

Análise comparativa de modelos ANN, TabNet e FT-Transformer na classificação de transtornos neuropsiquiátricos específicos utilizando sinais de EEG

Mateus Balda Mota², Alessandro Bof de Oliveira¹, Patricia Bof¹,
Dante Augusto Couto Barone²

¹Campus Alegrete – Universidade Federal do Pampa (UNIPAMPA)
Av. Tiaraju, 810 – Ibirapuitã – 97546-550 – Alegrete – RS – Brazil

alessandrooliveira@unipampa.edu.br, pati.bof@gmail.com

²Instituto de Informática – Universidade Federal do Rio Grande do Sul (UFRGS)
Caixa Postal 15.064 – 91.501-970 – Porto Alegre – RS – Brazil

(mateus.balda,barone)@inf.ufrgs.br

Abstract. *This study evaluates neural networks for classifying EEG signals to diagnose mental disorders, using data from 945 patients, power spectral density (PSD), and functional connectivity (FC) across 19 channels. Three models were compared: multilayer perceptron (ANN), TabNet, and FT-Transformer. The average accuracy was 91.93%, with TabNet performing best for depression and bipolar disorder, ANN for panic disorder and adjustment disorder, and FTT for post-traumatic stress disorder. Despite limitations such as small sample sizes and heterogeneity, the results indicate that neural networks outperform traditional methods, highlighting the potential of multimodal data approaches.*

Resumo. *Este estudo avalia redes neurais na classificação de sinais de EEG para diagnóstico de transtornos mentais, usando dados de 945 pacientes, densidade espectral de potência (PSD) e conectividade funcional (FC) em 19 canais. Três modelos foram comparados: perceptron multicamada (ANN), TabNet e FT-Transformer. A acurácia média foi 91,93%, com TabNet melhor em depressão e bipolaridade, ANN em pânico e adaptação, e FTT em estresse pós-traumático. Apesar de limitações como amostras reduzidas e heterogeneidade, os resultados indicam que redes neurais superam métodos tradicionais, apontando para abordagens de dados multimodais.*

1. Introdução

A eletroencefalografia (EEG) capta a atividade elétrica do cérebro nas camadas corticais por meio de eletrodos posicionados no couro cabeludo [Siuly et al. 2016]. Essa técnica monitora a atividade cerebral capturada a partir de bandas de frequências como *delta*, *theta*, *alpha*, *beta* e *gamma* [Siuly et al. 2016]. As condições mentais apresentam elevada prevalência social, afetando uma em cada oito pessoas, representando um total de 970 milhões de indivíduos em 2019. Desses, 301 milhões viviam com transtornos de ansiedade, 280 milhões com depressão, 40 milhões com transtorno bipolar, 24 milhões com esquizofrenia e 14 milhões com distúrbios alimentares [World Health Organization 2022].

[Parsa et al. 2023] revisaram estudos que aplicaram redes neurais na classificação de sinais de EEG para o diagnóstico de transtornos psiquiátricos, doenças neurodegenerativas e do neurodesenvolvimento, alcançando uma acurácia média de 91,83%. Estudos evidenciam o potencial das redes neurais na análise de EEG para diferentes condições: [Ay et al. 2019] propôs um modelo híbrido CNN-LSTM para detectar depressão com precisão superior a 99% em testes de EEG, com um conjunto de dados pequeno. [Wang et al. 2022] utilizou uma rede neural MUCHf-Net para classificar EEGs de depressão, esquizofrenia e indivíduos saudáveis, com precisão de 91,12%, destacando dificuldades em diferenciar depressão de esquizofrenia. [Shah et al. 2023] apresentou o ETSNet, uma rede neural que alcançou 99,57% de precisão ao classificar esquizofrenia, parentes biológicos e controles saudáveis. [Júnior 2023] combinou redes CNN e LSTM com algoritmos genéticos para classificar EEGs de coma e AVC, O modelo obteve 83,3% de acurácia e F1-score de 82,6% para coma, e 93,3% de acurácia e 93,8% de F1-score com o algoritmo genético. Para AVC, a acurácia foi de 76,3% e F1-score de 74,6%. Por fim, o [Olatinwo et al. 2025] propôs um modelo híbrido CNN-BiLSTM para diagnóstico de transtornos mentais, superando os modelos base e alcançando acurácias de 76-80%, com ênfase na interpretação das previsões através do método LIME.

