

Utilização de Redes Neurais Convolucionais para Classificação da Esquizofrenia através de Microestados

João Vitor M. Vianna¹, Karin Satie Komati²

¹Coordenação de Informática
Instituto Federal do Espírito Santo (IFES), Campus Serra

²Programa de Pós-graduação em Computação Aplicada (PPComp)
Instituto Federal do Espírito Santo (IFES), Campus Serra
Avenida dos Sabiás, 330 – Morada de Laranjeiras
CEP: 29166-630, Serra – ES – Brasil

jvmacielv@gmail.com, kkomati@ifes.edu.br

Abstract. *This article explores the application of convolutional neural networks (CNNs) in classifying schizophrenia through microstates generated from electroencephalogram (EEG) data. The dataset is balanced, consisting of 28 patients equally divided between individuals with schizophrenia and healthy individuals. The microstates, generated using Global Field Power (GFP), were used as input for a CNN with four convolutional layers and three fully connected layers. The results are promising, with the model achieving an accuracy of 75%, sensitivity of 71,4%, precision of 76,9%, and an F1-score of 74,1%.*

Resumo. *Este artigo explora a aplicação de redes neurais convolucionais (CNNs) na classificação da esquizofrenia através de microestados gerados do eletroencefalograma (EEG). A base de dados é balanceada, consistindo em 28 pacientes divididos igualmente entre indivíduos com esquizofrenia e saudáveis. Os microestados, gerados através do Global Field Power (GFP), foram utilizados como entrada para uma CNN com quatro camadas convolucionais e três camadas totalmente conectadas. Os resultados são promissores, o modelo atingiu uma acurácia de 75%, sensibilidade de 71,4%, precisão de 76,9% e medida-F1 de 74,1%.*

1. Introdução

O estudo do cérebro humano e o seu funcionamento é importante para a compreensão do funcionamento das ações e reações do corpo. O cérebro é responsável pelo controle do sistema nervoso permitindo a memória, pensamentos, movimentos, emoções, o controle de outros sistemas [Wang et al. 2020]. O órgão é composto por bilhões de neurônios, os quais são responsáveis pela passagem de informações entre si, através de correntes elétricas de baixa voltagem. Dessa forma, quando o órgão não possui um bom funcionamento, algumas de suas estruturas necessitam de atenção médica para um diagnóstico.

O eletroencefalógrafo é a máquina responsável pela captação da energia gerada pelo cérebro através de eletrodos colocados no couro cabeludo do paciente [Tudor et al. 2005]. Além disso, faz a correção de amplitude do sinal elétrico, possuindo um amplificador, e o registro do sinal elétrico durante o seu uso. O resultado do procedimento é o Eletroencefalograma (EEG), o qual permite a visualização da energia em

uma determinada área do cérebro em um determinado tempo. Com a geração dessas informações, é possível obter uma análise detalhada ao determinar um tempo específico de coleta de dados, chamados de microestados.

Os microestados são representações da distribuição de energia em um período de tempo pré-definido em que há uma dominância de estado cerebral [Michel and Koenig 2018]. Quando analisados, a diferenciação de áreas com maior e menor atividade energética são visíveis e divisíveis, concedendo a possibilidade de tratar as regiões do cérebro de forma individual, ou observar como o órgão se comporta em alguns casos onde há presença de doenças cerebrais, como o Alzheimer, Parkinson, e a esquizofrenia.

A Figura 1 expõe um exemplo de imagens de microestados em diferentes condições cerebrais. A legenda de cor indica a variação da atividade elétrica, a cor azul representa valores mais próximos à -3, a cor verde próximo ao 0 (zero) e a cor vermelha para valores mais próximos ao máximo, +3. A primeira imagem de microestado é de uma pessoa em condição normal (à esquerda), onde pode-se observar a predominância da coloração esverdeada (atividade elétrica com valor próximo ao zero). O outro exemplo (à direita) é de uma pessoa com cefaleia (dor de cabeça), que possui uma região com partes em vermelho e laranja, indicando alta variação da atividade elétrica localizada.

