

A Systematic Mapping of Feature Extraction and Feature Selection Methods of Electroencephalogram Signals for Neurological Diseases Diagnostic Assistance

Wallace F. Almeida, Clodoaldo A. M. Lima and Sarajane M. Peres

Abstract—Electroencephalogram (EEG) is a non-invasive tool used to monitor the electrical activities of the brain. EEG signal analysis has several applications in the medical field. It is widely used for clinical diagnostics and for advances in the Brain-Computer Interface (BCI) area. In recent years, several studies about the automatic execution of this analysis have been proposed, motivated by the fact that the visual inspection demands a long time from an expert, besides being subject to a misdiagnosis. In order to extract and select relevant information from recordings of brain electrical activity, many computerized analysis methods have been developed based on different approaches. Although some proposed methods have achieved good performance, many of them are not suitable for real-world application due to their high computational cost. Thus, there is opportunity in the area to identify and categorize techniques in order to support studies about the influence of these techniques on diagnostic performance and to propose the optimization of this task. In this context, this Systematic Mapping evaluates the 144 primary studies identified according to the criteria defined in the protocol. The purpose is to highlight which neurological disorders have been studied in recent years and which techniques for feature extraction and feature selection have been applied during signal analysis, individually or jointly, to provide specifically an automatic diagnosis of a neurological disorder using a classifier.

Index Terms— Diagnosis, EEG, electroencephalogram, feature extraction, feature selection, neural disease

I. INTRODUÇÃO

O eletroencefalograma (EEG) é um exame médico largamente utilizado no estudo da função cerebral e de distúrbios neurológicos, tais como, Epilepsia, Alzheimer e Mal de Parkinson. O EEG é uma série temporal que contém os registros de atividade elétrica do cérebro, cujas fontes são os potenciais de ação das células nervosas do cérebro. Este sinal foi gravado pela primeira vez em 1924 por Hans Berger [1]. O EEG desempenha um papel cada vez mais importante no

estudo do mecanismo cerebral e das manifestações clínicas das doenças do cérebro. Por exemplo, a análise do desenvolvimento de doenças cerebrais pode ajudar a compreender melhor a base fisiopatológica e farmacológica, algo que é vital no tratamento de doenças cerebrais e fornece informações úteis para aplicações clínicas.

Em geral, o diagnóstico de distúrbios neurológicos é realizado por especialistas com base na observação visual de sinais de EEG. Entretanto, um grande volume de dados é gerado pelos sistemas de monitoração de EEG, o que faz com que a análise visual completa destes dados seja custosa e sujeita a equívocos, tornando-a inviável na prática. Com isso, surge-se uma grande demanda por métodos computacionais capazes de extrair, de forma automática, informação útil para a realização de diagnósticos.

A análise automatizada de um EEG é uma tarefa complexa, devido à presença de artefatos, que causam interferência no sinal durante o processo de captura, e a natureza não-estacionária do sinal. Por essa razão, técnicas de processamento não linear para EEG têm recebido atenção da comunidade científica nos últimos anos. O intuito da aplicação de técnicas de processamento não linear é alterar a representação de suas amostras e/ou reduzir a sua dimensionalidade, facilitando a posterior extração de características intrínsecas durante a etapa de classificação.

A arquitetura de um sistema de classificação baseado em sinais de EEG é ilustrada na Fig. 1. Inicialmente, o sinal de EEG é pré-processado para a remoção de ruídos e possíveis interferências no sinal por meio de filtragem e suavização, entre outros métodos de pré-processamento. Esta etapa pode ser aplicada para um ou mais canais desse sinal. Posteriormente, é realizada a etapa de extração de características, que consiste em extrair as informações mais relevantes para a tarefa de classificação. Com base nas características extraídas, é realizada a seleção de características, que visa selecionar um subconjunto que produz uma melhora ou mantém a habilidade de discriminação do classificador. A seleção de características é importante por diversas razões como a melhoria no desempenho de generalização, e ganho de desempenho em cenários com escassez de tempo de execução. Finalmente, as características

W. F. Almeida, Universidade de São Paulo, São Paulo, São Paulo, Brasil (e-mail: wallace.almeida@usp.br)

C. A. M. Lima, Universidade de São Paulo, São Paulo, São Paulo, Brasil (e-mail: c.lima@usp.br)

S. M. Peres, Universidade de São Paulo, São Paulo, São Paulo, Brasil (e-mail: sarajane@usp.br)

selecionadas são classificadas por algoritmos, tal como de aprendizado de máquina [2].

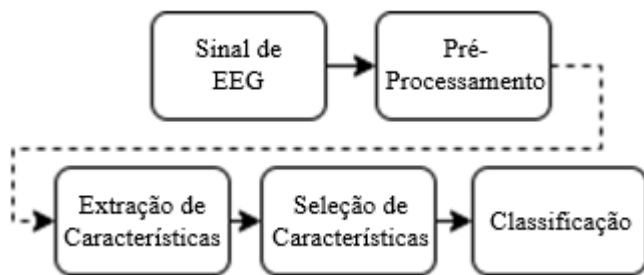


Fig. 1. Estrutura de um sistema de classificação baseado em sinais de EEG.

O objetivo principal deste Mapeamento Sistemático (MS) é identificar e analisar estudos primários relacionados à aplicação de técnicas de extração e seleção de características de sinais de EEG, com foco no diagnóstico de algum distúrbio neurológico. A proposta é elencar os diferentes tipos de técnicas aplicadas, e destacar os distúrbios abordados nos últimos anos. Utilizando um protocolo de pesquisa bem definido, que busca minimizar o viés na análise e na condução, este trabalho possibilita determinar o atual panorama da área de pesquisa ao consolidar seus principais estudos. O resultado possibilita auxiliar novas contribuições na área, podendo ser utilizado como um dos pontos de partida da pesquisa. O MS realizado é motivado pela ausência de um panorama abrangente e organizado na área, e identificação de áreas pouco exploradas. Este artigo apresenta a seguinte organização: o referencial teórico é descrito na seção II; a seção III descreve o método usado no MS; os resultados e discussões que respondem às questões de pesquisa compõem a seção IV; a seção V apresenta as conclusões deste trabalho.

II. REFERENCIAL TEÓRICO

Considere o problema de classificação a partir de dados amostrados em sua formulação clássica. Dado um conjunto de treinamento $\{(x_1, y_1), \dots, (x_N, y_N)\}$, onde x_i , $i = 1, \dots, N$, são tipicamente vetores da forma $x_i = [x_{i1}, x_{i2}, \dots, x_{im}]^T$, cujos componentes são valores numéricos discretos ou contínuos (também chamados de características ou atributos de x_i), e $y_i \in \{1, \dots, K\}$, $i = 1, \dots, N$, são índices que indicam a classe de x_i , sendo o número de classes K tomado como finito. As características x_{ij} são informações que caracterizam um sinal ou uma série temporal. Para evitar informação redundante, as características devem ser o mais independente possível entre si. Extrair características relevantes, discriminantes e não-redundantes é uma etapa fundamental para a preparação de dados que serão utilizados na tarefa de classificação. As técnicas de extração de características, como a Transformada discreta Wavelet, reduzem a dimensionalidade de um sinal, projetando um vetor de alta dimensão em um espaço de baixa dimensionalidade, com mínima perda de informação [2]. Métodos de extração de características de sinal de EEG podem

ser categorizados no domínio do tempo, frequência, ou tempo-frequência [3]. O foco da etapa de seleção de características é encontrar um subconjunto a partir dos dados extraídos do espaço original. Esse subconjunto deve descrever os dados de forma eficiente, reduzir os efeitos de ruídos e características irrelevantes ou redundantes, e ainda ser capaz de proporcionar bons resultados de predição [2]. Baseado no critério utilizado para avaliação do subconjunto de características, métodos de seleção de características podem ser classificados em três categorias: métodos de filtro, invólucro e embarcados [4]. Métodos de filtro são definidos como um passo de pré-processamento para o processo de classificação, que podem remover características irrelevantes antes que a indução do classificador ocorra. Assim, espera-se que seja válido para qualquer conjunto de funções. Portanto, um método de filtro emprega propriedades intrínsecas aos dados. Por exemplo, um método baseado em filtro bastante conhecido é o coeficiente de correlação de Pearson. O método de invólucro é definido como uma busca por meio da exploração de subconjuntos de características. Nessa busca, o desempenho de um algoritmo de classificação aplicado sobre esses subconjuntos guia a tomada de decisão referente à qualidade de cada subconjunto de características em particular. Neste método, o algoritmo de classificação é considerado uma caixa preta, sendo empregado para avaliar a utilidade relativa dos subconjuntos de atributos escolhidos. Já os métodos embarcados incorporam a seleção de características como parte do processo de treinamento e podem ser mais eficientes em vários aspectos. Esses métodos fazem melhor uso dos dados disponíveis, uma vez que não é necessário dividi-los em um conjunto de treinamento e seleção. Além disso, os métodos embarcados alcançam uma solução mais rapidamente, pois não realizam o retreinamento para cada subconjunto das características investigadas.

