



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PIAUÍ - UFPI
PROGRAMA DE PÓS-GRADUAÇÃO EM BIOTECNOLOGIA - PPGBIOTEC

ERIC GABRIEL SOUZA CRESPO

**UTILIZAÇÃO DO VETOR *PERCEPTUALLY IMPORTANT POINTS* COMO
ENTRADA PARA CLASSIFICAÇÃO DE PADRÕES COM REDE NEURAL
ARTIFICIAL *MULTI LAYER PERCEPTRON* EM SÉRIE TEMPORAL**

PARNAÍBA - PI

2019

ERIC GABRIEL SOUZA CRESPO

**UTILIZAÇÃO DO VETOR *PERCEPTUALLY IMPORTANT POINTS* COMO
ENTRADA PARA CLASSIFICAÇÃO DE PADRÕES COM REDE NEURAL
ARTIFICIAL *MULTI LAYER PERCEPTRON* EM SÉRIE TEMPORAL**

Dissertação apresentada ao Programa de Pós-Graduação em Biotecnologia (PPGBiotec) da Universidade Federal do Piauí (UFPI), *Campus* Ministro Reis Velloso, como requisito parcial para obtenção do título de Mestre em Biotecnologia, sob orientação do Prof. Dr. Silmar Silva Teixeira.

PARNAÍBA - PI

2019

ERIC GABRIEL SOUZA CRESPO

**UTILIZAÇÃO DO VETOR *PERCEPTUALLY IMPORTANT POINTS* COMO
ENTRADA PARA CLASSIFICAÇÃO DE PADRÕES COM REDE NEURAL
ARTIFICIAL *MULTI LAYER PERCEPTRON* EM SÉRIE TEMPORAL**

Dissertação apresentada ao Programa de Pós-Graduação em Biotecnologia (PPGBiotec) da Universidade Federal do Piauí (UFPI), Campus Ministro Reis Velloso, como requisito para o título de Mestre em Biotecnologia, sob orientação do Prof. Dr. Silmar Silva Teixeira e co-orientação do Prof. Dr. Ariel Soares Teles.

APROVADA EM: ___/___/___

BANCA EXAMINADORA

Prof. Dr. Silmar Silva Teixeira
Universidade Federal do Piauí – *Campus* Ministro Reis Velloso
(Presidente)

Prof. Dr. Victor Hugo do Vale Bastos
Universidade Federal do Piauí – *Campus* Ministro Reis Velloso
(Membro)

Prof. Dr. Ariel Soares Teles
Instituto Federal do Maranhão – *Campus* Barreirinhas
(Membro)

Prof. Dr. Alair Pedro Ribeiro de Souza e Silva
Universidade Federal do Rio de Janeiro
(Membro)

RESUMO

O reconhecimento de padrões em séries temporais (RPST) é uma das sub-áreas da computação que mais crescem em pesquisas no mundo. Seu desenvolvimento exponencial, tem estabelecido o *crossover* entre outras áreas por intermédio de diversas aplicações e soluções na área da saúde, ensino e pesquisa. Embora haja avanço da RPST nas neurociências, ainda não foi desenvolvido um sistema com RPST que reconheça e elimine os artefatos do eletroencefalograma. Neste contexto, o objetivo deste estudo foi desenvolver um sistema com a utilização do RPST para identificar, analisar e eliminar os artefatos do sinal eletroencefalográfico. Para esta proposição, foi utilizada a identificação de pontos críticos, ou seja, vales e picos que tornam possíveis a identificação de um comportamento padronizado pela RPST, com a utilização da regra de *perceptually important points* (PIP). Em seguida, foram selecionados aleatoriamente dados de sinal eletroencefalográfico com artefatos de piscada dos olhos. Os resultados demonstram que o PIP é uma métrica comparativa de RPST que pode ser utilizada como entrada em Redes Neuras Artificiais (RNA) para categorizar o padrão do espectro do eletroencefalograma, apresentando uma taxa de precisão de 98,8% quanto ao acerto dos artefatos. Conclui-se que a utilização do vetor angular PIP como solução para identificação em séries temporais é aplicável e precisa.

Palavras-chave: Eletroencefalograma, EEG, Padrão, MOTIFS, remoção de artefatos, Inteligência Artificial.

ABSTRACT

Pattern Recognition in Time Series (RPST) is one of the fastest growing computing sub-areas in the world. Its exponential development has established the crossover among other areas, such as neuroscience, through various applications and solutions in the medical field, teaching and research. Although RPST has advanced in the neurosciences, a system with TPRS that recognizes and eliminates electroencephalogram artifacts has not been developed yet. In this context, the objective of this study was to develop a system with the use of RPST to identify, analyze and eliminate electroencephalographic signal artifacts. For this proposition, it was used the identification of critical points, that is, valleys and peaks that make it possible to identify a behavior standardized by the RPST, using the rule of perceptually important points (PIP). Then, electroencephalographic signal data were randomly selected with artifacts of eye blinking. The results demonstrate that the PIP is a comparative metric of RPST that can be used as input in Artificial Neural Networks (RNA) to categorize the pattern of the electroencephalogram spectrum, presenting an accuracy rate of 98.8% regarding the accuracy of artifacts elapsed along the electroencephalogram. In conclusion, the angular vector PIP use as a solution for identification in time series is applicable and accurate.

Keywords: Electroencephalography, EEG, pattern, MOTIFS, remove, Artificial Intelligence.

LISTA DE FIGURAS

Figura 1: Fluxo de funcionamento do método de leitura (read.tst).	33
Figura 2: Exemplo da aplicação de PIP em ST na identificação de pontos de interesse.	34
Figura 3: Modelo do algoritmo PIP	34
Figura 4: Etapa Visual PIP	35
Figura 5: Fórmula da distância Gaussiana.....	35
Figura 6: Neurônio Artificial	36
Figura 7: Fórmula do Potencial de Ativação.....	36
Figura 8: Sinal de Saída.....	36
Figura 9: Topologia da RNA.....	37
Figura 10: Exemplo não linearmente separável.....	37
Figura 11: Fórmula do Coeficiente Angular	38
Figura 12: Fórmula da função sigmoid	38
Figura 13: Fórmula do número de Euler.x.....	38
Figura 14: Fórmula do Erro Quadrático Médio	39
Figura 15: Arquitetura do <i>software</i>	39
Figura 16: Tela do <i>software</i> NitLab Clear EEG.	40
Figura 17: Desenho do Estudo.....	42
Figura 18: Acurácia de leitura e gravação	44
Figura 19: Teste de Q Pontos	45
Figura 20: Gráfico do comportamento oscilatório total do eletrodo Fp1 original.	47
Figura 21: Gráfico do comportamento oscilatório dos primeiros 5,5 segundos do eletrodo Fp1.	47
Figura 22: Gráfico do comportamento oscilatório total do eletrodo Fp1.	48
Figura 23: Gráfico do comportamento oscilatório dos primeiros 5,5 segundos do eletrodo Fp1 pós processamento.	48
Figura 24: Gráfico do comportamento oscilatório dos primeiros 5,5 segundos do eletrodo Fp1 sem artefato piscada de olho.	49
Figura 25: Comparativo em métodos de limpeza.....	49

LISTA SIGLAS E ABREVIATURAS

AG	Algoritmo Genético
CA	Coeficiente Angular
EEG	Eletroencefalografia
EEGq	Eletroencefalografia quantitativa
IA	Inteligência Artificial
PIP	Perceptually Important Points
PMC	Perceptron Multicamadas
RNA	Rede Neural Artificial
RPST	Reconhecimento de Padrões em Série Temporal

SUMÁRIO

CAPÍTULO I	9
1 INTRODUÇÃO	9
1.1 Justificativa	10
1.2 Objetivos.....	10
1.2.1 Objetivo Geral.....	10
1.2.2 Objetivos Específicos	11
1.3 Hipótese.....	11
CAPÍTULO II	12
2 REFERENCIAL TEÓRICO	12
2.1 Estrutura e Técnica de Análise de sinal Neurobiológico	12
2.2 Padrões de Sinais Biológicos Neurais (motifs)	14
2.3 Artefatos Eletroencefalográficos	16
2.4 Técnicas de Inteligência Artificial na Interpretação de sinal Biológico Neural..	18
2.5 Avanços da Tecnologia da Informação Integrados ao uso da Eletroencefalografia.....	24
CAPÍTULO III	29
3 MATERIAL E MÉTODOS	29
3.1 Critérios de Elegibilidade dos Artigos	29
3.1.1 Critérios de Inclusão.....	29
3.1.2 Critérios de Exclusão	30
3.2 Softwares utilizados no desenvolvimento	30
3.2.1 NetBeans IDE 8.2.....	30
3.2.2 MATLAB R2018a	30
3.3 Tipo de Artefato	31