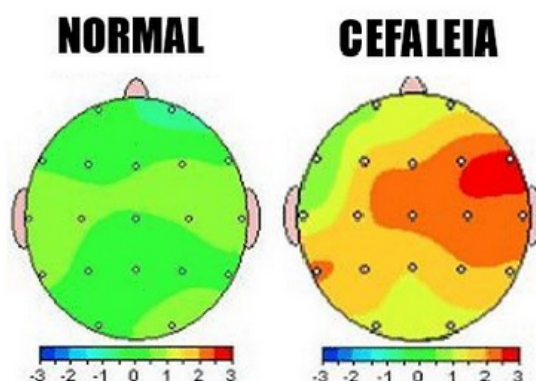


Figura 1. Exemplo de microestados.

A esquizofrenia é um distúrbio neurológico identificado por diversos sintomas, como ilusões, alucinações, fala desorganizada ou comportamento e falta de coordenação motora [Patel et al. 2014]. As técnicas atuais de diagnóstico de esquizofrenia e população de alto risco são baseadas em entrevistas psiquiátricas subjetivas e histórico da saúde do paciente, quando dois ou mais sintomas citados são encontrados no paciente [Hany et al. 2024]. O diagnóstico e a intervenção precoces podem mitigar a progressão e melhorar os resultados do tratamento. De acordo com os resultados do artigo de Sun et al [Sun et al. 2021], há evidências que sugerem uma relação entre a esquizofrenia e os microestados de EEG. Além disso, o distúrbio neurológico, quando identificado, demonstra mudanças na região do lobo pré-frontal e medial, possuindo indícios do distúrbio sendo passíveis de análise e observação [Karlsodt et al. 2010].

Trabalhos anteriores já adotaram o uso de técnicas de aprendizado de máquina

para a classificação de esquizofrenia baseado em microestados [Kim et al. 2021, Keihani et al. 2022]. A proposta deste trabalho é usar uma rede neural CNN (do inglês, Convolutional Neural Network), que recebe as imagens de microestados para a classificação de esquizofrenia. A arquitetura da CNN é composta por camadas, camadas de convolução, camadas de *pooling*, função de ativação e por fim *fully connected layer* [Bhatt et al. 2021]. A base de dados é a “EEG in schizophrenia”¹, e as métricas são acurácia e medida-F1.

As próximas seções estão organizadas da seguinte forma: a Seção 2 apresenta os trabalhos correlatos; a Seção 3 apresenta os métodos, métricas e conjunto de dados investigados neste artigo; a Seção 4 apresenta os resultados dos experimentos e a discussão; e as considerações finais são apresentadas na Seção 5.

2. Trabalhos Correlatos

O trabalho de doutorado de Alves [Alves 2023], em que a proposta foi a utilização de modelos de decodificação do EEG para Detecção de correlatos neurais de transtornos mentais. A tese realiza a utilização da geração de microestados, com o cálculo de GFP (Global Field Power) para obter um período pré-determinado de análise e variação de energia. Além disso, foram realizadas análises em diferentes tipos de transtornos mentais, como a depressão, o TDAH, a síndrome do pânico, e por fim, a esquizofrenia. A base de dados utilizada possui 84 pacientes, todos adolescentes, dos quais 39 são saudáveis e 45 possuem esquizofrenia. Além disso, a frequência da amostragem é de 128Hz, sendo que, 7.680 amostras representam um canal referente a um posicionamento do eletrodo no couro cabeludo. Outro ponto importante é ressaltar que a base de dados possui uma distribuição de 16 eletrodos para a captação do sinal elétrico. Os algoritmos utilizados no trabalho foram SVM (do inglês, Support Vector Machine) e DT (do inglês, Decision Tree). Ao realizar as comparações entre algoritmos, a proposta obteve resultados promissores, obtendo mais de 90% de acurácia na utilização de SVM e DT.

