



**UNIVERSIDADE FEDERAL DO CEARÁ**  
**CENTRO DE TECNOLOGIA**  
**DEPARTAMENTO DE ENGENHARIA DE TELEINFORMÁTICA**  
**CURSO DE GRADUAÇÃO EM ENGENHARIA DE COMPUTAÇÃO**

**PAULO DAVI RAMOS ALBUQUERQUE**

**DETECÇÃO DE CRISES EPILÉPTICAS A PARTIR DE SINAIS DE  
ELETROENCEFALOGRAMA USANDO REDES NEURAIS AUTOCODIFICADORAS**

**FORTALEZA**

**2025**

PAULO DAVI RAMOS ALBUQUERQUE

DETECÇÃO DE CRISES EPILÉPTICAS A PARTIR DE SINAIS DE  
ELETROENCEFALOGRAMA USANDO REDES NEURAI AUTOCODIFICADORAS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Guilherme de Alencar Barreto.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação  
Universidade Federal do Ceará  
Sistema de Bibliotecas  
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

---

- A312d Albuquerque, Paulo Davi Ramos.  
Detecção de crises epiléticas a partir de sinais de eletroencefalograma usando redes neurais autocodificadoras / Paulo Davi Ramos Albuquerque. – 2025.  
53 f. : il. color.
- Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Tecnologia, Curso de Engenharia de Computação, Fortaleza, 2025.  
Orientação: Prof. Dr. Guilherme de Alencar Barreto.
1. Crises epiléticas. 2. Eletroencefalograma. 3. Redes autocodificadoras. 4. Detecção de anomalias. 5. Detecção em tempo real. I. Título.

CDD 621.39

---

PAULO DAVI RAMOS ALBUQUERQUE

DETECÇÃO DE CRISES EPILÉPTICAS A PARTIR DE SINAIS DE  
ELETROENCEFALOGRAMA USANDO REDES NEURAI AUTOCODIFICADORAS

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia de Computação do Centro de Tecnologia da Universidade Federal do Ceará, como requisito parcial à obtenção do grau de bacharel em Engenharia de Computação.

Aprovada em: 10/03/2025.

BANCA EXAMINADORA

---

Prof. Dr. Guilherme de Alencar Barreto (Orientador)  
Universidade Federal do Ceará (UFC)

---

Prof. Dr. Charles Casimiro Cavalcante  
Universidade Federal do Ceará (UFC)

---

Dr. Rewbenio A. Frota  
Petrobras S.A.

À meus pais, por toda dedicação em me educar e impulsionar. À Rieli Rodrigues, minha companheira de longa data que sempre me motiva a seguir em frente. E, em especial, a todos que sofrem com crises epiléticas.

## **AGRADECIMENTOS**

Ao Colégio Cônego Francisco Pereira, por formar a base da minha educação tanto nos aspectos intelectuais quanto pessoais.

À Universidade Federal do Ceará, pelo investimento em pesquisa e inovação que gerou uma graduação da qual pude desfrutar e que levarei pelo resto da vida.

Ao Prof. Dr. Guilherme Barreto, pela sua dedicação em formar novos engenheiros e por toda sua disponibilidade e apoio tanto durante a graduação quanto durante a orientação.

Aos membros da banca examinadora pela disponibilidade para analisar e avaliar o conteúdo deste trabalho.

A todos meus colegas e familiares que consultei para receber feedbacks que me auxiliaram na produção deste trabalho.

"O primeiro passo é sempre o mais difícil, o segundo, continua sendo difícil, mas aí você já não tem mais medo de caminhar." (Vanderlei Longo)

## RESUMO

Crises epilépticas são condições anômalas no cérebro de um indivíduo que podem causar espasmos, convulsões ou até complicações maiores. Uma das formas de identificar essas anomalias é com a realização de um encefalograma (EEG), exame responsável por captar a atividade cerebral do paciente. Com esses dados, modelos de reconhecimento de padrões podem ser utilizados para determinar se os sinais recebidos são normais ou não. Este trabalho propõe o a modelagem de tais sinais com redes neurais autocodificadoras (do inglês, *autoencoders*), algoritmos capazes de detectar anomalias no sinal de EEG a partir do erro de reconstrução do modelo. Além disso, foi utilizada uma abordagem de treino que simulasse a aquisição em tempo real dos sinais, possibilitando a extensão da aplicação para esse tipo de uso. Foram avaliados na tarefa de detecção de anomalias os seguintes modelos: autoencoder linear (PCA) e redes autocodificadoras com 1 e 3 camadas ocultas. Vários cenários de simulação foram desenvolvidos, a saber: (i) Cenário 1: Treino e teste *offline* usando todos os conjuntos de dados do paciente. O treino é executado apenas com dados negativos (i.e., não convulsivos); (ii) Cenário 2: Similar ao Cenário 1, porém, o treinamento inclui algumas instâncias positivas (esquema *Open Set*); e (iii) Cenário 3: Treino *offline* com uma única realização do sinal de EEG. Teste *online* com o restante dos sinais de EEG do paciente. Dentre os modelos treinados, o que apresentou o melhor desempenho para as métricas utilizadas foi a rede autocodificadora de 3 camadas ocultas, alcançando 91% (acurácia), 93% (sensibilidade) e 91% (especificidade).

**Palavras-chave:** crises epilépticas; eletroencefalograma; modelagem; *autoencoder*; detecção de anomalias; detecção em tempo real.

## ABSTRACT

Seizures are abnormal conditions in an individual's brain that can cause spasms, convulsions, or even more serious complications. One way to identify these anomalies is through an electroencephalogram (EEG), a test responsible for capturing the patient's brain activity. With this data, pattern recognition models can be used to determine whether the received signals are normal or not. This work proposes the modeling of such signals with autoencoder neural networks, algorithms capable of detecting anomalies in the EEG signal based on the model's reconstruction error. Additionally, a training approach was used to simulate the real-time acquisition of signals, enabling the extension of the application for this type of use. The following models were evaluated in the anomaly detection task: linear autoencoder (PCA) and autoencoder networks with 1 and 3 hidden layers. Several simulation scenarios were developed, namely: (i) Scenario 1: Offline training and testing using all patient datasets. Training is performed only with negative (i.e., non-seizure) data; (ii) Scenario 2: Similar to Scenario 1, however, training includes some positive instances (*Open Set* scheme); and (iii) Scenario 3: Offline training with a single realization of the EEG signal. Online testing with the remaining patient EEG signals. Among the trained models, the one that presented the best performance for the metrics used was the 3-hidden-layer autoencoder network, achieving 91% (accuracy), 93% (sensitivity) and 91% (specificity).

**Keywords:** seizures; electroencephalogram; modeling; autoencoder; anomaly detection; real time detection.

## LISTA DE FIGURAS

Figura 1 – Exemplo de sinais obtidos dos 23 canais de um Eletroencefalograma (EEG) de escalpo. . . . .	19
Figura 2 – Arranjo dos eletrodos de acordo com o padrão do sistema 10-20. . . . .	20
Figura 3 – Arquitetura geral de uma rede autocodificadora. . . . .	22
Figura 4 – Arquitetura de uma rede autocodificadora com três camadas ocultas. A representação latente é obtida a partir da saída dos neurônios da camada mais central (de menor dimensão). . . . .	26
Figura 5 – Detalhamento dos canais utilizados no EEG. . . . .	27
Figura 6 – Sinal ictal abstraído do canal 1 do paciente chb01 . . . . .	29
Figura 7 – Evolução das métricas para o paciente chb01 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	42
Figura 8 – Evolução das métricas para o paciente chb03 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	42
Figura 9 – Evolução das métricas para o paciente chb07 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	43
Figura 10 – Evolução das métricas para o paciente chb14 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	43
Figura 11 – Evolução das métricas para o paciente chb01 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	48
Figura 12 – Evolução das métricas para o paciente chb03 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	48
Figura 13 – Evolução das métricas para o paciente chb05 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	48
Figura 14 – Evolução das métricas para o paciente chb07 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	49
Figura 15 – Evolução das métricas para o paciente chb14 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	49
Figura 16 – Evolução das métricas para o paciente chb18 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta. . . .	49
Figura 17 – Evolução das métricas para o paciente chb01 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	49

Figura 18 – Evolução das métricas para o paciente chb03 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	50
Figura 19 – Evolução das métricas para o paciente chb05 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	50
Figura 20 – Evolução das métricas para o paciente chb07 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	50
Figura 21 – Evolução das métricas para o paciente chb14 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	50
Figura 22 – Evolução das métricas para o paciente chb18 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas. . .	51
Figura 23 – Hipóteses mostrando a proporção ictal/não-ictal. . . . .	52

## LISTA DE TABELAS

Tabela 1 – Informações dos pacientes . . . . .	28
Tabela 2 – Dados das convulsões registradas po paciente . . . . .	29
Tabela 3 – Resultados dos modelos autocodificadores para o Cenário 1. . . . .	37
Tabela 4 – Resultados dos modelos autocodificadores para o Cenário 2. . . . .	38
Tabela 5 – Resultados para a rede autocodificadora com 1 camada oculta variando-se o valor mínimo da função objetivo durante o treinamento. . . . .	38
Tabela 6 – Resultados do modelo PCA para o Cenário 3. . . . .	39
Tabela 7 – Resultados para o paciente chb01. . . . .	39
Tabela 8 – Resultados para o paciente chb03. . . . .	39
Tabela 9 – Resultados para o paciente chb05. . . . .	39
Tabela 10 – Resultados para o paciente chb07. . . . .	40
Tabela 11 – Resultados para o paciente chb14. . . . .	40
Tabela 12 – Resultados para o paciente chb18. . . . .	40

## **LISTA DE ABREVIATURAS E SIGLAS**

.edf	European Data Format
CHB	Hospital Infantil de Boston
DDP	Diferenças de Potencial
EEG	Eletroencefalograma
MLP	Perceptron Multicamadas
OLS	Mínimos Quadrados Ordinários
OMS	Organização Mundial de Saúde
PCA	Análise de Componentes Principais
VE	Variância Explicada
VT	Variância Total

## LISTA DE SÍMBOLOS

$\mu V$	Microvolts
$\lambda$	Autovalor
$N_{files}$	Número de arquivos
$TP$	Verdadeiros positivos
$TN$	Verdadeiros negativos
$FP$	Falsos positivos
$FN$	Falsos negativos
$q$	Dimensão dos dados após a transformação com PCA
$V_{min}$	Valor mínimo da função objetivo durante o treinamento
$N_i$	Número de amostras da classe $i$
$\mathbf{C}_x$	Matriz de convarância
$tol$	Porcentagem da informação que se deseja manter após a redução de dimensionalidade realizada por PCA
$e_k^2$	Norma quadrática do erro de reconstrução da amostra de índice $k$
$L$	Limiar de anomalia
$AF$	Função de ativação escolhida após os testes empíricos
$P_{rate}$	Porcentagem de casos positivos nos dados

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>14</b>
<b>1.1</b>	<b>Objetivos do Trabalho</b>	<b>16</b>
<b>1.2</b>	<b>Organização do restante da monografia</b>	<b>17</b>
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>18</b>
<b>2.1</b>	<b>Crises Epiléticas</b>	<b>18</b>
<b>2.2</b>	<b>Eletroencefalograma de Escalpo</b>	<b>18</b>
<b>2.3</b>	<b>O problema de Detecção de Anomalias</b>	<b>21</b>
<b>2.4</b>	<b>PCA e Redes Autocodificadoras</b>	<b>21</b>
<b>2.4.1</b>	<i>PCA como Modelo Autocodificador Linear</i>	<b>22</b>
<b>2.4.2</b>	<i>Limiar de Anomalia</i>	<b>25</b>
<b>2.5</b>	<b>Redes Neurais Autocodificadoras Baseadas em MLP</b>	<b>25</b>
<b>3</b>	<b>MATERIAL E MÉTODOS</b>	<b>27</b>
<b>3.1</b>	<b>Conjunto de dados</b>	<b>27</b>
<b>3.2</b>	<b>Cenários de simulação</b>	<b>30</b>
<b>3.3</b>	<b>Pré-Processamento e Extração de Atributos</b>	<b>31</b>
<b>3.4</b>	<b>Experimentos Preliminares</b>	<b>33</b>
<b>3.4.1</b>	<i>Ampliação dos testes</i>	<b>34</b>
<b>3.5</b>	<b>Avaliação dos Resultados</b>	<b>35</b>
<b>4</b>	<b>RESULTADOS</b>	<b>37</b>
<b>4.1</b>	<b>Resultados para os Cenários 1 e 2</b>	<b>37</b>
<b>4.2</b>	<b>Resultados para o Cenário 3</b>	<b>38</b>
<b>5</b>	<b>CONCLUSÕES E TRABALHOS FUTUROS</b>	<b>44</b>
	<b>REFERÊNCIAS</b>	<b>45</b>
	<b>APÊNDICE A –MÉTRICAS DOS TESTES EXPLORATÓRIOS</b>	<b>48</b>
	<b>APÊNDICE B –HIPÓTESES DE OLIVEIRA (2021)</b>	<b>52</b>

# 1 INTRODUÇÃO

As crises epiléticas são anomalias cerebrais que afetam o sistema nervoso de um indivíduo e fazem com que seus emissores de impulsos elétricos enviem sinais em excesso, provocando convulsões. Tais crises podem ser originadas por uma irregularidade em apenas um segmento do cérebro (crises epiléticas focais) ou em toda a extensão cerebral (crises epiléticas generalizadas), durando de alguns segundos à alguns minutos (MARCUSE, FIELDS and YOO, 2016).

