para dispositivos móveis e outros recursos educacionais interativos.

Para além da construção do sistema, o projeto também prevê a adaptação de jogos educativos já disponíveis na internet para o contexto escolar, estimulando uma abordagem mais lúdica, participativa e envolvente no ensino dos ODS. Embora essa etapa ainda esteja em desenvolvimento, ela revela um importante potencial de expansão e consolidação da proposta.

A metodologia adotada possui caráter aplicado e tecnológico, com ênfase na criação de soluções digitais voltadas à educação. A arquitetura adotada combina práticas de engenharia de software com estratégias pedagógicas fundamentadas na gamificação, buscando criar um sistema Web educacional interativo, acessível e capaz de evoluir conforme novos requisitos surjam no projeto de extensão. Como resultado inicial, o desenvolvimento da aplicação Web contribui para ampliar a disseminação dos ODS por meio de ferramentas acessíveis, ao mesmo tempo em que estabelece uma base consistente para futuras pesquisas sobre o uso de tecnologias no processo de ensino-aprendizagem.

[1]Disponível em: https://extensaoods.ufersa.dev.br

II. Fundamentação sobre os ODS

Desde o final do século XX, observa-se uma intensa concentração populacional em áreas urbanas, refletindo um processo de urbanização acelerada que trouxe profundas transformações na dinâmica social e espacial das cidades. Nesse contexto, a segregação socioespacial urbana emergiu como um fenômeno significativo, fragmentando o espaço urbano de acordo com critérios econômicos e sociais, e estabelecendo zonas de privilégio e exclusão que impactam diretamente o acesso a serviços, infraestrutura e oportunidades de desenvolvimento [3]. Tal divisão territorial, além de reproduzir desigualdades históricas, compromete a equidade no usufruto dos recursos urbanos, reforçando a necessidade de estratégias de planejamento que considerem a justiça social e a inclusão.

Frente a esse cenário, o conceito de desenvolvimento sustentável torna-se central para a formulação de políticas públicas e práticas urbanas. Conforme delineado pelo Relatório de Brundtland (1987), o desenvolvimento sustentável consiste em atender às necessidades da geração presente sem comprometer a capacidade das gerações futuras de satisfazerem suas próprias necessidades, estabelecendo um equilíbrio entre crescimento econômico, preservação ambiental e bem-estar social. Essa perspectiva enfatiza a importância de ações integradas e planejadas que promovam cidades resilientes e equitativas, capazes de sustentar a qualidade de vida ao longo do tempo.

Em resposta a essa necessidade, a ONU instituiu, em 2015, a Agenda 2030 para o Desenvolvimento Sustentável, a qual define 17 Objetivos de Desenvolvimento Sustentável. Tais objetivos constituem uma agenda global voltada para o avanço simultâneo do crescimento econômico, da justiça social e da proteção ambiental, promovendo direitos humanos e reduzindo desigualdades em nível mundial. A implementação dos ODS representa um instrumento estratégico para a superação de desafios contemporâneos que afetam tanto a geração atual quanto as futuras, incluindo pobreza, degradação ambiental e exclusão social [4].

Dessa forma, a incorporação dos princípios do desenvolvimento sustentável e dos ODS no planejamento urbano não apenas responde a exigências éticas e sociais, mas também configura um imperativo estratégico para a construção de cidades inclusivas, resilientes e sustentáveis, capazes de integrar crescimento econômico, equidade social e preservação ambiental.

Portanto, diante do cenário de complexidade e desigualdade urbana, aliado à urgência de disseminar os princípios do desenvolvimento sustentável, torna-se essencial promover ferramentas educacionais inovadoras que incentivem a compreensão e a aplicação prática dos ODS. Nesse contexto, uma arquitetura de sistema de suporte ao ensino gamificado dos ODS apresenta-se como uma solução adequada, pois combina tecnologia, aprendizagem ativa e engajamento lúdico para facilitar a internalização dos objetivos de desenvolvimento sustentável.

III. Desenvolvimento da Arquitetura

A arquitetura do sistema foi concebida para sustentar uma plataforma Web educacional dedicada ao ensino gamificado dos ODS. O projeto prioriza desempenho, organização modular e capacidade de crescimento, com a vantagem de fornecer uma experiência interativa e envolvente ao ensino dos ODS.

A. Visão Geral da Arquitetura

O sistema consiste em uma aplicação Web estruturada e centrada no *front-end*, sem dependência de um *back-end* dedicado, embora sua organização permita futura integração com serviços externos de forma desacoplada. Nesse formato, a própria aplicação assume tanto a responsabilidade pela apresentação quanto pela lógica de interação com o usuário, enquanto os dados e conteúdos são fornecidos por meio de arquivos estáticos.

O sistema foi desenvolvido como uma aplicação Web baseada no *framework Next.js*[2], em conjunto com a biblioteca *React*, utilizando *TypeScript* como linguagem principal. A distribuição ocorre na forma de um site estático, o que favorece um carregamento mais rápido, garante alta disponibilidade e simplifica a infraestrutura necessária. Essa abordagem mostra-se especialmente adequada para plataformas educacionais com foco na entrega de conteúdo e em experiências interativas.

Essa escolha não foi por acaso: ela permite simplificar o processo de implantação, otimizar o tempo de carregamento e tornar a manutenção mais prática, aspectos especialmente relevantes em uma plataforma voltada para conteúdo educacional e interações executadas no lado do cliente. Como consequência dessa escolha, o custo de manutenção da infraestrutura também foi reduzido.

Por fim, a organização da aplicação foi planejada para ser funcional, com páginas temáticas estruturadas que abrangem tanto seções institucionais quanto áreas específicas para jogos educativos. Parte desses jogos foi incorporada por meio de arquivos estáticos, enquanto outros foram desenvolvidos como componentes *React*, o que amplia a flexibilidade e enriquece as possibilidades de interação dentro da plataforma.

B. Arquitetura de Interface e Experiência do Usuário

A interface foi organizada com base no padrão *Atomic Design*, estruturando os componentes em diferentes níveis, como átomos, moléculas e organismos. Essa abordagem contribui para o reuso de elementos, garante maior consistência visual e favorece a evolução do sistema de forma organizada e escalável.

O desenvolvimento priorizou uma experiência responsiva e intuitiva, com foco na usabilidade em diferentes dispositivos. Para a estilização, foi utilizado o *Tailwind CSS*[3], permitindo mais agilidade na construção da interface. Recursos adicionais, como o *Framer Motion*[4], foram empregados para criar animações mais fluidas, enquanto o *Embla Carousel*[5] foi utilizado

[2]Disponível em: https://nextjs.org/
[3]Disponível em: https://tailwindcss.com/
[4]Disponível em: https://motion.dev/
[5]Disponível em: https://www.embla-carousel.com/

na exibição de conteúdos interativos, tornando a navegação mais dinâmica.

A lógica de comportamento da aplicação foi estruturada por meio de contextos globais e funções reutilizáveis, responsáveis por gerenciar a navegação, destacar seções e adaptar a interface conforme as interações do usuário. Isso contribui para uma experiência mais fluida e consistente ao longo do uso da plataforma.

C. Infraestrutura e Implantação

A aplicação foi disponibilizada em ambiente de produção por meio dos serviços de computação em nuvem da AWS, utilizando o *AWS Amplify* como plataforma de hospedagem e integração.

Essa escolha permite uma conexão contínua com o repositório de código, possibilitando *deploys* automatizados e mantendo a aplicação sempre atualizada. Além disso, a infraestrutura em nuvem garante alta disponibilidade e contribui para a escalabilidade, a confiabilidade e a simplificação do gerenciamento do sistema.

D. Processo de Desenvolvimento

O processo de desenvolvimento seguiu uma abordagem incremental e colaborativa, apoiada pelo uso de controle de versão com Git e pela estratégia *Git Flow*. As funcionalidades foram construídas em ciclos evolutivos, com revisões de código realizadas por meio de *Pull Requests* antes de sua integração ao repositório principal, garantindo maior qualidade e consistência ao longo do projeto.

Para organizar as atividades, foi adotado o método *Kanban* como suporte ágil, permitindo acompanhar continuamente as tarefas, visualizar o fluxo de trabalho e monitorar o progresso das funcionalidades. Com isso, o desenvolvimento tornou-se mais transparente, organizado e eficiente.

Antes da implementação, a prototipação visual foi utilizada como etapa orientadora, contribuindo para a construção de uma interface centrada no usuário e alinhada aos objetivos educacionais da plataforma.