3.4	Caracterização das Amostras	31
3.5	Leitura e Gravação de Dados	32
3.5.1	Métodos de Leitura.....	32
3.5.2	Métodos de Gravação	33
3.6	Identificação de Pontos de Interesse	33
3.7	Similaridades entre ondas	35
3.8	Inteligência Artificial	35
3.9	Arquitetura do software.....	39
3.10	Visualização das telas do software	40
3.11	Descrição do software	41
3.12	Procedimento experimental	41
3.13	Desenho do estudo.....	42
4	RESULTADOS.....	44
4.1	Leitura e Gravação dos Dados	44
4.2	Resultados de Q pontos	44
4.3	Resultados de Similaridade	45
4.4	Resultados Visuais das etapas de Limpeza do sinal	47
4.5	Tempo para Aplicação.....	50
4.6	Análise estatística.....	50
5	DISCUSSÃO	52
6	CONCLUSÃO E TRABALHOS FUTUROS	55
	Referências Bibliográficas	57

1 INTRODUÇÃO

Os registros elétricos provindos do cérebro por intermédio do eletroencefalógrafo têm sido utilizados na pesquisa científica e em análises clínicas (MARILÚ, *et al.*, 2012). Quando considerada a análise quantitativa do traçado do eletroencefalograma (EEG), essa é caracterizada como eletroencefalografia quantitativa (EEGq), a qual, diferencia-se da forma de análise dos dados com recursos computacionais que os quantificam para posterior análise comparativa (KELMANN *et al.*, 2012). A medida que a tecnologia evolui, novos recursos de *hardware* e *software* são aprimorados, abrindo um leque de possibilidades de aplicações e melhorias na análise do sinal da EEGq, assim permitindo uma avaliação mais objetiva da atividade elétrica cerebral (OTERO *et al.*, 2011). Por exemplo, a utilização do Reconhecimento de Padrão em uma Série Temporal (RPST) pode ser utilizado para análise da repetição estrutural de parte do espectro da EEGq associada a um determinado evento (KELMANN *et al.*, 2012).

Os sinais do eletroencefalograma (EEG) contêm informações de natureza fisiológicas abundantes das atividades cerebrais, assim sua interpretação desempenha um papel substancial na medicina clínica e nas neurociências (WEI *et al.*, 2016). As gravações de EEG são comumente contaminadas por artefatos, representados por potenciais que não se originam do cérebro, mas de várias outras fontes (HARTMANN *et al.*, 2014). A ocorrência de artefatos no EEG dificulta o uso confiável de técnicas de análise automática, assim o pré-processamento por triagem

manual e marcação de artefatos vêm sendo aplicado ao longo dos anos. Porém, trata-se de uma tarefa demorada e passiva de erros humanos, tendo em vista que alguns tipos de artefatos podem se assemelhar à atividade do EEG (VAN *et al.*, 2001). Neste contexto, os comumente utilizados para a remoção de artefatos são denominados de filtragens lineares, os quais assumem que os artefatos e não artefatos são removidos por meio de um filtro de alta frequência (YANG *et al.*, 2018). Estruturado nas lacunas presentes, o estudo tem o objetivo de desenvolver um modelo computacional que identifique padrões em um EEG e remova os seus artefatos.

1.1 Justificativa

O estudo se justifica em relação a importância da identificação de padrões e remoção de artefatos em séries temporais eletroencefalográficas. Desse modo, o estudo poderá fornecer, por meio de uma análise de pós-processamento dos dados computadorizada, a remoção dos artefatos, assim resultando no melhoramento do sinal resultante.

1.2 Objetivos

1.2.1 Objetivo Geral

- Desenvolver um modelo computacional que identifique padrões em um RPST, e remova artefatos.

1.2.2 *Objetivos Específicos*

- Desenvolver métodos de leitura e gravação dos arquivos de compatibilidade com o EEG e MatLab;
- Identificar pontos de interesse do espectro do EEG;
- Realizar correlação Gaussiana entre o espectro modelo e os dados analisados;
- Aplicar algoritmo genético para identificação da estrutura seletora dos Q pontos;
- Aplicar a rede neural artificial nos dados;
- Analisar a funcionalidade do sistema.

1.3 Hipótese

- O uso de técnicas computacionais para identificação e remoção de artefatos da EEGq é eficaz em relação ao modelo manual atualmente aplicado.

- A utilização do *Perceptualli Important Points* como entrada para Redes Neurais Artificiais *Multe Layer Perceptron* causa melhor acurácia dos resultados em identificação de padrão em séries temporais.

2 REFERENCIAL TEÓRICO

2.1 Estrutura e Técnica de Análise de sinal Neurobiológico

O cérebro humano é estruturado em milhões de neurônios que desempenham diversos papéis no controle e comportamento, sendo diretamente relacionado aos estímulos motores e sensoriais (KUMAR *et al.*, 2012). Para que haja a compreensão das funções cognitivas, sensitivas e motoras, uma das ferramentas amplamente utilizadas é a Eletroencefalografia quantitativa (EEGq), pois possibilita a análise da atividade cortical (MIRAGLIA *et al.*, 2018; TAHA *et al.*, 2018). Nesse caso, os sinais têm origem de uma base química complexa, na qual a atividade elétrica da membrana neural é dependente da contribuição metabólica, com controles enzimáticos e ativados por íons na gênese do potencial elétrico da membrana (WILLIAMS *et al.*, 2003). Neste contexto, a EEGq possibilita, de forma não invasiva, analisar os sinais neurobiológicos nos domínios do tempo e da frequência (WATERSTRAAT *et al.*, 2015) por intermédio da aplicação de eletrodos posicionados no couro cabeludo, que são direcionados para um *software* de análise (LIGHT *et al.*, 2010).

Para que a EEG seja aplicável e eficaz, algumas particularidades e processos devem ser compreendidas: a) a amplitude de onda é um fator que envolve diretamente a relação entre a variação de voltagem e o tempo, normalmente a amplitude é considerada baixa, média ou alta, em uma visão geral do traçado; b) A correlação entre a interpretação das variações de amplitude das ondas são: Delta (< 3.5 Hz),

Theta (4~8 Hz), Alpha (8~13 Hz), Beta (13~30 Hz) e Gama (30~100 Hz) (KUMA *et al.*, 2012).

A onda delta é a atividade cerebral mais lenta e relacionada com a indução do hormônio do crescimento e com características mais proeminentes nos estágios três e quatro do sono. A presença de onda delta em adultos acordados é considerada um comportamento anormal (ASSENZA *et al.*, 2012). Entre 4 até 8Hz, encontra-se a banda de frequência teta, a qual é comumente observada em relaxamentos profundos e meditação (JADHAV *et al.*, 2017). Um dos motivos para a observação da onda teta tem sido os efeitos na produção de serotonina, que por sua vez, aumenta o relaxamento e traz a sensação de alívio perante dor (VOLF *et al.*, 2015). A banda alfa é encontrada em todo córtex cerebral, com predominância no hemisfério não dominante nas regiões occipital e parietal. Os ritmos alfa são índices confiáveis de inibição cortical, não apenas durante o sono, mas também em indivíduos adultos acordados que não estão envolvidos em tarefas cognitivas específicas (CANTERO *et al.*, 2002). Alguns fatores como: abrir dos olhos e a influência de luz podem bloquear ou atenuar sua atividade (KUMAR *et al.*, 2012). Já a banda beta está diretamente relacionada ao comportamento e ações, como os sentidos da visão, toque, olfato e paladar e atos motores e está presente nos lobos frontal e parietal (LAL *et al.*, 2001).