2. Metodologia

O conjunto de dados de [Park 2021] inclui informações de 945 pacientes do *SMG-SNU Boramae Medical Center* (2011–2018), com avaliações psicológicas, EEG quantitativo (QEEG) e diagnósticos confirmados segundo o DSM-5. Os sinais foram registrados em 19 canais, processados utilizando FFT e transformados em medidas de Densidade Espectral de Potência (PSD) e Coerência Funcional (FC), resultando em 1140 atributos, além de variáveis demográficas e clínicas, totalizando um *dataset* de dimensão 945×1148 , aprovado pelo comitê de ética. Os valores ausentes nas características *education* e *IQ* (28 no total) foram imputados com o algoritmo *KNNImputer* ($k = 5$), e os *outliers* foram tratados via método IQR ($factor = 1.5$) e winsorização com *NumPy clip*, correspondendo a cerca de 2,44% dos dados. O desbalanceamento de classes foi tratado com o método *SMOTE*, deixando todas as classes com o mesmo número de observações, e a classificação foi tratada como um problema de classificação binária (controle vs. transtorno).

O conjunto foi organizado em três grupos de atributos (**PSD**, **FC** e **PSD+FC**), avaliados separadamente para seis bandas de frequência (*delta*, *theta*, *alpha*, *beta*, *high beta*, *gamma*) do EEG e todas combinadas, totalizando 21 cenários por transtorno vs. controle. Os dados foram convertidos para tensores no formato *PyTorch*, divididos em treino (80%) e teste (20%) aleatoriamente, e carregados em lotes de 32 amostras pelo *DataLoader*. Foram comparados três modelos: nossa proposta de perceptron multicausada, com quatro camadas ocultas, com 128, 64, 32 e 16 neurônios respectivamente, *BatchNorm*, ativação GELU, *dropout* 10% em cada camada, otimização *Adam* com *ReduceLROnPlateau*, 200 épocas e *early stopping*); a **TabNet** (otimizada com *Adam* e *StepLR*, redução de 10% a cada 30 épocas); e o **FT-Transformer** (entrada apenas numérica, saída binária e uso do último *token* para predição). Os métodos comparativos **TabNet** e **FT-Transformer** foram escolhidos por apresentarem bons resultados em classificação de dados tabulares. As métricas de avaliação foram **acurácia** (proporção de acertos), **sensibilidade** (proporção de positivos identificados corretamente) e área sob a curva **AUC** (capacidade de discriminação entre classes) [Brownlee 2021].

3. Resultados

Os resultados, compilados na Tabela 1 indicam que não há modelo universalmente superior. A TabNet destacou-se nos casos de depressão (96,20% acurácia; 96,60% AUC), bipolaridade (89,40% acurácia; 90,50% AUC) e dependência (81,50% acurácia; 79,70% AUC), sendo escolhida como referência por sua consistência. O ANN foi mais eficaz em pânico (97,30% acurácia; 99,40% AUC; 100% sensibilidade) e adaptação (94,70%), enquanto o FTT obteve os melhores resultados em estresse pós-traumático (97,30% acurácia; 100% sensibilidade) e uso de álcool (92,10%; 91,10%).

Tabela 1. Desempenho, em porcentagem, dos modelos na classificação da classe *specific disorder* entre controles saudáveis e transtornos.