E. Estrutura da Aplicação

A estrutura da aplicação é baseada em páginas e seções, o que facilita a navegabilidade, tornando mais fácil encontrar o conteúdo e as funcionalidades disponíveis. Essa organização é complementada, internamente, por uma arquitetura de componentes responsável por sustentar a construção das interfaces.

A navegação é majoritariamente feita a partir de uma única página principal que concentra diferentes seções organizadas continuamente. O acesso direto às seções é facilitado por meio de elementos posicionados no topo da página (*header*) e no final (*footer*), como forma de auxiliar e facilitar o rápido acesso aos segmentos da aplicação.

Além disso, o sistema fornece um *feedback* visual durante a navegação, destacando a área atual exibida na parte superior, o que contribui para a clareza e orientação das seções anteriores e posteriores. Dessa forma, a aplicação contém um modelo de página única, no qual o conteúdo é acessado por meio da rolagem e dos atalhos de navegação.

F. Organização em Camadas

A aplicação é organizada em camadas, com o objetivo de separar responsabilidades para um maior controle e escalabilidade do sistema, adotando o princípio SoC (*Separation of Concerns*). A Figura 1 detalha essa organização do sistema.

A camada de interface é organizada através do *Atomic Design*, sendo estruturada em níveis crescentes de complexidade, como átomos, moléculas e organismos, onde a responsabilidade e a lógica são gradualmente estabelecidas.

A camada de lógica é implementada através de contextos globais e *custom hooks*, responsáveis por gerenciar o estado e o fluxo da aplicação conforme a navegação do usuário. Isso permite um maior controle do sistema, tornando a experiência de uso mais interativa à medida que o conteúdo é consumido.

A camada de roteamento é gerenciada pelo roteamento nativo do *Next.js*, que rastreia as rotas de acordo com os links acessados. Essa abordagem permite que a troca de rotas ocorra sem o recarregamento da página, garantindo uma transição suave e comportamento *SPA* (*Single Page Application*), mesmo em um ambiente de exportação estática.

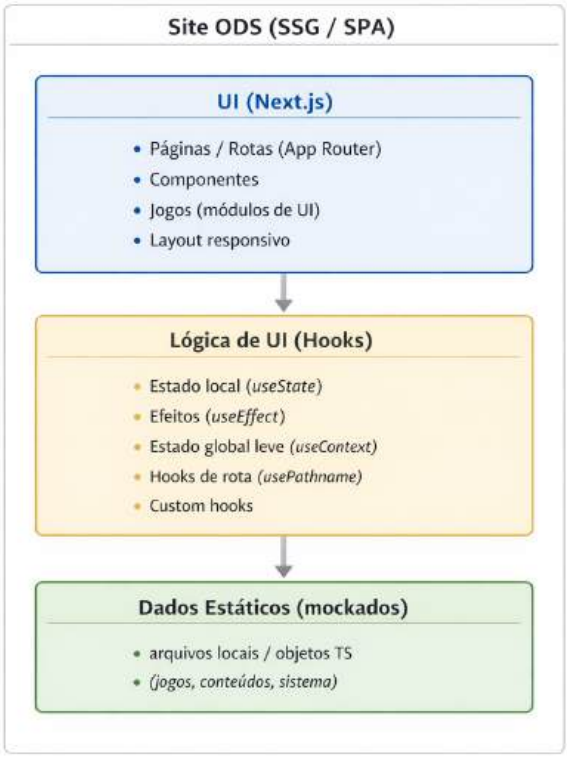


Figura 1. Arquitetura geral do sistema

IV. Discussões e Resultados

A. Arquitetura Tecnológica e Implementação

O sistema Web "Extensão ODS UFERSA" foi desenvolvido utilizando o *framework Next.js* com foco em geração de site estático (SSG). Essa escolha técnica foi fundamental para garantir tempos de carregamento reduzidos e uma arquitetura de *front-end* independente, o que resultou em uma operação eficiente com baixos custos de infraestrutura. A infraestrutura baseada em *AWS Amplify* consolidou a eficiência do fluxo de *Continuous Deployment*, assegurando alta disponibilidade e escalabilidade imediata. Para atender às demandas interativas do projeto, integraram-se animações via *Framer Motion* e o sistema de carrosséis *Embla Carousel*, conferindo à plataforma a fluidez característica de uma *Single Page Application* (SPA) sem comprometer a robustez técnica.

B. Interface, Usabilidade e Funcionalidades

A interface foi concebida sob a metodologia *Atomic Design*, utilizando o suporte do *Tailwind CSS* para garantir modularidade e consistência visual. A decomposição do *layout* em átomos, moléculas e organismos permitiu a criação de um ambiente responsivo e intuitivo, conforme evidenciado na Figura 2. Na prática, a experiência do usuário é guiada por uma página principal de navegação contínua, otimizada por atalhos estratégicos no cabeçalho e rodapé. O núcleo interativo da aplicação concentra-se na seção de jogos (Figura 3), que propõe desafios educativos dedicados ao ensino dos ODS. A adaptação visual entre as versões *desktop* e *mobile* foi priorizada para assegurar que a proposta pedagógica mantivesse sua eficácia em diferentes contextos de uso.

C. Abordagem Pedagógica e Validação

O desenvolvimento foi pautado por uma gestão incremental, utilizando *Git Flow* e o método *Kanban*. Essa estrutura de trabalho facilitou ciclos rápidos de *feedback* e validações periódicas junto ao corpo de participantes do projeto, garantindo que o produto final refletisse as expectativas reais. Embora o projeto não tenha seguido uma fase formal de elicitação de requisitos, a adoção de prototipagem de alta fidelidade foi decisiva para alinhar o *design* aos objetivos pedagógicos propostos. A estratégia de gamificação atua como o principal motor de engajamento, transpondo conteúdos teóricos para um ambiente de aprendizado lúdico. Ao contrário da versão anterior, a implementação atual utiliza a interatividade direta para fomentar a conscientização sustentável. A validação prática confirmou que a dinâmica dos jogos facilita a assimilação dos temas globais, consolidando a plataforma como um recurso de apoio viável tanto para a educação básica quanto para iniciativas de extensão universitária.

D. Evolução do Sistema

O desenvolvimento do sistema foi concebido como um processo contínuo, estruturado em fases evolutivas. O projeto prevê a expansão da plataforma, incluindo a integração futura com aplicações *mobile*, ampliação do conjunto de jogos e

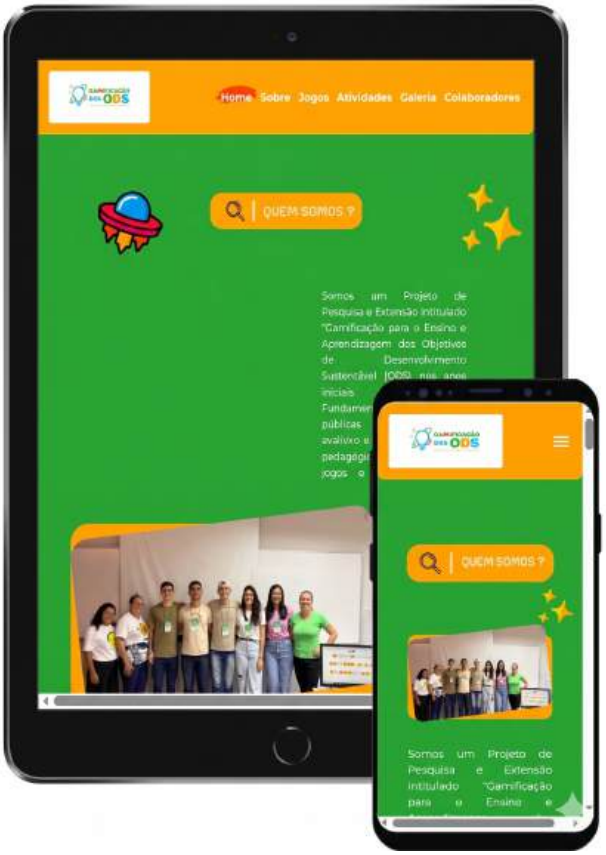


Figura 2. Representação da interface responsiva e adaptação dos componentes baseada em *Atomic Design*.