Em várias situações e condições, o ritmo beta se relaciona com respostas estimulatórias e cognitivas a ambientes externos e estados mentais quando acordados, que variam pelas diferenças individuais e fatores ambientais e também parece estar envolvida com o aprendizado motor e memória (SCHNEIDER *et al.*, 2016). Diretamente associada à percepção e à consciência, girando em torno de 30~100Hz, a banda gama foi analisada depois do desenvolvimento do EEG digital, já que o analógico era incapaz de mensurar e gravar registros com um ritmo de

frequência maior que 25Hz. Esta onda é comumente encontrada durante a hiperatividade e integração sensoriais (BARRY *et al.*, 2010).

Devido ao grande volume de informação na captura do sinal do EEG, o desenvolvimento de ferramentas que aprimorem a análise dos sinais pode auxiliar em pesquisas e diagnósticos (BARRY *et al.*, 2010). O sinal do EEG é complexo e estocástico, possibilitando a extração de informações da atividade cortical, tanto visual como em arquivos de dados (LEWANDOWSKI *et al.*, 2012). A análise do sinal EEG é basicamente realizada em três etapas ou fases: remoção de artefatos ou pré-processamento e na extração de caracteres e classificação. Na primeira etapa, o sinal é submetido ao pré-processamento que remove os artefatos do traçado; na próxima, a extração de características do sinal já “limpo” e, por último, a classificação do espectro para a análise dos casos (RAMOS-AGUILAR *et al.*, 2017).

2.2 Padrões de Sinais Biológicos Neurais (motifs)

Um dos maiores desafios da neurociência moderna é entender como a cognição emerge do fluxo de informações no cérebro (ROSÁRIO *et al.*, 2015). A conectividade neurofisiológica é geralmente estimada a partir de sinais fisiológicos, como aqueles obtidos a partir do EEG (STAM *et al.*, 2010) ou ressonância magnética funcional (fMRI) (STAM *et al.*, 2007), aplicados em diferentes métodos derivados da teoria das Redes Complexas (REIJNEVELD *et al.*, 2007; FALLANI *et al.*, 2010).

Neste contexto, pesquisas forneceram parâmetros quantitativos usando Informações mútuas (MEUNIER *et al.*, 2009), correlações de Pearson (DE HAAN *et al.*, 2009), Causalidade de Granger e coerência espectral (BULLMORE *et al.*, 2009) para analisar a direção preferida do fluxo de informações entre dois nós adjacentes

de redes cerebrais durante a informação, processamento ou repouso. O processo de aquisição do sinal neurobiológico apresenta como resultado espectro bidimensional em função do tempo (RICHHARIYA *et al.*, 2018).

Diversas características são necessárias para a identificação da singularidade do sinal, tais como: amplitude (oscilação em relação ao eixo horizontal do espectro), comprimento de onda (distância de picos ou vales) e o número médio de oscilações por determinado tempo, denominado frequência (ANGHINAH *et al.*, 2005). Essas peculiaridades, quando analisadas separadamente e/ou em conjunto, podem demonstrar a característica da atividade cortical (SCHNEIDER *et al.*, 2009). A persistência periódica desses fenômenos leva à manifestação de um determinado padrão espectral. Este, por sua vez, pode ser associado ao comportamento neurobiológico, haja vista que a não presença periódica na onda mostra a ausência de um padrão consistente (GARIPPELLI *et al.*, 2007).

Apesar dos enormes avanços no poder de computação e da disponibilidade de gravações digitais, o padrão ouro para a interpretação ainda é a análise visual. Neste caso, a grande variabilidade nos padrões de EEG, tanto em condições fisiológicas quanto em doenças, limita os esforços para automatizar o processo de identificação de padrões (LODDER *et al.*, 2013). O EEG é dividido em bandas de frequência, cada uma das quais reflete um grau diferente de atividade cerebral, sendo assim, bandas tipicamente diferenciadas podem revelar indícios de determinado comportamento neural padronizado (LEE *et al.*, 2014). Basicamente, quando a análise é realizada e um padrão é identificado, diversas possibilidades de aplicações em estudos podem ser executadas, desde a formalização matemática do espectro ondulatório, até a construção de uma base de conhecimento computadorizada (LAWHERN *et al.*, 2012).

Quando há qualquer tipo de manifestação em uma onda temporal ligada exclusivamente a determinados eventos característicos, há a presença de fenômenos denominados *motifs*, que podem ser ocasionados por meios internos ou externos e devem ser analisados e separados em grupos para um possível auxílio diagnóstico ou aplicação em tarefas (SCHNEIDER *et al.*, 2012). Quando direcionados para a neurociência, a detecção e classificação automática de registros eletroencefalográficos padronizados (*motifs*) são utilizados campos de pesquisa voltados ao desenvolvimento de interfaces cérebro máquina (GOEL *et al.*, 1996).

Diversos algoritmos para a classificação de *motifs* em EEG foram propostos, porém, em sua grande maioria, eles são considerados limitados devido a serem capazes de classificar somente uma característica do traçado e quando combinados dão outra representatividade (RADÜNTZ *et al.*, 2016). No entanto, diferentes métodos vêm sendo propostos para uma real classificação de padrões oriundos do EEG, em via geral, são algoritmos de reconhecimento de padrões com origem de uma combinação de diferentes técnicas de aprendizado de máquina, como Redes Neurais Artificiais (RNA), Algoritmo Genético (AG), Lógica Fuzzy (LF) entre outros (KALKE *et al.*, 2018). Em geral, os algoritmos utilizam de técnicas de pré-processamento para um tratamento, a qual pode omitir algumas características do sinal a ser analisado (ALFARO *et al.*, 2016).

2. 3 Artefatos Eletroencefalográficos

O eletroencefalograma é um sinal biológico que reflete mudanças elétricas em redes de neurônios corticais e subcorticais, sendo uma ferramenta utilizada em

diversas aplicações médicas emergentes (ARUNKUMAR *et al.*, 2013). Sendo assim, diversos estudos visam colaborar com o aprimoramento da técnica. Uma das sub-áreas de estudos tem como objetivo auxiliar na aplicação e detecção automatizada de artefatos, amplamente aceita como útil para auxiliar aos profissionais na aquisição correta de dados do traçado (O'REGAN *et al.*, 2013).

Os artefatos podem ter origem de várias fontes de campos elétricos causando interferência na faixa de frequência o EEG. Originalmente as fontes incluem ruído elétrico a uma frequência de 50 ou 60 Hz, dependendo da região geográfica. Campos elétricos em eletricidade externa de dispositivos eletrônicos, como telefones celulares ou dispositivos implantados, como marca-passos (HARTMANN *et al.*, 2014). A aquisição do sinal do EEG pode ser interpretada como manifestações elétricas, sendo analógicas, na qual a discretização é realizada com o fim de conversão para um sinal digital, e sua gravação (HOFFMANN *et al.*, 2008). Devido ao sinal do EEG ter como fonte a atividade do córtex cerebral, toda e qualquer manifestação de potenciais elétricos de outra origem são denominados como artefatos (HOLROYD *et al.*, 2012). Em geral, o traçado do EEG apresenta artefatos relacionados com a piscada e movimento dos olhos, ranger dos dentes, articulação têmpora mandibular, dentre outros, assim os artefatos são bem característicos no sinal do EEG e as técnicas de análise do sinal do EEG permite identificá-las (HOFFMANN *et al.*, 2008).

Os artefatos são comumente encontrados na inicialização do EEG, sendo uns dos principais gargalos quanto a interpretação do EEG e distinção do sinal cerebral. As atividades de baixa amplitude e alta frequência são mais notáveis ao decorrer do espectro, oriundas dos músculos do couro cabeludo, outros potenciais tais como a de alta voltagem é comumente encontrada nas regiões frontais devido a piscada dos olhos (CHANG *et al.*, 2009). A análise do sinal do EEG pode ser seriamente

descaracterizada quando artefatos de uma ou múltiplas origens estão presentes, resultando em diagnósticos errado (VIOLA *et al.*, 2009). Neste contexto, os artefatos devem ser removidos. Em muito casos, a tentativa de uma possível diminuição da influência dos artefatos no EEG é realizada com paradigmas experimentais realizados por pesquisadores (GERLA *et al.*, 2017). No momento da coleta, a tentativa de limitar a influência de efeitos externos e internos no experimento é dada por uma sequência de instruções ao indivíduo submetido a pesquisa, como: não realizar movimentos bruscos, evitar contrações musculares exarcebadas ou qualquer reação motora desnecessária que não esteja durante a coleta, pois todos esses fatores podem distanciar das atividades de interesse registradas no EEG (LAWHERN *et al.*, 2012). Quando profissionais analisam artefatos da EEG, é primeiramente observado o espectro que se diferencie notoriamente do traçado, porém por se tratar de uma técnica visual e passiva de muitos erros, é demorada e subjetiva (SKUPCH *et al.*, 2013).

