

Comparação de Técnicas de Classificação Unária para Detecção de Crises Epilépticas via EEG

Patrícia T. Leitão, Antônio Marcos S. Oliveira, Guilherme A. Barreto, Charles C. Cavalcante

Programa de Pós-Graduação em Engenharia de Teleinformática (PPGETI)

Universidade Federal do Ceará (UFC), Centro de Tecnologia, Campus do Pici, Fortaleza, Ceará

patricia.tavares@alu.ufc.br, soliveiramarcos@hotmail.com, {gbarreto, charles}@ufc.br

Resumo—Este trabalho apresenta uma análise comparativa de algoritmos de detecção de anomalias, também chamada de classificação unária (*one-class classification*) aplicados a sinais de EEG com o objetivo de detectar crises epiléticas. Nesta tarefa, apenas os dados sem anomalias (classe negativa) são usados para construir o modelo de classificação. Foram avaliados sete métodos: distância euclidiana mínima ao centróide (DEMC), *kernel* DEMC (KDEMC), distância Mahalanobis mínima ao centróide (DMMC), PCA, *kernel* PCA (KPCA), *one-class SVM* (OC-SVM) e *isolation forest* (IF). Os experimentos utilizaram dados do conjunto *CHB-MIT Scalp EEG Dataset*, com diferentes hipóteses de extração dos segmentos com ocorrência de crises (EEG ictal) e sem ocorrência de crises (EEG não-ictal) para a geração dos conjuntos de treino, validação e teste. Para extração de atributos dos vários canais, usou-se o método do vetor de covariâncias aplicado a cada 2s de registro do EEG. Os resultados obtidos evidenciam o desempenho superior dos classificadores KDEMC e KPCA, com destaque a este último que atingiu acurácia de 97,27% e especificidade de 86,61%. Além disso, a análise das curvas ROC sugere que a Hipótese 3, uma dentre 7 estratégias propostas neste artigo para a montagem dos conjuntos de treino/teste conduz a um melhor desempenho dos classificadores em relação às demais.

Index Terms—Crises epiléticas, eletroencefalograma, detecção de anomalias, classificação unária, métodos de *kernel*.

I. INTRODUÇÃO

A epilepsia é uma condição crônica do cérebro, não contagiosa, que atinge aproximadamente 50 milhões de pessoas no mundo todo [1]. As crises epiléticas resultam de atividade elétrica anormal no cérebro e podem ser categorizadas em dois grupos: convulsivas e não convulsivas. As crises não convulsivas são definidas por alterações no nível de consciência ou manifestações comportamentais. Por outro lado, indivíduos com crises convulsivas são usualmente acometidos por episódios súbitos de contrações musculares involuntárias. Além de suas manifestações clínicas, a epilepsia carrega um estigma psicossocial significativo [1].

A primeira vez que uma convulsão foi registrada em um eletroencefalograma (EEG) foi em 1932 por Hans Berger [2], sendo desde então utilizado no diagnóstico da epilepsia com o auxílio, por exemplo, de exames de neuroimagem [3]. O EEG de escalpo é uma técnica neurofisiológica não invasiva realizado por meio da colocação de eletrodos sobre o couro

cabeludo [4], sendo capaz de detectar atividades convulsivas ao refletir as condições eletrofisiológicas do cérebro em um determinado período [5]. O equipamento é geralmente composto por uma touca contendo eletrodos em posições específicas do couro cabeludo, de acordo com sistemas de posicionamento padrão (e.g., sistema 10-20), permitindo uma captação adequada e consistente da atividade elétrica cerebral [4]. A análise visual de crises epiléticas em registros de EEG é um processo demorado e que demanda a atuação de especialistas capacitados para examinar toda a extensão dos registros eletroencefalográficos [6].

Diante desse desafio, há basicamente duas abordagens de aprendizado de máquinas desenvolvidas com o objetivo de realizar a detecção semiautomática de anormalidades relacionadas a ocorrência de crises epiléticas por meio de sinais de EEG [7]. A primeira abordagem envolve a formulação do problema como classificação binária. Neste caso, o classificador é treinado com dados de ambas as classes, contendo tanto vetores de atributos rotulados como consistentes com um segmento de *EEG ictal* (convulsivo) quanto aqueles rotulados como consistentes com um segmento de *EEG não-ictal* (não-convulsivo). A segunda abordagem trata o problema como classificação unária, também chamada de classificação de classe única (do inglês, *one-class classification*). Neste caso, o classificador é treinado apenas com vetores de atributos rotulados como EEG não-ictal, geralmente a classe com maior número de instâncias. Este tipo de abordagem requer o cômputo de um limiar de decisão, que define a fronteira entre a ocorrência ou não de uma anomalia (no caso, a ocorrência de crise epilética).

No presente artigo, usa-se o paradigma de classificação unária para a tarefa de detecção de anomalias por meio dos seguintes classificadores: distância euclidiana mínima ao centróide (DEMC), *kernel* DEMC (KDEMC), distância mahalanobis mínima ao centróide (DMMC), PCA, *kernel* PCA (KPCA), *isolation forest* (IF) e *one-class SVM* (OC-SVM). Esta decisão advém do fato que a abordagem alternativa (i.e. classificação binária) ser mais comum na área de detecção de crises epiléticas, enquanto a abordagem por classificação unária ainda carece de estudos mais abrangentes [8]. Neste sentido, a principal contribuição deste artigo reside em reportar os resultados de um amplo estudo comparativo envolvendo técnicas estatísticas clássicas de classificação unária (DEMC, DMMC e PCA), bem como algumas de suas variantes kernelizadas (KDEMC e KPCA), e o estado da arte em técnicas de

Os autores agradecem à CAPES (finance code 001), ao CNPq (processo 313251/2023-1) e ao Centro de Referência em Inteligência Artificial - CE-REIA, convênios 23067.055633/2021-19 (UFC) / 2020/09706-7 (FAPESP), pelo apoio financeiro.

aprendizado de máquinas para classificação unária (OC-SVM e IF).