Figura 3. Visualização da seção de jogos educativos e elementos de interação.

adaptação para diferentes contextos educacionais, especialmente no âmbito de escolas públicas e projetos de extensão universitária. Como resultado, foi publicado o site Gamificação ODS, hospedado de forma contínua (24/7) na plataforma AWS. Atualmente, a aplicação promove o aprendizado acerca dos ODS, atuando como ferramenta de apoio ao ensino na educação básica. O sistema disponibiliza recursos interativos que favorecem o processo de ensino-aprendizagem, por meio

da utilização de jogos educativos, tornando a experiência mais dinâmica e envolvente para os usuários. Além disso, a plataforma incentiva a conscientização e a adoção de práticas sustentáveis, inserindo os alunos em um contexto tecnológico alinhado às demandas educacionais contemporâneas. Dessa forma, a aplicação possibilita o aprendizado de forma lúdica, contribuindo para a disseminação dos princípios relacionados aos ODS e promovendo maior engajamento dos estudantes com as temáticas abordadas.

V. Considerações Finais e Trabalhos Futuros

Este trabalho apresentou o desenvolvimento de uma plataforma Web educacional voltada ao ensino dos ODS, fundamentada em uma abordagem gamificada e orientada ao uso de tecnologias digitais. A proposta buscou integrar conteúdo educacional, interatividade e acessibilidade, contribuindo para a disseminação dos ODS em diferentes contextos de ensino, com destaque para iniciativas de extensão universitária.

A arquitetura adotada mostrou-se alinhada aos objetivos do sistema ao empregar um modelo de *front-end* desacoplado, baseado em tecnologias modernas, com organização modular e distribuição estática. Essa escolha trouxe benefícios como melhor desempenho, maior simplicidade na implantação e facilidade de manutenção, além de proporcionar uma experiência fluida e responsiva ao usuário.

Sob a perspectiva pedagógica, a incorporação da gamificação e de recursos interativos demonstrou potencial significativo ao tornar o processo de ensino-aprendizagem mais dinâmico, participativo e significativo. A combinação entre jogos educativos e conteúdos informativos favorece o engajamento dos usuários e contribui para uma compreensão mais efetiva dos conceitos relacionados à sustentabilidade.

Como resultado principal, destaca-se a implementação do sistema Web funcional, já disponível para acesso público, que serve como base para futuras expansões e experimentações no campo educacional. Além disso, a solução desenvolvida abre espaço para a realização de estudos sobre o impacto do uso de tecnologias digitais no ensino dos ODS.

Apesar dos avanços, o sistema ainda se encontra em evolução. Entre as limitações identificadas estão a ausência de uma versão *mobile* dedicada e a necessidade de ampliação do conjunto de jogos e funcionalidades disponíveis. Destaca-se, ainda, a necessidade de aprofundar a validação da plataforma em ambientes escolares reais.

Como continuidade do trabalho, propõe-se a integração com aplicações *mobile*, a ampliação dos conteúdos educacionais e dos recursos interativos, bem como a realização de estudos empíricos com usuários. Com esses avanços, espera-se consolidar a solução como uma ferramenta efetiva de apoio à educação voltada ao desenvolvimento sustentável.

Referências

[1] ONUBR, "Nações Unidas do Brasil," 2019. [Online]. Available: https://nacoesunidas.org/. [Accessed: Apr. 09, 2026].

[2] P. A. S. Bittencourt and J. P. Albino, "O uso das tecnologias digitais na educação do século XXI," Revista Ibero-Americana de Estudos em Educação, vol. 12, no. 1, pp. 205–214, Jan. 2017.

[3] PAGANI, E. B.S.; MORAES ALVES, J.; CORDEIRO, S. M. A. Segregação socioespacial e especulação imobiliária no espaço urbano. Argumentum, v. 7, n. 1, p. 167-183, 2015.

[4] TREMBLAY, D.; FORTIER, F.; BOUCHER, J. F.; RIFFON, O.; VILLENEUVE, C. Sustainable development goal interactions: An analysis based on the five pillars of the 2030 agenda. Sustainable Development, v. 28, n. 6, p. 1584– 1596, 2020

Gamificação com Hardware de Baixo Custo como Ferramenta de Apoio à Motricidade dos Membros Superiores

Francisca Lorrayne de Lima Santos
Interdisciplinar em Tecnologia da Informação
UFERSA
Pau dos Ferros, Brasil
santosfranciscalorrayne@gmail.com

Francisco Carlos Gurgel da Silva Segundo
Engenharias e Tecnologia
UFERSA
Pau dos Ferros, Brasil
francisco.segundo@ufersa.edu.br

***Resumo*—Os jogos sérios têm sido amplamente utilizados em contextos educacionais, clínicos e terapêuticos por combinarem elementos lúdicos com objetivos funcionais, oferecendo uma experiência motivadora e orientada ao desenvolvimento de habilidades. Este trabalho propõe o desenvolvimento de uma ferramenta baseada em gamificação aplicada como apoio às atividades motoras dos membros superiores, voltada a pessoas com limitações de mobilidade, com foco em usuários com Síndrome de Down. O projeto fundamenta-se em estudos sobre jogos sérios e tecnologias assistivas, propondo o desenvolvimento de um sistema integrado de *hardware* e *software*. A metodologia adotada envolveu a construção de um protótipo vestível de baixo custo, composto por uma luva interativa integrada a um jogo digital embarcado, no qual as ações do usuário controlam elementos do ambiente virtual em tempo real. Os resultados obtidos indicam boa aceitação do sistema e elevado nível de engajamento dos usuários. Conclui-se que a combinação entre tecnologia assistiva, *hardware* interativo e jogo digital representa uma abordagem promissora como ferramenta de apoio às atividades motoras, tornando o processo mais acessível e atrativo.**

***Palavras-chave*—Gamificação; Tecnologia Assistiva; Sistema Integrado; Estimulação Motora; Ambientes Digitais.**

I. Introdução

O comprometimento motor dos membros superiores (MS) impacta diretamente a autonomia e a qualidade de vida dos indivíduos. Algumas pessoas nascem com comprometimento nos membros superiores, especialmente nas mãos, como é o caso de pessoas com Síndrome de Down que frequentemente apresentam hipotonia muscular e hipermobilidade articular. Essa condição limita a capacidade de segurar objetos e de realizar atividades que exigem coordenação motora fina [1].

Pesquisas apontam que as limitações motoras em pessoas com Síndrome de Down podem ser reduzidas com a prática de atividades acompanhadas por um profissional especializado em fisioterapia. A revisão [2] evidencia que a fisioterapia é fundamental para melhorar o tônus, fortalecer a musculatura dos membros superiores e inferiores e favorecer a coordenação motora fina e grossa, promovendo assim uma maior autonomia funcional. Adicionalmente, o estudo [3] salienta que a constância nas práticas terapêuticas resulta em ganhos significativos na estabilidade postural, na força muscular e na execução de movimentos funcionais, sobretudo em crianças com hipotonia e hipermobilidade articular. Esses resultados destacam a importância da adesão à fisioterapia com profissionais preparados para a população que apresenta comprometimento dos membros superiores, o que justifica o desenvolvimento de tecnologias assistivas e abordagens terapêuticas voltadas para essas necessidades. No entanto, a efetividade dessas intervenções depende diretamente da adesão contínua ao tratamento.

As abordagens tradicionais de reabilitação dos membros superiores apresentam problemas, como baixa adesão, devido à monotonia das práticas, o que gera desmotivação do paciente que, em muitos casos, pode comprometer os resultados terapêuticos e levar até mesmo a desistência da fisioterapia. Diante desse cenário, torna-se necessária a adoção de soluções que aumentem a adesão ao tratamento, diminuam a desistência dos pacientes e tornem a fisioterapia mais inovadora e engajada. Consequentemente, espera-se um tratamento mais eficiente e menos desgastante. A aplicação de gamificação e jogos sérios em contextos de apoio à fisioterapia domiciliar permite a personalização dos exercícios, promovendo maior engajamento e adesão à terapia.

A gamificação aliada ao *hardware* apresenta-se como uma alternativa promissora para tornar o processo terapêutico de apoio à reabilitação mais eficiente e menos desgastante. Segundo o estudo [4], a gamificação é regularmente definida como o uso de elementos de jogos em contextos não relacionados a jogos. Diante disso, quando aplicada como ferramenta complementar no contexto da reabilitação dos membros superiores, poderá potencializar o engajamento do paciente, em função do uso de métodos mais lúdicos e menos repetitivos, tornando-se uma importante aliada no apoio ao processo de recuperação funcional.

Apesar dos avanços no uso de gamificação e dispositivos

baseados em *hardware* na melhoria da condição motora, pode-se observar uma limitação na integração entre duas soluções, a de baixo custo e abordagens gamificadas voltadas à motricidade dos membros superiores, confirmando uma lacuna existente no desenvolvimento de ferramentas acessíveis, ágeis e interativas neste contexto.