O artigo de Lun et al. [Lun et al. 2020] propõe uma abordagem para a classificação de dados de eletroencefalografia de imagética motora (MI-EEG) utilizando uma rede neural convolucional sem pré-processamento. Este método registra a atividade elétrica cerebral associada a movimentos imaginados. O conjunto de dados inclui dados de frequência MI-EEG e medições do GFP, extraídos de sinais capturados por 64 eletrodos em um sistema de espaçamento 10-10, envolvendo 109 participantes com uma frequência de amostragem de 160Hz. Os eletrodos selecionados são simétricos, com 9 eletrodos em cada hemisfério do cérebro. A arquitetura proposta da CNN é composta por cinco camadas convolucionais. Desde a segunda até a quinta camada, são aplicados processos de *pooling*, seguidos por uma camada de *flattening* e camadas totalmente conectadas. O treinamento e a validação foram conduzidos utilizando tamanhos de conjunto de dados crescentes para avaliar o desempenho da classificação. Os resultados mostraram uma acurácia de 95,76% para 10 sujeitos, 97,28% para 20 sujeitos, 96,01% para 60 sujeitos e 94,80% para 100 sujeitos.

¹<https://repod.icm.edu.pl/dataset.xhtml?persistentId=doi:10.18150/repod.0107441>

3. Materiais e Métodos

3.1. A base de dados

A base de dados utilizada é composta por exames de EEG realizados em 28 pacientes no total, em que 14 pacientes possuem a esquizofrenia e 14 pacientes não apresentam a esquizofrenia [Olejarczyk and Jernajczyk 2017]. Para cada exame realizado, foi utilizada uma frequência de 250 Hz e um padrão de espaçamento entre os elétrodos de 10-20. Os canais utilizados são totalizados em 19, conforme apresentado na Figura 2, sendo eles: Fp1, Fp2, F7, F3, Fz, F4, F8, T3, C3, Cz, C4, T4, T5, P3, Pz, P4, T6, O1, O2.




Figura 2. Posicionamento de Eletrodos

3.1.1. Do EGG para microestados

Cada um dos eletrodos coletam os sinais com relação ao tempo. A parte superior da Figura 3 apresenta 19 canais coletados em um exame de EEG, que são as curvas (na cor preta) em relação ao tempo. A curva abaixo dos eletrodos (em preto) é uma conversão resumida dos sinais, o GFP (Global Field Power), uma medida obtida através do cálculo matemático de desvio padrão de frequência de todos os eletrodos utilizados para o monitoramento da atividade cerebral. A última parte são os microestados.

Para calcular o GFP, faz-se necessário a realização do cálculo matemático, que consiste no desvio padrão de todos os eletrodos num dado instante de tempo, conforme Equação (1). Sendo assim, é possível quantificar a quantidade de atividade energética em cada ponto de análise topográfica do couro cabeludo, onde cada valor será utilizado para compor um gráfico plotado em função do tempo, e assim, obtém-se a variação única de energia [Skrandies 1990].

$$GFP = \sqrt{\frac{\sum_i^C (V_i(t) - V_{mean}(t))^2}{C}} \quad (1)$$

Sendo V_i o potencial instantâneo no eletrodo i e V_{mean} a média de potenciais instantâneos nos eletrodos, o GFP é a raiz da média das diferenças de potencial ao quadrado de todos os n eletrodos. O GFP mede a resposta global do cérebro a um evento, em que as topografias do campo elétrico nos máximos locais da curva GFP são consideradas os microestados do EEG [Khanna et al. 2015].

