

# Classificação Automática de Sinais Anormais de EEG por meio de Microestados e Aprendizado de Máquina

David W. Küster \* Patrick M. Ciarelli \*

\* Departamento de Engenharia Elétrica, Universidade Federal do Espírito Santo, ES, Brasil (e-mail: davidwkuster@gmail.com; patrick.ciarelli@ufes.br).

---

**Abstract:** Automatic classification of electroencephalography (EEG) signals into normal or abnormal is the first step for the automatization in the detection of neuropathologies, and has the potential to considerably reduce the time between signal capture and medical report. A technique that has not yet been explored for this specific task, but which has shown a good ability to detect mental disorders, due to its capacity to capture spatial and temporal information, is the EEG microstate analysis. This work proposes a methodology for detecting abnormal EEG signals combining the use of microstates and a Learning Vector Quantization (LVQ) network for better discrimination of the microstates. Experimental results in a public database suggest that microstate analysis, which uses the topographic characteristics of the signal, is promising for the normal/abnormal EEG classification, regardless of an *a priori* specified neuropathology.

**Resumo:** A classificação automática dos sinais de eletroencefalografia (EEG) entre normal ou anormal é o primeiro passo para a automatização da detecção de neuropatologias, tendo o potencial de reduzir consideravelmente o tempo entre a captura do sinal e o laudo médico. Uma técnica que ainda não foi explorada para esta tarefa específica, mas que tem mostrado boa capacidade na detecção de transtornos mentais, devido a capacidade de capturar informação espacial e temporal, é a de análise de microestados de EEG. Neste trabalho é proposta uma metodologia para detecção dos sinais anormais que combina o uso de microestados e uma rede *Learning Vector Quantization* (LVQ) para uma melhor discriminação dos microestados. Resultados experimentais em uma base de dados pública sugerem que a análise de microestados, que utiliza as características topográficas do sinal, é promissora para a classificação normal/anormal de EEG, independentemente de uma neuropatologia especificada *a priori*.

**Keywords:** EEG Microstates; LVQ Optimization; Signal Processing; Classification; Abnormal EEG.

**Palavras-chaves:** Microestados EEG; Otimização LVQ; Processamento de Sinais; Classificação; EEG Anormal.

---

## 1. INTRODUÇÃO

As deficiências neurofisiológicas podem ser precedidas do aparecimento de sintomas clínicos. Isso ocorre em diversas doenças neurológicas, conforme reportado por Khanna et al. (2014). O monitoramento de biomarcadores neurofisiológicos pode permitir a detecção precoce de distúrbios e contribuir para o entendimento das deficiências subjacentes. Uma das principais técnicas para estudo dos padrões neurofisiológicos é o Eletroencefalograma (EEG) (Hu e Zhang, 2019). Essa técnica consiste no monitoramento da atividade cerebral através da aquisição dos potenciais em uma série de eletrodos distribuídos pelo crânio de um paciente. O EEG é uma ferramenta poderosa e muito difundida, utilizada no diagnóstico clínico de distúrbios do sono, epilepsia, Alzheimer, coma, morte cerebral e diversas outras condições patológicas (Obeid e Picone, 2018).

A técnica possui algumas vantagens clínicas no estudo da função cerebral que potencializam sua utilização: não é invasiva, custo relativo baixo e alta resolução temporal. Isso permite levantar informações importantes de coordenação neural local e de longo alcance (Khanna et al., 2015). Apesar de seus benefícios, a interpretação dos sinais de EEG é um processo dependente da análise subjetiva do examinador e demanda profissionais cujo treinamento leva anos (Lopez et al., 2016). Isso limita sua utilização no acompanhamento de pacientes e de biomarcadores associados à detecção precoce de funcionamento anormal da rede neural.

Há uma série de técnicas para análise da informação contida no sinal de EEG, sendo as mais difundidas aquelas relacionadas à análise das características temporais e espectrais do sinal (McMackin et al., 2019). Em geral, elas caracterizam a morfologia temporal das formas de onda e distribuições de frequência em certos eletrodos pré-selecionados (Poulsen et al., 2018). Nessa análise clássica, um sinal de EEG é considerado normal quando as frequências, tensões, formas de onda e outras características estão contidas em certos intervalos pré-determinados,

---

\* Esse trabalho foi parcialmente financiado pela Fundação de Amparo à Pesquisa do Espírito Santo (FAPES), número 598/2018.

compatíveis com o funcionamento cerebral normal (Lopez, 2017).