A organização deste trabalho segue a seguinte ordem. Na Seção II, é apresentado o conjunto de dados utilizado no trabalho. Na Seção III, são apresentados os algoritmos de classificação unários utilizados e as estratégias de determinação dos limiares de anomalias correspondentes. A metodologia é apresentada na Seção IV, enquanto que os resultados e conclusões estão presentes nas Seções V e VI, respectivamente.

II. SOBRE O CONJUNTO DE DADOS

O conjunto de dados utilizado neste trabalho pertence ao projeto *CHB-MIT Scalp EEG Dataset* [9], [10] e consiste em gravações contínuas de EEG de escalpo, realizados em 23 pacientes (majoritariamente) pediátricos no Hospital Infantil de *Boston, Massachusetts, EUA*, após a suspensão da medicação anticonvulsiva. Entre os pacientes, 6 são do sexo masculino, com idades variando de 3 a 22 anos e 17 são do sexo feminino, com idades entre 1,5 e 19 anos. O conjunto de dados completo descompactado corresponde a um total de 42,6 GB de dados.

Todos os sinais foram gravados a uma taxa de amostragem de 256 Hz por segundo, com 16 bits de resolução. A maioria dos arquivos contém sinais oriundos de 23 canais de EEG, que foram gravados utilizando o sistema de posicionamento internacional de eletrodos 10-20. De todos os 664 arquivos, 129 apresentam crises, totalizando 198 crises, já que alguns deles contêm mais de uma crise por arquivo. Para cada paciente existe um arquivo chamado *chbnn-summary.txt* contendo informações sobre todos os arquivos do paciente e suas crises, quando existentes, incluindo os instantes de início e término das crises [11].

A. Segmentação dos Sinais de EEG

Para o desenvolvimento deste trabalho, faz-se necessário o uso de técnicas de transformação dos registros dos sinais de EEG dos 23 canais disponíveis em vetores de atributos rotulados. Primeiramente, deve-se definir a duração mínima de um segmento de EEG capaz de prover informação sobre o estado epilético do paciente. Neste trabalho, segue-se a recomendação de [12] que consiste em capturar leituras dos 23 canais do EEG em janelas de 2s.

Como o conjunto CHB-MIT Scalp EEG possui registros com duração de uma hora (3600 segundos), com taxa de amostragem do EEG de 256 Hz, tem-se que em 1s registra-se a leitura de 256 amostras para cada canal. Para uma janela de 2s, tem-se a leitura 512 amostras por canal. Considerando os 23 canais, a cada 2s tem-se um recorte de dados consistindo em uma matriz de 23 linhas $\times$ 512 amostras. Cada matriz dessa, será convertida em um vetor de atributos. Assim, para um registro de duração de 3600s, ter-se-á um total de $3600/2 = 1800$ vetores de atributos.

B. Extração de Atributos via Vetor de Covariâncias

Neste artigo, utiliza-se uma técnica estatística de extração de atributos conhecida como *vetor de covariâncias* [13], que destaca-se por sua simplicidade, baixo custo computacional




Figura 1: Ilustração das 7 hipóteses de construção dos conjuntos de treino-teste.

e elevada eficiência quando comparada com técnicas de extração alternativas, como wavelets e transformada rápida de Fourier [14].

No contexto da presente aplicação, primeiramente estima-se a matriz de covariância de cada recorte de 2s do EEG, cada recorte correspondendo a uma matriz $\mathbf{X}_t \in \mathbb{R}^{23 \times 512}$ com 23 linhas $\times$ 512 amostras. Considerando o número de atributos p de entrada como sendo o número de canais do EEG (i.e., $p = 23$), a matriz de covariância $\Sigma_t \in \mathbb{R}^{p \times p}$ associada a $\mathbf{X}_t$ tem dimensões 23×23 .

Uma vetorização direta da matriz de covariância, por exemplo, empilhando suas colunas uma embaixo da outra, resultaria em um vetor de atributos $\mathbf{x}_t \in \mathbb{R}^{529 \times 1}$. Contudo, a matriz de covariância é simétrica, de modo que o vetor de atributos resultante teria componentes iguais. Para evitar tal redundância, selecionam-se apenas os elementos pertencentes à diagonal principal (variâncias) e as covariâncias da porção triangular superior da matriz de covariância Σ_t . Deste modo, o número de componentes do vetor de atributos reduz-se de 529 para 276; ou seja, $\mathbf{x}_t \in \mathbb{R}^{276 \times 1}$. Mais detalhes sobre este método de extração de atributos podem ser encontrados em [11].

C. Geração dos Exemplos Positivos e Negativos

Uma vez montados os vetores de atributos rotulados para cada paciente, deve-se definir as estratégias de construção dos conjuntos de exemplos da classe negativa (não-convulsiva) e da classe positiva (convulsiva). Cabe lembrar que no presente estudo, aborda-se o problema de detecção de crises epiléticas como um problema de classificação unária, de modo que o treinamento do classificador é feito somente com exemplos negativos; enquanto o conjunto de teste possui tanto exemplos da classe negativa quanto da positiva.