Vale destacar que a seleção de características refere-se à sua seleção no espaço de medição, sendo as características obtidas um subconjunto das variáveis originais de entrada. Em contrapartida, a extração de características utiliza uma transformação das variáveis originais de entrada, e as características fornecidas são um conjunto de novas variáveis no espaço transformado. Geralmente, as características fornecidas pelo método de extração de características podem não ter um significado físico isolado [5].

III. MÉTODO DE PESQUISA

O Mapeamento Sistemático (MS) é definido como um estudo secundário com o objetivo de identificar, avaliar e comparar todos os trabalhos relevantes disponíveis para uma ou mais questões de pesquisa de uma área de interesse. Estudos que abordam de maneira direta um ou mais tópicos dentro da área de interesse, com a finalidade de responderem a uma questão de pesquisa específica, contribuem para um MS e são classificados como estudos primários. De modo complementar, um estudo que faz uma análise de estudos primários com o objetivo de consolidar o conhecimento sobre uma área ou tema específico, é definido como um estudo secundário. [6].

Um MS é um estudo similar a uma revisão sistemática

(RS). Enquanto a última objetiva uma avaliação e análise aprofundada de cada estudo primário identificado, um MS é um estudo de escopo que visa identificar as principais evidências disponíveis em um tópico [7]. Um MS é preferível sobre uma RS quando o tópico é muito amplo, pois ele direciona o foco de futuras RS e identifica áreas para a realização de novos estudos primários [6]. Nesse cenário optou-se por conduzir um MS. Este MS segue as diretrizes propostas em [6]. As diretrizes incluem três etapas fundamentais: i) planejamento, ii) condução, e relatório, que corresponde à seção IV.

A. Planejamento

O planejamento do MS inclui a justificativa para sua execução, as questões de pesquisa e o protocolo de condução.

1) Justificativa

Dentre os estudos relacionados ao tema abordado neste MS, não foram identificados trabalhos conduzidos sistematicamente nos motores de busca definidos. Os trabalhos identificados são revisões de literatura não-sistemáticas e estão relacionados na Tabela I.

Nesse contexto, o presente MS se diferencia dos demais por ser um levantamento amplo, atualizado, com minimização de viés e reprodutível. Juntamente com os demais esforços da comunidade científica na construção de estudos secundários, esse MS é um agregador do conhecimento científico da área, e serve como um acelerador de atividades de pesquisa.

TABELA I
ESTUDOS SECUNDÁRIOS RELACIONADOS

Ano	Refs.	Ano	Refs.	Ano	Refs.
2018	[8], [9]	2017	[3], [10], [11], [12]	2016	[13]
2015	[14]	2014	[15], [16], [17], [18]	2013	[19]

2) Questões de pesquisa

As questões de pesquisa definidas para este trabalho são:

(Q1) *Quais técnicas são usadas para extração de características e como são classificadas?* Com relação à categorização, foi considerada a divisão em termos de domínio: tempo, frequência, tempo-frequência.

(Q2) *Quais técnicas são utilizadas para seleção de características e como são classificadas?*

3) Protocolo

Segundo [6], o protocolo do MS define o método empregado para conduzir o mapeamento. Sua construção, para este MS, compreende: (i) definição dos motores de busca; (ii) estratégia de pesquisa; (iii) estratégia de seleção de estudos primários; (iv) estratégia de avaliação da qualidade dos estudos; e (v) métodos de extração e síntese dos dados. Os motores de busca utilizados foram *Scopus* e *Web of Science (WoS)*. Estes foram escolhidos a fim de maximizar o número de estudos elegíveis recuperados, uma vez que eles contemplam as principais editoras digitais, como *IEEEExplore*, *Elsevier* e *Springer-Link*. Para a estratégia de pesquisa, uma *string* de busca canônica foi

elaborada. Sua elaboração visou maximizar o número de estudos elegíveis recuperados para esse MS, contemplando flexões de número (singular e plural), siglas e expressões completas, variações pela presença de hífen e etc. Inicialmente, a *string* busca trabalhos relacionados às etapas de extração ou seleção de características. Em seguida restringe às possíveis variações de EEG ou a área de interface cérebro-computador. Por fim limita a busca por técnicas com objetivo de diagnóstico de algum distúrbio.

4) String de busca

```
("Feature* Select*" OR "Feature* Extract*") AND
("EEG" OR "Electroencephalogra*" OR "Electro-
encephalogra*" OR "brain computer interfac*") AND
("diagnos*" OR "detect*" OR "recognit*") AND
("disease" OR "seizure") AND ("technique*" OR
"strateg*" OR "method*")
```

A estratégia de seleção de estudos primários ocorreu a partir da definição de um conjunto de critérios de inclusão (CI) e exclusão (CE). Esses critérios foram elaborados de modo a selecionar estudos acessíveis e pertencentes ao escopo do MS. Após a aplicação da *string* nos motores de busca, um estudo recuperado é selecionado como estudo primário se todos os CI forem satisfeitos. No entanto, se o estudo tiver ao menos um critério de exclusão satisfeito, ele é descartado.

5) Critérios de Inclusão

(CI1) Trabalhos que adotem e descrevam uma ou mais técnicas de extração ou seleção de características empregadas na classificação do sinal de EEG, e não apenas mencionem que a atividade constitui uma etapa do processo.

(CI2) Trabalhos que adotem e descrevam uma ou mais técnicas de extração ou seleção de características empregadas em pesquisas da área de interface cérebro-computador.

6) Critérios de Exclusão

(CE1) Trabalhos não disponibilizados eletronicamente na Internet.

(CE2) Trabalhos não disponíveis no idioma inglês.

(CE3) Trabalhos não relacionados diretamente às áreas de Ciência da Computação e Engenharia.

(CE4) Trabalhos com ano de publicação anterior a 2013.

(CE5) Trabalhos classificados como estudos secundários, tais como questionários, revisões.

(CE6) Trabalhos não revisados por pares tais como relatórios técnicos, livros, capítulos de livros, etc.

(CE7) Trabalhos que abordam as técnicas de extração ou seleção de características de maneira pouco precisa, ou então combinadas com outros tipos de sinais.

Para avaliação da qualidade dos estudos primários foram estabelecidos critérios de qualidade (CQ) que permitiram analisar e comparar a qualidade e relevância dos estudos selecionados. Para elaborar os critérios de qualidade,

foram considerados fatores relacionados à contribuição, detalhamento do trabalho, possibilidade de replicação das técnicas e disponibilização de expressões matemáticas baseadas nos conceitos descritos ou propostos nos estudos.

7) Critérios de Qualidade

(CQ1) O método de experimentação é apresentado?

(CQ2) As expressões para as técnicas de extração de características são formalmente apresentadas?

(CQ3) As técnicas de seleção de características são formalmente apresentadas?

(CQ4) A proposta do artigo é comparada com outras propostas?

(CQ5) As bases de dados estão disponíveis para fins de reprodutibilidade?

Para cada um dos cinco critérios de qualidades listados, pontuações foram atribuídas da seguinte forma: 1 - se o critério foi satisfeito em sua totalidade; 0,5 - se o critério foi atendido de modo parcial; 0 - se o critério não foi satisfeito. Com as devidas pontuações atribuídas aos estudos primários, foi possível identificar aqueles com maior relevância para o estudo das técnicas de extração e seleção de características e assim fundamentar as respostas para as questões de pesquisa de modo sistemático.

B. Condução

Esta seção descreve os passos principais que conduziram este MS. Esses passos constituem duas fases: i) identificação, seleção e avaliação de qualidade dos estudos primários; ii) extração e síntese de dados dos estudos primários.

1) Identificação, seleção e avaliação de qualidade dos estudos primários.