Dessa forma, este trabalho tem como objetivo desenvolver e analisar o uso da gamificação em conjunto com *hardware* de baixo custo como ferramenta de apoio à motricidade dos membros superiores, por meio da análise de engajamento, usabilidade e interação dos usuários com o sistema.

Como objetivos específicos, buscam-se: (i) desenvolver um protótipo vestível de baixo custo; (ii) integrar o dispositivo a um jogo digital; (iii) analisar qualitativamente a aceitação e o engajamento dos usuários a partir de observações durante o uso, considerando critérios como nível de interação, tempo de adaptação e facilidade de uso; (iv) identificar limitações e potencialidades da proposta com base nos testes preliminares realizados em ambiente controlado.

A solução proposta baseia-se na aplicação de elementos lúdicos, nos quais o paciente pode controlar o personagem com os próprios movimentos e assim estimular os movimentos dos membros superiores, como flexão e extensão dos dedos, além da coordenação motora fina, favorecendo o processo de adesão à fisioterapia, tornando o processo terapêutico mais dinâmico e eficaz. Desse modo, pretende-se contribuir para a melhoria da qualidade de vida dos pacientes, oferecendo alternativas inovadoras, que integram o uso da tecnologia como ferramenta de apoio ao tratamento.

II. Trabalhos Relacionados

A. Reabilitação motora dos membros superiores

A reabilitação motora dos membros superiores é imprescindível para o processo de recuperação funcional de pessoas com comprometimentos motores, impactando diretamente sua autonomia e qualidade de vida. Nesse contexto, [2] apontam que a fisioterapia é fundamental para melhorar o tônus, fortalecer a musculatura dos membros superiores e inferiores e favorecer a coordenação motora fina e grossa, promovendo maior autonomia funcional.

Adicionalmente, [3] destacam que a constância nas práticas terapêuticas resulta em ganhos significativos na estabilidade postural, na força muscular e na execução de movimentos funcionais, sobretudo em crianças com hipotonia e hipermobilidade articular. Esses resultados evidenciam a importância da adesão à fisioterapia com profissionais preparados para atender indivíduos com comprometimento dos membros superiores.

Apesar dos benefícios, a eficácia dessas intervenções depende da adesão dos pacientes, que ainda representa um desafio no contexto terapêutico.

B. Adesão à fisioterapia e gamificação na reabilitação motora

Apesar dos benefícios da fisioterapia, as abordagens tradicionais de reabilitação dos membros superiores apresentam limitações, como a baixa adesão decorrente da monotonia das práticas, o que pode gerar desmotivação e comprometer os resultados terapêuticos, levando, em alguns casos, à interrupção do tratamento. Nesse contexto, a gamificação surge como uma ferramenta de apoio à adesão ao tratamento.

Segundo [4], a gamificação é definida como o uso de elementos de jogos em contextos não relacionados a jogos. Quando aplicada como ferramenta complementar no contexto da reabilitação dos membros superiores, pode potencializar o engajamento dos pacientes por meio de abordagens mais lúdicas e interativas, contribuindo para o processo de recuperação funcional.

Entretanto, sua aplicação em contextos terapêuticos ainda depende da adaptação às limitações motoras dos usuários e da integração com dispositivos físicos capazes de capturar os movimentos de forma eficiente.

C. Soluções baseadas em hardware para fisioterapia

Diversas soluções baseadas em *hardware* já são utilizadas no apoio à motricidade, especialmente em relação aos movimentos finos dos membros superiores. Entre essas abordagens, destaca-se a utilização de luvas inteligentes, como a proposta de [5], que investiga o impacto de um sistema digital no apoio à reabilitação motora após Acidente Vascular Cerebral (AVC). O estudo evidencia a eficácia do uso de dispositivos interativos no processo terapêutico.

Outro exemplo relevante é o *PARS (Portable Arm Rehabilitation System)*, que apresenta uma solução acessível para terapias dos membros superiores utilizando *hardware* de baixo custo [6]. Essas abordagens evidenciam o potencial do uso de dispositivos físicos e sensores na captura de movimentos e no auxílio às atividades fisioterapêuticas.

Contudo, apesar dos avanços, essas soluções apresentam limitações relacionadas ao custo, à complexidade de implementação e à necessidade de acompanhamento especializado, o que pode dificultar sua adoção em contextos com poucos recursos.

A partir dessa análise, observa-se uma limitação na integração entre soluções de baixo custo, dispositivos físicos acessíveis e abordagens baseadas em gamificação no contexto da reabilitação motora dos membros superiores, evidenciando uma lacuna na literatura. Dessa forma, o presente trabalho busca contribuir ao propor uma solução que combina esses elementos de maneira integrada e acessível.

III. Metodologia

O presente trabalho consiste em uma pesquisa aplicada, de abordagem qualitativa e caráter exploratório. Dessa forma, foram realizados testes na APAE, uma associação sem fins lucrativos que atende usuários com diagnósticos variados, como Síndrome de Down, transtorno do espectro do autismo e deficiência intelectual, com cerca de doze (12) participantes. Cada teste consistiu na utilização da luva sensorizada integrada ao jogo digital, na qual os participantes realizaram movimentos de abertura e fechamento das mãos, com o objetivo de estimular a coordenação motora fina e interagir com o sistema.

A coleta de dados foi realizada por meio de observação direta durante os testes na APAE, considerando os seguintes critérios: engajamento, facilidade de uso, tempo de adaptação e resposta aos estímulos. Os resultados obtidos foram analisados de forma qualitativa, com o intuito de identificar padrões, como por exemplo: comportamentos, limitações e potencialidades da proposta no contexto terapêutico.

IV. Funcionamento do Sistema

No desenvolvimento do circuito da luva foi utilizado uma placa microcontroladora Arduino com três *push buttons* conectados em uma *protoboard*. Eles foram ligados diretamente aos pinos digitais 2, 4 e 8, onde foram configurados como entradas, utilizando o *Ground* (GND) como referência.

Como ilustrado na Fig. 1, o sistema integra a luva sensorizada, o circuito eletrônico e o ambiente de jogo digital.



Fig. 1. Protótipo completo do sistema desenvolvido.

De modo geral, o acionamento do sistema ocorre quando os dedos entram em contato com as placas condutoras fixadas à luva, conectando o pino ao nível lógico baixo. Essa alternativa foi adotada para manter a complexidade o mais baixa possível, já que não foram utilizados resistores de *pull-up* ou *pull-down* externos. Assim, o funcionamento do circuito depende do estado interno do pino: ele é lido como *high* quando as mãos estão abertas e *low* quando os dedos pressionam a placa de contato colada na luva. O circuito utilizou o *pull-up* interno do Arduino, eliminando a necessidade de resistores externos. Dessa forma, o pino permanece em *high* normalmente e, ao pressionar, seu estado muda para *low*, conectando-se diretamente ao GND do Arduino.

A luva foi escolhida devido a sua adaptabilidade à anatomia da mão, o que proporciona maior liberdade durante a interação com o sistema. Durante a utilização da luva, são estimulados vários movimentos funcionais do membro superior, descritos tecnicamente segundo a nomenclatura da fisioterapia. Em síntese, o principal movimento exigido pelo jogo corresponde à flexão e extensão dos dedos, que é feita de forma repetitiva durante a abertura e o fechamento das mãos o que aciona as placas de contato. O mesmo está diretamente associado à preensão palmar, visto que o contato entre as superfícies condutoras vai de acordo com a capacidade do usuário de envolver e pressionar os dedos contra a palma da mão, habilidade fundamental para a execução de atividades funcionais do cotidiano [7].

A construção da luva foi pensada de forma que permitisse que os elementos eletrônicos não se tornassem desconfortáveis ao usuário. Com isso, cada dedo da luva passou a receber uma pequena tira de velcro, permitindo que o contato entre as superfícies atue como um gatilho para as placas de contato, que são responsáveis por enviar os comandos ao Arduino, garantindo, assim, melhor estabilidade e execução dos movimentos, além de permitir ajustes de acordo com o formato anatômico da mão.

O código foi estruturado de forma modular, permitindo fácil manutenção e futuras expansões, como a inclusão de novos sensores e mecânicas de jogo.

V. Resultados e Discussão

Os resultados obtidos neste trabalho devem ser analisados considerando o caráter exploratório e qualitativo da pesquisa. A análise realizada não teve como propósito avaliar ganhos funcionais específicos dos membros superiores, mas sim identificar aspectos relacionados à aceitação do dispositivo, como o engajamento dos usuários e o potencial terapêutico da proposta no contexto da fisioterapia.