Esta patologia pode ser diagnosticada através de exames de EEG de escalpo onde eletrodos são colocados no couro cabeludo para capturar e gravar os sinais elétricos do cérebro. No entanto, a análise dos sinais de EEG por um profissional treinado consome muito tempo e pode, eventualmente, induzir a erros de diagnóstico. Por isso, a utilização de técnicas semi-automatizadas com o intuito de auxiliar esses profissionais é bastante interessante (Oliveira, 2021).

De interesse para este trabalho, está a extração de atributos e a classificação de EEG via técnicas de aprendizado de máquinas para diagnóstico de crises convulsivas epiléticas. Neste sentido, há vários trabalhos na literatura que abordam esta aplicação. Restringido-nos aos trabalhos que utilizam o conjunto de dados do Hospital Infantil de Boston (Gutttag, 2010), podemos mencionar inicialmente o trabalho de Fredes et al. (2024)<sup>1</sup> que desenvolveram uma técnica automatizada para identificar crises epiléticas em dados de EEG, combinando processamento de sinais e aprendizado de máquina. A abordagem inclui quatro etapas: pré-processamento, decomposição, extração de características e classificação. Avaliada com dois conjuntos de dados públicos, a maior precisão alcançada foi de 92,82% para a banda alfa e 90,55% para a banda beta, demonstrando capacidade adequada de detecção de crises com baixo custo computacional.

O estudo realizado por Sánchez-Hernández et al. (2024)<sup>2</sup> utilizou modelos de aprendizado profundo para detecção de crises epiléticas e avaliou três bancos de dados de EEG. Os classificadores foram treinados e avaliados sob diferentes condições, e as taxas de acurácia mais significativas foram 0,84, 0,73 e 0,64 para os bancos de dados CHB-MIT, Siena e TUSZ, respectivamente. A correlação entre características do EEG e valores de importância (medidas

<sup>1</sup> S. Urbina Fredes, A. Dehghan Firoozabadi, P. Adasme, D. Zabala-Blanco, P. Palacios Játiva, and C. Azurdia-Meza. Enhanced epileptic seizure detection through wavelet-based analysis of eeg signal processing. *Applied Sciences*, 14(5783), 2024.

<sup>2</sup> S.E. Sánchez-Hernández, S. Torres-Ramos, I. Román-Godínez, and R.A. Salido-Ruiz. Evaluation of the relation between ictal eeg features and xai explanations. *Brain Sciences*, 14:306, 2024.

utilizadas para estimar a relevância de cada variável na construção do modelo) mostrou-se baixa ou insignificante na maioria dos casos. Concluiu-se que as condições de treinamento podem afetar o desempenho dos classificadores e a correlação com os valores de importância.

Já o estudo por Dweiri & Al-Omary (2024)<sup>3</sup> desenvolveu um novo algoritmo de aprendizado de máquina para detecção de crises adequado para sistemas vestíveis. Foi implementado o XGBoost para classificar crises a partir de um único canal de EEG obtido do banco de dados CHB-MIT. Os resultados mostraram que classificar segmentos de EEG de 1 segundo é suficiente para obter a informação necessária para a detecção de crises, alcançando uma sensibilidade de até 89% com baixo custo computacional. Mir et al. (2023)<sup>4</sup> desenvolveu um modelo de aprendizado profundo utilizando uma rede autocodificadora convolucional profunda, DCAE-ESD-Bi-LSTM, para a detecção automática de crises epiléticas usando dados de EEG. Os resultados no conjunto de dados CHB-MIT e no conjunto coletado pelos autores mostraram a relevância da abordagem proposta, alcançando uma precisão de 99,8%, acurácia de 99,7%, sensibilidade de 99,8%, especificidade e precisão de 99,9%, e F1 score de 99,6%.

Sánchez-Hernández et al. (2022)<sup>5</sup> compararam o desempenho de métodos de seleção de características em diferentes modelos de classificação para detectar crises epiléticas nos bancos de dados CHB-MIT e Siena Scalp EEG. Foram avaliados diferentes conjuntos de características e número de características selecionadas, além da similaridade entre subconjuntos de características selecionadas. O melhor F1-score (0,90) foi obtido pelo classificador KNN com o conjunto de dados CHB-MIT. Alharthi et al. (2022)<sup>6</sup> integraram sinais de EEG locais do hospital da Universidade *King Abdulaziz* ao conjunto de dados CHB-MIT. Os conjuntos de dados integrados, que contêm canais seletivos, foram testados e avaliados usando modelos de aprendizado profundo (1D-CNN, Bi-LSTM e mecanismos de atenção). Os resultados alcançaram até 96,87% de acurácia, 96,98% de precisão e 96,85% de sensibilidade, superando outros sistemas mais recentes com um maior número de canais de EEG.

Para os leitores interessados, um *survey* de vários trabalhos anteriores que usam o conjunto de dados de EEG do Hospital Infantil de Boston pode ser encontrado em Prasanna

<sup>3</sup> Y.M. Dweiri and T.K. Al-Omary. Novel ml-based algorithm for detecting seizures from single-channel eeg. *NeuroSci*, 5:59–70, 2024.

<sup>4</sup> W.A. Mir, M. Anjum, Izharuddin, and S. Shahab. Deep-eeg: An optimized and robust framework and method for eeg-based diagnosis of epileptic seizure. *Diagnostics*, 13:773, 2023.

<sup>5</sup> S.E. Sánchez-Hernández, R.A. Salido-Ruiz, S. Torres-Ramos, and I. Román-Godínez. Evaluation of feature selection methods for classification of epileptic seizure eeg signals. *Sensors*, 22:3066, 2022.

<sup>6</sup> M.K. Alharthi, K.M. Moria, D.M. Alghazzawi, and H.O. Tayeb. Epileptic disorder detection of seizures using eeg signals. *Sensors*, 22:6592, 2022.

(2021). Mais detalhes sobre este conjunto serão apresentados no Capítulo 3.

Embora seja um tópico que vem sendo pesquisado há anos, percebe-se que grande parte dos trabalhos desenvolvidos visando o uso de técnicas de aprendizado de máquinas para detecção de crises epiléticas não abordam ou não dão a devida atenção a questões relacionadas ao uso prático da ferramenta de detecção, conforme evidenciado por Ali et al. (2024)<sup>7</sup>. Dentre os fatores relevantes para a aplicabilidade real de tais sistemas destacam-se: (i) o uso sequencial (i.e., em tempo real) de sinais de EEG apresentam um grande desequilíbrio de classes; (ii) há uma grande variabilidade entre sinais de EEG de pacientes diferentes; e (iii) a detecção de eventos de crise em tempo real é de mais interesse prático do que a detecção de segmentos aleatórios comum em trabalhos puramente acadêmicos.

Isto posto, neste trabalho de conclusão de curso pretendemos investigar diferentes cenários de treinamento e teste dos modelos de aprendizado de máquinas para detecção de crises epiléticas usando os sinais de EEG do conjunto de dados CHB-MIT, contribuindo desta forma para o uso prático de tais estudos. Para tratar a questão do desequilíbrio entre as classes convulsiva (escassa em dados) e não-convulsivas (abundante em dados), usaremos modelos de aprendizado de máquinas treinados na tarefa de detecção de anomalias/novidades (Albuquerque & Barreto, 2023). Estes modelos serão treinados e testados tanto em cenários de uso não-sequencial dos dados quanto em cenários de uso sequencial (emulando o teste em tempo real), haja visto que um modelo capaz de receber e processar sinais de maneira *online* possui um alto valor para aplicações no âmbito da saúde, tendo em vista que em muitos casos os pacientes estão sendo monitorados em tempo real e uma indicação imediata de seu estado é de grande importância. A questão da variabilidade entre sinais de pacientes diferentes não será tratada neste trabalho de conclusão.

## 1.1 Objetivos do Trabalho

O objetivo principal deste trabalho é avaliar o desempenho de técnicas de detecção de anomalias na detecção de crises convulsivas epiléticas a partir de sinais de EEG

Além disso, este trabalho de conclusão de curso possui os seguintes objetivos específicos:

1. Implementar e avaliar a técnica PCA na detecção de anomalias em sinais de EEG em

<sup>7</sup> Ali Emran, Maia Angelova, and Chandan Karmakar. Epileptic seizure detection using chb-mit dataset: The overlooked perspectives. Royal Society Open Science, 11:230601, 2024.

- diferentes cenários de simulação;
2. Implementar e avaliar a rede neural autocodificadora de 1 camada oculta na detecção de anomalias em sinais de EEG em diferentes cenários de simulação;
  3. Implementar e avaliar a rede neural autocodificadora de 3 camadas ocultas na detecção de anomalias em sinais de EEG em diferentes cenários de simulação;

## **1.2 Organização do restante da monografia**

No Capítulo 2 são apresentados os fundamentos teóricos necessários para o entendimento das técnicas de detecção de anomalias avaliadas neste trabalho com o fim de detectar crises epiléticas convulsivas a partir de sinais de EEG.

No Capítulo 3 são definidos o conjunto de dados utilizados no trabalho e os métodos escolhidos. Além disso, é feita uma descrição do pré-processamento realizado e das métricas designadas para a avaliação de desempenho.

No Capítulo 4 são expostos os resultados obtidos a partir da metodologia definida no Capítulo 3, com análises, tabelas e gráficos.

Por fim, no Capítulo 5 é feita uma breve conclusão do trabalho, com ideias para possíveis trabalhos futuros que podem dar prosseguimento ao estudo.

## **2 FUNDAMENTAÇÃO TEÓRICA**

Alguns conceitos importantes devem ser discutidos para reforçar o entendimento do leitor sobre o conteúdo deste trabalho.

### **2.1 Crises Epilépticas**

As crises epilépticas são caracterizadas por anomalias temporárias na atividade cerebral, que podem ocasionar desde uma breve perda de atenção até uma convulsão corporal completa. A ocorrência regular de crises epilépticas pode aumentar o risco de lesões físicas por parte do indivíduo e potencialmente ocasionar a sua morte. Dessa forma, um dispositivo que possa detectar acuradamente uma crise e administrar um medicamento ou alertar um cuidador poderia ajudar a mitigar os desafios oriundos dessa problemática. (Guttag, 2010)

Indivíduos com epilepsia, uma desordem no sistema nervoso central, experienciam crises epilépticas recorrentes que acontecem de maneira imprevisível e sem alerta (Guttag, 2010). Segundo a Organização Mundial de Saúde (OMS), a epilepsia afeta cerca de 50 milhões de pessoas no mundo todo. Dessas, aproximadamente 40 milhões vivem em países de média e baixa renda. O diagnóstico da epilepsia é feito de maneira clínica, mas outros procedimentos podem ser utilizados para ajudar em sua identificação.

Tendo em vista os riscos oferecidos pelas crises epilépticas, a sua detecção rápida e eficiente é de extrema importância para evitar maiores danos ao indivíduo que está sofrendo.