Para essa fase, os seguintes passos foram seguidos:

i) *Identificação de estudos primários relevantes nos motores de busca.* Para isso, a *string* de busca foi executada em ambos os motores de busca. Os trabalhos recuperados totalizaram 1004 registros, considerando trabalhos duplicados no resultado.

ii) *Aplicação dos critérios de inclusão e exclusão.* Com bases nos critérios de inclusão e exclusão definidos, os candidatos a estudos primários foram analisados por meio da leitura e análise do título, resumo e palavras-chave. Visando maximizar a confiabilidade deste MS, em caso de dúvidas sobre a inclusão ou exclusão do trabalho, a introdução foi analisada. Foram selecionados 144 estudos primários candidatos:

iii) *Avaliação de qualidade dos estudos primários.* Este passo visa assegurar a qualidade dos estudos primários. Tratando-se de um MS, optou-se por não remover nenhum dos trabalhos pelos CQ, mantendo esse filtro apenas em relação aos CE.

2) Extração e síntese de dados.

Para esta etapa, os estudos primários resultantes foram lidos integralmente, com o intuito de extrair informações que pudessem responder às questões de pesquisa.

IV. RESULTADOS E DISCUSSÕES

Após a condução do protocolo, 144 estudos primários foram selecionados, sendo 63% provenientes de periódicos e 37% de conferências. A Fig. 2 mostra a distribuição ao longo do tempo, incluindo o distúrbio diagnosticado. A partir dela, são identificados, em média, 24 trabalhos publicados por ano. Com um total de 46 trabalhos, 2017 é o ano com o maior número de publicações dentre os analisados. Neste mapeamento, estudos sobre epilepsia foram encontrados com maior frequência quando comparado aos demais distúrbios, o que corrobora com os resultados de uma revisão de literatura anterior [12], não sistemática. A partir destes estudos, as respostas às questões de pesquisa foram elaboradas.

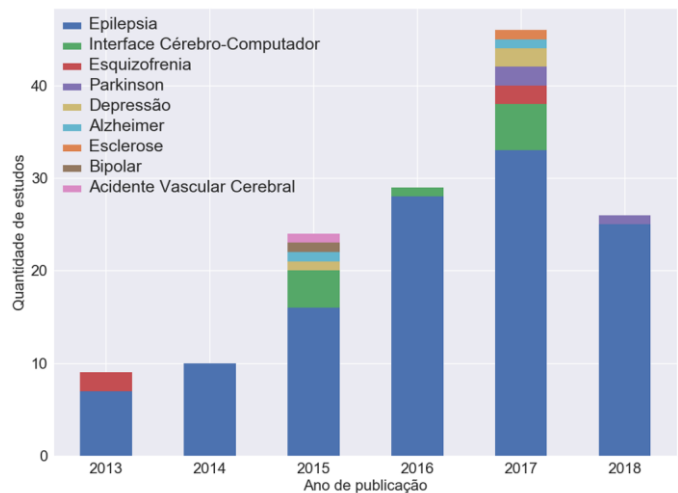


Fig. 2. Estudos por ano e os distúrbios abordados.

Na avaliação dos 144 trabalhos observa-se que as técnicas de extração de características pertencentes ao domínio do tempo, aparecem em maior número quando comparada às demais categorias. Esse fato deve-se principalmente a facilidade de implementação destas técnicas, visto que são obtidas a partir dos sinais brutos, não requerendo nenhuma transformação. Por outro lado, as técnicas no domínio do tempo e domínio da frequência assumem que o sinal é estacionário. Portanto, não capturam mudanças nas propriedades estatísticas dos sinais ao longo do tempo. Além disso, foi possível identificar uma quarta categoria, a baseada em dinâmica não linear, não mapeada nos estudos secundários anteriores. A respeito das técnicas de seleção de características pode-se observar a manutenção das três categorias identificadas previamente na seção II. Outro ponto de destaque é a desproporção entre os estudos das técnicas: apenas 14,81% dos trabalhos dedicam-se principalmente a tarefa de seleção de características, enquanto 51,85% abordam principalmente as tarefas de extração de características e 33,33% contemplam ambos os assuntos com a mesma importância.

A. Questão de Pesquisa Q1

Após a leitura na íntegra dos estudos selecionados, uma listagem das técnicas de extração de características utilizadas foi construída (Fig. 3). A escolha da técnica pode variar em função do diagnóstico desejado e do tipo de classificador utilizado. Foram identificadas quatro classificações para as

técnicas de extração de características, com foco no diagnóstico de distúrbios neurológicos: domínio do tempo, domínio da frequência, domínio de tempo-frequência e dinâmica não-linear. Nos estudos primários, as categorias das técnicas de extração estão distribuídas da forma: domínio do tempo com 78,33% dos estudos; domínio da frequência com 25,83% dos estudos; domínio de tempo-frequência com 42,50% dos estudos; dinâmica não-linear com 19,17% dos estudos.

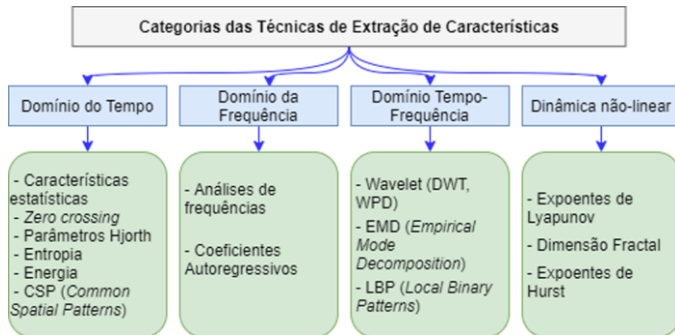


Fig. 3. Técnicas para Extração de Características em EEG.

B. Questão de Pesquisa Q2

As técnicas de seleção de características identificadas e suas respectivas categorias, estão listadas na Tabela II, e a distribuição de seu uso nos estudos primários é: baseada em métodos de filtro com 74,55% dos estudos; baseada em invólucro com 16,26% dos estudos; embarcados com 10,91% dos estudos. Essas técnicas visam escolher um subconjunto ótimo dentre as características recuperadas, reduzindo a dimensionalidade do problema.

TABELA II
TÉCNICAS DE SELEÇÃO DE CARACTERÍSTICAS EM EEG

Categoria	Técnicas
Filtro	Análise de Componente Principal (PCA); Teste t-student; ANOVA; Bhattacharyya; Análise de Discriminante Linear (LDA); Característica de Operação do Receptor (ROC); Wilcoxon; Seleção de Características por Informação Mútua (MIFS); Relevância Simétrica de dupla entrada (DISR); Relief / Relief; Correlação baseada em filtro (FCBF); Score de Fisher; Análise de Componente Independente (ICA); Maximização de Informação Mútua (MIM); Relevância Máxima e Redundância Mínima (MRMR); F-Score; Teste de Ansari Bradley; Qui-Quadrado; Seleção de Características Híbrida Adaptativa baseada em União (AHFSE); Análise de Discriminante Esparsa (SDA); Aprendizado Bayesiano Esparsa de faixas de frequências (SBLFB).
Invólucro	Seleção Sequencial para frente (SFS); Otimização de Colônia de Formigas (ACO); Algoritmos Genéticos (GA); Eliminação Recursiva de Características (RFE); Seleção Sequencial para trás (SBS); Busca por caça; Busca Dispersa; Seleção de características ponderada (WFS)
Embarcados	Análise de Componente por Vizinhaça (NCA); Otimização baseada em biogeografia (BBO); Regressão Logística Esparsa e Multinomial via Regularização L1 (SBMLR); Regressão ortogonal para frente (OFR); Rede Neural com função ponderada e difusa de pertencimento (NNWFMF).

Essa redução é realizada por técnicas que usam métodos baseados em filtro, invólucro ou embarcados. Métodos baseados em filtro utilizam um critério de correlação entre as características. Nos métodos baseados em invólucro, as características são selecionadas com base na resolução de um problema de otimização. Já os métodos embarcados fazem a seleção durante o treinamento do algoritmo de aprendizado de máquina, sendo geralmente mais eficientes, porém específico para aquele algoritmo [20] [4].

A Fig. 4 apresenta uma análise cruzada da aplicação das técnicas de extração e seleção de características. Após análise dos estudos primários, foi construída a Tabela III na qual pode-se analisar o resultado dos critérios de qualidade aplicados. A pontuação atribuída destaca a relevância e contribuição de cada artigo para o MS. O valor total representa a soma dos critérios multiplicada pelo número de estudos.