Conforme Obeid e Picone (2018), certas patologias neurológicas causam desvios nos padrões normais do sinal de EEG que podem ocorrer a qualquer instante ou de forma intermitente sendo muito difíceis de se capturar em exames de rotina e geralmente necessitam de monitoramento a longo prazo. Segundo os autores, historicamente foram utilizadas três abordagens para o problema de classificação automática do sinal de EEG: (i) classificação única do sinal todo, (ii) classificação de segmentos do sinal, e (iii) decodificação sequencial. Todas essas abordagens consideram apenas as características temporais e espectrais do sinal e a presença de eventos anormais, bem como a correlação entre estes. Os autores afirmam que a maioria dos estudos tiveram foco em um número pequeno de pacientes. Nesse tipo de abordagem, a primeira etapa da classificação automática consiste em verificar algum desvio do padrão normal. A seguir, os trechos de interesse são processados para classificação dos padrões anormais detectados e os eventos associados são anotados no sinal. Alguns métodos consideram a correlação entre os eventos. Por fim, é feita a identificação de patologias específicas associadas às alterações no sinal e aos eventos associados.

Sob outra perspectiva, muitas pesquisas têm trabalhado com outras características do sinal de EEG além daquelas clássicas. Trabalhos recentes têm apontado que, em repouso (na ausência da execução de alguma tarefa específica), o cérebro opera alternando entre certos mapas (distribuição do potencial elétrico no escalpo) envolvidos na atividade funcional. Essas redes de conectividade cerebral são apontadas como fundamentais nos processos sensoriais e cognitivos e são denominadas *Rest State Networks* (RSNs) (Niazy et al., 2011). Segundo estudos de conectividade cerebral utilizando fMRI (Imagem por Ressonância Magnética funcional), esses mapas surgem devido às funções do cérebro em repouso serem caracterizadas por flutuações coerentes no sinal BOLD (*blood-oxygen-level-dependant*). Essas flutuações são distintas das contribuições de sinal advindas da respiração e do sistema cardiovascular e operam como um estado exploratório contínuo do cérebro (Heine et al., 2012).

Uma ferramenta denominada análise de microestados (Lehmann et al., 1987) tem sido aplicada para o entendimento desse comportamento. Através da premissa de que as diferentes topografias cerebrais são geradas por diferentes configurações de fontes neurais, estudos demonstram que os microestados são capazes de refletir os estados funcionais globais do cérebro e estão intrinsecamente correlacionados com as RSNs de fMRI (Poulsen et al., 2018). Uma série de estudos sobre diferentes patologias ao longo dos últimos dez anos identificou um grupo de 4 microestados, denominados canônicos, como sendo capazes de representar entre 65% e 84% da variância global do sinal de EEG (Michel e Koenig, 2018). Entretanto, dependendo da aplicação, o número de microestados deve ser selecionado de acordo com a base de dados (Michel e Koenig, 2018). Nesses estudos, os microestados do sinal normal apresentam topografias e

propriedades dinâmicas consistentes, desviando desse padrão de maneiras diferentes para patologias distintas. Esses resultados sugerem que os microestados e suas propriedades dinâmicas seriam capazes de discriminar um sinal normal de EEG de uma maneira diferente da análise clássica. Existem vários trabalhos que buscam fazer uma identificação de doenças específicas com uso de microestados, entretanto não foram identificados trabalhos que utilizem microestados para a classificação inicial do sinal de EEG entre normal e anormal, em particular em uma base de dados ampla.

O trabalho de Lopez (2017) é o primeiro estudo que identificou-se tratando do tema de classificação automática de sinais anormais de EEG, com base em um banco de dados que conta com uma série de diferentes neuropatologias. Nele são utilizadas técnicas de aprendizado de máquina e *deep learning*, entretanto, elas são aplicadas utilizando a análise clássica do sinal de EEG, baseada nas características temporais e espectrais.

Assim, a proposta do presente trabalho é verificar a aplicabilidade da análise de microestados, que usam a configuração topográfica do sinal e suas propriedades dinâmicas, para determinar se um sinal de EEG capturado em estado de repouso, pode ou não ser classificado como normal ou anormal. O presente trabalho propõe, ainda, uma metodologia supervisionada para obtenção dos protótipos de microestados, por meio do uso de Redes Neurais Artificiais LVQ (*Learning Vector Quantization*) (Kohonen, 1995). No método tradicional é utilizada uma técnica não-supervisionada (Poulsen et al., 2018).

O restante da estrutura desse artigo é a seguinte: na Seção 2 são apresentados a base de dados e os métodos utilizados. Na Seção 3 é descrita a metodologia proposta. Os resultados obtidos são mostrados na Seção 4 e, por fim, na Seção 5 são apresentadas as conclusões.