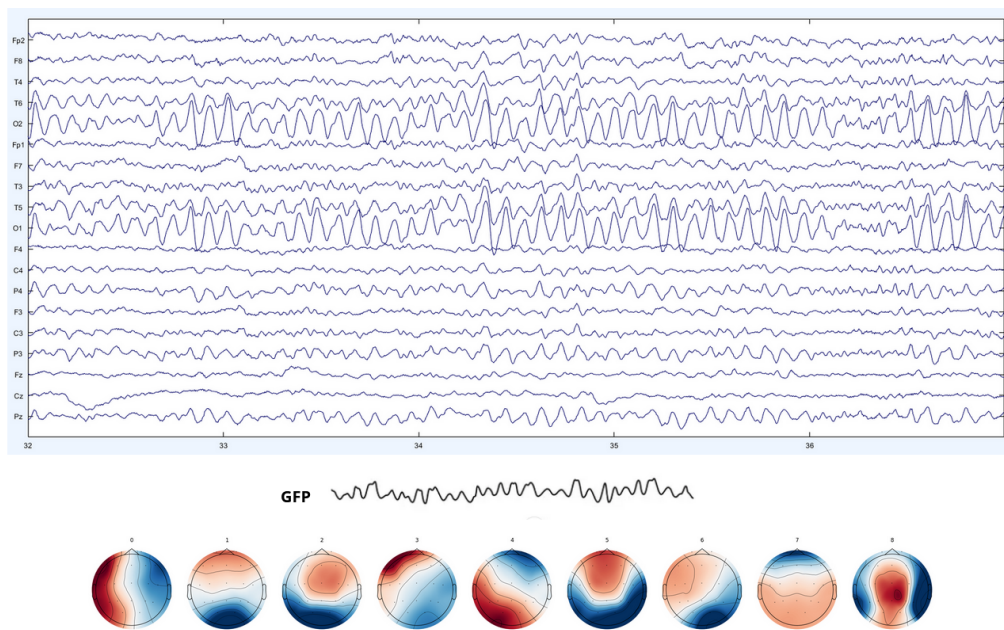


Figura 3. Exemplo de transformação do EEG para microestados.

Os microestados são imagens com padrões temporais de atividade elétrica cerebral que refletem a organização espacial e temporal das redes neurais envolvidas na percepção, cognição e consciência. Para cada paciente analisado, o algoritmo gerou um conjunto de 9 microestados. No próximo momento, a imagem é convertida para um tamanho de 32x32.

3.2. Métodos

A classificação foi realizada via CNN, cuja arquitetura é composta por diferentes camadas. A Figura 4 representa de forma visual a arquitetura usada nos experimentos deste artigo. A imagem de entrada, na dimensão 32 x 32 com 3 canais de cores. O código fonte pode ser acessado de forma pública²

A primeira etapa da arquitetura é um conjunto de 3 blocos (retângulos azuis). Cada bloco é composto por uma camada convolucional e de *pooling*. Nesse procedimento, é definido um *kernel*, uma matriz com dimensão $N \times N$ (no caso 3x3), a qual cada elemento é tratado como um peso. Para cada etapa na camada, o *kernel* realiza uma multiplicação matricial de dimensão $N \times N$ com a imagem de entrada, gerando um novo valor na matriz resultante de acordo com a dimensão multiplicada [Yamashita et al. 2018].

A camada de *pooling* é uma operação de redução da resolução, ou seja, a dimensionalidade de altura e largura de uma imagem de entrada [Zhao et al. 2024]. Neste trabalho é usada o *Max Pooling*, que obtém o maior valor em uma matriz de dimensão N

²<https://github.com/Maciel-Dev/cnnEegSchizophrenia>

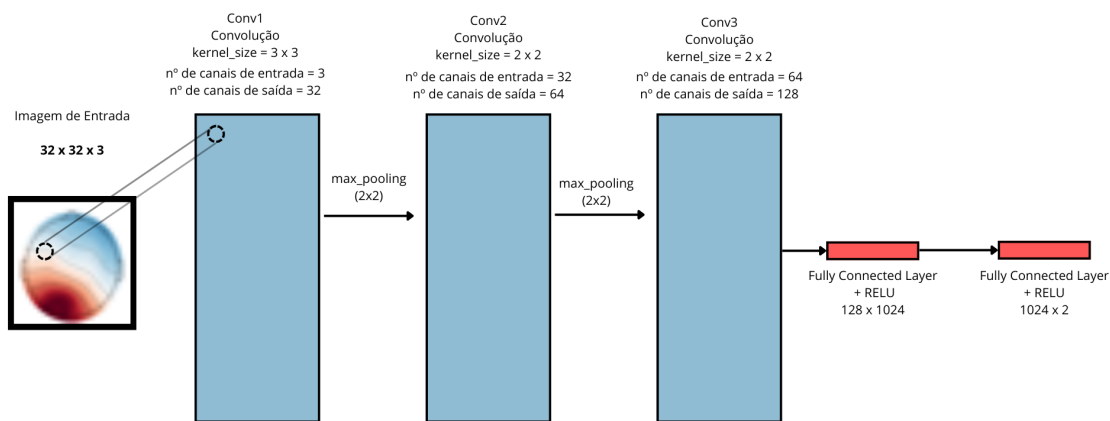


Figura 4. Arquitetura de CNN deste trabalho.

x N, no caso 2x2, e a saída gerada possui a metade da dimensão que foi obtida da camada de convolução.