A análise imprecisa do sinal da EEG pode levar diversos problemas no pós-processamento e em análises posteriores de mapas topográficos, neste contexto, a análise “refinada” dos artefatos é imprescindível para a interpretação da atividade cortical (HOFFMANN *et al.*, 2008). Uma vez que os artefatos foram removidos, os sinais cerebrais se tornam aptos para extração, pois tendem a menor erro em relação ao sinal de origem coletado (QUAZI *et al.*, 2017).

2.4 Técnicas de Inteligência Artificial na Interpretação de sinal Biológico Neural

Com o avanço da tecnologia, *hardwares* mais robustos foram desenvolvidos, possibilitando que *softwares* com maior grau de complexidade fossem criados

(WOLPAW *et al.*, 2002). Um exemplo, enquadra-se em algoritmos de maior robustez nas técnicas de Inteligências Artificiais (IA), tendo amplo espaço para aplicação em diversas áreas e com características computacionais de real aplicabilidade da computação moderna (KAPPOR *et al.*, 2012). Em 1956, no encontro de Dartmouth, foi proposto pela primeira vez, o termo “Inteligência Artificial”, mas só nas duas últimas décadas, as técnicas foram lapidadas e utilizadas em aplicações reais (HASSABIS *et al.*, 2017). Considerando que *softwares* comuns se utilizam de algoritmos que tratam apenas a manipulação de dados, os que se utilizam de (IA), podem construir suas próprias origens de conhecimentos, com base em acontecimentos, rotinas e eventos para a aquisição, representação e manipulação de conhecimento, sendo assim, a manipulação de dados pode ser interpretada como a capacidade de deduzir ou inferir novos conhecimentos, criar relações entre fatos e conceitos presentes ou decorridos (DONGRUI *et al.*, 2010).

Para melhor estratégia de controle no desenvolvimento de aplicações isoladas ou até mesmo de sistemas mais complexos e robustos, que necessitam de maior atenção, é definida a obtenção de regras e fatos que satisfaçam determinada problemática por meio de sua codificação. A primeira aplicação desenvolvida que de fato utilizou (IA) com base em um sistema especialista em conhecimento foi desenvolvida em 1967 (PAN *et al.*, 2016). Este sistema foi capaz de prever as estruturas de compostos químicos desconhecidos, sempre com base em diversas análises de rotinas anteriores (LUGER *et al.*, 2014). Durante a década de 1970, a introdução da tecnologia do microcomputador na medicina e na biologia revolucionou as abordagens em processamento de sinais. Novos métodos de análise de sinais e dados, bem como o aumento da capacidade de computação, fornecem ferramentas de (IA) aprimoradas para registro e análise das informações (BALDWIN *et al.*, 2012).

entre as novas ferramentas de computação, as Redes Neurais Artificiais (RNAs) têm sido empregadas com sucesso para processar sinais de EEG, a fim de estudar mecanismos cerebrais usando múltiplas abordagens (SINHA *et al.*, 2007). Redes neurais artificiais (RNAs) são ferramentas computacionais que utilizam uma combinação de várias unidades elementares de processamento (célula). Cada unidade é conectada a um número de unidades de rede para processar informações por função de transferência. A relação entre a entrada e a saída determina o comportamento da rede. Ao contrário dos métodos convencionais de computação, as RNAs são "treinadas" para produzir a relação de entrada-saída desejada (STOFFEL *et al.*, 2018).

Durante a fase de treinamento (aprendizado), exemplos de dados são apresentados à rede e, usando um algoritmo de aprendizado, os parâmetros são ajustados para o comportamento da rede. "A rede neural é treinada usando um banco de dados adequado de casos de "exemplo". Um "exemplo" é fornecido por um paciente cujos valores para os recursos selecionados foram coletados e avaliados. A qualidade do treinamento e a generalização resultante e, portanto, a capacidade de previsão da rede dependem fortemente do banco de dados usado para o treinamento, assim deve conter um número suficiente de "exemplos" confiáveis (para os quais o diagnóstico é conhecido) para permitir que a rede aprenda extraindo a estrutura oculta no conjunto de dados e usar esse "conhecimento" para "generalizar" a regra para novos casos (JAFARIAN *et al.*, 2018). Os dados de treinamento devem ser pré-processados antes da avaliação pela rede neural. Além disso, foi demonstrado que casos para os quais alguns dados estão faltando devem ser removidos do banco de dados para melhorar o desempenho de classificação da rede (GANNOUS E ELHADDAD, 2011).

Uma diminuição no desempenho de classificação da rede é observada para bancos de dados desequilibrados (MAZUROWSKI *et al.* 2008). Uma vez que, os recursos estejam adequados, banco de dados, método de pré-processamento de dados, algoritmo de treinamento e arquitetura de rede tenham sido identificados, os dados referentes a “novos” pacientes que não estão incluídos no banco de dados de treinamento podem ser avaliados pela rede treinada, sendo assim, a pergunta feita é se os novos dados pertencem à mesma população que os da base de dados (homocedasticidade) (STAUB *et al.*, 2015).

A falha na etapa descrita anteriormente pode levar a rede a classificar erroneamente os novos dados. Esse problema pode ser resolvido pelo uso de um parâmetro adicional que indica a população à qual uma determinada amostra pertence (STOFFEL *et al.*, 2018). De acordo com o conhecimento disponível do problema e o objetivo do operador, o procedimento de aprendizagem empregado pode ser "supervisionado", "não supervisionado" ou ambos. O procedimento de aprendizado supervisionado é executado com pares de padrões de entrada-saída conhecidos, enquanto o aprendizado não supervisionado consiste em apresentar exemplos de treinamento para a entrada de rede e a rede se organiza progressivamente para alcançar uma separação máxima entre as classes de exemplos que ocorrem naturalmente (LUGER *et al.*, 2014)

Com a disponibilidade de sistemas computacionais de ponta, as redes neurais artificiais (RNA) encontraram aplicação em muitas áreas do processamento de sinais, gerando um grande interesse e a aplicação de técnicas automatizadas principalmente para o estudo do fenômeno epiléptico no EEG para fornecer informações clínicas para o diagnóstico, monitoramento e controle de distúrbios neurológicos relacionados (SHARANREDDY *et al.*, 2013). As unidades de

monitoramento da epilepsia geram grandes quantidades de dados normais, misturados com descargas epileptiformes (DEs) e convulsões relativamente raras. Tem havido uma série de abordagens para automatizar a detecção de EDs e / ou convulsões.

Dois sistemas baseados em regras ou "especialistas", desenvolvidos por Davey *et al.* (1989) e Glover *et al.* (1989), usaram métodos específicos de organizar e aplicar o conhecimento para testar eficientemente os candidatos a EDs por uma série de questionamentos "se. . . então . . .". Esses sistemas produzem sensibilidades e especificidades comparáveis à análise visual especializada. No entanto, devido a seus ambientes de programação e demandas de processamento, eles não são eficientes o suficiente para serem executados em computadores pessoais baratos e prontamente disponíveis (WEBBER *et al.*, 1993; XIE *et al.* 2001; ROSADO *et al.* 2016). Este foi o primeiro método automatizado de detecção de ED a se tornar comercialmente disponível. Ele foi revisado e ampliado para diminuir a porcentagem de falsos positivos detectados, os quais podem prejudicar seu desempenho em ambientes de monitoramento intenso (GOTMAN *et al.*, 1985; GOTMAN *et al.*, 1991).