## 2. MATERIAL E MÉTODOS

### 2.1 Base de Dados

A pesquisa utilizou a base denominada TUAB (*The TUH Abnormal EEG Corpus*) (Lopez, 2017) que consiste de um *subset* da base de dados denominada TUEG (*The Temple University Hospital EEG Data Corpus*) (Obeid e Picone, 2016). As bases são disponibilizadas<sup>1</sup> pelo *Neural Engineering Data Consortium* (Obeid e Picone, 2016). A base de dados TUEG é o maior conjunto de dados clínicos de EEG disponibilizada publicamente (Obeid e Picone, 2016). Na Tabela 1 está descrita a quantidade de pacientes que constam da base de dados TUAB, versão 2.0.0, consistindo de um total de 2.383 pacientes. As versões anteriores da base constavam com alguns dados duplicados e inconsistentes que foram removidos, por isso a versão 2.0.0 tem algumas sessões a menos que a anterior. A base é dividida em 2.993

---

<sup>1</sup> [www.nedcdata.org](http://www.nedcdata.org)

sessões de EEG, que totalizam 1.142 horas, subdivididas em *Train* e *Evaluation* sem sobreposição de pacientes.

Tabela 1. Conjunto de Pacientes TUAB

Descrição	Normal	Anormal	Total
<i>Evaluation</i>	148	105	253
<i>Train</i>	1.237	893	2.130
Total	1.385	998	2.383

Na Tabela 2 há um detalhamento das sessões da base de dados TUAB. A base é composta por uma única montagem denominada TCP/AR, sendo o TCP referente à montagem bipolar *Temporal Central Parassagital* (Ferrell et al., 2020) dos eletrodos no sistema 10-20. Já a terminologia AR (*Average Referenced*) indica que o sinal é referenciado à média, o que é importante, uma vez que na literatura e nas ferramentas computacionais costuma-se assumir essa referência (Poulsen et al., 2018).

Tabela 2. Conjunto de Sessões TUAB

Descrição	Normal	Anormal	Total
<i>Evaluation</i>	150	126	276
<i>Train</i>	1.371	1.346	2.717
Total	1.521	1.472	2.993

Na Tabela 3 e na Figura 1, podem-se verificar as distribuições de gênero e de idade entre as sessões da base.

Tabela 3. Distribuição de gênero por sessão (TUAB)

Gênero	<i>Evaluation</i>		<i>Train</i>	
	M	F	M	F
Total	128	148	1.270	1.447

Todos os arquivos da base possuem pelo menos 15 minutos de duração (Lopez, 2017). Todas as sessões possuem um arquivo de texto associado contendo o laudo clínico do neurologista, que possuem um breve histórico médico do paciente, remédios utilizados, impressões clínicas e uma classificação do EEG entre normal e anormal.

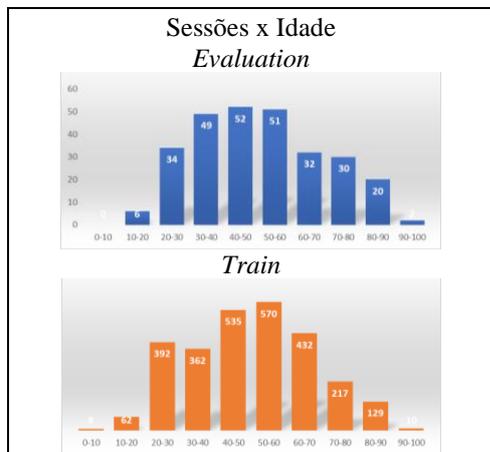


Figura 1. Distribuição de idade por sessão

Os sinais classificados pelo neurologista como anormais consistem de uma diversidade de desordens neurológicas

(Lopez, 2017; Obeid e Picone, 2016). As taxas de amostragem variam na base de dados, sendo sempre de, no mínimo, 250 Hz (Harati et al., 2014). Os sinais foram capturados em diversas configurações de ambiente clínico do hospital universitário *Temple University Hospital (TUH)*, em estado de repouso (Lopez, 2017). O banco de dados original foi processado automaticamente para a remoção dos seguintes padrões indesejados no sinal: movimento dos olhos, artefatos e ruído de origem não cerebral (Harati et al., 2014).

As seguintes etapas de pré-processamento foram utilizadas no método proposto neste trabalho:

- i. seleção dos 21 canais de EEG do sinal;
- ii. mapeamento dos eletrodos de cada canal em cada ponto do crânio conforme montagem 10-20 TCP/AR no EEGLab;
- iii. reamostragem dos sinais para 250 Hz, caso necessário (para compatibilidade no EEGLab);
- iv. aplicação de filtro do tipo passa banda com frequências de corte de 1 e 30 Hz – utilizando a função ‘*pop\_eegfiltnew()*’ do EEGLab, que aplica um filtro do tipo janela de *Hamming* (Poulsen et al., 2018; Zappasodi et al., 2017); e
- v. seleção de intervalo de 10 segundos de cada amostra com *offset* de 3 minutos do início da sessão.