Após passar pelas camadas de convoluções e *pooling*, a saída gerada é submetida às camadas totalmente conectadas (FC do inglês, fully connected layers), que são os retângulos vermelhos da figura. A última transformação realizada retorna um vetor, ou uma matriz de uma única dimensão, a qual podem estar conectados a uma ou mais camadas densas, em que cada entrada está conectada a cada saída por um peso que pode ser aprendido. A última camada da FC, normalmente possui o mesmo número de nós de saída que o número de classes (no caso 2). Cada camada totalmente conectada é seguida por uma função não linear, como ReLU (Rectified Linear Unit).

3.3. Métricas

Em análise preditiva, a matriz de confusão, figura 6, é uma tabela com duas linhas e duas colunas que relata o número de falsos positivos (FP), falsos negativos (FN), verdadeiros positivos (TP, do inglês True Positive) e verdadeiros negativos (TN, do inglês True Negative). Onde TP representam os casos em que o modelo previu corretamente a classe positiva. Ou seja, o modelo classificou corretamente um exemplo como pertencente à classe positiva. FP representam os casos em que o modelo previu incorretamente a classe positiva. Ou seja, o modelo classificou erroneamente um exemplo como pertencente à classe positiva, quando na verdade não era. TN representam os casos em que o modelo previu corretamente a classe negativa. Ou seja, o modelo classificou corretamente um exemplo como não pertencente à classe positiva. FN representam os casos em que o modelo previu incorretamente a classe negativa. Ou seja, o modelo classificou erroneamente um exemplo como não pertencente à classe positiva, quando na verdade era.

A acurácia se trata de uma medida do grau de que as previsões de um modelo correspondem à realidade sendo modelada. Algumas vezes, esta quantidade é expressa como uma porcentagem em vez de um valor entre 0,0 e 1,0. A acurácia de um classificador nos dados de teste pode ser calculada como número de objetos corretamente

classificados/número total de objetos como mostra a Equação 2.

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

A precisão é a fração de elementos Verdadeiro Positivo dividida pelo número total de unidades previstas como positivas (TP + TN). A precisão expressa a proporção de unidades que o modelo classifica como positivas e que realmente são positivas. Em outras palavras, a precisão nos diz o quanto podemos confiar no modelo quando ele prevê um indivíduo como positivo [Grandini et al. 2020], conforme Equação 3.

$$Precisão = \frac{TP}{TP + FP} \quad (3)$$

Sensibilidade é a fração de elementos Verdadeiro Positivo dividida pelo número total de unidades classificadas como positivas (soma da linha dos positivos reais). O Sensibilidade mede a precisão preditiva do modelo para a classe positiva: intuitivamente, mede a capacidade do modelo de encontrar todas as unidades positivas no conjunto de dados. O cálculo é descrito pela equação 4.

$$Sensibilidade = \frac{TP}{TP + FN} \quad (4)$$

O F1-Score avalia o desempenho de um modelo de classificação a partir da matriz de confusão, agregando as medidas de Precisão e Sensibilidade sob o conceito de média harmônica. A fórmula do F1-Score pode ser interpretada como uma média ponderada entre a Precisão e o Sensibilidade, onde o F1-Score atinge seu melhor valor em 1 e o pior valor em 0. A contribuição relativa da Precisão e do Sensibilidade é igual no F1-Score, e a média harmônica é útil para encontrar o melhor equilíbrio entre as duas quantidades. A equação 5 demonstra o cálculo.

$$F1 - score = \frac{2 * Precision * Recall}{Precision + Recall} \quad (5)$$

4. Experimentos, Resultados e Discussão

A base de dados resultou em 700 microestados, sendo 350 saudáveis e 350 com esquizofrenia. A divisão da base de dados para treinamento/teste é de 84%:16%. O gráfico abaixo demonstra o resultado de treinamento para 3.000 épocas.