### **2.2 Eletroencefalograma de Escalpo**

O primeiro EEG feito em humanos foi gravado em 1924 por Hans Berger, um professor de psiquiatria da Universidade de Jena (Alemanha), que também realizou o procedimento em seu filho, Klaus. Nessa experiência, Hans percebeu que a gravação era facilitada quando o rapaz estava com cabelo curto e, por esse motivo, o professor preferia realizar o procedimento em pacientes carecas (MISRA and KALITA, 2018).

Em suas investigações, Berger identificou dois tipos de ondas cerebrais, que ele chamou de alfa e beta, publicando seus achados em 1929. Mais tarde, esses resultados foram validados por outros pesquisadores que utilizaram equipamentos mais avançados, com amplificadores de maior ganho e maior frequência, muito mais sensíveis do que os que Berger havia empregado.

O EEG de escalpo é um exame acessível e não invasivo, capaz de registrar a atividade elétrica do córtex cerebral por meio da colocação de eletrodos de forma simétrica no couro cabeludo do paciente (MARCUSE, FIELDS and YOO, 2016). Esses eletrodos captam o potencial elétrico de diferentes regiões do cérebro, permitindo que sejam calculadas as Diferenças de Potencial (DDP) entre dois eletrodos de interesse. Essa DDP é registrada como a atividade de um canal do EEG, sendo o número de canais variável para cada aplicação do exame (são utilizados 23 canais na maioria dos dados deste trabalho). A Figura 1 ilustra o EEG de um paciente traçado no software EEGLAB<sup>1</sup>.

Figura 1 – Exemplo de sinais obtidos dos 23 canais de um EEG de escalpo.



Fonte: <https://archive.physionet.org/physiobank/charts/chbmit.png>


Entretanto, os sinais captados pelos eletrodos possuem valores absolutos muito baixos e, conseqüentemente, a DDP é medida em microvolts ( $\mu V$ ). Dessa forma, os sinais precisam ser amplificados por um fator de  $10^6$  para ser exibidos no computador, amplificando também potenciais indesejados que acompanham as medições. Tais potenciais recebem o nome de artefatos e devem ser corrigidos para evitar que interfiram na interpretação dos sinais obtidos. Alguns dos artefatos encontrados durante a realização do EEG são piscamento palpebral,

<sup>1</sup> Disponível em <https://sccn.ucsd.edu/eeglab/>

fechamento forçado dos olhos, fechamento forçado da mandíbula, movimentos de língua e varredura horizontal dos olhos (Dr. Renato Anghinah, 2006).

Existem diferentes padrões para a montagem dos eletrodos. Na obtenção dos dados utilizados neste trabalho foi utilizado o padrão 10-20 (Gutttag, 2010), assim chamado porque todos os eletrodos são colocados a distâncias compreendidas entre 10% e 20% das referências utilizadas no crânio. A Figura 2 ilustra a disposição dos eletrodos seguindo esse padrão.

Figura 2 – Arranjo dos eletrodos de acordo com o padrão do sistema 10-20.



Fonte: <https://www.diytdcs.com/tag/1020-system-positioning/>

As letras que identificam os eletrodos estão relacionadas ao lobo cerebral que monitoram da seguinte forma:

- F = Frontal
- Fp = Frontopolar
- T = Temporal
- C = Central
- P = Parietal
- O = Occipital
- A = Auricular

Além disso, o número que identifica o eletrodo indica a posição em que este foi colocado, sendo números ímpares indicativos do lado esquerdo do couro cabeludo, números pares do lado direito e a letra “z” minúscula indicativa da porção central.

### 2.3 O problema de Detecção de Anomalias

A detecção de anomalias é um tipo de classificação binária, também chamada de classificação de classe única (*one-class classification*) (P. Perera et al., 2021). É especialmente útil quando o número de exemplos de uma das classes ( $N_1$ ) é muito maior que o da outra classe ( $N_2$ ), ou seja,  $N_1 \gg N_2$ . A ideia consiste em construir um modelo matemático apenas da classe com o maior número de exemplos (normalmente a de exemplos negativos) e em seguida definir um limiar de decisão (L), que será usado para identificar se um dado vetor de atributos é portador de informação anômala, ou seja, estranha ao modelo construído.

Algumas das aplicações típicas para a detecção de anomalias são:

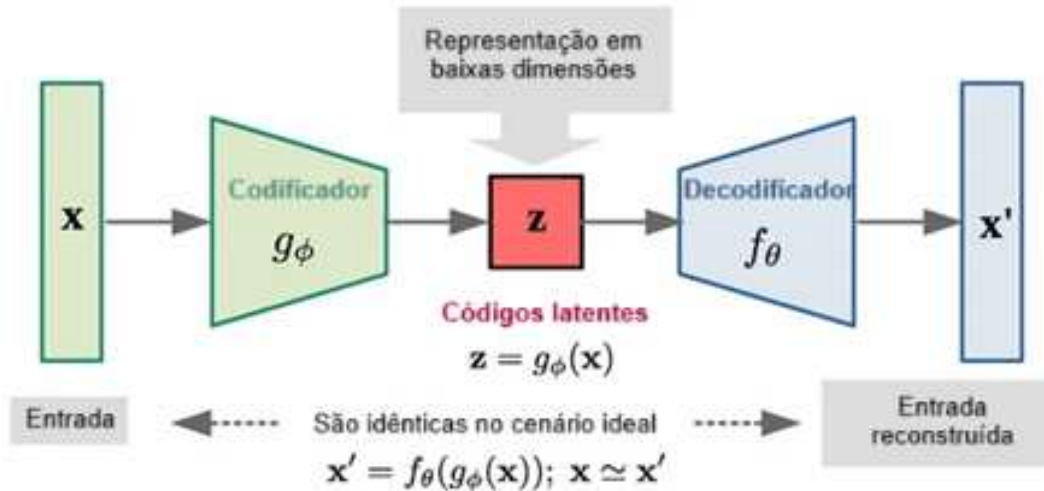
- Detecção de crises epiléticas convulsivas: costuma-se ter mais dados, na forma de sinais de EEG, representativos do estado *não-convulsivo* do que dados correspondentes ao estado convulsivo. Constroi-se então um modelo para representar a classe *não-convulsivo*
- Detecção de falhas em equipamentos elétricos (e.g., motor): dados obtidos do funcionamento normal (e.g., não-faltoso) são mais comuns do que dados de falhas/faltas. Constroi-se então um modelo para representar o motor em seu funcionamento normal (classe *não-falha*). Pode-se dizer que o modelo representa o motor em seu estado normal de funcionamento.

### 2.4 PCA e Redes Autocodificadoras

Nesta seção são apresentados os conceitos de redes codificadoras, PCA e limiar de anomalia, conforme apresentados em Barreto (2023).

Modelos autocodificadores são amplamente utilizados em problemas de detecção de anomalias. A ideia base por trás desses algoritmos é a modelagem de um sinal através de duas etapas: codificação e decodificação. Na codificação, o algoritmo utiliza uma técnica de compressão para reduzir a dimensão dos atributos de entrada com o mínimo de perda de informação possível. Já na decodificação, os dados resultantes da compressão são descomprimidos e o vetor de atributos retoma sua dimensão original. A Figura 3 ilustra esse processo.

Figura 3 – Arquitetura geral de uma rede autocodificadora.



Fonte: Adaptada de Sarajcev et al. (2020)

Assim como em modelos tradicionais de aprendizado de máquinas, o algoritmo de um modelo autocodificador é dividido em etapas de treino e teste. Na etapa de treino é calculado o erro quadrático médio obtido entre os dados originais e os reconstruídos e é identificado o valor do limiar de detecção a partir de um percentil definido pelo projetista/desenvolvedor.

#### 2.4.1 PCA como Modelo Autocodificador Linear

A *Análise de Componentes Principais (PCA)* é um procedimento matemático linear que almeja diagonalizar a matriz de covariância dos dados de entrada, ou, em outras palavras, descorrelacionar os atributos. Para tal, o algoritmo consiste em alguns passos.

Seja  $\mathbf{X}$  uma matriz  $p \times N$ , onde  $p$  é o número de atributos e  $N$  o número de amostras do problema em questão, de modo que cada coluna consiste em uma amostra do vetor de atributos. Nomearemos cada vetor de atributos  $\mathbf{x}_k$ , onde  $k = 1, \dots, N$ . Nessas circunstâncias, o procedimento é o seguinte:

1. Determinar o vetor médio dos dados em  $\mathbf{X} \in \mathbb{R}^{p \times N}$ :

$$\bar{\mathbf{x}} = \frac{1}{N} \sum_{k=1}^N \mathbf{x}_k \quad (2.1)$$

onde  $\bar{\mathbf{x}} \in \mathbb{R}^p$ .

2. Centralizar os dados:

$$\mathbf{x}_k = \mathbf{x}_k - \bar{\mathbf{x}} \quad (2.2)$$

3. Estimar a matriz de covariância dos dados em  $\mathbf{X}$ :

$$\mathbf{C}_x = E[\mathbf{x}\mathbf{x}^T] \approx \frac{1}{N} \sum_{k=1}^N \mathbf{x}_k \mathbf{x}_k^T \quad (2.3)$$

onde  $E[\cdot]$  denota o operador valor esperado e  $\mathbf{C}_x \in \mathbb{R}^{p \times p}$ .

4. Determinar os  $p$  autovalores da matriz  $\mathbf{C}_x$  e os  $p$  autovetores correspondentes. Em outras palavras, resolver o seguinte sistema de equações:

$$\mathbf{C}_x \mathbf{v} = \lambda \mathbf{v} \quad (2.4)$$

onde  $\lambda \in \mathbb{R}_{>0}$  e  $\mathbf{v} \in \mathbb{R}^p$  correspondem ao autovalor e autovetor associados.

5. Definir a matriz de transformação  $\mathbf{Q} \in \mathbb{R}^{N \times p}$  como

$$\mathbf{Q} = \mathbf{V}^T \quad (2.5)$$

onde  $\mathbf{V} \in \mathbb{R}^{p \times N}$  é a matriz cujas colunas correspondem aos autovetores  $\mathbf{v}$  encontrados no passo anterior.

6. Aplicar a matriz  $\mathbf{Q}$  sobre os vetores de atributos originais (codificação):

$$\mathbf{Z} = \mathbf{Q}\mathbf{X} \quad (2.6)$$

Feito o procedimento, a matriz  $\mathbf{Z} \in \mathbb{R}^{p \times N}$  corresponderá aos dados de entrada  $\mathbf{X}$  após uma mudança de base, sendo esta responsável por diagonalizar a matriz de covariância. Vale notar que a matriz  $\mathbf{V}$  é definida pelos autovetores encontrados no passo 4, e cada um deles possui um autovalor associado. Na técnica de PCA esses autovalores correspondem às variâncias dos novos atributos gerados após a transformação linear da Eq. 2.6.

Nesse contexto é definido o conceito de *Variância Total (VT)* que corresponde a soma da covariância dos dados após a transformação, ou seja:

$$VT = \lambda_1 + \lambda_2 + \dots + \lambda_p \quad (2.7)$$

Outrossim, o conceito conhecido como *Variância Explicada (VE)* consiste na porcentagem de  $VT$  que corresponde a um único autovalor, ou seja:

$$VE_i = 100 \times \frac{\lambda_i}{VT} \quad (2.8)$$

em que  $\lambda_i$  denota o  $i$ -ésimo autovalor da matriz  $\mathbf{C}_x$

Em geral, costuma-se ordenar os pares (autovalor, autovetor) em ordem decrescente e definir um valor de tolerância ( $tol$ ) para a variância explicada. Assim, são encontrados os  $q$  primeiros autovalores cuja soma de suas  $VE$  seja no mínimo  $tol$  e a matriz  $\mathbf{Q}$  pode ser definida como os  $q$  autovetores a eles associados.

Na prática, isso faz com que a matriz  $\mathbf{Q}$  tenha dimensões  $q \times p$ , o que resulta em uma redução na dimensionalidade dos dados, uma vez que a matriz  $\mathbf{X}$  terá dimensões  $p \times N$  enquanto a matriz  $\mathbf{Z}$  terá dimensões  $q \times N$ . Essa redução é especialmente interessante devido à escolha de  $tol$ , pois ela representa a porcentagem da informação original que será mantida após a redução de dimensionalidade. Em suma, o procedimento estará reduzindo o número de atributos do problema, reduzindo a complexidade de modelos que serão alimentados com a informação, removendo eventuais redundâncias e mantendo uma porcentagem de informação previamente definida.