A importância desta etapa de formação dos conjuntos de treino/teste reside justamente em saber de que segmento retirar

as instâncias rotuladas como negativas ou positivas. Esta etapa, aliás, é pouco explorada senão totalmente negligenciada em trabalhos correlatos na literatura especializada ainda hoje. Sendo esta, portanto, uma contribuição adicional do presente trabalho. Para este fim, foram construídas 7 hipóteses de construção, ilustradas na Figura 1.

As Hipóteses 1 a 3 geram conjuntos de exemplos negativos e positivos de mesmo tamanho (classes balanceadas). A diferença entre eles está na posição de extração dos segmentos não-ictais (em cinza) em relação aos segmentos ictais (em preto). A título de ilustração, a Hipótese 1 considera um determinado intervalo convulsivo de tamanho n , em que os vetores de atributos são extraídos de forma contínua. Já o intervalo de extração de amostras não-ictais conduz a um conjunto de exemplos negativos do mesmo tamanho de n , contudo extraídos metade antes e metade depois do período convulsivo. As hipóteses 4 a 7 geram conjuntos de exemplos negativos 3 vezes maior que o de exemplos positivos. A opção de aumentar apenas o conjunto de exemplos negativos (não-ictais) reside no fato de se ter muito mais segmentos deste tipo do que de segmentos positivos (ictais) devido à própria natureza da patologia.

III. CLASSIFICADORES UNÁRIOS AVALIADOS

A. Distância Euclidiana Mínima ao Centróide (DEMC)

A abordagem de classificação por distância mínima ao centróide está entre os métodos mais tradicionais em classificação unária. Trata-se de uma técnica simples e eficaz, especialmente em cenários em que a classe negativa (EEG não-ictal, no presente caso) possui muito mais instâncias que a classe positiva (EEG ictal). Nestas condições, o centróide da classe negativa $\bar{\mathbf{x}}_{neg} \in \mathbb{R}^{276 \times 1}$ serve como um modelo estatístico das instâncias desta classe; ou seja, daquelas que são rotuladas como *EEG não-ictal* [15].

Assim, a distância euclidiana entre o vetor de atributos $\mathbf{x} \in \mathbb{R}^{276 \times 1}$ e o centróide da classe negativa $\bar{\mathbf{x}}_{neg}$ é dado por

$$d_E^2(\mathbf{x}, \bar{\mathbf{x}}_{neg}) = \|\mathbf{x} - \bar{\mathbf{x}}_{neg}\|^2 = (\mathbf{x} - \bar{\mathbf{x}}_{neg})^T (\mathbf{x} - \bar{\mathbf{x}}_{neg}). \quad (1)$$

A regra de decisão para detecção de uma potencial anomalia consiste em calcular a distância mostrada na Eq. (1) e compará-la com um limiar de anomalia $L_E \in \mathbb{R}_{>0}$. Se $d_E^2(\mathbf{x}, \bar{\mathbf{x}}_{neg}) > L_E$, então $\mathbf{x}$ é (possivelmente) anômalo.

O limiar de decisão L_E é determinado calculando-se o percentil $100(1 - \alpha)$ para o conjunto de valores $\{d_E^2(\mathbf{x}_n, \bar{\mathbf{x}}_{neg})\}_{n=1}^{N_{trn}}$, que é o conjunto das N_{trn} distâncias dos vetores de treinamento ao centróide da classe negativa. Neste trabalho, usou-se $\alpha = 20\%$ para este classificador.

B. Kernel DEMC (KDEMC)

Seja $X = \{\mathbf{x}_1, \dots, \mathbf{x}_N\}$ um conjunto não-vazio de observações no espaço p -dimensional $\mathbb{R}^p$. Uma função $K : \mathcal{X} \times \mathcal{X} \rightarrow \mathbb{R}$ é dito ser uma função de *kernel* definida-positiva se, e somente se, K for simétrica, ou seja, $K(\mathbf{x}_i, \mathbf{x}_j) = K(\mathbf{x}_j, \mathbf{x}_i)$ [16]. O fundamento principal do uso de *kernel* está no fato de que o mapeamento ϕ , não precisa ser explicitamente

conhecido. Isso ocorre porque qualquer função *kernel* que satisfaça as condições anteriores pode ser escrita como

$$K(\mathbf{x}_i, \mathbf{x}_j) = \phi(\mathbf{x}_i)^T \phi(\mathbf{x}_j), \quad (2)$$

que é conhecida como truque do kernel [17]. Sendo assim, a distância euclidiana *kernel*, por exemplo, pode ser escrita da seguinte forma:

$$\begin{aligned} d_K^2(\phi(\mathbf{x}), \phi(\bar{\mathbf{x}}_{neg})) &= \|\phi(\mathbf{x}) - \phi(\bar{\mathbf{x}}_{neg})\|^2 \\ &= (\phi(\mathbf{x}) - \phi(\bar{\mathbf{x}}_{neg}))^T (\phi(\mathbf{x}) - \phi(\bar{\mathbf{x}}_{neg})) \\ &= \phi(\mathbf{x})^T \phi(\mathbf{x}) - 2 \phi(\mathbf{x})^T \phi(\bar{\mathbf{x}}_{neg}) + \phi(\bar{\mathbf{x}}_{neg})^T \phi(\bar{\mathbf{x}}_{neg}) \\ &= K(\mathbf{x}, \mathbf{x}) - 2K(\mathbf{x}, \bar{\mathbf{x}}_{neg}) + K(\bar{\mathbf{x}}_{neg}, \bar{\mathbf{x}}_{neg}). \end{aligned} \quad (3)$$

Para este caso, se $d_K^2(\phi(\mathbf{x}), \phi(\bar{\mathbf{x}}_{neg})) > L_K$, então $\mathbf{x}$ é (possivelmente) anômalo, em que $L_K \in \mathbb{R}_{>0}$ é o limiar de anomalia correspondente. Este limiar é calculado como no caso do classificador DEMC, porém usando o conjunto $\{d_K^2(\phi(\mathbf{x}_n), \phi(\bar{\mathbf{x}}_{neg}))\}_{n=1}^{N_{trn}}$. O valor $\alpha = 20\%$ foi usado também neste caso.