TABELA III
AVALIAÇÃO DE QUALIDADE DOS ESTUDOS PRIMÁRIOS

Refs.	CQ1	CQ2	CQ3	CQ4	CQ5	Total
[21]	0,5	0,5	0	0	1	2
[22]	0,5	0,5	0,5	0	0	1,5
[23]	0,5	1	0	0	0	1,5
[24, 25]	1	0	1	0	0	4
[26, 27]	1	0	1	0	1	6
[28]	1	0	1	1	1	4
[29]	1	0,5	1	0	0	2,5
[30 a 40]	1	1	0	0	0	22
[41, 42]	1	1	0	0	0,5	5
[43 a 65]	1	1	0	0	1	69
[66]	1	1	0	0,5	0	2,5
[67 a 71]	1	1	0	0,5	1	17,5
[72, 73]	1	1	0	1	0	6
[74]	1	1	0	1	0,5	3,5
[75 a 106]	1	1	0	1	1	128
[107]	1	1	0,5	0	0	2,5
[108]	1	1	0,5	0	1	3,5
[109 a 116]	1	1	0,5	1	1	36
[117 a 126]	1	1	1	0	0	30
[127 a 137]	1	1	1	0	1	44
[138, 139]	1	1	1	0,5	0	7
[140]	1	1	1	0,5	1	4,5
[141 a 143]	1	1	1	1	0	12
[144 a 164]	1	1	1	1	1	105
Média	0,99	0,95	0,41	0,50	0,75	3,61

Na condução do MS buscou-se minimizar fatores que pudessem influenciar negativamente os resultados e oferecer ameaças a validade deste mapeamento. Foram consideradas as ameaças com relação a validade da construção, validade interna e validade externa. Para tratar a validade da construção, os termos que compõem a *string* de busca foram definidos de modo a corresponderem a expressões bem estabelecidas na área de pesquisa. As bases de dados utilizadas, em conjunto, contemplam os resultados recuperados por outras bases de dados bem-conceituadas pela comunidade científica.




Fig. 4. a) Ocorrência conjunta de técnicas de extração e seleção de características nos estudos.

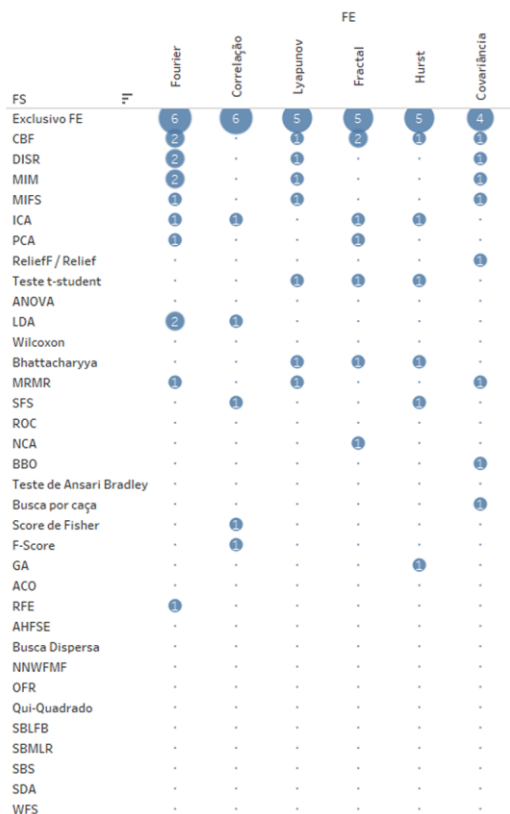


Fig. 4. b) Ocorrência conjunta de técnicas de extração e seleção de características nos estudos.




Fig. 4. c) Ocorrência conjunta de técnicas de extração e seleção de características nos estudos.




Fig. 4. d) Ocorrência conjunta de técnicas de extração e seleção de características nos estudos.

Para minimizar ameaças à validade interna, a aplicação de cada um dos critérios foi realizada em dois momentos distintos. Se um estudo foi selecionado, ou excluído, em ambas as análises, a decisão foi confirmada. No caso de divergência, uma análise posterior foi realizada. A respeito da validade externa, este MS não contemplou possíveis estudos relevantes que não foram revisados por pares, e pode contribuir tanto à comunidade científica, quanto à comunidade que desenvolve pesquisas no ramo industrial.

V. CONCLUSÃO

Este MS teve como objetivo identificar e analisar as técnicas de extração e seleção de características de sinais de EEG para diagnóstico de distúrbios neurológicos no período de 2013 a 2018, levando em consideração apenas artigos completos publicados em periódicos e conferências.

Durante a condução desse mapeamento, foram levantados 1004 estudos primários candidatos, como resultado da aplicação de uma *string* de busca abrangente, que minimizou as chances de perda de estudos relevantes. Na sequência, os critérios de inclusão e exclusão foram aplicados com o intuito de refinar a seleção de estudos primários, de forma a garantir que as etapas de interesse nesse mapeamento (extração e seleção de características) estivessem discutidas com clareza e em detalhes nos estudos. Esse procedimento resultou na seleção de 144 estudos primários. O procedimento sistemático de levantamento e seleção de estudos primários preenche uma lacuna importante até então presente nesta área de conhecimento – a ausência de um estudo sistemático e abrangente que organize o conhecimento referente à seleção e extração de características em análise de sinais EEG.

Além disso, uma análise cruzada da informação extraída desses estudos permitiu identificar como se dá a utilização conjunta de técnicas de extração e seleção de características e com que frequência tais combinações foram estudadas. O conhecimento resultante desse cruzamento de informação revela oportunidades de pesquisa e, portanto, contribui para a evolução do conhecimento na área de análise de sinais EEG.

REFERENCES

- [1] E. Niedermeyer, "Electroencephalography" in Niedermeyer's Electroencephalography: Basic Principles, Clinical Applications, and Related Fields, Wolters Kluwer Health/Lippincott Williams & Wilkins, 2011.
- [2] Y. Li, "Epileptic Seizure Detection Based on Time-Frequency Images of EEG Signals Using Gaussian Mixture Model and Gray Level Co-Occurrence Matrix Features," *Int. J. of Neural Systems* vol 28(7), 2018.
- [3] L. Boubchir, "A review of feature extraction for EEG epileptic seizure detection and classification," 40th Int. Conf. on Telecommunications and Signal Processing, TSP, pp. 456–460, 2017.
- [4] I. Guyon, "An Introduction to Variable and Feature Selection," *J. Mach. Learn. Res.* vol 3, pp. 1157–1182, 2003.
- [5] C.A.M. Lima, "Comitê de Máquinas: Uma abordagem Unificada Empregando Máquinas de Vetores-Suporte," Tese de Doutorado, UNICAMP, FEEC, Campinas, 2004.
- [6] B. Kitchenham and S. Charters, "Guidelines for performing Systematic Literature Reviews in Software Eng.," Technical Report EBSE 2007-001. Keele University and Durham University Joint Report. <http://www.dur.ac.uk/ebse/resources/Systematic-reviews-5-8.pdf>
- [7] A.R.C. Maita, "A systematic mapping study of process mining," *Enterprise Information Systems* vol 12(5), pp. 505–549, 2018.
- [8] M. Hamada, "A Systematic Review for Human EEG Brain Signals Based Emotion Classification, Feature Extraction, Brain Condition, Group Comparison," *J. of Med. Systems* vol 42(9), 2018.
- [9] R.V. Wankar, "Feature extraction and selection methods for motor imagery EEG signals: A review," *Proc. of 2017 Int. Conf. on Intelligent Comput. and Control, I2C2*, pp. 1–9, 2018.
- [10] R. Boostani, "A comparative review on sleep stage classification methods in patients and healthy individuals," *Comput. Methods and Programs in Biomed.* vol 140, pp. 77–91, 2017.
- [11] K. Giannakaki, "Emotional State Recognition Using Advanced Machine Learning Techniques on EEG Data," *Proc. - IEEE Symp. on Comput.-Based Med. Systems*, pp. 337–342, 2017.
- [12] E.H. Houssein, "EEG signals classification for epileptic detection: A review," *ACM Int. Conf. Proceeding Series*, 2017.
- [13] V.K. Harpale and V.K. Bairagi, "Time and frequency domain analysis of EEG signals for seizure detection: A review," *Int. Conf. on Microelectronics, Comput. and Commun., MicroCom*, 2016.
- [14] S. Vaid, "EEG signal analysis for BCI interface: A review," *Int. Conf. on Advanced Comput. and Commun. Technologies, ACCT*, pp. 143–147, 2015.
- [15] W.A.W. Azlan and Y.F. Low, "Feature extraction of electroencephalogram (EEG) signal - A review," *IEEE Conf. on Biomedical Eng. and Sciences: "Miri, Where Eng. in Medicine and Biology and Humanity Meet"*, pp. 801–806, 2014.
- [16] S. Sun and J. Zhou, "A review of adaptive feature extraction and classification methods for EEG-based brain-computer interfaces," *Proc. of the Int. Joint Conf. on Neural Networks*, pp. 1746–1753, 2014.
- [17] R. Jenke, "Feature extraction and selection for emotion recognition from EEG," *IEEE Trans. on Affective Comput.* vol 5(3), pp. 327–339, 2014.
- [18] S. Motamedi-Fakhr, "Signal processing techniques applied to human sleep EEG signals - A review," *Biomedical Signal Processing and Control* vol 10(1), pp. 21–33, 2014.
- [19] R. Hussein, "EEG feature extraction and selection techniques for epileptic detection: A comparative study," *IEEE Symp. on Computers and Inf., ISCI*, pp. 170–175, 2013.
- [20] T.T. Erguzel, "A hybrid artificial intelligence method to classify trichotillomania and obsessive-compulsive disorder," *Neurocomputing* vol 161, pp. 220–228, 2015.
- [21] F. Shayegh, "A model-based method for computation of correlation dimension, Lyapunov exponents and synchronization from depth-EEG signals," *Comput. Methods and Programs in Biomed.* vol 113(1), pp. 323–337, 2014.
- [22] S. Priyanka, "Feature selection and classification of Epilepsy from EEG signal," 2017 Int. Conf. on Energy, Commun., Data Analytics and Soft Comput., ICECDS 2017, pp. 2404–2406, 2018.
- [23] A.S. Shingare and A.M. Alnasrallah, "Epileptic seizure detection using ensemble classifier and HOS (Higher Order Statistics)," *Proc. - 2nd Int. Conf. on Comput., Commun., Control and Automation, ICCUBEA*, 2017.
- [24] F. Alimardani, "Presenting a new search strategy to select synchronization values for classifying bipolar mood disorders from schizophrenic patients," *Eng. Appl. of Artificial Intell.* vol 26(2), pp. 913–923, 2013.
- [25] T. T. Erguzel, "A wrapper-based approach for feature selection and classification of major depressive disorder-bipolar disorders," *Computers in Biology and Medicine* vol 64, pp. 127–137, 2015.
- [26] E. Gallego-Juggle, "A hybrid feature selection approach for the early diagnosis of Alzheimer's disease," *J. of Neural Eng.* vol 12(1), 2015.
- [27] M. Zabihi, "Patient-specific epileptic seizure detection in long-term EEG recording in pediatric patients with intractable seizures," *IET Conf. Publications* vol 2013 (619 CP), 2013.
- [28] A. Priyatinska, "Binary classification of multichannel-EEG records based on the e-complexity of continuous vector functions," *Comput. Methods and Programs in Biomed.* vol 152, pp. 131–139, 2017.
- [29] E. Pippa, "Improving classification of epileptic and non-epileptic EEG events by feature selection," *Neurocomputing* vol 171, pp. 576–585, 2016.
- [30] J.E. Jacob, "Diagnosis of epilepsy from interictal EEGs based on chaotic and wavelet transformation," *Analog Integr. Circuits and Signal Process.* vol 89(1), pp. 131–138, 2016.