Um outro aspecto importante da técnica é que os dados originais podem ser recuperados a partir dos dados transformados utilizando a inversa da matriz de transformação (decodificação), ou seja:

$$\hat{\mathbf{X}} = \mathbf{Q}^T \mathbf{Z} \quad (2.9)$$

Em casos onde houve redução de dimensionalidade essa transformação inversa conterà um erro decorrente da perda de informação nos dados.

A técnica de PCA pode ser entendida como um modelo autocodificador linear, onde a parte do codificador (compressor) é implementada pela operação da equação 2.9 e a parte do decodificador (reconstrutor) é implementada pela operação da equação 2.9. Dependendo da área de aplicação, cada vetor  $\mathbf{z}_k$  que compõe a matriz  $\mathbf{Z}$  pode ser chamado de *vetor-código* (telecomunicações) ou de vetor de *variáveis latentes* (aprendizado de máquinas).

A norma quadrática do erro de reconstrução da entrada  $\mathbf{x}$  do autoencoder é dado por:

$$\mathbf{e}_k^2 = \|\mathbf{x}_k - \hat{\mathbf{x}}_k\|^2 \quad (2.10)$$

em que  $k = 1, \dots, N$  e  $\|\cdot\|$  denota a norma euclidiana.

### 2.4.2 Limiar de Anomalia

Suponha que medimos várias grandezas físicas, agrupando-as em um vetor  $\mathbf{x} \in \mathbb{R}^p$ , e que juntas representam o estado de um processo industrial, de um equipamento, ou até de um paciente. Então podemos usar a seguinte regra de decisão para detectar anomalias no processo/equipamento/paciente:

$$\text{SE } \|\mathbf{x} - \hat{\mathbf{x}}\|^2 > L, \quad (2.11)$$

ENTÃO  $\mathbf{x}$  é (possivelmente) um estado anômalo.

em que  $L > 0$  denota o limiar de anomalia, computado como uma estatística dos erros quadráticos de reconstrução.

Em palavras, se o erro quadrático de reconstrução para um dado vetor  $\mathbf{x}$  é maior que o limiar  $L$ , então  $\mathbf{x}$  provavelmente denota um estado anômalo.

O limiar de decisão  $L$  pode ser calculado de duas maneiras, conforme será descrito a seguir:

- **MÉTODO 1** - O limiar de decisão  $L$  é determinado pelo valor crítico da distribuição chi-quadrado  $\chi_{(p, 1-\alpha)}^2$  com  $p$  graus de liberdade e nível de significância  $\alpha$ . A escolha deste método assume que os erros quadráticos  $\{e^2(\mathbf{x}, \hat{\mathbf{x}})\}$  seguem tal distribuição.

No Python,  $L = \text{chi2.ppf}(1 - \alpha, p)$

- **MÉTODO 2** - O limiar de decisão  $L$  é determinado calculando-se o percentil  $100 * (1 - \alpha)$  para o conjunto  $\{e^2(\mathbf{x}, \hat{\mathbf{x}})\}_{k=1}^{N_{trn}}$ , que é o conjunto dos erros quadráticos de reconstrução dos  $N_{trn}$  vetores de treinamento.

No Python,  $k = \text{np.percentile}(D2trn, 100 * (1 - \alpha))$

É importante salientar que os vetores utilizados no cálculo do limiar  $L$  não podem ser representativos de estados anômalos, uma vez que  $L$  é calculado com base em uma modelagem do estado normal do processo/equipamento/paciente em questão.

## 2.5 Redes Neurais Autocodificadoras Baseadas em MLP

A rede neural Perceptron Multicamadas (MLP) é um modelo não-linear de processamento da informação, onde cada camada recebe como entrada a saída da camada anterior e

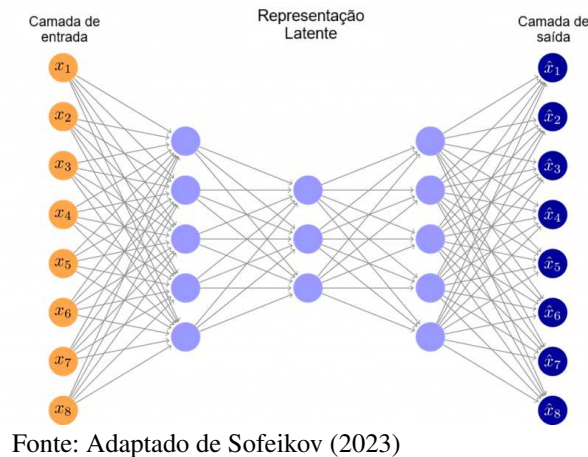
encaminha uma saída para a próxima.

A primeira camada de uma rede MLP é chamada de camada de entrada e recebe os atributos diretamente. A última camada é chamada de camada de saída e os resultados serão as saídas da rede como um todo. As demais camadas são chamadas de camadas ocultas. As entradas dessas camadas são o resultado da passagem da saída da camada anterior por uma função de ativação.

Seu funcionamento consiste em receber um valor numérico de entrada e gerar uma saída com base em pesos definidos na etapa de treino. Esses pesos são estimados pelo algoritmo de retropropagação do erro (*error backpropagation*) proposto por Rumelhart et al. (1986)<sup>2</sup>, que é um algoritmo de otimização baseado no gradiente de uma função objetivo, normalmente a soma dos erros quadráticos.

Na etapa de treino são definidas as entradas para refinar o modelo e as saídas que devem ser obtidas. Dessa forma, definindo as saídas para serem iguais as entradas e escolhendo um número de neurônios nas camadas ocultas menor que nas camadas de entrada/saída, o modelo MLP funcionará como um codificador e decodificador de dados, podendo ser utilizado no algoritmo do modelo autocodificador. A Figura 4 ilustra esse processo.

Figura 4 – Arquitetura de uma rede autocodificadora com três camadas ocultas. A representação latente é obtida a partir da saída dos neurônios da camada mais central (de menor dimensão).



O cálculo do limiar de anomalia é feito da mesma maneira que a descrita na seção 2.4.2.

<sup>2</sup> D. E. Rumelhart, G. E. Hinton, and R. J. Williams. Learning representations by backpropagation errors. *Nature*, 323:533–536, 1986.

### 3 MATERIAL E MÉTODOS

Neste capítulo será descrita a metodologia utilizada para a realização do trabalho. Dessa forma, serão explorados o conjunto de dados utilizado, o pré-processamento, a modelagem e a avaliação do desempenho obtido.

#### 3.1 Conjunto de dados

Para experimento neste trabalho foi utilizado o conjunto de dados CHB-MIT Scalp EEG Database, disponibilizado por Gutttag (2010) para download em <https://physionet.org/content/chbmit/1.0.0/>.

O conjunto de dados foi coletado no Hospital Infantil de Boston (CHB) e consiste na gravação de EEG de pacientes pediátricos com convulsões incuráveis. Os sujeitos tiveram suas medicações anticonvulsivantes interrompidas e foram monitorados durante vários dias com o intuito de caracterizar suas convulsões e avaliar sua candidatura para intervenção cirúrgica. As gravações foram coletadas de 22 indivíduos, dentre eles 5 homens, com idades entre 3 e 22 anos, e 17 mulheres, com idades entre 1 e 19 anos, possuindo 23 canais (John Gutttag, 2010). A Figura 5 mostra os eletrodos utilizados por cada canal.

Figura 5 – Detalhamento dos canais utilizados no EEG.

1	2	3	4	5	6
FP1-F7	F7-T7	T7-P7	P7-O1	FP1-F3	F3-C3
7	8	9	10	11	12
C3-P3	P3-O1	FP2-F4	F4-C4	C4-P4	P4-O2
13	14	15	16	17	18
FP2-F8	F8-T8	T8-P8	P8-O2	FZ-CZ	CZ-PZ
19	20	21	22	23	
P7-T7	T7-FT9	FT9-FT10	FT10-T8	T8-P8	

Fonte: Romney et al. (2021)

Cada paciente foi identificado por um inteiro de 1 a 22 e foram gerados vários arquivos de extensão *European Data Format (.edf)* contendo os sinais captados pelos 23 canais. Devido às limitações de máquina foram geradas algumas lacunas entre o fim de um arquivo e o início de seguinte, sendo essas lacunas em grande parte de 10s. Também foram gerados arquivos de nome “chbn-summary.txt” para cada paciente de identificador  $n$ , contendo informações sobre

a taxa de amostragem, os canais de EEG utilizados, os horários de início e fim das medições de cada arquivo, o número de convulsões identificadas por arquivo e os instantes de início e fim de cada uma delas. As convulsões foram identificadas por um profissional do hospital. A Tabela 1 contém algumas informações sobre os pacientes.

Tabela 1 – Informações dos pacientes

ID do paciente	Gênero	Idade	Arquivos EDF
chb01	F	11	42
chb02	M	11	36
chb03	F	14	38
chb04	M	22	42
chb05	F	7	39
chb06	F	1,5	18
chb07	F	14,5	19
chb08	M	3,5	20
chb09	F	10	19
chb10	M	3	25
chb11	F	12	35
chb12	F	2	24
chb13	F	3	33
chb14	F	9	26
chb15	M	16	40
chb16	F	7	19
chb17	F	12	21
chb18	F	18	36
chb19	F	19	30
chb20	F	6	29
chb21	F	13	33
chb22	F	9	31
chb23	F	6	9

Fonte: elaborada pelo autor.

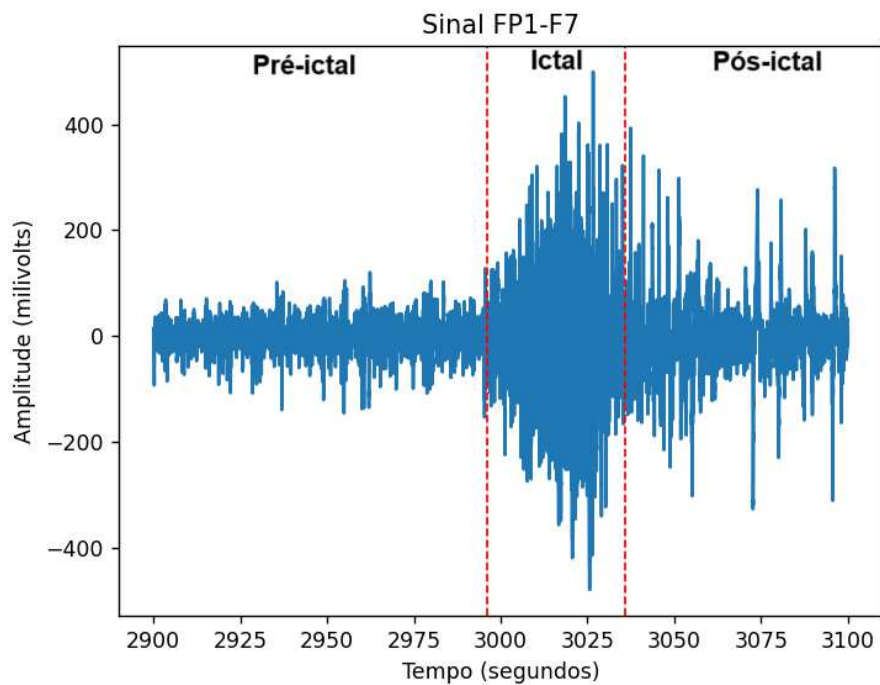
A fim de preservar a privacidade dos pacientes, as informações nos arquivos .edf e as datas das gravações foram alteradas, porém mantendo as devidas proporções para a utilização em pesquisas. A taxa de amostragem utilizada foi de 256Hz com uma resolução de 16 bits, utilizando o padrão 10-20 para posicionamento e nomenclatura dos eletrodos. A maior parte dos arquivos contém 1h de gravação. A Tabela 2 contém alguns dados sobre as crises convulsivas detectadas nos arquivos. Além disso, a Figura 6 mostra um exemplo de sinal de EEG capturado pelo canal 1 do paciente chb01, destacando os períodos antes (pré-ictal), durante (ictal) e após (pós-ictal) uma crise convulsiva.