C. Distância Mahalanobis Mínima ao Centróide (DMMC)

A distância de Mahalanobis é uma medida de dissimilaridade que leva em consideração a estrutura de covariância dos dados, sendo calculada como

$$d_M^2(\mathbf{x}, \bar{\mathbf{x}}_{neg}) = (\mathbf{x} - \bar{\mathbf{x}}_{neg})^T \Sigma_{neg}^{-1} (\mathbf{x} - \bar{\mathbf{x}}_{neg}), \quad (4)$$

em que $\Sigma_{neg} \in \mathbb{R}^{276 \times 276}$ é a matriz de covariância dos dados de treinamento (classe negativa) [18], sendo estimada como

$$\Sigma_{neg} = \frac{1}{N_{tr}} \sum_{n=1}^{N_{tr}} \mathbf{x}_{neg}(n) \mathbf{x}_{neg}^T(n) - \bar{\mathbf{x}}_{neg} \bar{\mathbf{x}}_{neg}^T. \quad (5)$$

Para este caso, se $d_M^2(\mathbf{x}, \bar{\mathbf{x}}_{neg}) > L_M$, então $\mathbf{x}$ é (possivelmente) anômalo, em que $L_M \in \mathbb{R}_{>0}$ é o limiar de anomalia correspondente, sendo este calculado como nos 2 casos anteriores, porém usando o conjunto $\{d_M^2(\mathbf{x}_n, \bar{\mathbf{x}}_{neg})\}_{n=1}^{N_{trn}}$ e $\alpha = 20\%$.

D. Análise de componentes principais (PCA)

A técnica PCA tem como objetivo principal gerar, por meio de uma transformação linear, um novo conjunto de atributos $\mathbf{z} \in \mathbb{R}^{q \times 1}$ de menor dimensão que os vetores de atributos originais $\mathbf{x} \in \mathbb{R}^{276 \times 1}$ ($q \ll 276$). Esta operação linear é realizada como $\mathbf{z} = \mathbf{V}_q^T \mathbf{x}$, em que $\mathbf{V}_q \in \mathbb{R}^{276 \times q}$ é uma matriz cujas colunas são formadas pelos q autovetores associados aos q maiores autovalores (em ordem decrescente de suas magnitudes) da matriz de covariância da classe negativa Σ_{neg} .

O valor de q é escolhido de modo a garantir que uma dada porcentagem da variância total dos dados originais seja preservada [19]. Isto garante que o erro de reconstrução de $\mathbf{x}$, $e_{PCA}^2(\mathbf{x}, \mathbf{x}_{rec}) = \|\mathbf{x} - \mathbf{x}_{rec}\|^2$, a partir do espaço de dimensão reduzida q seja o menor possível, segundo o critério dos mínimos quadrados. O vetor reconstruído é facilmente calculado pela transformação linear inversa $\mathbf{x}_{rec} = \mathbf{V}_q \mathbf{z}$.

Isto posto, a regra de decisão para detecção de anomalias baseia-se no erro de reconstrução para o vetor de atributos

atual; ou seja, se $e_{PCA}^2(\mathbf{x}, \mathbf{x}_{rec}) > L_{PCA}$, então $\mathbf{x}$ é (possivelmente) anômalo, em que $L_{PCA} \in \mathbb{R}_{>0}$ é o limiar de anomalia correspondente. Neste trabalho, foi usado o limite mínimo de preservação de 99% da variância total.

O limiar L_{PCA} é determinado calculando-se o percentil $100(1 - \alpha)$ para o conjunto de valores $\{e_{PCA}^2(\mathbf{x}_n, \mathbf{x}_{rec})\}_{n=1}^{N_{trn}}$, que é o conjunto dos N_{trn} erros de reconstrução de cada um dos vetores de treinamento. Neste trabalho, usou-se $\alpha = 5\%$ para este classificador.

E. Kernel PCA (KPCA)

A técnica KPCA funciona de modo similar ao PCA, porém a transformação dos vetores de atributos para um outro espaço que não o euclidiano original, a saber, para o espaço de Hilbert de reprodução por kernel (do inglês, *reproducing kernel Hilbert space*, RKHS). Um RKHS é um espaço de Hilbert de funções construído de maneira específica e única a partir de uma função *kernel* positiva definida. Nesse novo espaço, as componentes principais são extraídas a partir da análise dos autovalores/autovetores da matriz de *kernel* $\mathbf{K} = [k_{ij}] \in \mathbb{R}^{N_{trn} \times N_{trn}}$, em que o elemento $k_{ij} = K(\mathbf{x}_i, \mathbf{x}_j)$, $i, j = 1, \dots, N_{trn}$ [20].

Neste caso, a detecção de anomalias baseia-se no erro de reconstrução $e_{KPCA}^2(\phi(\mathbf{x}), \phi(\mathbf{x}_{rec})) = \|\phi(\mathbf{x}) - \phi(\mathbf{x}_{rec})\|^2$, sendo calculado de modo similar ao exposto na Eq. (3). Aqui também foi usado o limite mínimo de preservação de 99% da variância total.