A aplicação da luva na prática demonstrou que o sistema apresenta funcionamento estável e resposta adequada aos estímulos realizados pelos usuários. Em síntese, a integração entre a luva sensorizada e o jogo digital mostrou-se eficiente, permitindo que os movimentos de flexão e extensão dos dedos fossem corretamente traduzidos em comandos dentro do ambiente virtual.

Como apresentado na Fig. 2, observa-se a interação dos participantes com a luva sensorizada.



Fig. 2. Testes do protótipo do sistema realizados na APAE, evidenciando a interação dos usuários com a luva sensorizada e o ambiente de jogo digital.

Em geral, observou-se que alguns dos participantes apresentaram dificuldades para movimentar os dedos ao tentar

abrir e fechar as mãos, mas persistiram e obtiveram um bom desempenho. Dessa forma, esse comportamento reforça o potencial da gamificação como estratégia motivacional no contexto terapêutico.

Mesmo com a aceitação positiva da luva, também foram identificadas algumas limitações relacionadas às características motoras e cognitivas dos usuários. Entre elas, destacou-se a necessidade de maior tempo para compreensão das regras do jogo, bem como variações no tempo de resposta aos estímulos visuais e sonoros. Alguns alunos demonstraram limitações na coordenação motora fina, necessitando de auxílio inicial para colocar as luvas e se adaptar ao uso do dispositivo. Notou-se ainda variação no nível de atenção sustentada ao longo da atividade, influenciando o desempenho durante a interação com o jogo.

A análise de custo da luva sensorizada evidencia a viabilidade do desenvolvimento de uma solução tecnológica acessível, utilizando componentes de baixo custo e fácil obtenção no mercado. Conforme apresentado na Tabela 1, o investimento total para a construção do protótipo foi de 81,25 reais, valor significativamente inferior ao de sistemas comerciais com funcionalidades semelhantes.

Tabela I
TABELA DE CUSTO ESTIMADO DA LUVA

Item	Descrição	Unitário (R$)	Total (R$)
1	Luva de pano	10,00	20,00
2	Arduino	35,00	35,00
3	Jumpers macho-fêmea	1,00	7,00
4	Cabo de rede	3,00	6,00
5	Placas de contato em cobre	0,50	2,50
6	Caixa plástica	7,00	7,00
7	Solda estanho	2,50	2,50
8	Velcro	0,50	0,25
9	Cola quente	1,00	1,00
		Total estimado	**81,25**

Portanto, a luva apresenta-se como uma alternativa promissora para complementar práticas fisioterapêuticas tradicionais, tornando-as mais atrativas e interativas.

VI. CONCLUSÃO

O trabalho teve como objetivo desenvolver um dispositivo vestível que integra conceitos de gamificação como recurso de apoio ao processo terapêutico dos membros superiores, buscando tornar o processo fisioterapêutico mais lúdico, acessível e motivador. A proposta pretende contribuir para o aumento da adesão ao tratamento, reduzindo desistências ao oferecer uma experiência mais interativa e alinhada às necessidades dos pacientes.

A luva gamificada mostrou-se uma ferramenta relevante nesse contexto, pois possibilita que métodos tradicionais de fisioterapia se tornem mais dinâmicos e atrativos. Dessa forma, o paciente passa a realizar os movimentos terapêuticos de maneira mais leve e envolvente, muitas vezes percebendo menos a repetitividade dos exercícios. Essa característica favorece a continuidade do tratamento e amplia o engajamento.

Apesar dos resultados positivos, foram identificadas algumas limitações no processo inicial de adaptação dos usuários ao sistema. Diante disso, pretende-se, como trabalhos futuros, desenvolver versões da luva que atendam a diferentes perfis de usuários, bem como explorar a utilização dos contatos em outros membros do corpo. Além disso, propõe-se a criação de novas abordagens de jogos, juntamente com otimizações e melhorias no hardware desenvolvido, visando ampliar sua compatibilidade com diferentes dispositivos, como diferentes formas de entrada em televisores.

Adicionalmente, o desenvolvimento do jogo buscou criar um ambiente seguro, divertido e de baixo custo para a execução dos exercícios. A solução proposta demonstra potencial de aplicação em diferentes faixas etárias, tornando-se uma alternativa acessível e capaz de complementar práticas já utilizadas no processo terapêutico motor.

Ressalta-se que os testes realizados envolveram majoritariamente pessoas com Síndrome de Down, o que delimita o escopo dos resultados apresentados. Assim, futuras investigações poderão ampliar a aplicação do sistema para outros públicos, avaliando sua eficácia em diferentes condições clínicas.

REFERÊNCIAS

[1] GE. L. Guimarães et al., "Características motoras e cognitivas na Síndrome de Down: desafios e possibilidades na educação inclusiva," Revista Brasileira de Educação Especial, vol. 25, no. 4, pp. 653–670, 2019.

[2] G. do C. Mariz, K. M. da S. R. Silva, and A. G. Moraes, "Efeitos da equoterapia na reabilitação de praticantes com Síndrome de Down," REAL – Revista de Educação e Letras, vol. 3, no. 1, 2024.

[3] M. L. Santos and P. P. Lamb, "Efeitos da intervenção fisioterapêutica no desenvolvimento motor de crianças com Down Syndrome: a literature review," Research, Society and Development, vol. 12, no. 12, 2023.

[4] S. Deterding, "Beyond classical definition: the non-definition of gamification," SN Computer Science, vol. 2, no. 3, pp. 1–9, 2021, doi: 10.1007/s42979-021-00472-4.

[5] J. Kim *et al.*, "A Smart Glove Digital System Promotes Restoration of Upper Limb Motor Function," *Journal of Clinical Medicine*, vol. 11, no. 24, p. 7343, 2022. [Online]. Available: https://www.mdpi.com/2077-0383/11/24/7343. [Accessed: Dec. 04, 2025].

[6] M. Koçak and E. Gezgin, "PARS: low-cost portable rehabilitation system for upper arm," *HardwareX*, vol. 11, e00299, 2022.

[7] C. E. Lang, S. L. DeJong, and J. A. Beebe, "Recovery of thumb and finger extension and its relation to grasp performance after stroke," *Journal of Neurophysiology*, vol. 102, no. 1, pp. 451–459, 2009. [Online]. Available: https://pmc.ncbi.nlm.nih.gov/articles/PMC2712280/. [Accessed: Dec. 18, 2025].

[8] J. Urbina-Alarcón, A. Angulo, V. E. Abarca, and D. A. Elias, "Evaluation of wrist and finger function in healthy children through music-based video game therapy," *Journal of NeuroEngineering and Rehabilitation*, vol. 22, no. 1, p. 198, 2025, doi: 10.1186/s12984-025-01742-5. [Online]. Available: https://pubmed.ncbi.nlm.nih.gov/41023708/. [Accessed: Dec. 18, 2025].

Deep Learning Algorithm for Hypertension Prediction using Hyperparameter Optimization via Latin Hypercube Sampling in High-Performance Computing Environments

Bruno Victor Paiva da Silva
PPgEEC
UFRN
Natal, RN, Brazil
bruno.silva.704@ufrn.edu.br

Jhoan Fernandes de Oliveira
DETEC
UFERSA
Pau dos Ferros, RN, Brazil
jhoan.oliveira@alunos.ufersa.edu.br

Felipe Hidequel Santos da Silva
PPgEEC
UFRN
Natal, RN, Brazil
felipe.santos.087@ufrn.edu.br

Thiago Vinicius Paiva da Silva
DETEC
UFERSA
Pau dos Ferros, RN, Brazil
thiago.silva80312@alunos.ufersa.edu.br

Artur Santos Nogueira
DETEC
UFERSA
Pau dos Ferros, RN, Brazil
artur.nogueira32975@alunos.ufersa.edu.br

Walber Jose Adriano Silva
DETEC
UFERSA
Pau dos Ferros, RN, Brazil
walber.silva@ufersa.edu.br

***Abstract*—Hypertension is a chronic condition characterized by persistently elevated blood pressure. Due to its asymptomatic nature in the early stages, it is frequently underdiagnosed, leading to diagnosis only after the occurrence of cardiovascular complications. This silent progression highlights the need for early diagnostic tools capable of identifying at-risk individuals before irreversible damage occurs to target organs. To fill this clinical gap, this study proposes a Deep Learning Algorithm for Hypertension Prediction based on clinical variables. A Hyperparameter Optimization process was conducted to define the architecture and adjust the predictive capacity. The search space was systematically explored using Latin Hypercube Sampling (LHS) to define the neuron configuration, learning rate, dropout, and L2 regularization. Due to the computational complexity of evaluating multiple neural network architectures through 10-fold Stratified Cross-Validation, the optimization pipeline was implemented in High-Performance Computing (HPC) environments. The model achieved an accuracy of 90.21% and an F1-Score of 90.19%, demonstrating the balance achieved between precision and recall.**

***Index Terms*—deep learning, hypertension, high-performace computing, otimization, latin hypercube.**

I. Introduction

Hypertension is a chronic condition defined by elevated blood pressure [1]. It becomes more prevalent with aging and is considered a multifactorial disease, with oxidative stress being one of its main contributing factors [2]. According to Mills, Stefanescu, and He (2020) [3], hypertension is a leading cause of cardiovascular diseases and premature mortality worldwide. The progression of the disease is often asymptomatic, which leads to late diagnosis, frequently occurring only after complications in target organs have developed.