Tabela 2 – Dados das convulsões registradas po paciente

ID do paciente	Nº de convulsões	Tempo total de convulsões (s)	Tempo médio de convulsões (s)
chb01	7	442	63
chb02	3	172	57
chb03	7	402	57
chb04	4	378	95
chb05	5	558	112
chb06	10	153	15
chb07	3	325	108
chb08	5	919	184
chb09	4	276	69
chb10	7	447	64
chb11	3	806	269
chb12	40	1475	37
chb13	12	535	45
chb14	8	169	21
chb15	20	1992	100
chb16	10	84	8
chb17	3	293	98
chb18	6	317	53
chb19	3	236	79
chb20	8	294	37
chb21	4	199	50
chb22	3	204	68
chb23	7	424	61

Fonte: elaborada pelo autor.

Figura 6 – Sinal ictal abstraído do canal 1 do paciente chb01



Fonte: elaborado pelo autor

### 3.2 Cenários de simulação

Para este trabalho foram utilizados apenas os arquivos referentes às medições de EEG dos pacientes chb01, chb03, chb05, chb07, chb14 e chb18. Esses pacientes foram escolhidos com base no trabalho de Oliveira (2021), cuja escolha se deu a partir de uma prévia de predições com os 22 pacientes e da escolha de alguns com os quais obteve-se uma boa acurácia (pacientes chb01, chb03, chb05 e chb18) e alguns em que se obteve uma baixa acurácia (pacientes chb07 e chb14).

Os arquivos desses pacientes passaram por uma etapa de extração de atributos para gerar os vetores de atributos e os respectivos rótulos. Esses dados obtidos foram utilizados para treinar modelos PCA e redes autocodificadoras com diferentes abordagens e técnicas e, na sequência, foram realizados testes para a avaliação de desempenho.

Antes de definir os 3 cenários de simulação usados para avaliar os métodos de detecção de anomalias descritos no capítulo anterior, precisamos definir os conceitos de treinamento com conjunto aberto (*Open Set*) e conjunto fechado (*Closed Set*). Estas definições foram baseadas naquelas discutidas em Brilhador et al. (2025)<sup>1</sup>, sendo detalhadas a seguir.

Treinamentos com conjuntos fechados são tradicionalmente utilizados na preparação de modelos de aprendizagem de máquina e consistem na especialização do modelo em cenários particulares. No contexto de detecção de anomalias, essa abordagem seria equivalente a treinar um modelo apenas com instâncias negativas (não anômalas). Apesar de comumente utilizada, essa técnica limita a atuação do modelo, tendo em vista que quando o conhecimento adquirido se tornar obsoleto deverá ser realizado um novo treinamento, já que o sistema não é capaz de se atualizar. Além disso, problemas na etapa de rotulação podem gerar consequências desastrosas no desempenho, especialmente para aplicações em áreas sensíveis.

Em contrapartida, treinamentos com conjuntos abertos assumem que o modelo deverá ser capaz de lidar com situações adversas que ocorrem na prática, preparando-o para tais situações. No contexto de detecção de anomalias, essa abordagem seria equivalente a treinar a aplicação com instâncias positivas e negativas (anômalas e não anômalas). Dessa forma, os sistemas são capazes de identificar os referidos cenários de maneira mais eficiente. Idealmente, modelos baseados nessa técnica são capazes de evoluir gradualmente, sem a necessidade de se realizar um novo treinamento.

---

<sup>1</sup> A. Brilhador, A. E. Lazzaretti, and H. S. Lopes. A survey on open world learning for image segmentation: Definitions, challenges, and directions. *Learning & Nonlinear Models*, 23(1):33–48, 2025.

Vale ressaltar que os modelos de detecção de anomalias avaliados neste trabalho são do tipo não-supervisionado (ou seja, não precisam de rótulos para a etapa de treino). Neste trabalho, o rotulamento foi utilizado apenas para a avaliação do desempenho do modelo e para os testes entre *Open Set* e *Closed Set*.

Os cenários de simulação definidos nesta pesquisa foram os seguintes:

- **Cenário 1:** Treino e teste *offline* usando todos os conjuntos de dados do paciente. O treino é executado apenas com dados negativos (i.e., não convulsivos);
- **Cenário 2:** Similar ao Cenário 1, porém, o treinamento inclui algumas instâncias positivas (esquema *Open Set*);
- **Cenário 3:** Treino *offline* com uma única realização do sinal de EEG. Teste *online* com o restante dos sinais de EEG do paciente.

### 3.3 Pré-Processamento e Extração de Atributos

Nesta seção serão detalhados os procedimentos utilizados no experimento. Durante todo o trabalho foi utilizada a linguagem de programação Python na versão 3.12.4, em um notebook com processador Intel(R) Core(TM) i7-10750H com 2,6GHz e 8,00GB de memória RAM. Os códigos, figuras e métricas gerados durante o trabalho estão presente no seguinte *GitHub*

A etapa de pré-processamento é essencial para a modelagem de sinais, visto que ela é responsável por traduzir os dados brutos que obtemos através das medições para o formato que será utilizado pelos modelos preditivos. Em geral, essa etapa envolve a filtragem de ruído, a remoção de variáveis redundantes e a vetorização dos atributos e rótulos. Os procedimentos adotados neste trabalho foram análogos aos utilizados por Oliveira (2021). A seguir, serão descritos os procedimentos utilizados para a extração de atributos e para a construção dos rótulos.

Inicialmente, foi realizado o download dos arquivos *.edf* dos pacientes chb01, chb03, chb05, chb07, chb14 e chb18, disponibilizados no conjunto de dados *CHB-MIT Scalp EEG Database*. Em seguida, esses arquivos foram lidos pela função *highlevel* da biblioteca **pyedflib**. Essa função retorna uma matriz  $\mathbf{X}_{raw}$  de dimensões  $c \times N$ , onde  $c$  é o número de canais e  $N$  o número de amostras contidos no arquivo *.edf*.

Então, são removidos todos os canais que possuam desvio padrão nulo, tendo em vista que estes possuem dados constantes que não ajudaram na detecção das convulsões (provavelmente foram resultado de algum mal contato ou problema na máquina). Após isso, os

sinais são separados em épocas.

Épocas são agrupamentos menores de dados utilizados para simplificar os atributos que serão utilizados como entrada para o modelo. Neste trabalho, foram utilizadas épocas de dois segundos de duração ou, conseqüentemente, 512 amostras, um intervalo de tempo razoável para determinar se o paciente está ou não tendo uma crise consulsiva.

Dessa forma, calculou-se a matriz de covariância de cada época utilizando a função *cov* da biblioteca **numpy**, e foi realizada uma vetorização dessa matriz de covariância. Considere a matriz de covariância de dimensões  $p \times p$  mostrada a seguir:

$$\Sigma = \begin{bmatrix} \sigma_{1,1} & \sigma_{1,2} & \dots & \sigma_{1,p} \\ \sigma_{2,1} & \sigma_{2,2} & \dots & \sigma_{2,p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p,1} & \sigma_{p,2} & \dots & \sigma_{p,p} \end{bmatrix}_{23 \times 23} \quad (3.1)$$

Por ser uma matriz simétrica, uma vetorização simples conduziria a um vetor de dimensões  $p^2 \times 1$  e teria componentes iguais. Por isso, para evitar este tipo de redundância, a vetorização que utilizamos aqui é a mesma usada em Oiveira (2021), em que apenas os elementos da porção triangular superior são utilizados, resultando no seguinte vetor de atributos:

$$\text{vect}(\Sigma) = \begin{bmatrix} \sigma_{1,1} \\ \sqrt{2}\sigma_{1,2} \\ \sigma_{2,2} \\ \vdots \\ \sqrt{2}\sigma_{1,p} \\ \sqrt{2}\sigma_{2,p} \\ \sigma_{p,p} \end{bmatrix}_{276 \times 1} \quad (3.2)$$

Uma vez que os dados possuem 23 canais, a matriz de covariância possuirá  $23 \times 23 = 529$  elementos. Seja  $N_e$  o número de elementos do vetor gerado e  $c$  o número de atributos (conseqüentemente, o número de canais), temos:

$$N_e = c + \frac{c^2 - c}{2} = \frac{c^2 + c}{2} = \frac{c(c + 1)}{2} \quad (3.3)$$

Com base na equação anterior, identificamos que o vetor de atributos terá dimensões  $276 \times 1$ . O coeficiente  $\sqrt{2}$  que aparece no vetor de atributos garante que a norma quadrática deste vetor seja igual à norma de Frobenius da matriz de covariância original.

Na sequência, os vetores de atributos gerados foram agrupados (na mesma ordem de coleta das épocas) em uma matrix  $\mathbf{X}$  de dimensões  $276 \times 1800$  (considerando um arquivo tradicional com 1h de duração). Nessa perspectiva, o número  $p$  de atributos utilizado pelo modelo será  $p = 276$  e o número  $N$  de amostras (em um arquivo de 1h) será  $N = 1800$ .

Finalmente, os atributos foram normalizados com base no z-score e os eventuais valores nulos (resultantes de algum problema de divisão durante a execução do pré processamento) foram substituídos por 0.

Para o rotulamento, foram analisados os arquivos “chbnn-summary.txt” de cada paciente e identificados os intervalos que continham crises convulsivas. Dessa forma, cada época que continha pelo menos 1s de amostras convulsivas foi considerada anômala, enquanto as demais foram consideradas normais.

Assim, para arquivos de 1h de duração, foram gerados 1800 vetores de atributos, um por época (i.e., segmentos de 2 segundos de duração), em que a cada segmento é atribuído o rótulo da época correspondente, sendo o valor -1 indicativo de uma amostra negativa, ou normal, e o valor +1 indicativo de uma amostra positiva, ou anômala.

Por exemplo, se o terceiro elemento do vetor de rótulos do arquivo chb01\_01 contiver o valor +1, significa que a terceira época desse mesmo arquivo possui uma crise convulsiva.

Após as etapas de pré-processamento dos sinais e extração de atributos, foi realizada a modelagem dos dados com os modelos de detecção de anomalias baseados em PCA e em redes autocodificadoras. Para isso, foram realizados vários testes com diferentes abordagens para comparação de resultados. Todos os modelos utilizaram o Método 2 com percentil 95 para o estabelecimento do limiar de anomalia.

### 3.4 Experimentos Preliminares

Inicialmente, foi investigada a otimização de alguns atributos importantes para o treino dos modelos, tais como a utilização (ou não) da estratégia *Open Set*, a quantidade de arquivos ideal para treino e alguns hiperparâmetros para redes neurais. Para isso, foi avaliado o desempenho dos modelos para detectar as crises convulsivas do paciente chb01 de maneira offline.

Primeiramente, foi utilizada a técnica de PCA com tolerância de 99%. Nesta execução, foram comparadas as diferenças de desempenho obtidas ao utilizar *Open Set*. Além disso, foram registrados os valores médios de atributos resultantes após a codificação com PCA ( $q$ ).

Em seguida, a rede codificadora foi utilizada com uma única camada oculta de tamanho  $q$ . Inicialmente, os testes foram feitos com o otimizador Adam, número máximo de iterações 1000, valor mínimo da função objetivo durante o treinamento de  $10^{-5}$  e ritmo de aprendizagem adaptativo. A função de ativação foi variada para se determinar aquela com maior desempenho, identificada como *AF*. Também foi variada a utilização de *Open Set* para cada abordagem. Na sequência, a função de ativação foi sempre utilizada como *AF*, sendo avaliada a performance do modelo com valor mínimo da função objetivo durante o treinamento de  $10^{-8}$  e  $10^{-3}$ . O valor ótimo obtido,  $V_{min}$ , também foi aplicado aos demais modelos que utilizaram redes neurais.

Finalmente, foram realizados testes com PCA para determinar a quantidade de arquivos ideal ( $N_{files}$ ) para realizar o treinamento no Cenário 3, tendo em vista que os dados foram coletados em sequência e apenas os  $N_{files}$  primeiros arquivos seriam utilizados no treinamento, a fim de simular o comportamento da aplicação em tempo real.

### 3.4.1 Ampliação dos testes

Após a identificação dos hiperparâmetros de desempenho ideais, foi realizada uma comparação entre 5 modelos para cada paciente. Todos os modelos utilizaram os hiperparâmetros encontrados no passo anterior e foram treinados de maneira online.

1. Autocodificador com PCA ( $tol = 0,99$ );
2. MLP com 1 camada oculta de  $q$  neurônios;
3. MLP com 3 camadas ocultas de tamanhos 138, 69 e 138 neurônios;
4. Um comitê organizado com os três modelos acima;
5. O classificador Mínimos Quadrados Ordinários (OLS) com Hipótese 1 de Oliveira (2021) (ver Apêndice B).