Assim, se $e_{KPCA}^2(\phi(\mathbf{x}), \phi(\mathbf{x}_{rec})) > L_{KPCA}$, então $\mathbf{x}$ é (possivelmente) anômalo, em que $L_{KPCA} \in \mathbb{R}_{>0}$ é o limiar de anomalia correspondente, sendo este calculado como no caso do PCA, porém usando o conjunto $\{d_M^2(\mathbf{x}_n, \bar{\mathbf{x}}_{neg})\}_{n=1}^{N_{trn}}$ e $\alpha = 5\%$.

F. Isolation Forest (IF)

Assim, como os classificadores unários anteriores, o classificador IF também baseia-se na premissa de que anomalias são observações raras e incomuns no conjunto de dados [21]. De modo geral, os conjuntos de dados são frequentemente desbalanceados, contendo uma quantidade significativamente maior de instâncias negativas em relação às positivas (ou anômalas) [22]. A detecção de anomalias via IF é realizada por meio da construção de uma floresta de árvores de decisão usando apenas instâncias da classe negativa (não convulsiva), onde subconjuntos destes dados são amostrados e particionados aleatoriamente. Instâncias que são isoladas em poucas divisões, ou seja, com caminhos curtos nas árvores são mais propensas a serem classificadas como anômalas (i.e. EEG ictal), enquanto observações negativas (i.e., EEG não-ictal) exigem mais partições para serem separadas [21].

G. SVM Unário

O classificador SVM unário (OCSVM, do inglês *one-class SVM*) é uma variação da máquina de vetores de suporte (SVM), desenvolvida para lidar com problemas de classificação unária [23]. Seu funcionamento baseia-se em mapear os dados normais para um espaço de alta dimensionalidade por




Figura 2: Passos utilizados para o projeto dos classificadores unários para detecção de anomalias em sinais de EEG avaliados neste trabalho.

Fonte: Autores.

meio de uma função *kernel* [24]. Seu funcionamento baseia-se em mapear os dados normais para um espaço RKHS, em geral de dimensão infinita, por meio de uma função *kernel* [24]. Nesse espaço transformado, o algoritmo busca encontrar um hiperplano que maximize a margem entre os dados e a origem, separando assim as observações normais de possíveis anomalias, tornando-o uma abordagem eficaz e amplamente aplicável em tarefas práticas de detecção de anomalias [24], sendo considerado o estado da arte para esta tarefa.

IV. METODOLOGIA

Para a construção dos modelos foram utilizados as bibliotecas Python NumPy e Scikit-learn. A sequência de passos utilizada na metodologia deste trabalho é ilustrada na Figura 2. O conjunto de dados utilizado para o experimento possui sinais de EEG de cinco pacientes, a saber: cb01, cb03, cb05, cb14 e cb18. Para cada paciente, foram testadas 7 hipóteses para geração das instâncias rotuladas como negativas (EEG não-ictal) e positivas (EEG ictal). Uma parcela (80%) das instâncias negativas foram usadas para treinamento dos classificadores. A parcela restante (20%) das instâncias negativas foi adicionada ao conjunto das instâncias positivas para comporem o conjunto de teste. Em resumo, o conjunto de treino só possui instâncias negativas, enquanto o conjunto de treino possui instâncias negativas e positivas. Desta forma, a análise comparativa de desempenho envolveu sete classificadores unários para detecção de anomalias. Por fim, foi realizada a avaliação dos desempenhos dos classificadores. Os atributos foram normalizados via *Z-score*, de modo a apresentarem média zero e variância unitária. Além disso, o procedimento de treinamento e teste foi repetido 100 vezes para cada modelo de classificação a fim de se obter estatísticas de desempenho.

As funções de *kernel* testadas foram: linear, polinomial, *RBF* e sigmoidal. Para a escolha dos hiperparâmetros, foram

testados os valores do parâmetro gama (γ) de 0,1, 0,01, 0,001 e 0,0001. Já para o *kernel* polinomial, foram realizados testes para graus 2 e 3. Após testes investigativos sistemáticos, os melhores valores são reportados neste artigo. Como forma de avaliação dos modelos de detecção de anomalias, foram calculadas as seguintes métricas de desempenho: acurácia média, precisão média, sensibilidade média, especificidade média, Escore-F1 médio e média geométrica (MG) entre sensibilidade e especificidade, conforme definidas a seguir.

$$\begin{aligned} \text{Acurácia} &= \frac{VP + VN}{VP + VN + FP + FN}, \text{ Precisão} = \frac{VP}{VP + FP}, \\ \text{Sensibilidade} &= \frac{VP}{VP + FN}, \text{ Especificidade} = \frac{VN}{VN + FP}, \\ \text{Escore-F1} &= 2 \cdot \frac{\text{Precisão} \times \text{Sensibilidade}}{\text{Precisão} + \text{Sensibilidade}}, \\ \text{MG} &= \sqrt{\text{Sensibilidade} \times \text{Especificidade}}, \end{aligned}$$

em que VP denota a quantidade de verdadeiros positivos, VN denota os verdadeiros negativos, FP denota os falsos positivos, FN denota os falsos negativos. A precisão mede a correção geral pela proporção de segmentos classificados corretamente, a sensibilidade mede a capacidade de detectar todos os segmentos anômalos, enquanto a especificidade mede a capacidade de evitar detecções falsas.

Para análise comparativa dos modelos em relação às hipóteses de geração dos exemplos negativos e positivos, também foram utilizadas a curva ROC e a área AUC. A curva ROC resulta do gráfico da taxa de verdadeiro positivo em relação à taxa de falso positivo.