Conforme Lopez, (2017), 10 segundos representa a duração média de sinal para que um especialista treinado seja capaz de classificá-lo como normal ou anormal. Ainda, de forma a desconsiderar alterações no sinal em repouso oriundas do ambiente clínico (como ruídos e interferências externas, desconforto do paciente com os eletrodos e com o ambiente, etc.) foram descartados os 3 minutos iniciais do sinal. Esse intervalo foi selecionado empiricamente, sendo o menor intervalo que manteve o nível de erro consistente nos testes.

## 2.2 Teoria e Processamento do Sinal

### 2.2.1 Microestados de EEG

A técnica de microestados consiste no exame de mapas topográficos de potencial cerebral extraídos do sinal de EEG filtrado na frequência do denominado canal alfa (8 – 12 Hz) com posterior localização de máximos na curva de *GFP* (*Global Field Power*), conforme obtido por (1).

$$GFP = \sqrt{\frac{1}{C} \sum_{i=1}^C (V_i(t) - V_{méd}(t))^2} \quad (1)$$

onde  $C$  é o número de eletrodos,  $t$  é um dado instante de tempo,  $V_i(t)$  é o potencial do  $i$ -ésimo eletrodo no instante  $t$ ,  $V_{méd}$  é o potencial médio de todos os eletrodos.

O  $GFP_n$  é uma medida singular e independente de referência do potencial do sinal ao longo dos eletrodos.

Matematicamente, o *GFP* é o desvio padrão de todos os eletrodos num dado instante de tempo (Murray et al., 2008). Por serem os pontos com a maior relação sinal ruído (SNR), a probabilidade de encontrar um microestado nos picos da curva *GFP* é maximizada (Poulsen et al., 2018).

De forma a determinar os microestados principais, os pontos de máximo local obtidos através de (1) são alimentados a um algoritmo de análise espacial de *clusters*. Podem ser utilizadas diversas técnicas, sendo as principais o TAAHC (*Topographic Atomize and Agglomerate Hierarchical Clustering*) e o *k-means* modificado (Poulsen et al., 2018). Segundo (Michel e Koenig, 2018), o *k-means* modificado é o método mais utilizado na literatura, sendo a escolha dessa técnica adequada por permitir comparações futuras com outros estudos.

Na Figura 2, pode-se verificar o aspecto de um conjunto de protótipos de microestados calculados a partir de um sinal de EEG. Após a obtenção dos protótipos principais de microestados, o sinal de EEG original pode ser representado como uma sequência desses mapas topográficos através do processo de *backfit* (ver Seção 2.2.2).

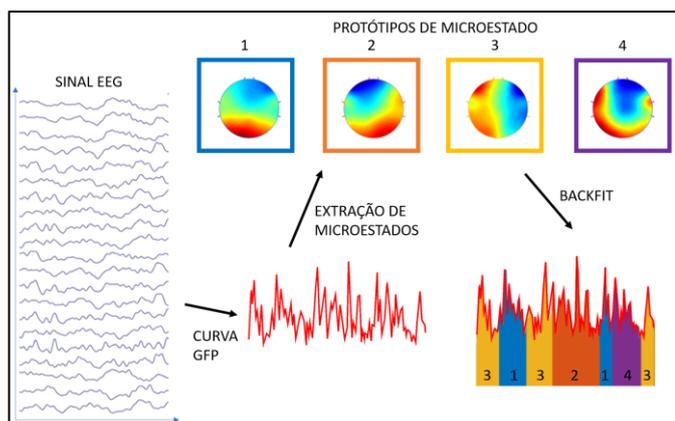


Figura 2. Microestados extraídos do sinal de EEG

Apesar de não existirem métodos específicos para seleção da quantidade de protótipos numa análise baseada em microestados (Poulsen et al., 2018), no presente trabalho foram utilizadas as quantidades de microestados para representação do sinal de EEG entre 2 e 16. Os testes de classificação apresentaram os melhores resultados com a seleção de 16 microestados, de forma que esta quantidade foi selecionada para representação do sinal. Quantidades maiores de microestados não puderam ser investigados devido às limitações na *toolbox* utilizada.

### 2.2.2 Backfit e Temporal Smoothing

O processo de *backfit* se refere a representar o sinal de EEG original em uma sequência de microestados, cujos protótipos foram previamente identificados, conforme Seção 2.2.1.

