

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 inaccessibilidade 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 para o desenvolvimento do modelo de classificação.

A. Pré-processamento

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

- 1) Seleção de atributos: foram mantidas as variáveis clínicas e demográficas de maior relevância biológica 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:

$$w_0 = 0,7736, \quad w_1 = 1,4137 \quad (1)$$


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 :

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

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.

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.




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

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/rtps/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. Olowade, "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>