V. RESULTADOS E DISCUSSÃO

Esta seção apresenta os resultados obtidos da aplicação dos classificadores unários para detecção de anomalias (i.e. crises convulsivas) em sinais de EEG. Embora os experimentos tenham sido realizados com dados de cinco pacientes, por limitação de espaço são reportados, sem perda de generalidade, apenas os resultados de 3 pacientes identificados como *chb01*, *chb03* e *chb05*.

Primeiramente, são apresentados os resultados referentes a uma investigação abrangente sobre o impacto das 7 hipóteses ilustradas na Figura 1 para construção dos exemplos das classes negativa (não-convulsiva) e positiva (convulsiva). Este estudo foi levado a cabo usando apenas os dados do paciente *chb03* e o resultados obtidos estão mostrados na Figura 3 para todos os classificadores avaliados.

Uma análise dos valores AUC das Figuras 3(a)-(g) mostram que as melhores hipóteses por classificador são as seguintes: (DEMC) Hipótese 3, (KDEMC) Hipótese 3, (DMMC) Hipóteses 2 a 5, (PCA) Hipóteses 3 e 4, (KPCA) Hipótese 3, (OCSVM) Hipótese 4 e (IF) Hipóteses 3 e 4. A Figura 3(h) traz a melhor curva ROC de cada modelo avaliado usando os dados do paciente *chb03*.

Desta análise pode-se inferir que as melhores hipóteses de geração de exemplos para este paciente são as Hipóteses 3 e 4, alcançando valores de AUC maiores que as demais. Contudo, entre as duas, recomenda-se o uso da Hipótese 3 visto que

esta usa menos dados negativos para chegar basicamente aos mesmos desempenhos. Pode-se concluir, portanto, que não adianta acrescentar tanto mais exemplos negativos aos conjuntos de treino/teste que isso não vai melhorar tanto o desempenho dos classificadores. É suficiente ter o mesmo número de exemplos negativos e positivos.


Em testes similares com dados dos pacientes *chb01* e *chb05*, cujos resultados não são mostrados aqui para otimizar o uso do espaço, a mesma conclusão foi obtida no que tange a Hipótese 3 ser a melhor para construção dos conjuntos de exemplos negativos e positivos. Assim, os próximos resultados a serem mostrados consideram o uso da Hipótese 3.

No próximo conjunto de experimentos, são avaliados os desempenhos dos classificadores unários na detecção de crises convulsivas usando a Hipótese 3 para diferentes pacientes. Os resultados numéricos estão reportados nas Tabelas 1, 2 e 3, que apresentam os valores médios de acurácia e desvio-padrão (d.p.), sensibilidade, especificidade e precisão para todos os classificadores usando os dados dos pacientes *chb01*, *chb03* e *chb05*.


Ao analisar as tabelas, pode-se observar que os classificadores unários KDEMC e KPCA apresentam os melhores desempenhos gerais (considerando principalmente as métricas precisão e escore-F1 para os 3 pacientes. As linhas de resultados correspondentes estão destacadas em negrito. É importante ressaltar que, neste tipo de aplicação, busca sempre minimizar o número de falsos positivos e o número de falsos negativos. Daí a importância das métricas precisão e escore-F1. Por exemplo, apesar de os classificadores DMMC e PCA para os 3 pacientes terem atingidos as mais altas sensibilidades (i.e., detectaram todas as ocorrências de EEG-ictal) para os 3 pacientes, apresentaram péssimas especificidades (i.e., houve muita ocorrência de falsos positivos. Por isso, dá-se mais ênfase às métricas sensibilidade, especificidade, precisão e escore-F1 na seleção dos melhores modelos.

Destaque especial deve ser dado ao classificador unário DEMC, o mais simples de todos os implementados, que aparece como o de terceiro melhor desempenho para os 3 pacientes. Uma outra vantagem importante deste classificador reside no fato de não possuir hiperparâmetros.


No caso específico do paciente *chb03*, que foi aquele usado na escolha da Hipótese 3 como a melhor para geração dos exemplos positivos e negativos, os valores reportados na Tabela 2 foram obtidos com os seguintes hiperparâmetros. Para o modelo KDEMC, este apresentou melhor desempenho com uma função *kernel* polinomial de terceiro grau e $\gamma = 0,01$. Já para o modelo KPCA, utilizou-se uma função *kernel* polinomial de segundo grau e $\gamma = 0,01$. Os classificadores unários do estado da arte (IF e OC-SVM) apresentaram desempenhos equivalentes, mas inferiores aos apresentados pelos classificadores KDEMC e KPCA. O modelo KPCA usou *kernel* polinomial de ordem 2 nos resultados dos experimentos. O modelo DEMC se destacou como já mencionado, aparecendo entre os 3 melhores para este paciente. Os classificadores DMMC e PCA apresentaram as mais baixas especificidades para o paciente *chb03*. Este resultado indica que estes modelos,




(a) DEMC




(b) KDEMC




(c) DMMC




(d) PCA




(e) KPCA



(f) OCSVM



(g) IF



(h) Melhores de Cada Classificador

Figura 3: Avaliação via curvas ROC e AUC do impacto das 7 hipóteses de geração de exemplos das classes negativa e positiva no desempenho dos classificadores unários avaliados usando dados do paciente chb03.

Tabela 1: Melhores resultados dos classificadores unários avaliados usando dados do paciente chb01.