A difícil comparação no desempenho de vários métodos de RNA ocorre devido ao não treinamento comum, não há casos de testes claros e nenhum método de avaliação do desempenho. Portanto, há diferenças entre as várias abordagens de detecção de ED, que incluem condições clínicas, métodos de aquisição de dados, número de sujeitos, número de canais de dados de entrada e a eficiência computacional da RNA para implementação em tempo real (GURESEN *et al.*, 2011). No entanto, a diferença mais importante entre os métodos está em como os dados do EEG são preparados para apresentação à RNA para treinamento e testes (BELL *et al.*, 2012). O método de pré-processamento influencia os recursos de uma abordagem

específica. Um procedimento ideal deve exigir um pré-processamento mínimo e ser aplicável a dados brutos (SARMA *et al.*, 2016).

A detecção e rejeição de artefatos no EEG no entanto, é uma tarefa difícil para a qual poucos sistemas de redes neurais foram desenvolvidos. O principal resultado é a precisão heterogênea dos sistemas desenvolvidos (ROBERT *et al.*, 2002). O tratamento de artefatos de EEG provavelmente se tornará um problema primordial com o aumento da automação do processamento de sinais. A necessidade de compressão do EEG é justificada pela necessidade de medidas de alta precisão, medições de longo prazo, transmissão de dados em telemedicina ou a falta de equipamentos especiais para armazenar arquivos de dados volumosos, no entanto, a complexidade das formas de onda do EEG é a razão para algumas tentativas de compressão do mesmo (ZHANG *et al.*, 2012). Estudos preliminares envolvendo redes neurais foram realizados (BARGIOTTI *et al.*, 1993; Battiti *et al.*, 1995; CÁRDENAS-BARRERA *et al.*, 2004; ANDRAUS *et al.*, 2012; BIRVINSKAS *et al.*, 2013).

Quando altas taxas de compressão (de 50 a 80%) foram obtidas, Battiti *et al.* (1995), investigações adicionais foram necessárias para confirmar a plausibilidade da compressão da rede neural do EEG. Um método útil para entender a dinâmica cerebral e o diagnóstico clínico de anormalidades cerebrais é a localização de origem do sinal com base na EEG, a qual envolve a localização de fontes intracranianas por meio de técnicas de otimização, como métodos iterativos (MICHELMANN *et al.* 2018). Uma vez que uma rede neural é treinada, ela não requer mais iterações e é capaz de capturar dinâmicas não lineares do problema de localização de origem, enquanto mantém a robustez do ruído essencial para a análise de EEG (ROBERT *et al.* 2002). A posição de erro na localização da fonte tem sido observada como inferior a 5% para todas as investigações (ABEYRATNE *et al.*, 1991; ABEYRATNE *et al.*,

2001; YUASA *et al.*, 1998; ZHANG *et al.*, 1998; VAN HOEY *et al.*, 2000; SUN e SCLABASSI, 2000; TUN *et al.*, 2000).

Embora os métodos interativos em algum momento, forneçam melhores resultados do que as redes neurais na situação livre de ruído, os métodos de rede neural apresentam melhor desempenho a baixas relações sinal/ruído mais realistas (TUN *et al.*, 2000). Resultados positivos obtidos na maioria das aplicações desenvolvidas mostram relevância para o processamento de eletroencefalograma, dentre elas algumas não estão mais em uso, outras são estudos pilotos ou preliminares com resultados promissores, outros são incluídos em projetos clínicos nos quais as redes neurais são um componente essencial (PATEL *et al.* 2012).

2.5 Avanços da Tecnologia da Informação Integrados ao uso da Eletroencefalografia

Na área da saúde, pode-se observar campos ainda em exploração, quando o assunto é *crossover* com a computação. Perante as diversas lacunas e possibilidades de aplicações, temos a *Brain Computer Interface* (BCI), que consiste em um sistema computacional que adquire, analisa e traduz sinais cerebrais em comandos de saída em tempo real (GÖKSU *et al.*, 2012). O termo BCI pode ser atribuído a Jacques Vidalwho, que na década de 1970 criou o sistema BCI com potenciais evocados visuais (VIDAL *et al.*, 1973). Desde então, os avanços na tecnologia de computadores, aprendizado de máquina e neurociência permitiram o desenvolvimento de uma ampla variedade de sistemas BCI (WOLPAW *et al.*, 2012).

A maioria dos estudos em BCIs têm se concentrado em usá-los para restaurar a comunicação e o controle de pessoas paralisadas por distúrbios neuromusculares crônicos, como a amiotrofia, esclerose lateral (ELA), acidente vascular cerebral (AVC)

ou lesão medular de alto nível (MCCANE *et al.*, 2015). BCIs podem usar métodos não invasivos ou invasivos. Embora BCIs de métodos invasivos tenham maior resolução espacial e possam fornecer sinais de controle com muitos graus de liberdade, as BCIs que dependem de eletrodos no córtex enfrentam problemas substanciais para obter e manter registros estáveis de longo prazo. Os pequenos locais de gravação de alta impedância tornam os eletrodos penetrantes suscetíveis à degradação do sinal devido ao encapsulamento (SHAIN *et al.*, 2003). Além disso, pequenos deslocamentos dos minúsculos eletrodos de penetração podem afastar os locais de registro das camadas corticais que contêm os grandes neurônios facilmente gravados, como neurônios piramidais na camada 5 do córtex motor (GÖKSU *et al.*, 2012).

As BCIs de métodos não invasivos usam a atividade da EEG e são seguros e baratos, mas possuem resolução espacial relativamente baixa (FREEMAN *et al.*, 2003) e são suscetíveis a artefatos que geralmente, requerem treinamento extensivo do usuário (ZHANG *et al.*, 2015). Embora haja avanços nas tecnologias de análise cortical não invasivas, há um potencial significativo na alavancagem das tecnologias, como por exemplo em próteses neurais cognitivas (SONG *et al.*, 2007). Os métodos não invasivos ainda são abordagens mais práticas e aceitáveis pelo usuário para melhorar as interações entre humanos e sistemas por meio das BCIs (CINCOTTI *et al.*, 2004). Neste caso, o sistema BCI com base na EEG compreende quatro subsistemas modulares; o primeiro adquire os sinais do EEG e reduz os ruídos e processa os artefatos encontrados; o segundo processa os sinais para derivar as frequências do sinal e traduzindo-os em comandos de saída para o controle de um aplicativo; o terceiro é o próprio aplicativo; e o quarto é o protocolo que especifica a operação geral do sistema (por exemplo, quando ocorrem estímulos) (SCHALK *et al.*, 2004).

Um dos conceitos fundamentais que influenciarão as futuras BCIs é o uso de índices cerebrais que fornecem informações que não são prontamente ou robustamente disponíveis através de outros canais, assim uma fonte potencial para essa informação são os processos cerebrais associados à percepção humana de "erros", que podem ser sinais de erro específicos produzidos pelo cérebro, como a negatividade relacionada ao erro, ou combinações de sinais associados a erros, como frustração, raiva, atenção, envolvimento ou compreensão (HORLOYD *et al.*, 2012). Tais percepções sobre o processamento cerebral poderiam ser mescladas com os avanços esperados em computação e inteligência artificial para ir além da mera transmissão de informação entre o homem e a máquina, e para a análise, interpretação e previsão de situações mutuamente derivadas. Ou seja, o sistema combinado humano-computador pode ser capaz de detectar e integrar informações sobre as capacidades, estados, metas e ações passadas e presentes dos operadores e dos computadores, além da tarefa global e das restrições ambientais assim, a obtenção das informações acima descrita, pode levar a compreensão das funções e do comportamento do cérebro humano, possibilitando previsões sobre os resultados de desempenho e, por fim, levando a mudanças revolucionárias nas formas fundamentais pelas quais humanos e computadores interagem (XING-YU *et al.*, 2013).

Além disso, como o Sistema Nervoso Central, processa e armazena informações de maneiras muito diferentes dos sistemas atuais de computador com os quais interagem, a interpretação da atividade cortical pode afetar concepções de quando e onde no projeto geral do sistema a interação humano-computador deve ocorrer (TIWARI *et al.*, 2018). Embora haja um potencial para o desenvolvimento de futuras aplicações das BCIs que esperam ser desbloqueadas nas centenas de índices

de comportamento neural identificados pela comunidade de pesquisa em neurociência (MORAN *et al.*, 2010), as BCIs atuais e de curto prazo provavelmente continuarão orientadas para tarefas o que inclui: 1) BCIs que são a interface primária para a tarefa que o usuário está explicitamente executando, como o uso de sinais cerebrais para controlar o movimento de uma prótese e 2) BCIs que suportam diretamente a tarefa que o usuário está executando, mas não são a interface principal, como um sistema que monitora os sinais cerebrais do usuário para prever o desempenho durante a condução e mitigar períodos de desempenho ruim previsto .