- [31] N.N. Kulkarni and V.K. Bairagi, "Extracting Salient Features for EEG-based Diagnosis of Alzheimer's Disease Using Support Vector Machine Classifier," *IETEJ. of Research* vol 63(1), pp. 11–22, 2017.
- [32] M. Lee, "Classification of Both Seizure and Non-Seizure Based on EEG Signals Using Hidden Markov Model," *Proc. - IEEE Int. Conf. on Big Data and Smart Comput., BigComp*, pp. 469–474, 2018.
- [33] S.-C. Liao, "Major depression detection from EEG signals using kernel eigen-filter-bank common spatial patterns," *Sensors (Switzerland)* vol 17(6), 2017.
- [34] Q.T. Ly, "Detection of turning freeze in Parkinson's disease based on S-transform decomposition of EEG signals," *Proc. of the Annual Int. Conf. of the IEEE Eng. in Medicine and Biology Society, EMBS*, pp. 3044–3047, 2017.
- [35] S.K. Prabhakar and H. Rajaguru, "GMM better than SRC for classifying epilepsy risk levels from EEG signals," *ICIIBMS 2015 - Int. Conf. on Intelligent Inf. and Biomedical Sciences*, pp. 347–350, 2016.
- [36] S.K. Prabhakar and H. Rajaguru, "Morphological operator-based feature extraction technique along with suitable post classifiers for epilepsy risk level classification," *ICIIBMS 2015 - Int. Conf. on Intelligent Inf. and Biomed. Sciences*, pp. 446–451, 2016.
- [37] B. Pushpa and D. Najumissa, "Classification of Epileptic seizure EEG signals using EMD and ANFIS," *2014 Int. Conf. on Inf., Electronics and Vision, ICIEV*, 2014.
- [38] D. Trad, "A feature extraction technique of EEG based on EMD-BP for motor imagery classification in BCI," *5th Int. Conf. on Information and Commun. Technology and Accessibility, ICTA*, 2016.
- [39] V.S. Vijith, "Epileptic seizure detection using non-linear analysis of EEG," *Proc. of the Int. Conf. on Inventive Comput. Tech.*, 2016.
- [40] Y. Zhang, "Combined feature extraction method for classification of EEG signals," *Neural Comput. and Appl.* vol 28(11), pp. 3153–3161, 2017.
- [41] B. Boashash, "Principles of time-frequency feature extraction for change detection in non-stationary signals: Appl. to newborn EEG abnormality detection," *Pattern Recognition* vol 48(3), pp. 616–627, 2015.
- [42] S. Li, "Feature extraction and recognition of ictal EEG using EMD and SVM," *Computers in Biology and Medicine* vol 43(7), pp. 807–816, 2013.
- [43] H. Alawieh, "Patient-aware adaptive ngram-based algorithm for epileptic seizure prediction using EEG signals," *IEEE 18th Int. Conf. on e-Health Networking, Appl. and Services, Healthcom*, 2016.
- [44] N.K. Ambulkar and S.N. Sharma, "Detection of epileptic seizure in EEG signals using window width optimized S-transform and artificial neural networks," *IEEE Bombay Section Symp.: Frontiers of Technology: Fuelling Prosperity of Planet and People, IBSS*, 2016.
- [45] S. Ammar and M. Senouci, "Seizure detection with single-channel EEG using Extreme Learning Machine," *17th Int. Conf. on Sciences and Techniques of Automatic Control and Comput. Eng.*, pp. 776–779, 2017.
- [46] P. Bhuvaneshwari and J.S. Kumar, "Total Variation Based Multi Feature Model for Epilepsy Detection Using Support Vector Machine," *IETE J. of Research* vol 62(6), pp. 822–832, 2016.
- [47] T. Das, "Classification of EEG Signals for Prediction of Seizure using Multi-Feature Extraction," *1st Int. Conf. on Electronics, Materials Eng. and NanoTechnology, IEMENTech*, 2017.
- [48] R. Jacob and K.P. Menon, "Implementation of EEG feature extractor and classifier for seizure detection on FPGA," *Proc. of the 2017 Int. Conf. on Intelligent Comput. and Control Systems, ICICCS*, pp. 307–310, 2018.
- [49] E. Kabir, "Epileptic seizure detection from EEG signals using logistic model trees," *Brain Inf.* vol 3(2), pp. 93–100, 2016.
- [50] M. Kaleem, "EEG seizure detection and epilepsy diagnosis using a novel variation of Empirical Mode Decomposition," *Proc. of the Annual Int. Conf. of the IEEE Eng. in Medicine and Biology Society, EMBS*, pp. 4314–4317, 2013.
- [51] J.-H. Kang, "An efficient detection of epileptic seizure by differentiation and spectral analysis of electroencephalograms," *Computers in Biology and Medicine* vol 66, pp. 352–356, 2015.
- [52] S. Kumari, "Application of empirical mode decomposition for feature extraction from EEG signals," *IEEE Int. Conf. on Comput. Commun. and Control, IC4*, 2016.
- [53] N. Mohite, "Epileptic electroencephalogram classification," *Int. Conf. on Commun. and Sign. Process, ICCSP - Proc.*, pp. 467–471, 2014.
- [54] M.Z. Parvez and M. Paul, "Novel approaches of EEG signal classification using IMF bandwidth and DCT frequency," *Biomedical Eng. - Appl., Basis and Commun.* vol 27(3), 2015.
- [55] M.Z. Parvez and M. Paul, "Seizure prediction by analyzing EEG signal based on phase correlation," *Proc. of the Annual Int. Conf. of the IEEE Eng. in Medicine and Biology Society, EMBS*, pp. 2888–2891, 2015.
- [56] E. Pippa, "Automatic estimation of the optimal AR order for epilepsy analysis using EEG signals," *2015 IEEE 15th Int. Conf. on Bioinformatics and Bio Eng., BIBE*, 2015.
- [57] K. Samiee, "Long-term epileptic EEG classification via 2D mapping and textual features," *Expert Systems with Appl.* vol 42(20), pp. 7175–7185, 2015.
- [58] M. Sharanreddy and P.K. Kulkarni, "Automated EEG signal analysis for identification of epilepsy seizures and brain tumour," *J. of Med. Eng. and Techno-logy* vol 37(8), pp. 511–519, 2013.
- [59] L.S. Vidyaratne and K.M. Iftikharuddin, "Real-Time Epileptic Seizure Detection Using EEG," *IEEE Trans. on Neural Systems and Rehabilitation Eng.* vol 25(11), pp. 2146–2156, 2017.
- [60] F. Wang, "Novel feature extraction method based on weight difference of weighted network for epileptic seizure detection," *36th Annual Int. Conf. of the IEEE Eng. in Medicine and Biology Society, EMBC*, pp. 3256–3259, 2014.
- [61] J. Wang, "Feature extraction based on sparse representation with application to epileptic EEG classification," *Int. J. of Imaging Systems and Technology* vol 23(2), pp. 104–113, 2013.
- [62] Y. Yuan, "A multi-view deep learning method for epileptic seizure Detection using short-time Fourier transform," *ACM-BCB 2017 - Proc. of the 8th ACM Int. Conf. on Bioinf., Comput. Biology, and Health Inf.*, pp. 213–222, 2017.
- [63] T. Zhang, "AR based quadratic feature extraction in the VMD domain for the automated seizure detection of EEG using random forest classifier," *Biomed. Sign. Process. and Contr.* vol 31, pp. 550–559, 2017.
- [64] X. Zhang and H. Chen, "A seizure detection method based on well-solved nonlinear and non-stationary problems with electroencephalographic signals," *Biomedical Eng. - Appl., Basis and Commun.* vol 30(5), 2018.
- [65] Y. Zhang, "Classification of EEG Signals Based on Autoregressive Model and Wavelet Packet Decomposition," *Neural Proces. Letters* vol 45(2), pp. 365–378, 2017.
- [66] B. Szufflitowska and P. Orlowski, "Classification of electroencephalograph signals using time-frequency decomposition and linear discriminant analysis," *Proc. of SPIE - The Int. Soc. for Opt. Eng.*, 2017.
- [67] A.E. Elmahdy, "Epileptic seizure detection using singular values and classical features of EEG signals," *Int. Conf. on Bio Signal Analysis, Processing and Systems, ICBAPS*, pp. 162–167, 2015.
- [68] M.Z. Parvez and M. Paul, "Epileptic seizure detection by analyzing EEG signals using different transformation techniques," *Neurocomputing* vol 145, pp. 190–200, 2014.
- [69] M.Z. Parvez and M. Paul, "Epileptic seizure detection by exploiting temporal correlation of electroencephalogram signals," *IET Signal Processing* vol 9(6), pp. 467–475, 2015.
- [70] M. Yusaf, "Robust seizure detection in EEG using 2D DWT of time-frequency distributions," *Electr. Let.* vol 52(11), pp. 902–903, 2016.
- [71] Y. Zhang, "Classification of EEG signals based on AR model and approximate entropy," *Proc. of the Int. Joint Conf. on Neural Networks*, 2015.
- [72] T. Fatma, "Automatic detection of non-convulsive seizures: A reduced complexity approach," *J. of King Saud University - Comput. and Information Sciences* vol 28(4), pp. 407–415, 2016.
- [73] O.W. Samuel, "Towards Efficient Decoding of Multiple Classes of Motor Imagery Limb Movements Based on EEG Spectral and Time Domain Descriptors," *J. of Medical Systems* vol 41(12), 2017.
- [74] A. Gupta, "A novel signal modeling approach for classification of seizure and seizure-free EEG signals," *IEEE Trans. on Neural Systems and Rehabilitation Eng.* vol 26(5), pp. 925–935, 2018.
- [75] A. Ahmadi, "Epileptic seizure classification using novel entropy features applied on maximal overlap discrete wavelet packet transform of EEG signals," *7th Int. Conf. on Comput. and Knowl. Eng.*, pp. 390–395, 2017.
- [76] T.N. Alotaiby, "Epileptic seizure prediction using CSP and LDA for scalp EEG signals," *Comput. Intell. and Neuroscience*, 2017.
- [77] D. Biswas and M.F. Hossain, "Epileptic seizure detection based on selected features of different complexities using ANN," *3rd Int. Conf.*