Modelos	Kernel	Acurácia e d.p.	Sensibilidade	Especificidade	Precisão	Escore-F1	MG
DEMC	—	95,26% ± 1,09	98,67%	78,22%	95,79%	97,20%	87,77%
KDEMC	RBF	95,53% ± 1,13	98,66%	79,87%	96,10%	97,36%	88,69%
DMMC	—	90,67% ± 1,26	100%	44,04%	89,95%	94,71%	66,11%
PCA	—	92,17% ± 0,01	100%	53,04%	91,44%	95,52%	72,60%
KPCA	POLY	95,57% ± 0,01	97,68%	85,04%	97,04%	97,36%	91,10%
IF	—	43,40% ± 0,04	36,25%	79,12%	90,00%	51,29%	53,07%
OC-SVM	RBF	93,74% ± 0,01	99,56%	64,67%	93,39%	96,37%	80,10%

Tabela 2: Melhores resultados dos classificadores unários avaliados usando dados do paciente chb03.

Modelos	Kernel	Acurácia e d.p.	Sensibilidade	Especificidade	Precisão	Escore-F1	MG
DEMC	—	94,14% ± 1,13	99,51%	79,29%	96,02%	97,73%	88,75%
KDEMC	POLY	96,35% ± 1,21	99,51%	80,56%	96,26%	97,85%	89,44%
DMMC	—	91,18% ± 1,43	99,51%	49,51%	90,81%	94,96%	69,92%
PCA	—	93,75% ± 0,01	99,51%	64,93%	93,44%	96,37%	80,23%
KPCA	POLY	97,27% ± 0,01	99,40%	86,61%	97,39%	98,38%	92,74%
IF	—	96,00% ± 0,01	99,51%	78,46%	95,88%	97,65%	88,23%
OC-SVM	RBF	95,08% ± 0,01	99,51%	72,90%	94,85%	97,12%	85,09%

Tabela 3: Melhores resultados dos classificadores unários avaliados usando dados do paciente chb05.

Modelos	Kernel	Acurácia e d.p.	Sensibilidade	Especificidade	Precisão	Escore-F1	MG
DEMC	—	91,64% ± 1,19	98,57%	80,08%	89,23%	93,66%	88,83%
KDEMC	RBF	94,94% ± 1,85	97,97%	79,93%	96,04%	96,99%	88,43%
DMMC	—	87,59% ± 1	100%	26,21%	87,03%	93,06%	50,85%
PCA	—	87,51% ± 0,01	100%	25,72%	86,95%	93,02%	50,43%
KPCA	POLY	95,00% ± 0,01	97,59%	82,16%	96,45%	97,01%	89,50%
IF	—	90,22% ± 0,01	96,61%	79,58%	88,81%	92,52%	87,64%
OC-SVM	RBF	90,29% ± 0,01	99,29%	45,79%	90,07%	94,45%	67,26%

embora capazes de detectar todas as crises, o fazem às custas de uma alta taxa de falsos positivos.

VI. CONCLUSÃO

Neste trabalho, foi realizada uma ampla análise comparativa de diferentes classificadores unários para detecção de crises convulsivas a partir de sinais de EEG. Foram avaliados tantos classificadores estatísticos clássicos, como os de distância euclidiana (DEMC) e distância Mahalanobis mínima ao centróide (KDEMC) e o baseado em PCA, quanto versões kernel do distância euclidiana mínima (KDEMC) e do PCA (KPCA), comparando-os com dois classificadores do estado da arte em classificação unária (IF e OC-SVM). No total 7 classificadores unários foram avaliados.

A tarefa de classificação de interesse envolveu a detecção de crises epiléticas a partir de sinais de EEG. Um conjunto de dados público para *benchmark* (CHB-MIT Scalp EEG) foi utilizado nos experimentos de comparação de desempenho, em que também foram testadas diferentes estratégias para a construção dos conjuntos de exemplos das classes negativa e positiva. Para a extração de atributos foi usado o método do vetor de covariâncias, método este rápido e eficiente para a tarefa de interesse, conforme averiguado nas métricas de desempenho reportadas no artigo.

Os resultados obtidos permitiram inferir que os classificadores unários baseados em *kernel*, como o KDEMC e KPCA apresentaram desempenho bem superior e mais consistentes para os dados de diferentes pacientes. Observou-se ainda que as diferentes hipóteses influenciaram diretamente no desempenho dos modelos, sendo a Hipótese 3 a considerada mais adequada para a tarefa de detecção de crises epiléticas.

Como trabalho futuro, almeja-se investigar o desempenho dos classificadores unários avaliados para o conjunto restante de 18 pacientes do conjunto de dados CHB-MIT Scalp EEG.

Além disso, almeja-se embarcar os classificadores unários em incubadoras neonatais disponíveis no laboratório SPIRAL (spiral.ufc.br) avaliados neste artigo para detecção de crises convulsivas em tempo real [25]. Por fim, outras linhas de investigação que já estão sendo desenvolvidas pelos autores envolvem a inclusão de técnicas de aprendizado profundo, tais como redes recorrentes profundas baseadas no modelo LSTM [26] e autoencoders profundos, no rol de classificadores unários a serem avaliados, bem como outras técnicas de extração de atributos [27].