Para tanto, é utilizada uma medida de distância entre o mapa topográfico de cada instante  $n$  e os protótipos de microestados obtidos, sendo associado a cada instante o protótipo mais similar. A medida utilizada no presente

trabalho é o GMD (*Global Map Dissimilarity*), que pode ser calculada, para dois mapas topográficos quaisquer  $\mathbf{x}_n$  e  $\mathbf{x}_{n'}$ , conforme (2) (Murray et al., 2008).

$$GMD = \frac{1}{\sqrt{C}} \left\| \frac{\mathbf{x}_n}{GFP_n} - \frac{\mathbf{x}_{n'}}{GFP_{n'}} \right\| \quad (2)$$

onde  $\mathbf{x}_n$  e  $\mathbf{x}_{n'}$  são os vetores contendo dois mapas topográficos quaisquer e  $GFP_n$  e  $GFP_{n'}$  são obtidos por (1).

Como o sinal de EEG possui uma série de ruídos e artefatos indesejados, que podem contribuir para o aparecimento de trechos muito curtos assinalados a um determinado microestado, por vezes até amostras individuais, após assinalar a cada amostra um microestado através do *backfitting*, é feito um pós-processamento denominado *temporal smoothing*, que consiste em eliminar segmentos muito pequenos, menores que um certo limiar predeterminado (Poulsen et al., 2018). O processo consiste em remapear as amostras de trechos menores que o limiar para o microestado adjacente que possua a menor distância GMD. O processo é repetido até que não haja segmentos muito curtos no sinal (Poulsen et al., 2018).

### 2.2.3 Características dos Microestados

A partir da representação do sinal de EEG por uma série de microestados, é possível extrair algumas informações estatísticas úteis para a caracterização do sinal. A seguir são apresentadas as utilizadas neste trabalho (Poulsen et al., 2018).

- i. **Duração:** pode ser definida como o tempo de duração de um dado microestado no sinal, medida em milissegundos.
- ii. **Ocorrência:** se refere à média da quantidade de vezes por segundo em que um determinado microestado é dominante.
- iii. **Cobertura:** é o percentual de tempo em que um determinado microestado permanece ativo no sinal todo.
- iv. **Probabilidades de transição:** mensuram as probabilidades de um dado protótipo de microestado de transicionar para outros protótipos de microestados.
- v. **Variância Global Explicada (GEV):** pode ser definida como a capacidade de um protótipo de microestado  $k$  de explicar a variância contida na base de dados e é calculada por (3) (Murray et al., 2008), para cada amostra  $n$  que tenha sido rotulada como pertencente ao protótipo de microestado  $k$ .

$$GEV(k) = \sum_n^N GEV_n \quad (3)$$

A GEV de uma dada amostra  $n$ , que mede a similaridade dessa amostra com o protótipo de microestado com o qual ela foi rotulada, é calculada por (4) (Poulsen et al., 2018):

$$GEV_n = Corr(\mathbf{x}_n, \mathbf{a}_{ln})^2 \cdot \frac{GFP_n^2}{\sum_{n'} GFP_{n'}^2} \quad (4)$$

onde  $N$  é o número de amostras,  $n'$  são todas as amostras,  $\mathbf{x}_n$  é o mapa topográfico da  $n$ -ésima amostra,  $\mathbf{a}_{ln}$  é o protótipo de microestado assinalado à  $n$ -ésima amostra e  $Corr$  é a medida de correlação espacial. Ambos  $\mathbf{x}_n$  e  $\mathbf{a}_{ln}$  são vetores de dimensão  $C$ . A GEV representa o quadrado da correlação entre a amostra  $n$  e seu protótipo de microestado, normalizada pela fração do quadrado do GFP dessa amostra  $n$ , em relação ao quadrado do GFP total de todas as amostras contidas no sinal.

### 2.2.4 Learning Vector Quantization

De forma a melhorar os resultados da detecção de sinais anormais de EEG, é proposto utilizar neste trabalho uma rede neural LVQ (*Learning Vector Quantization*) (Kohonen, 1995) com o objetivo de obter protótipos de microestados que discriminam melhor os sinais normais de EEG daqueles anormais de forma supervisionada. O LVQ foi escolhido pela sua capacidade de obter protótipos supervisionados, uma vez que os métodos tradicionais para obter os microestados são não-supervisionados. Uma rede LVQ é um classificador especificamente projetado para classificação estatística, capaz de definir regiões referentes a cada classe no espaço de dados de entrada (Kohonen, 1995). O LVQ possui protótipos em sua estrutura cujos pesos são ajustados para permitir uma melhor discriminação das diferentes classes.

## 3. METODOLOGIA

Utilizando a base de dados descrita, inicialmente são selecionados conjuntos de treino balanceados entre classes. Testes foram executados com 500, 1000, e 2000 sessões de treino e, por fim, com todas as sessões (2717). Cada amostra é referente a um trecho de 10 segundos extraído de cada uma das sessões selecionadas, após os 3 minutos iniciais do sinal. A seguir, todas as amostras de treino, independente de rótulo, são concatenadas em um único *set* do EEGLab. O *set* contendo todas as amostras é utilizado para segmentação dos protótipos de microestados, são utilizados 100 pontos de pico da curva GFP de cada amostra, extraídos aleatoriamente (Poulsen et al., 2018). A segmentação inicial é feita com o algoritmo do *k-means* modificado e, assim, são selecionados 16 protótipos de microestados. Na Figura 3 é mostrada a sequência com todas as etapas da metodologia.