- on Electrical Information and Commun. Technology, EICT, pp. 1–5, 2018.
- [78] R. Djemili, “Application of empirical mode decomposition and artificial neural network for the classification of normal and epileptic EEG signals,” *Biocyber. and Biomed. Eng.*, vol 36(1), pp. 285–291, 2016.
- [79] H. Göksu, “EEG based epileptiform pattern recognition inside and outside the seizure states,” *Biomedical Signal Processing and Control* vol 43, pp. 204–215, 2018.
- [80] A.K. Jaiswal and H. Banka, “Local pattern transformation-based feature extraction techniques for classification of epileptic EEG signals,” *Biomedical Signal Processing and Control* vol 34, pp. 81–92, 2017.
- [81] A.K. Jaiswal and H. Banka, “Epileptic seizure detection in EEG signal using machine learning techniques,” *Australasian Physical and Eng. Sciences in Medicine* vol 41(1), pp. 81–94, 2018.
- [82] K. Jindal and R. Upadhyay, “Epileptic seizure detection from EEG signal using Flexible Analytical Wavelet Transform,” 2017 Int. Conf. on Comput. Commun. and Electronics, COMPTELIX, pp. 67–72, 2017.
- [83] E. Kabir, “A computer aided analysis scheme for detecting epileptic seizure from EEG data,” *Int. J. of Comput. Intell. Systems* vol 11(1), pp. 663–671, 2018.
- [84] C.-Y. Kee, “Binary and multi-class motor imagery using Renyi entropy for feature extraction,” *Neural Comput. and Appl.* vol 28(8), pp. 2051–2062, 2017.
- [85] Z. Lasefr, “An efficient automated technique for epilepsy seizure detection using EEG signals,” *IEEE 8th Annual Ubiquitous Comput., Electronics and Mobile Commun. Conf., UEMCON*, pp. 76–82, 2018.
- [86] D. Li, “A sequential method using multiplicative extreme learning machine for epileptic seizure detection,” *Neurocomputing* vol 214, pp. 692–707, 2016.
- [87] M. Li, “Application of MODWT and log-normal distribution model for automatic epilepsy identification,” *Biocyber. and Biomed. Eng.* vol 37(4), pp. 679–689, 2017.
- [88] M. Li, “Automatic epileptic EEG detection using DT-CWT-based non-linear features,” *Biomedical Signal Processing and Control* vol 34, pp. 114–125, 2017.
- [89] M. Li, “Classification of epilepsy EEG signals using DWT-based envelope analysis and neural network ensemble,” *Biomedical Signal Processing and Control* vol 31, pp. 357–365, 2017.
- [90] S. Madan, “A case study on Discrete Wavelet Transform based Hurst exponent for epilepsy detection,” *J. of Med. Eng. and Tech.* vol 42(1), pp. 9–17, 2018.
- [91] A.S.M. Murugavel and S. Ramakrishnan, “Hierarchical multi-class SVM with ELM kernel for epileptic EEG signal classification,” *Med. and Biological Eng. and Comput.* vol 54(1), pp. 149–161, 2016.
- [92] S. Nara, “Efficient Recognition of Ictal Activities in EEG through Correlation Based Dimensionality Reduction,” pp. 2547–2550, 2016.
- [93] M.Z. Parvez and M. Paul, “Seizure prediction using undulated global and local features,” *IEEE Trans. on Biomedical Eng.* vol 64(1), pp. 208–217, 2017.
- [94] S. Patidar and T. Panigrahi, “Detection of epileptic seizure using Kraskov entropy applied on tunable-Q wavelet transform of EEG signals,” *Biomedical Signal Process. and Control* vol 34, pp. 74–80, 2017.
- [95] M. Qaraqe and D. Al-Thani, “A machine learning algorithm for the automatic detection of ictal activity using energy and synchronization features,” 2017 IEEE Int. Symp. on Signal Proc and Inform. Technol., ISSPIT 2017, pp. 353–359, 2018.
- [96] F. Riaz, “EMD-based temporal and spectral features for the classification of EEG signals using supervised learning,” *IEEE Trans. on Neural Systems and Rehabilitation Eng.* vol 24(1), pp. 28–35, 2016.
- [97] Z. R. Zamir, “Detection of epileptic seizure in EEG signals using linear least squares preprocessing,” *Comput. Methods and Programs in Biomed.* vol 133, pp. 95–109, 2016.
- [98] S. Rukhsar, “Detection of epileptic seizure in EEG signals using phase space reconstruction and euclidean distance of first-order derivative,” *Proc. of the Int. Conf. on Inventive Comput. and Inf., ICICI*, pp. 821–826, 2018.
- [99] K. Samiee, “Epileptic seizure classification of EEG time-series using rational discrete short-time fourier transform,” *IEEE Trans. on Biomedical Eng.* vol 62(2), pp. 541–552, 2015.
- [100] K. Sivasankari and K. Thanushkodi, “An improved EEG signal classification using Neural Network with the consequence of ICA and STFT,” *J. of Electr. Eng. and Technology* vol 9(3), pp. 1060–1071, 2014.
- [101] J.-L. Song, “Automated detection of epileptic EEGs using a novel fusion feature and extreme learning machine,” *Neurocomputing* vol 175(PartA), pp. 383–391, 2015.
- [102] J.-L. Song and R. Zhang, “Automatic seizure detection using a novel EEG feature based on nonlinear complexity,” *Proc. of the Int. Joint Conf. on Neural Networks*, pp. 1686–1695, 2016.
- [103] J.-L. Song and R. Zhang, “Application of extreme learning machine to epileptic seizure detection based on lagged Poincaré plots,” *Multidimensional Syst. and Signal Process.* vol 28(3), pp. 945–959, 2017.
- [104] E. Tessa, “Time domain analysis of epileptic EEG for seizure detection,” *Int. Conf. on Next Generat. Intellig. Systems, ICNGIS*, 2017.
- [105] E. Yavuz, “An epileptic seizure detection system based on cepstral analysis and generalized regression neural network,” *Biocybernetics and Biomedical Eng.* vol 38(2), pp. 201–216, 2018.
- [106] Q. Yuan, “Epileptic EEG Identification via LBP Operators on Wavelet Coefficients,” *Int. J. of Neural Systems* vol 28(8), 2018.
- [107] A. Mohammed, “Toward on-demand deep brain stimulation using online Parkinson’s disease prediction driven by dynamic detection,” *IEEE Trans. on Neural Systems and Rehabilitation Eng.* vol 25(12), pp. 2441–2452, 2017.
- [108] M.H. Kolekar and D.P. Dash, “A nonlinear feature based epileptic seizure detection using least square support vector machine classifier,” *IEEE Region 10 Annual Int. Conf., Proc. TENCON*, 2016.
- [109] A. Anugraha, “A machine learning application for epileptic seizure detection,” *Proc. of Int. Conf. on Comput. Intell. in Data Science*, pp. 1–4, 2018.
- [110] P. Artimeyanant, “Electroencephalography-based feature extraction using complex network for automated epileptic seizure detection,” *Expert Systems* vol 34(3), 2017.
- [111] R. Dhiman, “Biogeography based hybrid scheme for automatic detection of epileptic seizures from EEG signatures,” *Applied Soft Comput. J.* vol 51, pp. 116–129, 2017.
- [112] D. Gajic, “Classification of EEG signals for detection of epileptic seizures based on wavelets and statistical pattern recognition,” *Biomedical Eng. -Appl., Basis and Commun.* vol 26(2), 2014.
- [113] R. Hussein, “L1-regularization based EEG feature learning for detecting epileptic seizure,” *IEEE Global Conf. on Signal and Information Processing, Global SIP 2016 - Proc.*, pp. 1171–1175, 2017.
- [114] R. Hussein, “High-performance EEG feature extraction for fast epileptic seizure detection,” *IEEE Global Conf. on Signal and Information Processing, Global SIP Proc.*, pp. 953–957, 2018.
- [115] K. Samiee, “Epileptic seizure detection in long-term EEG records using sparse rational decomposition and local Gabor binary patterns feature extraction,” *Knowl.-Based Systems* vol 118, pp. 228–240, 2017.
- [116] Z. Zhang, “Automatic epileptic seizure detection in EEGs using MF-DFA, SVM based on cloud computing,” *J. of X-ray science and technology* vol 25(2), pp. 261–272, 2017.
- [117] S. Dora, “Automatic seizure detection in multichannel EEG using McCIT2FIS approach,” *IEEE Int. Conf. on Fuzzy Systems*, 2015.
- [118] M.-P. Hosseini, “Real-time epileptic seizure detection from EEG signals via random subspace ensemble learning,” *Proc. - IEEE Int. Conf. on Autonomic Comput., ICAC*, pp. 209–218, 2016.
- [119] M.-P. Hosseini, “Random ensemble learning for EEG classification,” *Artificial Intell. in Medicine* vol 84, pp. 146–158, 2018.
- [120] A. Khaleghi, “EEG classification of adolescents with type I and type II of bipolar disorder,” *Australas. Phys. and Eng. Sci. in Med.* vol 38(4), pp. 551–559, 2015.
- [121] Y. Liu, “Separation and recognition of electroencephalogram patterns using temporal independent component analysis,” *Int. J. of Pattern Recognition and Artificial Intell.* vol 29(1), 2015.
- [122] W. Mumtaz, “Electroencephalogram (EEG)-based computer-aided technique to diagnose major depressive disorder (MDD),” *Biomedical Signal Processing and Control* vol 31, pp. 108–115, 2017.
- [123] S. Raghu, “Features ranking for the classification of epileptic seizure from temporal EEG,” 2016 Int. Conf. on Circuits, Controls, Commun. and Comput., I4C, 2017.
- [124] L. Santos-Mayo, “A computer-aided diagnosis system with EEG based on the p3b wave during an auditory odd-ball task in schizophrenia,” *IEEE Trans. on Biomedical Eng.* vol 64(2), pp. 395–407, 2017.