Os desenvolvedores têm tido sucesso com BCIs orientados a tarefas, onde o próprio aplicativo controla as condições sob as quais o usuário executa, em vez de tentar encontrar índices cerebrais que generalizem qualquer tarefa que um usuário esteja realizando, assim BCIs orientadas a tarefas terão acesso a mais contexto para o que o usuário está fazendo e, portanto, maior capacidade para interpretar os sinais neurais recebidos (SUNNY *et al.*, 2016). Futuras BCIs orientadas a tarefas, baseadas em avanços nas tecnologias de sensores, algoritmos de análise, inteligência artificial, sensoriamento multiespectivo do cérebro, comportamento e ambiente por meio de tecnologias difundidas e algoritmos de computação serão capazes de coletar e analisar dados cerebrais por longos períodos (RAMADAN *et al.*, 2017).

Quando as tecnologias de sensoriamento cerebral são utilizadas durante a vida diária, surge a possibilidade de usar a infraestrutura da BCI para aplicações oportunistas (TIWARI *et al.*, 2018). Ou seja, uma vez que os usuários usem regularmente sensores cerebrais para fins específicos, as BCIs oportunistas (tecnologias BCI que oferecem ao usuário um benefício, mas não suportam diretamente a tarefa que o usuário está executando), podem ser empregadas sem sobrecarga adicional, exemplos de BCIs oportunistas são os aplicativos de

computação abrangentes que ajustam o ambiente local do usuário (como a cor da iluminação, música ou talvez até mesmo odor, ou sugestões para opções de dieta, exercício, entretenimento ou tratamento) alteram ou melhoram o humor ou estado mental do usuário (GARIPELLI *et al.*, 2008). Além disso, as aplicações médicas que periodicamente selecionam o usuário para indicadores de doenças neurais e buscam uma variedade de atenuações, as quais podem incluir: geração de tarefas para análise e triagem adicionais (movendo a BCI para o domínio orientado a tarefas (BOCKBRADER *et al.*, 2018). No entanto, devido à falta de restrições sob o funcionamento dos aplicativos, o desenvolvimento da BCI avançará por meio da coleta e análise de dados em grande escala por longos períodos, bem como o desenvolvimento de técnicas para personalização do utilizador (LOPEZ *et al.*, 2018). Embora esses problemas limitem o desenvolvimento em curto prazo, no longo prazo, as BCIs oportunistas podem ter ramificações que salvam vidas, além de muitos outros benefícios potenciais para aplicações médicas, educacionais, de trabalho e sociais (ABDULKADER *et al.*, 2015).

O avanço de pesquisas neurocientíficas e neurotecnológicas oferece a oportunidade de fornecer recursos preditivos de computadores para os estados e processos emocionais e cognitivos das pessoas que os usam, potencialmente revolucionando não apenas as interfaces, mas também as interações básicas que as pessoas têm com esses sistemas (KERICK *et al.*, 2011; WU *et al.*, 2010).

3 MATERIAL E MÉTODOS

No primeiro momento foi realizada uma análise nas bases de dados *Science Direct* e *Scopus*, para realização da fundamentação teórica. Para esta proposição foi utilizado como estratégia de busca as seguintes expressões (“*Electroencephalography*” OR “EEG”) AND (“*pattern*” OR “*motifs*”) AND (“*remove*”) AND (“*artificial intelligence*” OR “*IA*”). Os trabalhos retornados da busca foram analisados por título e resumo, dos quais só foram inclusos para análise final os que atendam aos devidos critérios de inclusão.

3.1 Critérios de Elegibilidade dos Artigos

3.1.1 Critérios de Inclusão

- Trabalhos que abordassem técnicas de pré e pós-processamento, com reconhecimento de padrões (motifs) e/ou remoção de artefatos eletroencefalográficos;
- Trabalhos escritos em inglês;
- Soluções computacionais fossem foco dos materiais e métodos;
- A utilização de algoritmos não proprietários e editáveis como principal método de solução;
- Utilizar alguma técnica de aprendizado de máquina.

3.1.2 Critérios de Exclusão

- Trabalhos que não abordassem técnicas de pré e pós-processamento de motifs e/ou remoção de artefatos eletroencefalográficos;
- Trabalhos não escritos em inglês;
- Soluções computacionais não fossem foco dos materiais e métodos;
- A utilização de algoritmos proprietários e não editáveis como principal método de solução;
- Trabalhos que não utilizem técnica de aprendizado de máquina.

3.2 Softwares utilizados no desenvolvimento

Para a implementação dos algoritmos foram utilizados os seguintes *softwares*:

3.2.1 NetBeans IDE 8.2

Na sua versão 8.2, o NetBeans IDE fornece analisadores de código e editores prontos para trabalhar com as tecnologias Java 8 mais recentes -- Java SE 8, Java SE *Embedded* 8 e Java ME *Embedded* 8. O IDE também possui uma faixa de aprimoramentos que melhoram ainda mais seu suporte para Maven e Java EE com o PrimeFaces; ferramentas para HTML5, em particular para AngularJS; e aprimoramentos para o suporte a PHP e C / C++. O IDE é executado em muitas plataformas, como *Windows*, *Linux*, *Solaris* e *MacOS*.

3.2.2 MATLAB R2018a

MATLAB (*MATrix LABoratory*) trata-se de um *software* interativo de alta performance voltado para o cálculo numérico. Capaz de integrar análise numérica, cálculo com matrizes, processamento de sinais e construção de gráficos em ambiente fácil de usar, onde problemas e soluções são expressos somente como eles são descritos matematicamente, ao contrário da programação tradicional. O MATLAB é um sistema interativo cujo elemento básico de informação é uma matriz que não requer dimensionamento. Esse sistema permite a resolução de muitos problemas numéricos em apenas uma fração do tempo que se gastaria para escrever um programa semelhante em linguagem Fortran, Basic ou C. Além disso, as soluções dos problemas são expressas quase exatamente como elas são escritas matematicamente.

3.3 Tipo de Artefato

Para a realização do treinamento da rede neural artificial foi necessário a utilização de bases de exemplos amostrais para a convergência ao aprendizado, seguindo esse princípio o tipo de artefato eletroencefalográfico piscada de olho foi escolhido como gatilho classificador da rede. O artefato piscada de olho foi selecionado para o treinamento, pois trata-se de uma sinal de fácil replicação em coleta e de amplitude destacável, e estando comumente diversas vezes presente em um eletroencefalograma.

3.4 Caracterização das Amostras

Na caracterização das amostras foram adotados critérios de elegibilidade nos dois grupos de eletroencefalogramas, dos quais destinados a fase de treinamento da RNA para a identificação do padrão piscada de olho. Dos dois grupos escolhidos o

primeiro é oriundo da base de dados Keras EEG, aonde foram obtidas 500 eletroencefalogramas não simulados, e 30 eletroencefalogramas por meio de coletas eletroencefalográficas no Laboratório de Neuroinovação Tecnológica & Mapeamento Cerebral (NitLab) na Universidade Federal do Piauí – Campus Ministro Reis Velloso, dos quais 10 foram aplicados a base de reforço e 20 a camada de aplicação. Os indivíduos componentes de toda a base de dados seguiam os seguintes critérios:

- a) Destro
- b) Não uso de fármacos neuromoduladores
- c) Faixa etária 21~30 anos
- d) Não consumo de cafeína nas últimas 42 horas

3.5 Leitura e Gravação de Dados

Foram utilizadas 150 bases de dados de sinais com artefatos de origem do sinal da EEG, no formato de saída binarizado (.tst), disponíveis no Laboratório de Neuroinovação Tecnológica & Mapeamento Cerebral (NitLab) na Universidade Federal do Piauí – Campus Ministro Reis Velloso. Para a criação da biblioteca NitLab-EEG Clear os métodos de Leitura e gravação foram implementados em linguagem de programação JAVA.