Algumas observações devem ser feitas:

- O número de neurônios na rede de três camadas ocultas foi escolhido de tal forma que o valor de atributos se reduza pela metade até o centro da rede e duplique do centro ao fim, tendo em vista que o vetor de atributos possui dimensão  $256 \times 1$ .
- O comitê utilizado foi composto pelo autocodificador com PCA e pelas redes autocodifica-

doras com 1 e 3 camadas ocultas. Foi escolhido o sistema de voto majoritário, em que a classificação com maior votos por parte dos modelos foi escolhida como a decisão final.

- O OLS é um método linear utilizado tanto para regressão quanto para classificação que foi escolhido por Oliveira (2021). Neste trabalho são testadas várias hipóteses para a coleta dos dados, sendo a Hipótese 1 escolhida para a comparação dos modelos uma vez que esta apresenta o caráter mais próximo de uma coleta *online* (tendo em vista a continuidade temporal das amostras coletadas).

Por fim, foi realizada uma busca em grade (*grid search*) para avaliar a variação das métricas com base na quantidade de neurônios na camada central das redes autocodificadoras com 1 e com 3 camadas ocultas.

### 3.5 Avaliação dos Resultados

Para analisar o desempenho dos classificadores foram coletadas as seguintes métricas:

1. **TP:** verdadeiros positivos (*true positives*), correspondente ao número de vezes que o modelo classificou corretamente uma amostra como anômala;
2. **FP:** falsos positivos (*false positives*), correspondente ao número de vezes que o modelo classificou equivocadamente uma amostra como anômala;
3. **TN:** verdadeiros negativos (*true negatives*), correspondente ao número de vezes que o modelo classificou corretamente uma amostra como normal;
4. **FN:** falsos negativos (*false negatives*), correspondente ao número de vezes que o modelo classificou equivocadamente uma amostra como normal.
5. **Acurácia:** porcentagem de acerto do modelo, calculada através da fórmula:

$$Acc = \frac{TP + TN}{TP + FP + TN + FN} \quad (3.4)$$

6. **Sensibilidade ou TP\_rate:** taxa de verdadeiros positivos, destaca a capacidade do modelo em detectar anomalias. É calculada através da fórmula:

$$Sensibilidade = \frac{TP}{TP + FN} \quad (3.5)$$

7. **FP\_rate:** taxa de falsos positivos, calculada através da fórmula:

$$FP\_rate = \frac{FP}{FP + TN} \quad (3.6)$$

8. **Especificidade ou TN\_rate:** taxa de verdadeiros negativos, destaca a capacidade do modelo em se adequar ao problema proposto e evitar “alarmes falsos”. É calculada através da fórmula:

$$Especificidade = \frac{TN}{FP + TN} \quad (3.7)$$

9. **FN\_rate:** taxa de falsos negativos, calculada através da fórmula:

$$FN\_rate = \frac{FN}{TP + FN} \quad (3.8)$$

10. **MG:** média geométrica entre a sensibilidade e a especificidade, calculada através da fórmula:

$$MG = \sqrt{Sensibilidade \times Especificidade} \quad (3.9)$$

11. **Precisão:** indica a confiabilidade de uma predição positiva do modelo, calculada através da fórmula:

$$Precisao = \frac{TP}{TP + FP} \quad (3.10)$$

12. **F1-Score:** média harmônica entre a sensibilidade e a precisão, calculado através da fórmula:

$$F1 - Score = 2 \times \frac{Precisao \times Sensibilidade}{Precisao + Sensibilidade} \quad (3.11)$$

Dessas métricas, foram destacadas a acurácia, a sensibilidade e a especificidade, uma vez que, em conjunto, essas métricas dão uma boa dimensão do desempenho do modelo. Uma atenção especial deve ser atribuída à sensibilidade, uma vez que uma sensibilidade baixa indica que o modelo não está reconhecendo bem amostras anômalas, o que pode ser extremamente prejudicial em uma aplicação da área médica.

## 4 RESULTADOS

Neste capítulo serão apresentados e discutidos os resultados obtidos com a metodologia proposta. Serão apresentadas as métricas acurácia, sensibilidade e especificidade, conforme descrito no capítulo anterior. As demais métricas podem ser verificadas no GitHub <sup>1</sup>

### 4.1 Resultados para os Cenários 1 e 2

Em primeiro lugar, foram coletadas as métricas referentes ao desempenho dos modelos utilizando a estratégia tradicional de *Closed Set* com os dados do paciente chb01. O modelo linear foi treinado com tolerância de 99% e os modelos de redes autocodificadoras com 1 camada oculta com as funções de ativação "ReLU", "Logística" e "Tanh". Os resultados estão expostos na Tabela 3.

Tabela 3 – Resultados dos modelos autocodificadores para o Cenário 1.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	60,83	98,58	60,74
MLP - ReLU	63,42	98,34	63,34
MLP - Logística	76,75	96,77	76,70
MLP - Tanh	70,42	97,39	70,35

Fonte: elaborada pelo autor.

Os dados mostram um desempenho regular dos modelos. Apesar de uma acurácia não muito alta, a alta sensibilidade é bem promissora, uma vez que indica que o modelo possui uma alta tendência a identificar anomalias. A principal deficiência do modelo está nos valores baixos de acurácia e especificidade, que indicam um alto número de FP (fato também confirmado analisando as demais métricas). Entretanto, este número elevado está dentro do esperado, tendo em vista a discrepância entre as quantidades de amostras positivas e negativas nos dados.

Em seguida, foi analisado o desempenho dos modelos utilizando a abordagem de *Open Set*, que pode ser observado na Tabela 4

É possível notar que o desempenho do modelo evoluiu com a utilização da técnica de *Open Set*, uma vez que os ganhos em acurácia e especificidade foram bem maiores que as perdas em sensibilidade, que se manteve alta. Dessa forma, foi decidido utilizar a técnica de *Open Set* nos testes subsequentes. Outrossim, foi calculada a média do número de dimensões

<sup>1</sup> Disponível em <https://github.com/Pdral/autoencoder>

Tabela 4 – Resultados dos modelos autocodificadores para o Cenário 2.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	62,27	98,53	62,18
MLP - ReLU	65,46	98,23	65,38
MLP - Logística	78,26	96,50	78,21
MLP - Tanh	71,86	97,33	71,80

Fonte: elaborada pelo autor.

obtido após a transformação de PCA nos testes anteriores, sendo obtido o valor  $q = 93$ .

Com os resultados, a função de ativação Logística com o uso de *Open Set* foi escolhida como a melhor combinação para o treinamento das redes neurais do tipo MLP para os dados em questão. Por fim, foi estudada a mudança obtida no desempenho ao se variar o valor mínimo da função objetivo durante o treinamento no modelo, utilizando a rede de 1 camada no Cenário 2, conforme exposto na Tabela 5.

Tabela 5 – Resultados para a rede autocodificadora com 1 camada oculta variando-se o valor mínimo da função objetivo durante o treinamento.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
MLP com $V_{min} = 10^{-5}$	78,26	96,50	78,21
MLP com $V_{min} = 10^{-3}$	79,75	96,25	79,71
MLP com $V_{min} = 10^{-8}$	78,26	96,50	78,21

Fonte: elaborada pelo autor.

Os resultados mostraram um desempenho bem similar entre os modelos, de modo que foi decidido que os testes iriam continuar usando  $V_{min} = 10^{-5}$

## 4.2 Resultados para o Cenário 3

Como a tarefa de maior interesse para este trabalho envolve o treino e teste dos modelos autocodificadores de acordo com o Cenário 3, iremos apresentar um estudo mais sistemático e abrangente cujos resultados são apresentados a seguir.

Inicialmente, foram realizados testes com o modelo PCA variando-se o valor de  $N_{files}$ , sendo os resultados registrados na Tabela 6.

Os resultados mostram que o desempenho do modelo melhorou à medida que se aumentou o número de arquivos utilizados no treino. Levando em consideração que o ganho de desempenho ao se aumentar a quantidade de arquivos de 3 para 4 não foi tão grande quanto nos aumentos anteriores e tendo ainda em vista a importância da sensibilidade para o problema em

Tabela 6 – Resultados do modelo PCA para o Cenário 3.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA - 1 arquivo	62,68	98,84	62,59
PCA - 2 arquivos	72,95	97,67	72,89
PCA - 3 arquivos	84,19	97,37	84,16
PCA - 4 arquivos	85,14	97,10	85,12

Fonte: elaborada pelo autor.

questão, foi decidido que  $N_{files} = 4$  era o valor ideal para o treinamento.

Com os hiperparâmetros definidos na seção anterior, foram calculadas as métricas para os modelos autocodificadores utilizando PCA, MLP com 1 camada oculta, MLP com 3 camadas ocultas e um *ensemble* de modelos para cada paciente, conforme indicado no capítulo anterior. Então, os resultados obtidos foram comparados entre si e com os resultados da Hipótese 1 de Oliveira (2021), conforme mostram as Tabelas 7 a 12. Vale lembrar que a Hipótese 1 corresponde ao treino e teste *offline* do modelo OLS para dados com classes equilibradas:

Tabela 7 – Resultados para o paciente chb01.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	85,14	97,10	85,12
MLP (1 camada)	88,58	95,65	88,57
MLP (3 camadas)	91,80	94,20	91,80
Comitê	88,30	96,38	88,28
Hipótese 1	94,25	94,75	72,54

Fonte: elaborada pelo autor.

Tabela 8 – Resultados para o paciente chb03.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	78,30	100,00	78,27
MLP (1 camada)	82,38	100,00	82,36
MLP (3 camadas)	86,47	100,00	86,45
Comitê	83,28	100,00	83,26
Hipótese 1	95,96	96,41	69,87

Fonte: elaborada pelo autor.

Tabela 9 – Resultados para o paciente chb05.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	70,12	94,54	70,05
MLP (1 camada)	83,69	85,45	83,68
MLP (3 camadas)	87,15	82,42	87,16
Comitê	80,36	89,09	80,34
Hipótese 1	96,06	97,23	60,24

Fonte: elaborada pelo autor.

Tabela 10 – Resultados para o paciente chb07.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	85,44	93,29	85,42
MLP (1 camada)	82,53	91,46	85,51
MLP (3 camadas)	88,12	86,59	88,12
Comitê	85,38	91,46	85,37
Hipótese 1	72,54	72,67	59,44

Fonte: elaborada pelo autor.

Tabela 11 – Resultados para o paciente chb14.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	72,08	45,90	72,12
MLP (1 camada)	83,39	32,79	83,46
MLP (3 camadas)	87,49	26,23	87,58
Comitê	81,62	36,07	81,69
Hipótese 1	55,76	55,75	57,58

Fonte: elaborada pelo autor.

Tabela 12 – Resultados para o paciente chb18.

Modelo	Acurácia (%)	Sensibilidade (%)	Especificidade (%)
PCA	68,86	89,57	68,80
MLP (1 camada)	75,29	90,80	75,24
MLP (3 camadas)	80,11	83,44	80,10
Comitê	75,49	91,41	75,44
Hipótese 1	82,74	83,49	39,09

Fonte: elaborada pelo autor.

Os resultados mostram que os modelos obtiveram um bom desempenho na detecção de crises convulsivas na maioria dos pacientes, exceto para o chb14. Em alguns casos os resultados obtidos foram até melhores que aqueles observados com a Hipótese 1, e mesmo em casos em que os resultados foram inferiores vale lembrar que a abordagem online sem seleção de intervalos durante a geração de atributos e classificação é muito mais próxima de uma aplicação real e está sujeita a mais fatores que podem afetar o desempenho.

Em geral, o modelo autocodificador PCA obteve as melhores métricas de sensibilidade em quanto os modelos com técnicas de MLP obtiveram sensibilidades menores e métricas gerais mais balanceadas. Vale observar que o modelo com comitê sempre manteve uma sensibilidade próxima da melhor obtida e um balanceamento geral muito bom entre as métricas, embora não tenha se destacado em nenhuma das métricas individualmente.