The fact that the disease begins before it is diagnosed highlights the importance of early detection. Identifying hypertension in its initial stages enables timely intervention, improving disease management and reducing mortality rates.

Artificial Intelligence (AI) has emerged as a powerful technology capable of analyzing large volumes of healthcare data to identify complex and predictive patterns [4].

Within this context, Machine Learning (ML), a subfield of AI, provides a set of techniques for building predictive models. Among these, Artificial Neural Networks (ANNs) represent a class of computational models inspired by the functioning of the human brain.

ANN architectures vary according to the type of data and tasks they address. Convolutional Neural Networks (CNNs) are particularly effective in processing spatial data, especially images, while Recurrent Neural Networks (RNNs) are designed for sequential data, such as text [5].

Among these architectures, the Multilayer Perceptron (MLP) stands out as a general-purpose model, commonly applied to classification and regression problems involving structured data. It is also recognized as one of the most versatile neural network architectures in terms of applicability [6].

MLPs have been widely used in diagnostic applications. However, the complexity of healthcare data and the need for more robust processing motivate the exploration of advanced approaches. In this context, the present study focuses on the development of a Multilayer Perceptron model optimized through structured hyperparameter tuning techniques, supported by high-performance computing resources, aiming to improve the accuracy and generalization of hypertension risk

prediction.

II. Theoretical review

A. Hypertension

Hypertension, also known as high blood pressure, is a condition in which the blood pressure in the arteries remains persistently elevated. According to Williams et al. (2018) [7], hypertension can be classified into three stages based on blood pressure levels, the presence of cardiovascular risk factors, hypertension-mediated organ damage, or comorbidities. The first stage, termed uncomplicated, corresponds to hypertensive patients without target-organ damage or associated diseases. The second stage, termed asymptomatic disease, is characterized by the presence of target-organ damage, stage 3 chronic kidney disease, or diabetes mellitus without organ damage. The third stage, considered the most advanced, is called established disease and is associated with the presence of established cardiovascular disease, chronic kidney disease of stage 4 or higher, or diabetes mellitus with target-organ damage.

B. Neural Network

In risk classification, blood pressure levels are associated with various additional factors, such as advanced age, excessive salt consumption, sedentary lifestyle, among others. To perform an aggregated analysis of these factors, computational methods such as Artificial Neural Networks (ANNs) can be applied.

The first artificial neural network architecture was proposed in 1943 by McCulloch and Pitts, designed as a simplified computational model intended to represent the cooperative functioning of biological neurons in animal brains. This model aimed to demonstrate the capacity of artificial neurons to perform complex calculations based on propositional logic [8].

The Multilayer Perceptron (MLP) is one of the simplest ANN architectures (Géron, 2021). An MLP is composed of an input layer, one or more hidden layers, and a final layer called the output layer. The layers closest to the input layer are referred to as lower layers, while the layers closer to the output layer are called upper layers. Except for the output layer, all other layers are fully connected.

MLPs are generalizations of linear models that perform multiple processing steps to reach a decision [9], in which the prediction made by a linear regression is presented in Equation 1.

$$\hat{y} = w_0 \cdot x_0 + w_1 \cdot x_1 + \cdots + w_p \cdot x_p + b \qquad (1)$$

Where $\hat{y}$ is a weighted sum of the input features x_0 to x_p, weighted by the learned coefficients w_0 to w_p. In an MLP, the process of calculating weighted sums is repeated multiple times: first, computing hidden units that represent an intermediate processing stage, which are then recombined using weighted sums to generate the final result.

III. Related works

This section presents scientific publications related to the topic of this research. The work of Zhao et al. (2021) [10], is presented, in which the authors predict hypertension risks using machine learning models and compare their performance . Next, we present the work of Marin and Goga [11], in which hypertension prediction is performed using a dataset composed of different population groups and four machine learning algorithms. Moving on, we have the work of Dond (2025) [12] and Gong, Chen and Ding (2023) [13] in which they explore machine learning techniques related to blood pressure measurements and lifestyle habits.

Detailing the work, the study by Zhao et al. (2021) investigates the prediction of hypertension risk, a widely prevalent chronic condition, using machine learning models capable of operating with simple and easily collected risk factors. Using a dataset composed of 29,700 samples obtained from physical examinations, the authors initially selected the main risk factors through univariate logistic regression.

Based on these selected variables, four algorithms Random Forest, CatBoost, a multilayer perceptron (MLP) neural network, and logistic regression—were optimized using 10-fold cross-validation for hyperparameter tuning. The final performance was evaluated using metrics such as the area under the curve (AUC), which measures the model's overall ability to discriminate between classes, as well as accuracy, sensitivity, and specificity, which measures the model's ability to correctly identify negative samples in the test set.

Among the evaluated models, Random Forest achieved the best performance, as presented in Table I.

TABLE I
Performance metrics reported by Zhao et al. [10] for a classical machine learning model evaluated on a dataset of 29,700 samples.

Metric	Value
Accuracy	82%
Sensitivity	83%
Specificity	81%
AUC	92%

The study by Marin and Goga (2019) aimed to apply machine learning techniques to identify hypertension across different population groups, including the general population, hypertensive patients, and pregnant women with or without preeclampsia. This work utilized public datasets from the University of Massachusetts Amherst. The study by Dond (2025) explores the use of machine learning techniques to detect hypertension, leveraging the capability of algorithms to analyze large datasets, identify patterns, and make predictions based on various clinical and lifestyle factors. The patient data include blood pressure measurements, demographic information, and lifestyle habits.

Gong, Chen, and Ding (2023) propose a more reliable method for hypertension prediction based on non-invasive signals, such as electrocardiogram (ECG) and photoplethysmo-

gram (PPG). The authors employ causal inference techniques to select variables that are truly related to hypertension, rather than relying solely on correlation. The study is based on data from the National Health and Nutrition Examination Survey. To obtain the results, four machine learning algorithms were employed. The first, Gaussian Naive Bayes, is a probabilistic classifier. The second and third, logistic regression and Random Forest, are based on statistical modeling and ensemble learning, respectively. Finally, Support Vector Machines (SVM) operates by finding an optimal decision boundary between data classes. The results showed that the models were effective in identifying individuals without hypertension but correctly classified only approximately half of the cases in which hypertension was present, indicating a limitation in sensitivity for positive detections. Nevertheless, the authors emphasize that the automatic detection of abnormal health parameters using machine learning techniques is an important tool for monitoring and preventing critical health issues across different population groups.

Based on the reviewed studies, it can be observed that there is extensive literature employing machine learning techniques to classify the risk of hypertension using selected clinical and lifestyle-related parameters, with the support of high-performance computing tools to identify optimal hyperparameters. These studies generally report performance results above 80%, often focusing on the application of deep learning algorithms. The primary objective across these works is the early detection of hypertension risk, enabling preventive interventions at early stages.

IV. Development

The methodology of this work followed the practical steps of a complete machine learning project, as described in Chapter 2 of [14].

A. Problem overview

In the problem overview phase, the aim was to understand and establish the scientific and practical motivation for the study. The main objective of the method is to develop a deep learning model to detect the risk of hypertension in its early stages.

B. Data acquisition

From the second stage onwards, we use a dataset from a public database, which addresses clinical data of patients. The database used was provided by the Kaggle platform and is called: Hypertension Risk Prediction Dataset. It contains, among the data provided, 1985 records, 2 binary classes, and 11 influence features generated from clinical insights and public health data patterns. The variables in the database are:

1) *Age*: Patient's age (in years);
2) *Salt_Intake*: Daily salt intake (in grams);
3) *Stress_Score*: Scale from 0 to 10 measuring psychological stress level;
4) *BP_History*: Previous blood pressure history: normal, prehypertension, hypertension;
5) *Sleep_Duration*: Average number of hours of sleep per day;
6) *BMI*: Body Mass Index (BMI), a measure of obesity based on weight/height;
7) *Medication*: Type of medication used (None, Beta-blocker, Diuretic, ACE inhibitor, Other);
8) *Family_History*: Family history of hypertension;
9) *Exercise_Level*: Level of physical activity (Low, Moderate, High);
10) *Smoking_Status*: Smoker or Non-smoker;
11) *Has_Hypertension*: Presence of hypertension;

C. Data exploration and visualization

In stage 3, data exploration, the objective was to understand the distribution of features and identify possible class imbalances. The dataset was loaded using the pandas library, chosen because, according to Wes (2013), it is widely recognized as one of the main data manipulation tools in Python [15]. Pandas enables vectorized operations, the generation of descriptive statistics, and the creation of visualizations directly from the data.