A figura 5 apresenta o gráfico da acurácia pela época durante o treinamento. A acurácia do treinamento permanece em um crescimento exponencial e atinge o seu valor máximo acima de 85%. O modelo faz predição binária, pacientes que possuem esquizofrenia e aqueles que não possuem. O método de otimização usado foi o ADAM, com o *learning rate* de 0,00001, a função de *loss*, *CrossEntropyLoss*.

A matriz de confusão (Figura 6) apresenta os resultados: verdadeiro positivo, falso negativo, falso positivo e verdadeiro negativo. A linha representa o valor real e a coluna o valor predito. Para o modelo em questão, a matriz de confusão apresenta acurácia de 75%, a sensibilidade de 71,4%, a precisão de 76,9% e medida-F1 de 74,1%.

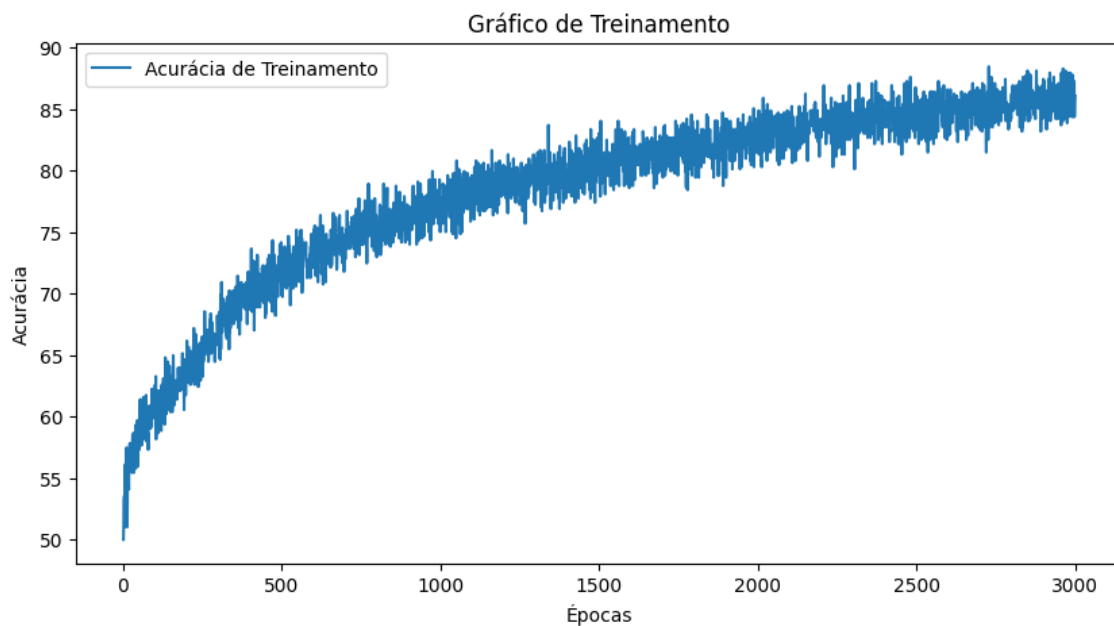


Figura 5. Gráfico de Acurácia do Treinamento.




Figura 6. Matriz de Confusão do experimento.

Realizando a comparação dos resultados com os trabalhos correlatos supracitados, é possível observar um valor reduzido obtido pelo modelo descrito nesse artigo. O primeiro trabalho correlato apresentou uma base de dados de 84 pacientes no total, possibilitando a normalização e aumento significativo de dados de entrada para treinamento e validação do modelo, obtendo um valor de 100% de acurácia utilizando SVM. A luz

dessa ótica, o segundo trabalho apresentou uma base de dados extensa, realizando um aumento gradual para validação de classificação do modelo, obtendo resultados acima de 90% de acurácia, utilizando mais camadas de convolução para a análise dos valores de entrada que o modelo recebia. Sendo assim, o modelo apresentado possui uma arquitetura mais simples, base de dados reduzida, ocasionando dessa forma, resultados inferiores aos obtidos nos trabalhos correlatos.

5. Conclusão

Este artigo apresentou resultados de um experimento para a classificação de esquizofrenia usando uma rede neural CNN, que recebe as imagens de microestados. Para trabalhos futuros e continuidade do estudo, pretende-se usar outros modelos de redes neurais, otimizar os hiper-parâmetros dos modelos, bem como usar técnicas mais robustas de validação cruzada. Usar outras bases de dados e fazer validações e testes entre diferentes bases de dados.