Por fim, foi realizada uma busca em grade para identificar a variação do desempenho

dos modelos com MLP de acordo com o número do neurônios na camada central. Para isso, os modelos foram treinados conforme nos passos anteriores, porém foram realizadas 50 rodadas para cada treino, de modo a verificar um comportamento médio e tentar anular o efeito da aleatoriedade nos pesos iniciais das redes autocodificadoras. Os valores explorados para o número de neurônios na camada central foram 5, 15, 25, 35, 45, 55, 65, 75, 85, 95 e 105.

Um leitor atento pode ter percebido que durante todos os testes realizados neste trabalho os valores de Acurácia e Especificidade foram praticamente os mesmos, e isso não é uma coincidência. Acontece que a Acurácia pode ser obtida a partir da fórmula:

$$Acc = Sensibilidade \times P\_rate + Especificidade \times (1 - P\_rate) \quad (4.1)$$

onde  $P\_rate$  corresponde à porcentagem de casos positivos nos dados.

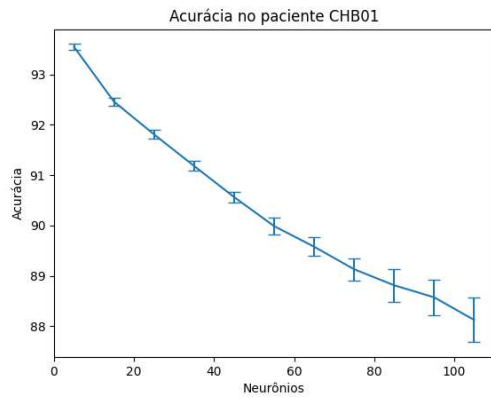
Levando em consideração que as amostras positivas (anômalas) estão presentes em uma quantidade muito menor que as negativas (normais) nos dados em questão,  $P\_rate$  terá um valor muito próximo de 0 e, analogamente,  $(1 - P\_rate)$  terá um valor muito próximo de 1. Dessa forma, o valor da acurácia será bem próximo ao da especificidade.

Por esse motivo, serão apresentados apenas os gráficos da acurácia e da sensibilidade obtidos nos testes exploratórios (tendo em vista que acurácia e especificidade são praticamente os mesmos em todos os casos). Contudo, todos os gráficos estão disponíveis para consulta no Apêndice A e no *GitHub*.

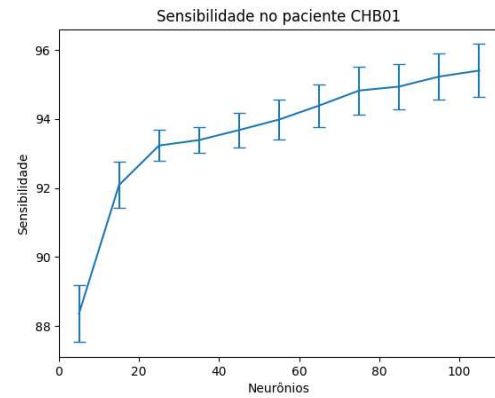
As Figuras 7 a 10 mostram alguns dos resultados obtidos para os modelos autocodificadores utilizando MLP com 1 ou 3 camadas ocultas. Os resultados dos demais pacientes foram bem semelhantes e, por isso, não serão exibidos aqui. Entretanto os demais gráficos podem ser consultados no Apêndice A e no *GitHub*.

Os resultados mostraram que um aumento no número de neurônios da camada central resulta em um aumento na sensibilidade e uma redução na acurácia e na especificidade. Dessa forma, um valor de compromisso (*trade-off*) precisa ser encontrado levando em consideração todos os pontos discutidos neste trabalho, como o papel crucial da sensibilidade para esta área de atuação.

É possível perceber um comportamento bem diferente nos pacientes chb07 e chb14, os mesmos com que o modelo de Oliveira (2021) teve um desempenho bem inferior. No paciente chb07 os resultados foram bons, porém os desvios obtidos nas medições foram altos, sugerindo que uma mudança nos pesos pode impactar bastante o desempenho do modelo. No paciente

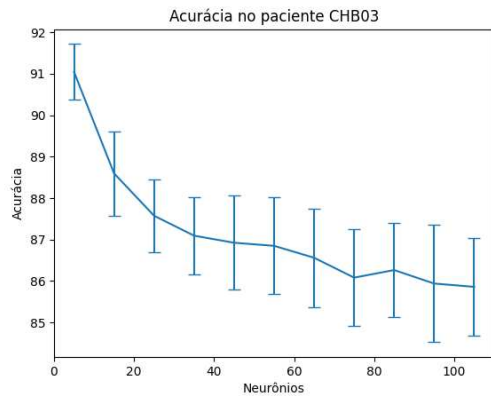


Fonte: elaborada pelo autor.  
(a) Acurácia

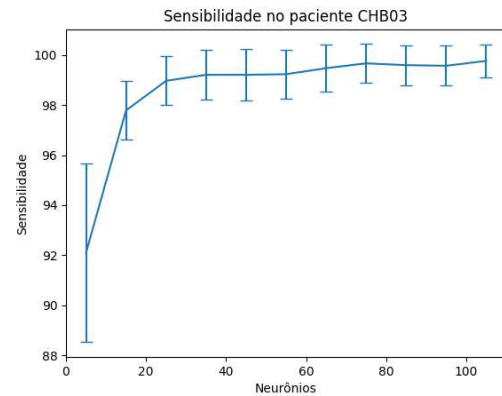


Fonte: elaborada pelo autor.  
(b) Sensibilidade

Figura 7 – Evolução das métricas para o paciente chb01 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.



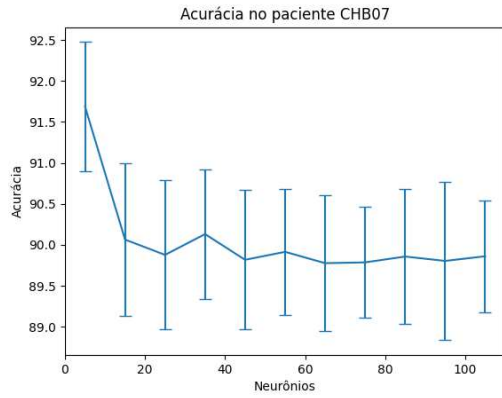
Fonte: elaborada pelo autor.  
(a) Acurácia



Fonte: elaborada pelo autor.  
(b) Sensibilidade

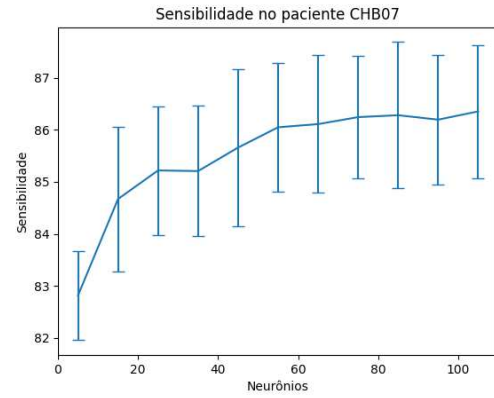
Figura 8 – Evolução das métricas para o paciente chb03 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.

chb14 os resultados foram bem ruins, especialmente a sensibilidade. Esses dados, em conjunção com os trabalhos anteriores citados, corroboram para a conclusão de que os modelos possuem mais dificuldades em detectar crises epilépticas desses pacientes, seja por conta de problemas na coleta ou devido a outras condições cerebrais adversas do paciente.



Fonte: elaborada pelo autor.


(a) Acurácia



Fonte: elaborada pelo autor.

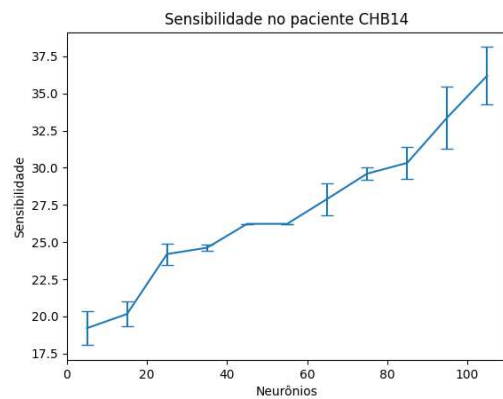
(b) Sensibilidade

Figura 9 – Evolução das métricas para o paciente chb07 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.



Fonte: elaborada pelo autor.

(a) Acurácia



Fonte: elaborada pelo autor.

(b) Sensibilidade

Figura 10 – Evolução das métricas para o paciente chb14 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.

## 5 CONCLUSÕES E TRABALHOS FUTUROS

Neste trabalho foi avaliado o desempenho de modelos autocodificadores para a detecção de crises convulsivas em tempo real. Para esta detecção, foram utilizadas várias técnicas tradicionais de reconhecimento de padrões, como PCA, MLP e comitê de decisão. Além disso, foi analisado o impacto da técnica *Open Set* no desempenho dos modelos. Para a avaliação de desempenho foram calculadas várias métricas, com uma atenção especial para acurácia, sensibilidade e especificidade. Finalmente, foram realizadas comparações com outro trabalho que utilizou uma abordagem semelhante com o mesmo conjunto de dados.

Os resultados obtidos foram promissores e até surpreendentes, demonstrando a capacidade desse algoritmo para aplicações de natureza *online*, em que os bio-sinais são lidos em tempo real. A sensibilidade, métrica mais importante para o cenário em questão, manteve um valor alto em grande parte dos pacientes e circunstâncias analisadas.

Este trabalho de pesquisa pode ser continuado e aperfeiçoado em diversas frentes, tais como as listadas a seguir:

- Estudo comparativo entre o desempenho dos classificadores usando o método de extração de atributos baseado na matriz de covariância com outros métodos disponíveis na literatura (e.g., domínio do tempo, da frequência, entropia, teoria do caos, etc.).
- Avaliação das técnicas estudadas neste trabalho em cenários com menos canais de leitura do EEG.
- Avaliação mais sistemática do uso de *ensembles* de redes autocodificadoras.
- Avaliar o desempenho da técnica de extração de atributos baseada em vetorização da matriz de covariância e as técnicas de detecção de anomalias implementadas neste trabalho em outras bases de dados de EEG.
- Desenvolvimento de um aplicativo para uso embarcado do sistema de detecção de anomalias desenvolvido neste trabalho.


## REFERÊNCIAS

- [1] Epileptic seizures detection using dct-ii and knn classifier in long-term eeg signals. *Iraqi Journal of Science*, 61(10):2687–2694, 2020.
- [2] L. Aguirre. *Introdução à identificação de sistemas – Técnicas Lineares e Não Lineares: Teoria e Prática*. UFMG, Belo Horizonte, 4 edition, 2015.
- [3] Renan Fonteles Albuquerque and Guilherme de Alencar Barreto. Unsupervised time series novelty detection using clustering-based local autoencoders. In E. Simas, D. D. Ferreira, and L. R. Oliveira, editors, *Anais do XVI Congresso Brasileiro de Inteligência Computacional (CBIC'2023)*, pages 1–7, Salvador, BA, 2023. SBIC.
- [4] M.K. Alharthi, K.M. Moria, D.M. Alghazzawi, and H.O. Tayeb. Epileptic disorder detection of seizures using eeg signals. *Sensors*, 22:6592, 2022.
- [5] Renato Anghinah. Artefatos biológicos no eeg quantitativo. *SciELO Brasil*, 2006.
- [6] A. Barachant, S. Bonnet, M. Congedo, and C. Jutten. Classification of covariance matrices using a riemannian-based kernel for bci applications. *Neurocomputing*, 112:172–178, 2013.
- [7] G. A. Barreto. Estimação da matriz de covariância, 2020. Notas de Aulas. Disciplina de Introdução ao Reconhecimento de Padrões. Curso de Engenharia de Computação da UFC.
- [8] G. A. Barreto. Análise das componentes principais, 2023. ResearchGate, Website: [https://www.researchgate.net/publication/375547201\\_Analise\\_das\\_Componentes\\_Principais\\_slides](https://www.researchgate.net/publication/375547201_Analise_das_Componentes_Principais_slides).
- [9] A. Brilhador, A. E. Lazzaretti, and H. S. Lopes. A survey on open world learning for image segmentation: Definitions, challenges, and directions. *Learning & Nonlinear Models*, 23(1):33–48, 2025.
- [10] Universidade Federal do Ceará. Biblioteca Universitária. Guia de normalização de trabalhos acadêmicos da universidade federal do ceará, 2013.
- [11] Y.M. Dweiri and T.K. Al-Omary. Novel ml-based algorithm for detecting seizures from single-channel eeg. *NeuroSci*, 5:59–70, 2024.