De forma a obter os microestados otimizados, os pesos iniciais da camada de entrada da rede LVQ são inicializados com os protótipos obtidos pelo *k-means*. A rede LVQ é treinada com os 100 picos GFP de cada amostra do sinal EEG, cada um com sua respectiva classe, utilizando como parâmetros uma taxa de aprendizagem de  $\alpha = 0,005$  e 30 épocas. Esses parâmetros foram obtidos empiricamente, de forma que, nos testes executados, a convergência se deu dentro do limite de épocas. Após o treino da rede, os pesos dos protótipos da rede LVQ são normalizados pela norma  $L2$ , e são chamados aqui de microestados otimizados. Para fins de comparação, o restante da metodologia foi executado uma

vez com os protótipos obtidos com o *k-means* modificado e uma vez com os protótipos otimizados por meio da rede LVQ para o conjunto de treino com 500 amostras. Após a definição dos protótipos dos microestados, eles são importados para execução do *backfit* de cada amostra de treino e de teste individualmente. Após o *backfit* é feito o *temporal smoothing*, cujo limiar é determinado empiricamente, para rejeição de segmentos muito curtos, em geral relacionados a ruído (Poulsen et al., 2018). Neste trabalho, foi utilizado um limiar de 30 ms. Por fim, é feito o cálculo das estatísticas dos protótipos de microestados obtidos. As características e estatísticas extraídas da configuração topográfica do sinal de EEG através da representação pelos microestados, conforme Seção 2.2.3, são utilizadas para o treino e teste dos classificadores. Para cada série de microestados, são extraídos 64 atributos estatísticos, sendo Duração, Ocorrência, Cobertura e GEV para cada um dos 16 protótipos.

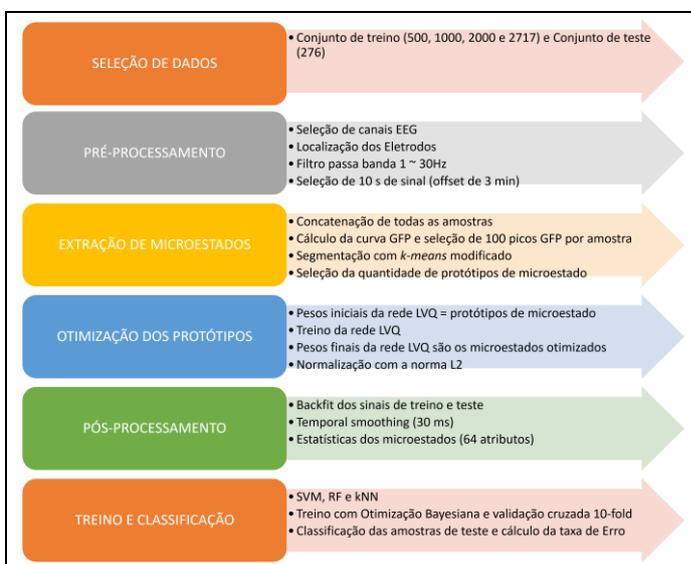


Figura 3. Sequência de Etapas da Metodologia

Os classificadores utilizados no presente trabalho foram os seguintes: SVM (*Support Vector Machine*) (Hu e Zhang, 2019), RF (*Random Forest*) (Breiman, 2001), e kNN (*k Nearest Neighbors*) (Duda et al., 2000). Para cada classificador foi utilizado o algoritmo de otimização Bayesiana (Snoek et al., 2012) com validação cruzada *10-fold* sobre o conjunto de treino, para definição dos valores dos hiperparâmetros. Para cada classificador foi utilizado um número máximo de 30 iterações da otimização Bayesiana. Para o SVM são otimizados a função do *kernel* (polinomial, gaussiana e linear), escala do *kernel* (0,001 a 1000), e *box constraint* (0,001 a 1000). Para a RF é otimizado o número de árvores  $N_t$  (1 a 200). Para o kNN é otimizado o valor de  $k$  (1 a 250).

Os dados de teste são, enfim, classificados pelos classificadores treinados e é calculada a taxa de erro de classificação conforme (5):

$$\text{Erro} = \frac{N_e}{N_t} \times 100\% \quad (5)$$

onde  $N_e$  é o número de amostras atribuídas à classe errada e  $N_t$  é o número total de amostras.