6. Agradecimentos

A professora Komati agradece ao CNPq (Conselho Nacional de Desenvolvimento Científico e Tecnológico) pela bolsa DT-2 (nº 302726/2023-3) e pelo projeto nº407742/2022-0; também agradece à FAPES (Fundação de Amparo à Pesquisa e Inovação do Espírito Santo) pelo projeto nº 1023/2022 P:2022-8TZV6.

Referências

- Alves, L. M. (2023). Modelos de decodificação do EEG para detecção de correlatos neurais de transtornos mentais. Tese de doutorado. Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal do Espírito Santo.
- Bhatt, D., Patel, C., Talsania, H., Patel, J., Vaghela, R., Pandya, S., Modi, K., and Ghayvat, H. (2021). CNN variants for computer vision: History, architecture, application, challenges and future scope. *Electronics*, 10(20):2470.
- Grandini, M., Bagli, E., and Visani, G. (2020). Metrics for multi-class classification: an overview. *ArXiv*, abs/2008.05756.
- Hany, M., Rehman, B., Rizvi, A., et al. (2024). *Schizophrenia*. StatPearls Publishing, Treasure Island (FL). Updated 2024 Feb 23.
- Karlsgodt, K. H., Sun, D., and Cannon, T. D. (2010). Structural and functional brain abnormalities in schizophrenia. *Current directions in psychological science*, 19(4):226–231.
- Keihani, A., Sajadi, S. S., Hasani, M., and Ferrarelli, F. (2022). Bayesian optimization of machine learning classification of resting-state EEG microstates in schizophrenia: a proof-of-concept preliminary study based on secondary analysis. *Brain Sciences*, 12(11):1497.
- Khanna, A., Pascual-Leone, A., Michel, C. M., and Farzan, F. (2015). Microstates in resting-state eeg: current status and future directions. *Neuroscience & Biobehavioral Reviews*, 49:105–113.
- Kim, K., Duc, N. T., Choi, M., and Lee, B. (2021). EEG microstate features for schizophrenia classification. *PloS one*, 16(5):e0251842.

- Lun, X., Yu, Z., Chen, T., Wang, F., and Hou, Y. (2020). A simplified CNN classification method for MI-EEG via the electrode pairs signals. *Frontiers in Human Neuroscience*, 14.
- Michel, C. M. and Koenig, T. (2018). EEG microstates as a tool for studying the temporal dynamics of whole-brain neuronal networks: A review. *NeuroImage*, 180:577–593. Brain Connectivity Dynamics.
- Olejarczyk, E. and Jernajczyk, W. (2017). EEG in schizophrenia. <https://doi.org/10.18150/repod.0107441>.
- Patel, K. R., Cherian, J., Gohil, K., and Atkinson, D. (2014). Schizophrenia: overview and treatment options. *Pharmacy and Therapeutics*, 39(9):638.
- Skrandies, W. (1990). Global field power and topographic similarity. *Brain topography*, 3:137–141.
- Sun, Q., Zhou, J., Guo, H., Gou, N., Lin, R., Huang, Y., Guo, W., and Wang, X. (2021). EEG microstates and its relationship with clinical symptoms in patients with schizophrenia. *Frontiers in Psychiatry*, 12:761203.
- Tudor, M., Tudor, L., and Tudor, K. I. (2005). Hans Berger (1873-1941) – the history of electroencephalography. *Acta medica Croatica: casopis Hrvatske akademije medicinskih znanosti*, 59(4):307–313.
- Wang, Y., Pan, Y., and Li, H. (2020). What is brain health and why is it important? *BMJ*, 371(m3683).
- Yamashita, R., Nishio, M., Do, R. K. G., and Togashi, K. (2018). Convolutional neural networks: an overview and application in radiology. *Insights into imaging*, 9:611–629.
- Zhao, X., Wang, L., Zhang, Y., Han, X., Deveci, M., and Parmar, M. (2024). A review of convolutional neural networks in computer vision. *Artificial Intelligence Review*, 57(4):99.