Transtorno	Melhor carac.	Acurácia (%)			AUC (%)			Sensibilidade (%)		
		ANN	FTT	TabNet	ANN	FTT	TabNet	ANN	FTT	TabNet
Estresse agudo	Delta PSD	92,10	86,80	92,10	95,50	92,20	97,20	94,70	100,00	84,00
Adaptação	Beta PSD	94,70	84,20	86,80	95,50	89,10	89,40	89,40	74,00	79,00
Uso de álcool	Beta alta FC	78,90	92,10	65,70	85,80	91,10	58,70	78,90	89,00	95,00
Depen. comportamental	Theta PSD + FC	73,60	73,60	81,50	76,10	79,70	79,70	73,60	74,00	79,00
Bipolar	Beta PSD	78,90	78,90	89,40	86,40	87,50	90,50	68,40	79,00	89,00
Depressivo	Beta FC	92,50	87,50	96,20	96,10	93,80	96,60	95,00	85,00	93,00
Pânico	PSD completa	97,30	89,40	78,90	99,40	94,70	83,30	100,00	84,00	95,00
Estresse pós-traumático	Gama PSD + FC	89,40	97,30	73,60	97,50	94,70	77,80	100,00	100,00	79,00
Ansiedade social	FC completa	86,80	76,30	78,90	94,40	85,50	85,80	84,20	79,00	84,00




Figura 1. Comparação da acurácia máxima e da AUC entre modelos para a classificação de transtornos específicos.

4. Discussão e conclusão

Diferentes arquiteturas, como ANN, TabNet e FT-Transformer foram avaliadas em combinação com pré-processamentos baseados em parâmetros de densidade espectral de potência (PSD) e conectividade funcional (FC) e bandas de EEG, com o objetivo de realizar a classificação binária entre controle vs. transtornos. Em comparação aos resultados

de [Park et al. 2021], os modelos propostos alcançaram desempenho superior na tarefa de classificação em *specific disorder*, obtendo acurácia média de 91,93%. Os resultados de predição controle vs. transtorno são promissores, e como desdobramentos deste trabalho indicamos a utilização de métodos de classificação em *ensemble* e a geração de dados com métodos baseados em redes neurais generativas.

Referências

- Ay, B., Yildirim, O., Talo, M., Baloglu, U. B., Aydin, G., Puthankattil, S. D., and Acharya, U. R. (2019). Automated depression detection using deep representation and sequence learning with eeg signals. *Journal of Medical Systems*, 43:1–12.
- Brownlee, J. (2021). Tour of evaluation metrics for imbalanced classification. Acessado em: 27 nov. 2024.
- Júnior, S. B. (2023). Algoritmos genéticos e aprendizado profundo baseado em redes neurais recorrentes do tipo lstm para auxílio ao diagnóstico médico.
- Olatinwo, D., Abu-Mahfouz, A., and Myburgh, H. (2025). Mental disorder assessment in iot-enabled wban systems with dimensionality reduction and deep learning. *Journal of Sensor and Actuator Networks*, 14(3).
- Park, S. M. (2021). Eeg machine learning. Retrieved August 16, 2021, from <https://osf.io/8bsvr>.
- Park, S. M., Jeong, B., Oh, D. Y., Choi, C. H., Jung, H. Y., Lee, J. Y., Lee, D., and Choi, J. S. (2021). Identification of major psychiatric disorders from resting-state electroencephalography using a machine learning approach. *Frontiers in Psychiatry*, 12:707581.
- Parsa, M., Rad, H. Y., Vaezi, H., Hossein-Zadeh, G.-A., Setarehdan, S. K., Rostami, R., Rostami, H., and Vahabie, A.-H. (2023). Eeg-based classification of individuals with neuropsychiatric disorders using deep neural networks: A systematic review of current status and future directions. *Computer Methods and Programs in Biomedicine*, 240:107683.
- Shah, S. J. H., Albishri, A., Kang, S. S., Lee, Y., Sponheim, S. R., and Shim, M. (2023). Etsnet: A deep neural network for eeg-based temporal–spatial pattern recognition in psychiatric disorder and emotional distress classification. *Computers in Biology and Medicine*, 158:106857.
- Siuly, S., Li, Y., and Zhang, Y. (2016). Eeg signal analysis and classification. *IEEE Trans Neural Syst Rehabil Eng*, 11:141–144.
- Wang, Z., Feng, J., Jiang, R., Shi, Y., Li, X., Xue, R., Du, X., Ji, M., Zhong, F., Meng, Y., et al. (2022). Automated rest eeg-based diagnosis of depression and schizophrenia using a deep convolutional neural network. *IEEE Access*, 10:104472–104485.
- World Health Organization (2022). Mental disorders. Accessed: 2024-10-10.