3.5.1 Métodos de Leitura

O método de leitura (read.tst) teve como principal característica a extração dos seguintes parâmetros contidos no arquivo de origem (.tst): Tipo do arquivo, versão do arquivo, frequência, número de canais, coeficientes angulares, coeficientes lineares, nome dos canais e corpo do arquivo.

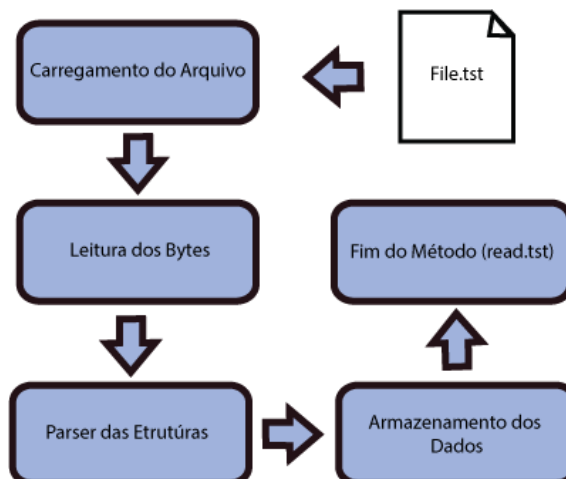


Figura 1: Fluxo de funcionamento do método de leitura (read.tst).

3.5.2 Métodos de Gravação

O método de gravação write.tst que corresponde a um método integrante da biblioteca TST_file, teve como característica a escrita binarizada dos dados respeitando a estrutura do formato original do arquivo (.tst).

3.6 Identificação de Pontos de Interesse

Para a busca de padrões em RPST foi utilizada a identificação de pontos de interesses ou relevantes que de fato caracterizassem o espectro em sua singularidade. Esses pontos foram considerados como pontos críticos, em RPST. Trata-se de vales e picos que tornam possível a identificação de um comportamento padronizado. Para a identificação de pontos característicos, foi utilizada a regra de *perceptually important points* (PIP), utilizada para a identificação de padrões em dados de séries temporais, assim resultando no vetor de pontos achados (figura 1).




Figura 2: Exemplo da aplicação de PIP em ST na identificação de pontos de interesse.

A identificação dos pontos consistiu em encontrar o ponto mais distante adjacente entre dois pontos, partindo de P_0 e P_n , onde P_0 é o primeiro ponto do espectro analisado e P_n o último, seguindo para que P_3 resultante. Foi calculado o ponto mais distante adjacente em relação ao ponto mais afastado do mesmo, assim gerando um P_4 , o algoritmo é satisfeito até Q (número de pontos) ser satisfeito. A demonstração simplificada em português mostra a sequência lógica a ser seguida para a identificação de Q pontos de interesse em relação a P (Figura 2).

```

LocalizarPIPs(P[n], Q)
  Tamanho = Q
  Saída = sp[0..Q]

Início
  sp[0] = p[0]
  sp[1] = p[n]

  Repetir
    Escolhe o p[i] com distância maior entre os pa[j] e pa[j], adjacnetes
    Adiciona p[j] a sp
    seleciona os pontos adjacentes de maior distância
  Até (sp[0..n] seja = Q)

FIM

```

Figura 3: Modelo do algoritmo PIP

Sequência ilustrativa dos passos realizados pelo algoritmo PIP mostrando o processo de identificação dos pontos de interesse (figura 3).




Figura 4: Etapa Visual PIP

3.7 Similaridades entre ondas

Realizada a identificação da estrutura de PIP de uma ST de origem, foi comparado o grau de similaridade entre as estruturas PIP de origem e candidata, por meio da análise da média acumulativa da distância gaussiana dos vértices e segmentos de ambos os espectros, demonstrado na (figura 4).

$$d(p, q)^2 = (q_1 - p_1)^2 + (q_2 - p_2)^2$$

Figura 5: Fórmula da distância Gaussiana.

3.8 Inteligência Artificial

Com o objetivo da classificação da série temporal, foi implementada uma Rede Neural Artificial (RNA) *Multi Layer Perceptron* (PMC), estrutura essa que é baseada no modelo do Neurônio Artificial (Figura 6), composto em sua grande maioria por sete (07) elementos básicos de funcionamento estrutural, sendo eles: 1) Sinais de Entrada $\{x_1, x_2, \dots, x_n\}$, assim, caracterizadas como sinais ou medidas advindas do meio externo ao neurônio. 2) Pesos Sinápticos $\{w_1, w_2, \dots, w_n\}$, valores de ponderação

diretamente ligados ao seu sinal de entrada respectivo, durante o processo de aprendizagem é o $W[n]$ que caracteriza o neurônio da rede. 3) Combinador Linear $\{\Sigma\}$, responsável por realizar o somatório dos processos sinápticos realizados, a fim de produzir o valor do potencial de ativação. 4) Limiar de Ativação $\{\theta\}$, trata-se de um elemento que serve para aumentar o grau de liberdade dos ajustes dos pesos. 5) Potencial de Ativação $\{u\}$ é o valor resultante do somatório do Combinador Linear $\{\Sigma\}$ e o Limiar de Ativação $\{\theta\}$ (figura 7). 6) Função de Ativação $\{g\}$, tem o objetivo de limitar a saída do neurônio dentro de determinado intervalo de valores, assim os normalizando. 7) Sinal de Saída $\{y\}$, é o resultado final produzido pelo neurônio artificial (figura 8).




Figura 6: Neurônio Artificial

$$u = \sum_{i=1}^n w_i \cdot x_i - \theta$$

Figura 7: Fórmula do Potencial de Ativação

$$y = g(u)$$

Figura 8: Sinal de Saída

Para a construção da RNA multicamadas, foram escolhidas as seguintes características utilizando o modelo do neurônio artificial:

- a) Topologia da Rede: Constituída por neurônios *Perceptron*, sua estrutura topológica foi definida como (8-2-1), sendo implementada com 8 (oito) entradas na camada de entrada, 2 (dois) neurônios na camada escondida, e 1 (um) neurônio na camada de saída, respectivamente (Figura 9).

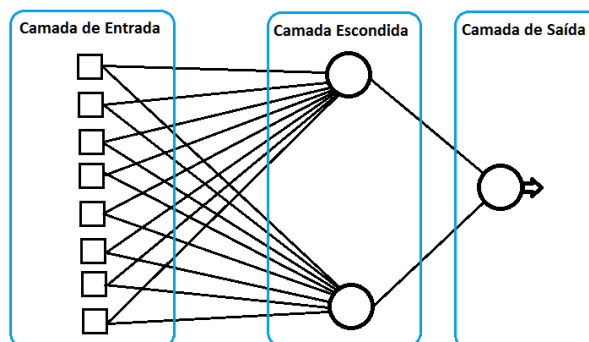


Figura 9: Topologia da RNA

- b) Tipo de Aprendizado: A estratégia de treinamento adotada foi do tipo supervisionado, onde a partir de cada amostra dos Sinais de Entrada $\{x_1, x_2, \dots, x_n\}$, são associados a um Sinal de Saída $\{y\}$.
- c) Tipo de Classificação: O caráter classificador adotado foi a configuração não linearmente separável (Figura 10), onde uma única reta é incapaz de separar as classes do problema.

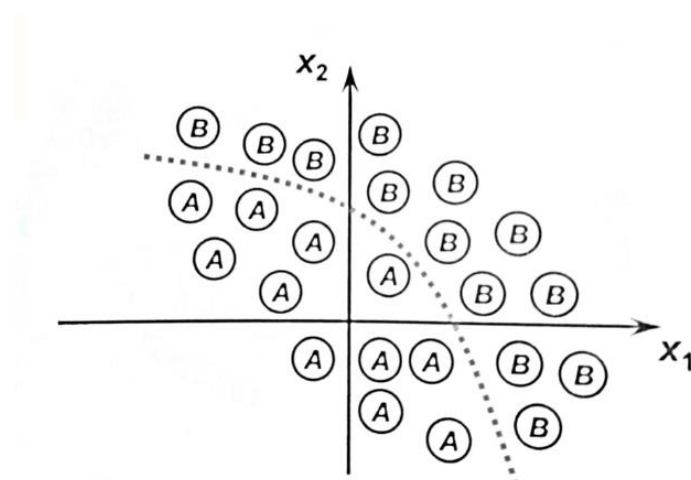


Figura 10: Exemplo não linearmente separável.