- [12] Ali Emran, Maia Angelova, and Chandan Karmakar. Epileptic seizure detection using chb-mit dataset: The overlooked perspectives. *Royal Society Open Science*, 11:230601, 2024.
- [13] J. Guttag. CHB-MIT Scalp EEG Database (version 1.0.0), 2010. PhysioNet. <https://doi.org/10.13026/C2K01R>.
- [14] Lara V. Marcuse, Madeline C. Fields, and Jiyeoun Yoo. *Rowan's PRIMER of EEG*. Elsevier, 2 edition, 2016.
- [15] J. A. McEwen and G. B. Anderson. Modeling the stationarity and gaussianity of spontaneous electroencephalographic activity. *IEEE Transactions on Biomedical Engineering*, BME-22(5):361–369, Sep. 1975.
- [16] W.A. Mir, M. Anjum, Izharuddin, and S. Shahab. Deep-eeg: An optimized and robust framework and method for eeg-based diagnosis of epileptic seizure. *Diagnostics*, 13:773, 2023.
- [17] U. K. Misra and J. Kalita. *Clinical eletroencephalography*. Elsevier, 2 edition, 2018.
- [18] A. M. Oliveira. Extração de características de sinais de eletroencefalograma usando matriz de covariância para identificação de crises epilépticas, 2021. Monografia (Graduação em Engenharia de Computação) - Centro de Tecnologia, UFC, Fortaleza.
- [19] World Health Organization. Epilepsy. <http://www.who.int/en/news-room/fact-sheets/detail/epilepsy>, 2018. Acesso em: 15/02/2021.
- [20] P. Perera, P. Oza, and V. M. Patel. One-class classification: A survey. *arXiv preprint arXiv:2101.03064*, 2021.
- [21] J. Prasanna, M.S.P. Subathra, M.A. Mohammed, R. Damaševičius, N.J. Sairamya, and S.T. George. Automated epileptic seizure detection in pediatric subjects of chb-mit eeg database—a survey. *Journal of Personalized Medicine*, 11:1028, 2021.
- [22] Alvin C. Rencher. *Methods of Multivariate Analysis*. John Wiley Sons, Inc., 2002.
- [23] Anibal Romney and Vidya Manian. Optimizing seizure prediction from reduced scalp eeg channels based on spectral features and maml. *IEEE Access*, 9:164348–164357, 2021.

- [24] D. E. Rumelhart, G. E. Hinton, and R. J. Williams. Learning representations by back-propagation errors. *Nature*, 323:533–536, 1986.
- [25] Stuart J. Russell and Peter Norvig. *Inteligência artificial*. Elsevier, 3 edition, 2013.
- [26] S. Sanei and J. A. Chambers. *EEG signal processing*. John Wiley Sons, 2007.
- [27] P. Sarajcev, A. Kunac, G. Petrovic, and M. Despalatovic. Power system transient stability assessment using stacked autoencoder and voting ensemble. *Energies*, 14(11):3148, 2021.
- [28] A. Shoeb. Chb-mit scalp eeg database, 2010.
- [29] A. H. Shoeb. *Application of machine learning to epileptic seizure onset detection and treatment*. PhD thesis, Massachusetts Institute of Technology, 2009.
- [30] J. P. Silva Júnior. Métodos de extração de atributos para detecção de crises epiléticas: uma abordagem comparativa. Master's thesis, Universidade Federal do Ceará, 2019.
- [31] Joseph I. Sirven and Steven C. Schachter. How to read an eeg, 2013. PhysioNet. <https://www.epilepsy.com/diagnosis/eeg/how-read>.
- [32] Sofeikov. Implementing variational autoencoders from scratch, 2021. Publicado no Medium, <https://medium.com/@sofeikov/implementing-variational-autoencoders-from-scratch-533782d8eb95>.
- [33] S.E. Sánchez-Hernández, R.A. Salido-Ruiz, S. Torres-Ramos, and I. Román-Godínez. Evaluation of feature selection methods for classification of epileptic seizure eeg signals. *Sensors*, 22:3066, 2022.
- [34] S.E. Sánchez-Hernández, S. Torres-Ramos, I. Román-Godínez, and R.A. Salido-Ruiz. Evaluation of the relation between ictal eeg features and xai explanations. *Brain Sciences*, 14:306, 2024.
- [35] S. Urbina Fredes, A. Dehghan Firoozabadi, P. Adasme, D. Zabala-Blanco, P. Palacios Játiva, and C. Azurdia-Meza. Enhanced epileptic seizure detection through wavelet-based analysis of eeg signal processing. *Applied Sciences*, 14(5783), 2024.
- [36] G. A. Worrell, L. Parish, S. D. Cranstoun, R. Jonas, G. Baltuch, and B. Litt. High-frequency oscillations and seizure generation in neocortical epilepsy. *Brain*, 127(7):1496–1506, 2004.


## APÊNDICE A – MÉTRICAS DOS TESTES EXPLORATÓRIOS



Fonte: elaborada pelo autor.  
(a) Acurácia




Fonte: elaborada pelo autor.  
(b) Sensibilidade




Fonte: elaborada pelo autor.  
(c) Especificidade


Figura 11 – Evolução das métricas para o paciente chb01 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.



Fonte: elaborada pelo autor.  
(a) Acurácia




Fonte: elaborada pelo autor.  
(b) Sensibilidade




Fonte: elaborada pelo autor.  
(c) Especificidade


Figura 12 – Evolução das métricas para o paciente chb03 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.



Fonte: elaborada pelo autor.  
(a) Acurácia



Fonte: elaborada pelo autor.  
(b) Sensibilidade



Fonte: elaborada pelo autor.  
(c) Especificidade

Figura 13 – Evolução das métricas para o paciente chb05 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.




Figura 14 – Evolução das métricas para o paciente chb07 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.




Figura 15 – Evolução das métricas para o paciente chb14 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.




Figura 16 – Evolução das métricas para o paciente chb18 variando-se o número de neurônios da camada latente da rede autocodificadora com 1 camada oculta.




Figura 17 – Evolução das métricas para o paciente chb01 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.




Figura 18 – Evolução das métricas para o paciente chb03 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.




Figura 19 – Evolução das métricas para o paciente chb05 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.




Figura 20 – Evolução das métricas para o paciente chb07 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.







Figura 21 – Evolução das métricas para o paciente chb14 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.



Fonte: elaborada pelo autor.  
(a) Acúrcia



Fonte: elaborada pelo autor.  
(b) Sensibilidade

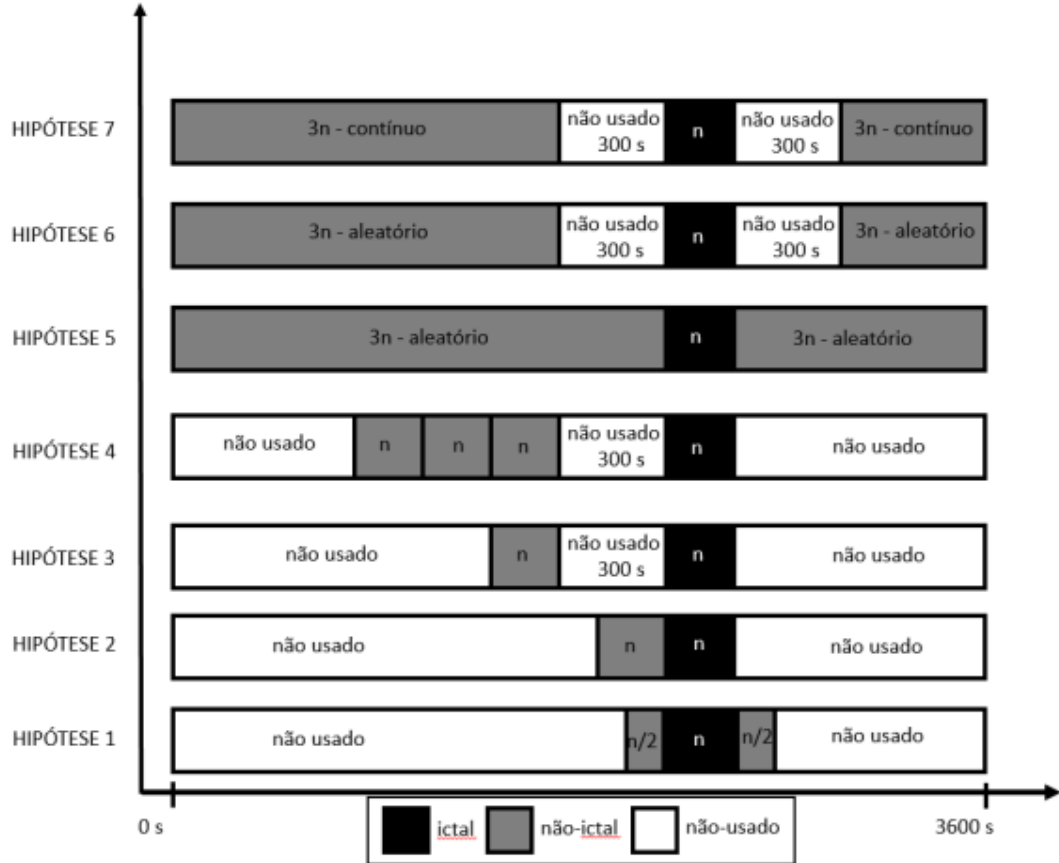


Fonte: elaborada pelo autor.  
(c) Especificidade

Figura 22 – Evolução das métricas para o paciente chb18 variando-se o número de neurônios da camada latente da rede autocodificadora com 3 camadas ocultas.

## APÊNDICE B – HIPÓTESES DE OLIVEIRA (2021)

Figura 23 – Hipóteses mostrando a proporção ictal/não-ictal.



Fonte: Oliveira (2021).

- **Hipótese 1:** Dado determinado intervalo convulsivo (ictal) de tamanho  $n$ , extrair de forma contínua, intervalo não-convulsivo (não-ictal) do mesmo tamanho de  $n$ , sendo este extraído metade antes e metade depois do período convulsivo, conforme mostrado na Figura 23. Esta hipótese é aquela que servirá como parâmetro para as demais, pois a partir dela, verificaremos se haverá melhora nos resultados do classificador.
- **Hipótese 2:** Dado determinado intervalo convulsivo (ictal) de tamanho  $n$ , extrair de forma contínua, intervalo não-convulsivo (não-ictal) do mesmo tamanho de  $n$ , sendo este extraído antes do período convulsivo conforme mostrado na Figura 23.
- **Hipótese 3:** Dado determinado intervalo convulsivo (ictal) de tamanho  $n$ , extrair de forma contínua, intervalo não-convulsivo (não-ictal) do mesmo tamanho de  $n$ , sendo este extraído antes do período convulsivo, mas distante 300 segundos deste, conforme mostrado na Figura 23.
- **Hipótese 4:** Dado determinado intervalo convulsivo (ictal) de tamanho  $n$ , extrair de forma

contínua, intervalo não-convulsivo (não-ictal) na proporção de três vezes o tamanho de  $n$ , sendo este extraído antes do período convulsivo, mas distante 300 segundos deste, conforme Figura 23.

- **Hipótese 5:** Dado determinado intervalo convulsivo (ictal) de tamanho  $n$ , extrair de forma aleatória, intervalo não-convulsivo (não-ictal) na proporção de três vezes o tamanho de  $n$ , sendo este extraído antes ou depois do período convulsivo, conforme Figura 23.
- **Hipótese 6:** Dado determinado intervalo convulsivo (ictal) de tamanho  $n$ , extrair de forma aleatória, intervalo não-convulsivo (não-ictal) na proporção de três vezes o tamanho de  $n$ , sendo este extraído antes ou depois do período convulsivo, mas distante 300 segundos deste, conforme Figura 23. Esta hipótese extrai aleatoriamente cada segundo que compõe o intervalo.
- **Hipótese 7:** Dado determinado intervalo convulsivo (ictal) de tamanho  $n$ , extrair de forma aleatória e contínua, intervalo não-convulsivo (não-ictal) na proporção de três vezes o tamanho de  $n$ , sendo este extraído antes ou depois do período convulsivo, mas distante 300 segundos deste, conforme Figura 23. Diferente da Hipótese 6, esta hipótese extrai um intervalo contínuo.