#### 4. EXPERIMENTOS E RESULTADOS

De forma a implementar e testar o uso da análise de microestados para classificação da base de dados, foi utilizado o EEGLab para a plataforma computacional Matlab®. O EEGLab (Delorme e Makeig, 2004) é uma ferramenta aberta para tratamento e análise de sinais de EEG contando com uma série de recursos pré-definidos, inclusive uma série de *toolboxes*, dentre as quais a *Microstate toolbox* (Poulsen et al., 2018), que foi utilizada para a etapa de mapeamento e análise dos microestados. A Figura 4 apresenta o aspecto dos 16 protótipos de microestados obtidos pelo *k-means* modificado (primeira linha) e os otimizados pela rede LVQ (segunda linha). Pode ser observado visualmente que o LVQ fez ajustes nos protótipos previamente obtidos pelo *k-means*. Por ser um algoritmo supervisionado, o LVQ ajustou os protótipos de microestados com a meta de maximizar a discriminação entre os dados normais e anormais.

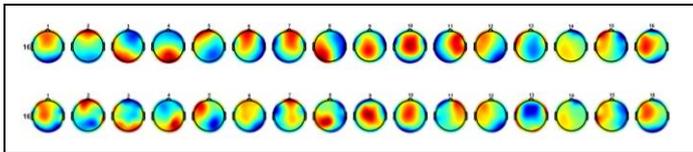


Figura 4. Protótipos de microestado originais (acima) e otimizados (abaixo)

A Tabela 4 apresenta os resultados obtidos com a implementação apresentada para os 3 classificadores utilizados e compara os resultados com e sem otimização com a Rede LVQ para o experimento utilizando o conjunto balanceado de 500 amostras de treino.

Tabela 4. Taxa de erro com e sem otimização (500 amostras)

	Sem Otimização	Com Otimização
	LVQ	LVQ
SVM	32,54%	<b>25,40%</b>
RF	32,14%	27,78%
kNN	30,16%	26,98%

Pode-se observar que a otimização com LVQ conseguiu consistentemente melhorar os resultados de classificação, sendo que o melhor resultado foi obtido pelo SVM com uma taxa de erro de 25,40%. Na Tabela 5 está o comparativo dos resultados utilizando-se os diferentes conjuntos de amostras para o treinamento dos classificadores com o uso do LVQ para otimizar os protótipos dos microestados.

Tabela 5. Taxa de erro com diferentes conjuntos de treino

	Número de amostras			
	500	1000	2000	2717
SVM	25,40%	24,60%	<b>21,43%</b>	22,10%
RF	27,78%	<b>26,98%</b>	29,76%	28,99%
kNN	26,98%	25,79%	<b>23,81%</b>	25,00%

No trabalho de Lopez (2017), foi inicialmente estabelecido um resultado de base com os classificadores kNN e RF. Todos os classificadores foram treinados usando as características extraídas de diferentes regiões do crânio, por pares de eletrodos, utilizando um período entre 3 e 9 segundos. As características utilizadas foram: *Mel Frequency Cepstral Coefficients (MFCCs)*, Energia, Energia diferencial e derivadas 1ª e 2ª dessas características. A dimensão do vetor de características é reduzida por meio de PCA (*Principal Component Analysis*). São apresentados outros classificadores e, por fim é desenvolvido o sistema CNN-MLP (*Convolutional Neural Networks - Multilayer Perceptron*), que obteve o melhor resultado. O CNN-MLP classifica os sinais através de uma rede com 3 camadas convolucionais que é treinada com o vetor de características de 4 diferentes regiões do escalpo e os dados de saída são agregados através da camada MLP, que é responsável por realizar a classificação das amostras.

Os resultados obtidos por Lopez (2017) e por este trabalho são apresentados na Tabela 6, sendo que o número de amostras de treinamento de cada método está entre parênteses. O método proposto neste trabalho obteve melhores resultados para os classificadores RF e kNN, apesar da comparação não ser muito adequada devido a diferença na quantidade de amostras de treinamento. O resultado obtido com o classificador SVM foi um pouco inferior ao do classificador CNN-MLP.

Tabela 6. Comparativo das taxas de erro dos classificadores

	(Lopez, 2017)	Este Trabalho
RF	31,70% (162)	26,98% (1000)
kNN	41,80% (162)	23,81% (2000)
SVM	-	<b>21,43%</b> <b>(2000)</b>
CNN-MLP	<b>21,20%</b> <b>(2785)</b>	-

#### 5. CONCLUSÕES

Neste trabalho foi proposto o uso da análise de microestados de EEG para detectar sinais anormais, em contraponto aos métodos tradicionais. Também foi proposto o uso da rede LVQ para obter de forma supervisionada os protótipos de microestados, diferente dos métodos comumente utilizados que são não-supervisionados.