In the context of this work, pandas was used to load the hypertension prediction dataset, analyze the class distribution, and identify imbalances. Class balance was evaluated using a distribution graph, as illustrated in the Figure 1.

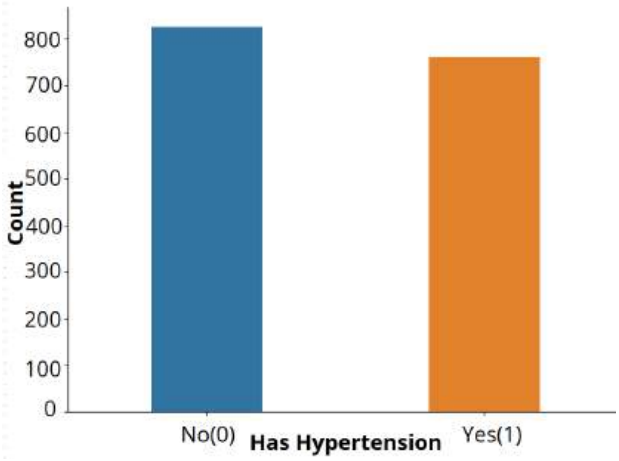


Fig. 1. Distribution of classes before the application of the SMOTE technique, illustrating the imbalance between the binary classes (No and Yes) for hypertension prediction.

D. Data preparation for Machine Learning algorithms

After data visualization, transformations were applied to the available dataset in order to standardize and preprocess the data for model training. Initially, categorical variables were converted into numerical format using one-hot encoding, and the target variable values "Yes" and "No" were mapped to 1 and 0, respectively. This conversion is necessary because machine learning models operate on numerical values. Next, the data were split into training and testing sets using the

train_test_split function from the scikit-learn library [16], which was divided into 80% training data and 20% test (validation) data, in order to evaluate the model's generalization capability. The training set was used to learn patterns, while the test set was kept separate for validation. This separation helps mitigate issues such as overfitting.

During the preparation of the training set, a class imbalance was observed in the target variable, with a predominance of samples from patients without hypertension. To address this issue, the Synthetic Minority Over-sampling Technique (SMOTE) [17] was applied, which generates synthetic samples of the minority class based on interpolation between nearest neighbors. This approach balances the classes and improves the model's ability to correctly identify positive hypertension cases.

Finally, the data were scaled using the StandardScaler method, also from the scikit-learn library. This procedure transforms each feature to have zero mean and unit variance, preserving the original data distribution while ensuring that all features contribute proportionally during the training process.

E. Model selection and training

In step 5, the architecture of the machine learning model responsible for making predictions was defined. A multilayer perceptron (MLP) network was selected due to its ability to model non-linear relationships between variables and adapt to different patterns present in the data. The model was implemented using the TensorFlow and Keras libraries [18], which are widely used in deep learning applications. This choice provided adequate control over network layers, activation functions, and training parameters, in addition to offering support for acceleration via Graphics Processing Units (GPUs), thereby reducing processing time.

1) Neural network architecture construction: To define the optimal deep learning model architecture, a structured hyperparameter optimization process was implemented using the Optuna framework [19]. The search space was explored using the Latin Hypercube Sampling (LHS) technique [20], which ensures a statistically uniform exploration of the parameter space.

A total of 30 independent trials were conducted, in which the algorithm simultaneously optimized the number of neurons (32 to 128), the learning rate (5×10^{-4} to 5×10^{-3}), the dropout rate (0.2 to 0.5), and the L2 regularization coefficient (10^{-4} to 10^{-2}).

To perform the model validation, a 10-fold Stratified Cross-Validation approach was adopted. This stratified method ensures that the proportional representation of the 'Yes' and 'No' classes is maintained across all 10 folds, avoiding biased training splits. Furthermore, instead of using a traditional exhaustive Grid Search, which is computationally prohibitive for continuous hyperparameter ranges, the search space was explored using the Latin Hypercube Sampling (LHS) technique [20]. The objective of the search was to maximize the model's F1-score across the folds, ensuring robust generalization. The model was structured with dense layers using the ReLU (Rectified Linear Unit) activation function in the hidden layers, aiming to mitigate the vanishing gradient problem and accelerate convergence. For the output layer, the sigmoid activation function was used, which is suitable for binary classification tasks. To prevent overfitting and optimize training time, an early stopping mechanism was adopted, monitoring the validation loss. Training was interrupted if no improvement was observed after a defined patience period, ensuring that the model retained the weights corresponding to its best generalization performance.

F. Fine-tuning

In stage 6, fine-tuning, techniques established in the literature were employed to mitigate overfitting. In particular, the dropout technique was used, which consists of randomly deactivating neurons during training, forcing the network to learn more robust and independent representations. This approach was combined with L2 regularization (weight decay), which penalizes large weights, thereby smoothing the model's decision function.

G. Solution presentation

In step 7, after training and fine-tuning the model, the obtained results were organized and presented for interpretation. In this stage, the objective was to validate the model's performance and demonstrate the effectiveness of the applied techniques. Evaluation metrics such as accuracy, precision, recall, and F1-score were used, along with the confusion matrix. These metrics enable a detailed analysis of the model's behavior, considering both correct and incorrect predictions, while the confusion matrix provides a class-wise breakdown of predictions, highlighting true positives, false positives, true negatives, and false negatives.

H. System deployment, monitoring, and maintenance

The final deployment phase consisted of structuring the computational environment to ensure reproducibility on HPC infrastructures. The execution of multiple neural network architectures requires significant computational resources, making parallel programming paradigms essential to distribute the workload efficiently, a foundational concept detailed by Pacheco (2011) [21]. The model was encapsulated using automation scripts managed by SLURM, which handle resource allocation, execution environment initialization, and job monitoring. The system was configured to generate detailed performance logs, enabling the tracking of metric convergence during training. Finally, maintenance is supported by storing the optimized hyperparameters in configuration files, allowing the model to perform inference on new data without requiring the re-execution of the optimization pipeline.

V. Results

To obtain the results, experiments were conducted on the supercomputer of the Federal University of Rio Grande do Norte, at NPAD (Nucleo de Processamento de Alto Desempenho), using a computational node from the AMD 512

partition with 256 GB of RAM. Based on the model training and the Figure 2, it was possible to obtain the loss function graph, which represents how much the model is wrong in its predictions.

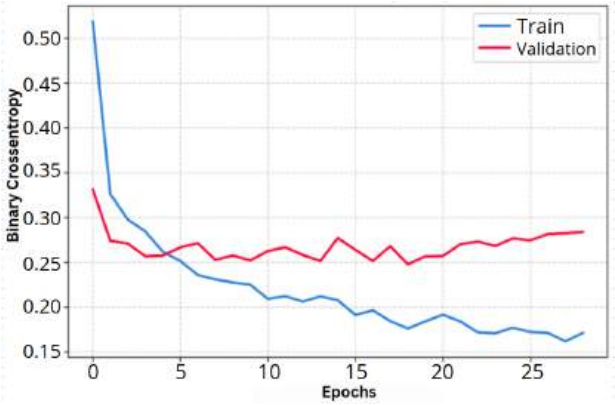


Fig. 2. Graph of the loss function, showing the lines during the periods relating to training and validation.

Additionally, the evolution of accuracy over the training epochs was recorded, as illustrated in the Figure 3, showing the accuracy values for both the training and validation sets.

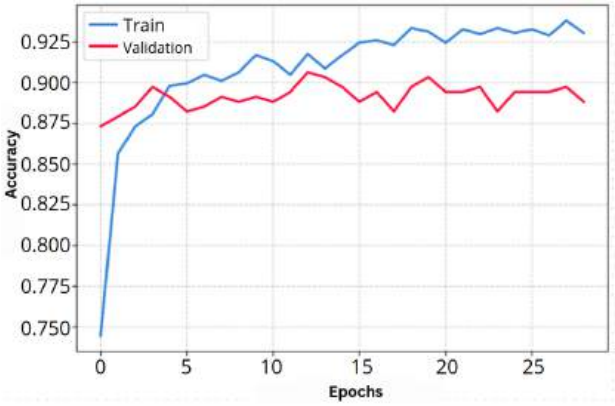


Fig. 3. Graph of the acurracy, showing the lines during the periods relating to training and validation.