REFERÊNCIAS

- [1] WHO, “Epilepsia,” *world health organization*, 2024.
- [2] S. Shorvon, “Psychoanalytical concepts of epilepsy,” *Epilepsy & Behavior*, vol. 101, p. 106599, 2019.
- [3] A. S. Toledo, A. L. M. Rocha, L. M. de Paula, M. O. Neves, and V. G. Meireles, “Epilepsia: uma revisão da literatura,” *Revista Ibero-Americana de Humanidades, Ciências e Educação*, vol. 10, no. 5, pp. 3419–3428, 2024.
- [4] J. O. Paul, M. N. Cunha, M. V. Araújo, and S. C. Pinto, “Explorando a eletroencefalografia (EEG): Atividades práticas em laboratório,” *RCMOS-Revista Científica Multidisciplinar O Saber*, vol. 1, no. 2, 2024.
- [5] H. U. Amin, M. Z. Yusoff, and R. F. Ahmad, “A novel approach based on wavelet analysis and arithmetic coding for automated detection and diagnosis of epileptic seizure in eeg signals using machine learning techniques,” *Biomedical Signal Processing and Control*, vol. 56, p. 101707, 2020.
- [6] S. M. Victor and J. V. Parise, “Classificação de sinais de EEG para detecção e identificação de distúrbios de epilepsia,” *Revista Mundi Engenharia, Tecnologia e Gestão (ISSN: 2525-4782)*, vol. 7, no. 1, 2022.
- [7] A. Karasmanoglou, G. Giannakakis, P. Vorgia, M. Antonakakis, and M. Zervakis, “Semi-supervised anomaly detection for the prediction and detection of pediatric focal epileptic seizures on fused eeg and ecg data,” *Biomedical Signal Processing and Control*, vol. 101, p. 107083, 2025.
- [8] M. K. Alharthi, K. M. Moria, D. M. Alhazzawi, and H. O. Tayeb, “Epileptic disorder detection of seizures using eeg signals,” *Sensors*, vol. 22, no. 17, 2022.
- [9] J. Guttig, “CHB-MIT scalp EEG database,” 2010. [Online]. Available: <https://physionet.org/content/chbmit/>

- [10] 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*, vol. 11, no. 10, 2021.
- [11] A. M. da Silva Oliveira, "Extração de características de sinais de eletroencefalograma usando matriz de covariância para identificação de crises epilépticas," Ceara, 2021.
- [12] A. Shoeb and J. Guttag, "Application of machine learning to epileptic seizure onset detection," in *Proceedings of the 27th International Conference on Machine Learning (ICML'2010)*, Haifa, Israel, June 21-24 2010, pp. 1–8.
- [13] "Classification of covariance matrices using a Riemannian-based kernel for BCI applications," *Neurocomputing*, vol. 112, pp. 172–178, 2013, advances in artificial neural networks, machine learning, and computational intelligence.
- [14] P. Barbosa and G. Barreto, "Parametrização de sinais de EEG para diagnóstico de epilepsia usando matrizes de kernel," in *Anais do 15 Congresso Brasileiro de Inteligência Computacional*. SBIC, 2021, pp. 1–8.
- [15] A. A. M. Castro and P. P. L. Prado, "Algoritmos para reconhecimento de padrões," *Revista Ciências Exatas*, vol. 8, no. 2002, 2002.
- [16] K. S. B. Castro, "Distâncias adaptativas e kernelizadas aplicadas a agrupamento de séries temporais tipo intervalo," Dissertação de Mestrado, Universidade Federal da Paraíba, 2022.
- [17] A. R. Rocha Neto, "Máquinas de vetores-suporte: uma revisão," *Learning & Nonlinear Models*, vol. 15, no. 1, pp. 16–4, 2017.
- [18] P. Kumari and S. Gupta, "Comparative analysis between euclidean distance metric and mahalanobis distance metric," *International Journal of Innovative Research in Technology and Science*, vol. 12, no. 2, pp. 271–277, 2024.
- [19] K. Bhaskar, A. Kumar, J. Bunce, J. Pressman, N. Burkell, and C. D. Rahn, "Data-driven thermal anomaly detection in large battery packs," *Batteries*, vol. 9, no. 2, p. 70, 2023. [Online]. Available: <http://dx.doi.org/10.3390/batteries9020070>
- [20] Y. Xia, Q. Ding, N. Jing, Y. Tang, A. Jiang, and S. Jiangzhou, "An enhanced fault detection method for centrifugal chillers using kernel density estimation based kernel entropy component analysis," *International Journal of Refrigeration*, vol. 129, pp. 290–300, 2021. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0140700721001444>
- [21] O. Lifandali, N. Abghour, and Z. Chiba, "Feature selection using a combination of ant colony optimization and random forest algorithms applied to isolation forest based intrusion detection system," *Procedia Computer Science*, vol. 220, pp. 796–805, 2023.
- [22] Y. Chabchoub, M. U. Togbe, A. Boly, and R. Chiky, "An in-depth study and improvement of isolation forest," *IEEE Access*, vol. 10, pp. 10 219–10 237, 2022.
- [23] L. G. C. Morais and A. V. da Silva Netto, "Detecção de anomalias na vibração de motores elétricos baseada em OCSVM," in *Simpósio Brasileiro de Automação Inteligente-SBAI*, vol. 1, no. 1, 2021.
- [24] J. Pang, X. Pu, and C. Li, "A hybrid algorithm incorporating vector quantization and one-class support vector machine for industrial anomaly detection," *IEEE Transactions on Industrial Informatics*, vol. 18, no. 12, pp. 8786–8796, 2022.
- [25] I. R. Sousa and G. A. Barreto, "Desenvolvimento de um controlador pi?du discreto otimizado e embarcado em incubadora neonatal," in *Anais do XVI Congresso Brasileiro de Inteligência Computacional (CBIC'2023)*. Salvador, BA: SBIC, 2023, pp. 1–8.
- [26] 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*, vol. 13, no. 4, 2023.
- [27] 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*, vol. 22, no. 8, 2022.