Comparando os melhores resultados da literatura e os do presente trabalho, que são da mesma ordem, sugere-se que a análise de microestados é um método promissor na tarefa de classificação de sinais anormais de EEG como etapa inicial do processo de identificação automática de distúrbios neurológicos. Contudo, mais estudos são necessários.

Algumas propostas para trabalhos futuros são o teste de outros algoritmos de segmentação supervisionados, o teste com classificadores que utilizem outras abordagens de aprendizado supervisionado, e teste de classificação com subconjuntos de características dos microestados, para análise daquelas que discriminam melhor os dados.

## REFERÊNCIAS

- Breiman, L., 2001. Random Forests. *Machine Learning* 45, 5–32.
- Delorme, A., Makeig, S., 2004. EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis 134, 9–21.
- Duda, R.O., Hart, P.E., Stork, D.G., Wiley, J., 2000. *Pattern Classification*, 2nd ed.
- Ferrell, S., Mathew, V., Refford, M., Tchiong, V., Ahsan, T., Obeid, I., Picone, J., 2020. The Temple University Hospital EEG Corpus : Electrode Location and Channel Labels.
- Harati, A., Lopez, S., Obeid, I., Picone, J., Jacobson, M.P., Tobochnik, S., 2014. The TUH EEG CORPUS: A big data resource for automated EEG interpretation. In: 2014 IEEE Signal Processing in Medicine and Biology Symposium (SPMB). IEEE, pp. 1–5.
- Heine, L., Soddu, A., Gómez, F., Vanhaudenhuyse, A., Tshibanda, L., Thonnard, M., Charland-Verville, V., Kirsch, M., Laureys, S., Demertzi, A., 2012. Resting state networks and consciousness Alterations of multiple resting state network connectivity in physiological, pharmacological, and pathological consciousness states. *Frontiers in Psychology* 3, 1–12.
- Hu, L., Zhang, Z., 2019. EEG signal processing and feature extraction, *EEG Signal Processing and Feature Extraction*.
- Khanna, A., Pascual-Leone, A., Farzan, F., 2014. Reliability of resting-state microstate features in electroencephalography. *PLoS ONE* 9, 1–21.
- Khanna, A., Pascual-Leone, A., Michel, C.M., Farzan, F., 2015. Microstates in resting-state EEG: Current status and future directions. *Neuroscience and Biobehavioral Reviews* 49, 105–113.
- Kohonen, T., 1995. *Learning Vector Quantization* 175–189.
- Lehmann, D., Ozaki, H., Pal, I., 1987. EEG alpha map series: brain micro-states by space-oriented adaptive segmentation. *Electroencephalography and Clinical Neurophysiology* 67, 271–288.
- Lopez, S., 2017. *Automated Interpretation of Abnormal Adult Electroencephalograms*. Temple University.
- Lopez, S., Suarez, G., Jungreis, D., Obeid, I., Picone, J., 2016. Automated Identification of Abnormal Adult EEGs. *Physiology & behavior* 176, 139–148.
- McMackin, R., Muthuraman, M., Groppa, S., Babiloni, C., Taylor, J.P., Kiernan, M.C., Nasserroleslami, B., Hardiman, O., 2019. Measuring network disruption in neurodegenerative diseases: New approaches using signal analysis. *Journal of Neurology, Neurosurgery and Psychiatry* 90, 1011–1020.
- Michel, C.M., Koenig, T., 2018. EEG microstates as a tool for studying the temporal dynamics of whole-brain neuronal networks: A review. *NeuroImage* 180, 577–593.
- Murray, M.M., Brunet, D., Michel, C.M., 2008. Topographic ERP analyses: A step-by-step tutorial review. *Brain Topography* 20, 249–264.
- Niazy, R.K., Xie, J., Miller, K., Beckmann, C.F., Smith, S.M., 2011. Spectral characteristics of resting state networks, 1st ed, *Progress in Brain Research*. Elsevier B.V.
- Obeid, I., Picone, J., 2016. The temple university hospital EEG data corpus. *Frontiers in Neuroscience* 10.
- Obeid, I., Picone, J., 2018. Machine Learning Approaches to Automatic Interpretation of EEGs. In: *Signal Processing and Machine Learning for Biomedical Big Data*. CRC Press, pp. 271–300.
- Poulsen, A.T., Pedroni, A., Langer, N., Hansen, L.K., 2018. Microstate EEGlab toolbox: An introductory guide. *bioRxiv* 1–30.
- Snoek, J., Larochelle, H., Adams, R.P., 2012. *Practical Bayesian Optimization of Machine Learning Algorithms*.
- Zappasodi, F., Croce, P., Giordani, A., Assenza, G., Giannantoni, N.M., Profice, P., Granata, G., Rossini, P.M., Tecchio, F., 2017. Prognostic Value of EEG Microstates in Acute Stroke. *Brain Topography* 30, 698–710.