It is observed that the loss decreases consistently, converging to a stable level for both the training and validation sets, indicating that the model has learned representative patterns from the data without exhibiting underfitting. Simultaneously, the accuracy shows an increasing trend, stabilizing at values above 90%. The close alignment between the training and validation curves demonstrates the effectiveness of the regularization techniques (dropout and L2) as well as the early stopping mechanism, ensuring that the model achieves robust generalization without showing signs of overfitting or divergence, even after extended training.

Through cross-validation, more reliable estimates of the model's performance were obtained for the accuracy, precision, recall, and F1-score metrics, reducing the dependence on a single data split. Table II presents the values of these metrics.

TABLE II
MODEL PERFORMANCE METRICS OBTAINED USING STRATIFIED 10-FOLD CROSS-VALIDATION.

Metric	Value
Accuracy	0.9021
Precision	0.9030
Recall	0.9008
F1-Score	0.9019

From Table II, it can be observed that the evaluation metrics are well balanced, indicating consistent model performance. The model achieved accuracy, precision, recall, and F1-score values of approximately 90%. In addition to the metrics obtained through cross-validation, the model's confusion matrix was also computed. As shown in Figure 4, it provides a detailed view of correct and incorrect predictions, including true positives, false positives, true negatives, and false negatives.

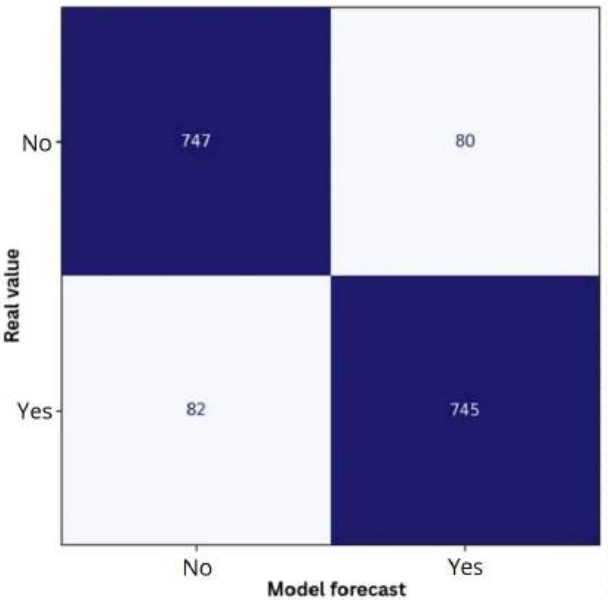


Fig. 4. Matrix Confusion (10 Folds).

From Figure 4, it can be observed that most predictions are concentrated along the main diagonal, corresponding to true positives and true negatives. In contrast, the off-diagonal elements indicate a smaller number of false positives and false negatives. Overall, the model produced 1,492 correct predictions and 162 incorrect predictions, demonstrating strong classification performance.

VI. CONCLUSION

This work aimed to develop a Multilayer Perceptron neural network model using the Optuna hyperparameter optimizer

and the Latin Hypercube Sampling technique to find the best combination of hyperparameters. The model's efficiency was evaluated using classification metrics, specifically assessing the number of correct and incorrect predictions, precision, recall, and F1-score. Results above 90% indicate that the model achieved a high rate of correct predictions compared to false negatives and positives. Based on the results obtained, future work proposes testing the model with larger datasets, as well as using other optimization strategies, such as Bayesian Optimization. Furthermore, to address the limitations of generating synthetic medical data via SMOTE, future studies will implement class weighting directly into the loss function to handle data imbalance dynamically. Another contribution would be to utilize traditional algorithms known in the literature, such as Random Forest, Decision Tree, and Gradient Boosting Machine, in an ensemble analysis.

VII. Acknowledgments

I would like to thank the LAPPS (Laboratory of Parallel Architectures for Signal Processing) coordination for granting NPAD access to conduct scientific research.

References

[1] J. Krzemińska, M. Wronka, E. Młynarska, B. Franczyk, and J. Rysz, "Arterial hypertension—oxidative stress and inflammation," *Antioxidants*, vol. 11, no. 1, p. 172, 2022.

[2] A. J. Donato, D. R. Machin, and L. A. Lesniewski, "Mechanisms of dysfunction in the aging vasculature and role in age-related disease," *Circulation research*, vol. 123, no. 7, pp. 825–848, 2018.

[3] K. T. Mills, A. Stefanescu, and J. He, "The global epidemiology of hypertension," *Nature reviews nephrology*, vol. 16, no. 4, pp. 223–237, 2020.

[4] E. J. Topol, "High-performance medicine: the convergence of human and artificial intelligence," *Nature medicine*, vol. 25, no. 1, pp. 44–56, 2019.

[5] Y. LeCun, Y. Bengio, and G. Hinton, "Deep learning," *nature*, vol. 521, no. 7553, pp. 436–444, 2015.

[6] F. A. Gomide, "Redes neurais artificiais para engenharia e ciências aplicadas: curso prático," 2012.

[7] B. Williams *et al.*, "2018 ESC/ESH Guidelines for the management of arterial hypertension: The Task Force for the management of arterial hypertension of the European Society of Cardiology (ESC) and the European Society of Hypertension (ESH)," *European Heart Journal*, vol. 39, no. 33, pp. 3021–3104, 2018. [Online]. Available: https://pubmed.ncbi.nlm.nih.gov/30165516/

[8] W. S. McCulloch and W. Pitts, "A logical calculus of the ideas immanent in nervous activity," *The bulletin of mathematical biophysics*, vol. 5, no. 4, pp. 115–133, 1943.

[9] A. C. Müller and S. Guido, *Introduction to machine learning with Python: a guide for data scientists*. " O'Reilly Media, Inc.", 2016.

[10] H. Zhao *et al.*, "Predicting the risk of hypertension based on several easy-to-collect risk factors: A machine learning method," *Frontiers in Public Health*, vol. 9, p. 619429, 2021.

[11] I. Marin and N. Goga, "Hypertension detection based on machine learning," in *Proceedings of the 6th Conference on the Engineering of Computer Based Systems*, 2019, pp. 1–4.

[12] V. T. Dond, "Using predictive analytics to detect hypertension with machine learning," *International Journal of Scientific Research in Engineering and Management*, 2025, unverified reference.

[13] K. Gong, Y. Chen, and X. Ding, "Causal inference for hypertension prediction," in *2023 45th Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC)*. IEEE, 2023, pp. 1–4.

[14] A. Géron, *Hands-On Machine Learning with Scikit-Learn, Keras, and TensorFlow*. Sebastopol, CA: O'Reilly Media, 2019.

[15] W. McKinney, *Python for Data Analysis*. O'Reilly Media, 2012.

[16] F. Pedregosa, G. Varoquaux, A. Gramfort, V. Michel, B. Thirion, O. Grisel, M. Blondel, P. Prettenhofer, R. Weiss, V. Dubourg *et al.*, "Scikit-learn: Machine learning in python," *the Journal of machine Learning research*, vol. 12, pp. 2825–2830, 2011.

[17] N. V. Chawla, K. W. Bowyer, L. O. Hall, and W. P. Kegelmeyer, "Smote: synthetic minority over-sampling technique," *Journal of artificial intelligence research*, vol. 16, pp. 321–357, 2002.

[18] M. Abadi, P. Barham, J. Chen, Z. Chen, A. Davis, J. Dean, M. Devin, S. Ghemawat, G. Irving, M. Isard *et al.*, "{TensorFlow}: a system for {Large-Scale} machine learning," in *12th USENIX symposium on operating systems design and implementation (OSDI 16)*, 2016, pp. 265–283.

[19] T. Akiba, S. Sano, T. Yanase, T. Ohta, and M. Koyama, "Optuna: A next-generation hyperparameter optimization framework," in *Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery & data mining*, 2019, pp. 2623–2631.

[20] M. D. McKay, R. J. Beckman, and W. J. Conover, "A comparison of three methods for selecting values of input variables in the analysis of output from a computer code," *Technometrics*, vol. 42, no. 1, pp. 55–61, 2000.

[21] P. Pacheco and M. Malensek, *An introduction to parallel programming*. Morgan Kaufmann, 2021.