- [125] A. Sánchez-González, "Patient prognosis based on feature extraction, selection and classification of EEG periodic activity," *Bio-Med. Materials and Eng.* vol 26, pp. S1569–S1578, 2015.
- [126] Q. Zhao, "An Alpha resting EEG study on nonlinear dynamic analysis for schizophrenia," *Int. IEEE/EMBS Conf. on Neural Eng., NER*, pp. 484–488, 2013.
- [127] S.E. Awan, "A surrogate channel-based analysis of EEG signals for detection of epileptic seizure," *IST 2016 IEEE Int. Conf. on Imaging Systems and Techniques, Proc.*, pp. 384–388, 2016.
- [128] M. Behnam and H. Pourghassem, "Lagged Correlogram Patterns-based seizure detection algorithm using optimized HMM feature fusion," *12th IEEE Int. Conf. Electronics, Energy, Environ., Commun., Comput., Control: (E3-C3)*, 2016.
- [129] M. Behnam and H. Pourghassem, "Singular Lorenz Measures Method for seizure detection using KNN-Scatter Search optimization algorithm," *Signal Processing and Intelligent Systems Conf., SPIS*, pp. 67–72, 2016.
- [130] B. Boashash and S. Ouelha, "Automatic signal abnormality detection using time-frequency features and machine learning: A newborn EEG seizure case study," *Knowl.-Based Systems* vol 106, pp. 38–50, 2016.
- [131] K. Gopika-Gopan, "Statistical features based epileptic seizure EEG detection - An efficacy evaluation," *Int. Conf. on Advances in Comput., Commun. and Inf., ICACCI 2015*, pp. 1394–1398, 2015.
- [132] K.A. Mamun, "Movement decoding using neural synchronization and inter-hemispheric connectivity from deep brain local field potentials," *J. of Neural Eng.* vol 12(5), 2015.
- [133] H. Rmili, "Real-time classification of EEG signals implemented on DSPIC for the diagnosis of epilepsy," *2017 Int. Conf. on Smart, Monitored and Controlled Cities, SM2C*, pp. 53–58, 2017.
- [134] Y. Song and J. Zhang, "Automatic recognition of epileptic EEG patterns via Extreme Learning Machine and multiresolution feature extraction," *Expert Systems with Appl.* vol 40(14), pp. 5477–5489, 2013.
- [135] M. Sood and S.V. Bhooshan, "Modular based dynamic analysis of EEG signals using non-linear feature," *Proc. of 2014 3rd Int. Conf. on Parallel, Distributed and Grid Comput., PDGC*, pp. 186–190, 2014.
- [136] T. Zhang, "Fuzzy distribution entropy and its application in automated seizure detection technique," *Biomed. Signal Proces. and Control* vol 39, pp. 360–377, 2018.
- [137] Y. Zhang, "Sparse Bayesian learning for obtaining sparsity of EEG frequency bands-based feature vectors in motor imagery classification," *Int. J. of Neural Systems* vol 27(2), 2017.
- [138] S. Noertjahjani, "Classification of epileptic and non-epileptic EEG events by feature selection f-score," *Proc. of the 2017 5th Int. Conf. on Instrumentation, Control, and Automation, ICA 2017*, pp. 182–187, 2017.
- [139] A. Torabi, "Diagnosis of multiple sclerosis from EEG signals using nonlinear methods," *Australa. Phys. and Eng. Sci. in Med.* vol 40(4), pp. 785–797, 2017.
- [140] H.R.A. Ghayab, "Classification of epileptic EEG signals based on simple random sampling and sequential feature selection," *Brain Inf.* vol 3(2), pp. 85–91, 2016.
- [141] S. Chen, "Epileptic seizure detection by combining robust-principal component analysis and least square-support vector machine," *Int. J. of Imaging Systems and Technology*, vol 27(4), pp. 368–375, 2017.
- [142] L. Wang, "Seizure pattern-specific epileptic epoch detection in patients with intellectual disability," *Biomed. Signal Proces. and Control* vol 35, pp. 38–49, 2017.
- [143] R. Yuvaraj, "A novel Parkinson's Disease Diagnosis Index using higher-order spectra features in EEG signals," *Neural Comput. and Appl.* vol 30(4), pp. 1225–1235, 2018.
- [144] A. Ahmadi, "Phase and amplitude coupling feature extraction and recognition of Ictal EEG using VMD," *IEEE 4th Int. Conf. on Knowl-Based Eng. and Innovation, KBEI*, pp. 0526–0532, 2018.
- [145] F. Alzami, "Adaptive Hybrid Feature Selection-Based Classifier Ensemble for Epileptic Seizure Classification," *IEEE Access* vol 6, pp. 29132–29145, 2018.
- [146] M. Behnam and H. Pourghassem, "Periodogram pattern feature-based seizure detection algorithm using optimized hybrid model of MLP and ant colony," *Proc. of the 23rd Iranian Conf. on Elect. Eng.* vol 10, pp. 32–37, 2015.
- [147] M. Behnam and H. Pourghassem, "Real-time seizure prediction using RLS filtering and interpolated histogram feature based on hybrid optimization algorithm of Bayesian classifier and Hunting search," *Comput. Methods and Programs in Biomed.* 132, pp. 115–136, 2016.
- [148] M. Behnam and H. Pourghassem, "Spectral Correlation Power-based Seizure Detection using Statistical Multi-Level Dimensionality Reduction and PSO-PNN Optimization Algorithm," *IETE J. of Research*, vol 63(5), pp. 736–753, 2017.
- [149] A. Bousbia-Salah and M. Talha-Kedir, "Time-frequency processing method of epileptic EEG signals," *Biomedical Eng. - Appl., Basis and Commun.* vol 27(2), 2015.
- [150] A. Ghaffari and H.E. Orimi, "EEG signals classification of epileptic patients via feature selection and voting criteria in intelligent method," *J. of Med. Eng. and Technology* vol 38(3), pp.146–155, 2014.
- [151] Y. Guo, "Automated epileptic seizure detection by analyzing wearable EEG signals using extended correlation-based feature selection," *IEEE 15th Int. Conf. on Wearable and Implantable Body Sensor Networks*, pp. 66–69, 2018.
- [152] A.R. Hassan, "Epileptic seizure detection in EEG signals using tunable-Q factor wavelet transform and bootstrap aggregating," *Comput. Methods and Programs in Biomed.* vol 137, pp. 247–259, 2016.
- [153] J. Jia, "Automated identification of epileptic seizures in EEG signals based on phase space representation and statistical features in the CEEMD domain," *Biomedical Signal Processing and Control* vol 38, pp. 148–157, 2017.
- [154] Y. Kaya, "Hidden pattern discovery on epileptic EEG with 1-D local binary patterns and epileptic seizures detection by grey relational analysis," *Australasian Physical and Eng. Sciences in Medicine* vol 38(3), pp. 435–446, 2015.
- [155] A.T. Khan, "Seizure onset patterns in EEG and their detection using statistical measures," *12th IEEE Int. Conf. Electronics, Energy, Environ., Commun., Comput., Control: (E3-C3), INDICON*, 2016.
- [156] S.-H. Lee, "Classification of normal and epileptic seizure EEG signals using wavelet transform, phase-space reconstruction, and Euclidean distance," *Comput. Methods and Programs in Biomed.* vol 116(1), pp. 10–25, 2014.
- [157] M. Li, "A novel seizure diagnostic model based on kernel density estimation and least squares support vector machine," *Biomedical Signal Processing and Control* vol 41, pp. 233–241, 2018.
- [158] Y. Li, "Epileptic Seizure Classification of EEGs Using Time-Frequency Analysis Based Multiscale Radial Basis Functions," *IEEE J. of Biomedical and Health Inf.* vol 22(2), pp. 386–397, 2018.
- [159] Y. Lu, "Classification of single-channel EEG signals for epileptic seizures detection based on hybrid features," *Technology and Health Care* vol 26(S1), pp. S337–S346, 2018.
- [160] M. Mursalin, "Automated epileptic seizure detection using improved correlation-based feature selection with random forest classifier," *Neurocomputing* vol 241, pp. 204–214, 2017.
- [161] S. Raghu and N. Sriraam, "Classification of focal and non-focal EEG signals using neighborhood component analysis and machine learning algorithms," *Expert Systems with Appl.* vol 113, pp. 18–32, 2018.
- [162] A. Sharmila and P. Mahalakshmi, "Wavelet-based feature extraction for classification of epileptic seizure EEG signal," *J. of Medical Eng. and Technology* vol 41(8), pp. 670–680, 2017.
- [163] S. Siuly and Y. Li, "Designing a robust feature extraction method based on optimum allocation and principal component analysis for epileptic EEG signal classification," *Comput. Methods and Programs in Biomed.* vol 119(1), pp. 29–42, 2015.
- [164] B. Şen and M. Peker, "Novel approaches for automated epileptic diagnosis using FCBF selection and classification algorithms," *Turkish J. of Electrical Eng. and Comput. Sciences* vol 21(SUPPL. 1), pp. 2092–2109, 2013.



Wallace Faverson de Almeida Possui graduação em Ciências de Computação pela Universidade de São Paulo (2013). Atualmente é mestrando em Sistemas de Informação pela Universidade de São Paulo. Tem experiência na área de Ciência da Computação, com ênfase em Metodologia e Técnicas da Computação.

**Clodoaldo Aparecido de Moraes Lima**

possui graduação em Engenharia Elétrica pela Universidade Federal de Juiz de Fora (1997), mestrado (modalidade Automação), doutorado (modalidade Engenharia de Computação) e pós-doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas (2000), (2004), (2005). Atualmente é professor doutor na Escola de Artes, Ciências e Humanidades da Universidade de São Paulo, atuando como docente-pesquisador no curso de Sistemas de Informação. Desenvolve pesquisas na área de Processamento de Sinais, principalmente sinais biomédicos, Aprendizado de Máquina, com ênfase em métodos de kernel e de comitê de máquinas, Sistemas Biométricos, Modelagem não-paramétrica e análise e Predição de Séries Temporais.

**Sarajane Marques Peres**

possui graduação em Ciência da Computação pela Universidade Estadual de Maringá (1996), mestrado em Engenharia de Produção pela Universidade Federal de Santa Catarina (1999) e doutorado em Engenharia Elétrica pela Universidade Estadual de Campinas (2006). Atualmente é professora-pesquisadora associada (livre docente), em regime de dedicação exclusiva, da Universidade de São Paulo, com credenciamento pleno no Programa de Pós Graduação em Sistemas de Informação da USP. Durante agosto de 2018 a dezembro de 2018 atuou como pesquisadora na Vrije Universiteit Amsterdam, nos Países Baixos, e durante janeiro de 2019 a junho de 2019 atuou como pesquisadora na Utrecht University, Países Baixos. Tem experiência na área de Ciência da Computação, com ênfase em Inteligência Computacional. Atualmente está pesquisando na área de Reconhecimento de Padrões aplicado a Análise de Gestos, Mineração de Textos e Mineração de Processos. Autora do livro didático: Introdução à Mineração de Dados: com aplicações em R, publicado como parte da Série Elsevier - SBC.