- d) Camada de Entrada: É definida pelos coeficientes angulares $x[m]$ do vetor resultante PIP, (Figura 10).

$$m = \operatorname{tg}\alpha = \Delta y / \Delta x$$

Figura 11: Fórmula do Coeficiente Angular

- e) Pesos Sinápticos: O conjunto dos Pesos Sinápticos $\{w_1, w_2, \dots, w_n\}$, no modelo implementado, foram inicialmente atribuídos ao seus valores, variáveis aleatórias respeitando o seguinte intervalo: $]0, 1] = \{x \in \mathbf{R}: 0 < w \leq 1\}$.
- f) Função de Ativação: A função de ativação aplicada foi a *sigmoid* (Figura 11), onde seus valores de saída são representados pelo intervalo $[0, 1] = \{x \in \mathbf{R}: 0 \leq y \leq 1\}$.

$$y = \frac{1}{1 + e^{-x}}$$

Figura 12: Fórmula da função sigmoid

Sendo $\{e\}$ o número de Euler, dado pelo somatório tendendo ao infinito da divisão $\frac{1}{n!}$, onde $\{\infty\}$ é representado pelo intervalo: $[1, +\infty[= \{x \in \mathbf{R}: x > 1\}$, (Figura 12).

$$e = \sum_{n=0}^{\infty} \frac{1}{n!}$$

Figura 13: Fórmula do número de Euler.x

- g) Precisão: Adotado como comparativo ao critério de parada, sendo $\varepsilon = 0,01$.

- h) Critério de Parada: Fica definido em função a condição resultante do Erro Quadrático Médio (EQM), expresso por (Figura 13):

$$|E_M^{atual} - E_M^{anterior}| \leq \varepsilon$$

Figura 14: Fórmula do Erro Quadrático Médio

- i) Taxa de Aprendizado: Representada por $\{n\}$, com o valor de $n = 0,05$. Tem como objetivo mensurar a descida do gradiente diretamente ligada ao salto dos Pesos Sinápticos $\{w_1, w_2, \dots, w_n\}$, o valor da taxa de aprendizado respeita o seguinte intervalo, $]0, 1[= \{x \in R: 0 < n < 1\}$.

3.9 Arquitetura do software

Apresenta uma visão geral e resumida dos elementos principais que integram a arquitetura do *software* (figura 6), com apresentação das camadas que a compõem. A primeira a camada de aplicação (alusão a toda interface gráfica de interação para com o usuário), camada de negócios, (representação das lógicas e rotinas adotadas pelo sistema), camada de persistência, (direcionada a gravação e leitura dos dados).



Figura 15: Arquitetura do *software*

3.10 Visualização das telas do software

As telas do *software* apresentam as interfaces gráficas disponíveis na aplicação, exemplificado na figura 16. Tela inicial da aplicação, para o carregamento do arquivo.tst, e visualização e gravação dos resultados. Para utilização do *software Nitlab Clear* utilize o seguinte endereço eletrônico abaixo e em seguida clique em *Nitlab Clear* e *download*.

<https://drive.google.com/open?id=1XNGwzT2sEGO2CjqhOQudQYVCMfsi02YQ>



Figura 16: Tela do *software* NitLab Clear EEG.

3.11 *Descrição do software*

O sistema tem como característica a usabilidade do usuário final em relação as rotinas implementadas na biblioteca TST_file. Utilizando-se de uma interface gráfica e intuitiva o usuário poderá carregar um arquivo.tst, iniciar uma varredura para a identificação automática de artefatos, visualizar os resultados e gravar o arquivo.tst já com o artefatos removidos.

3.12 *Procedimento experimental*

Foi realizada a aquisição do sinal eletroencefalográfico, com o intuito de gerar artefatos biológicos. Os sujeitos foram orientados a reproduzir artefatos específicos predeterminados pelo condutor da aplicação. Após o fim da eletroencefalografia, os arquivos de coleta foram submetidos a dois pós-processamentos para a identificação dos artefatos: 1) utilização da biblioteca TST_file, para que a análise seja realizada automaticamente; 2) foi realizado por um profissional capacitado, o qual analisou o traçado em busca de possíveis artefatos. Ao término, o resultado de cada processo foi comparado de maneira que os artefatos apresentados pelo sistema fossem convergentes ao realizado pelo profissional adjunto a uma base dados oriundos da biblioteca *Python Keras*.

3.13 Desenho do estudo

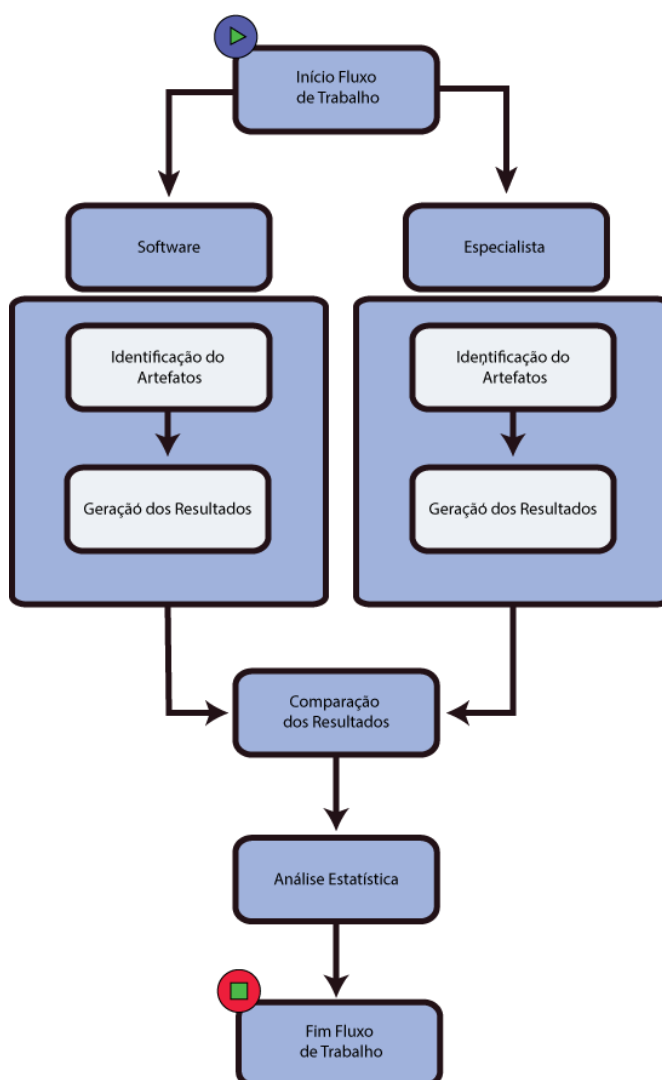


Figura 17: Desenho do Estudo

3.14 Análise Estatística

Foi realizado o *Kappa* pareado afim de analisar e comparar se os valores do sinal eletroencefalográfico entre limpo manualmente ou com o sistema desenvolvido. O tamanho do efeito será estimado vslor de Kappa. A normalidade dos dados será verificada pelo teste Kappa. A potência estatística e o intervalo de confiança de 95% (IC 95%) serão calculados para as variáveis dependentes. O poder estatístico será interpretado como: baixa potência de 0.1 a 0.3; alta potência de 0.8 a

0.9. Todas as análises foram conduzidas utilizando o SPSS para Windows versão 20.0 (SPSS Inc., Chicago, IL, USA).

4 RESULTADOS

4.1 *Leitura e Gravação dos Dados*

Considerando a base de dados formada por arquivos em “.tst”, a leitura e gravação dos arquivos foi estruturalmente fidedigna às originais, garantindo a integridade dos dados.



Figura 18: Acurácia de leitura e gravação

4.2 *Resultados de Q pontos*

Para caracterizar os pontos de interesse em determinado espectro, foi identificado que a máxima de Q interfere diretamente na comparação das estruturas PIP sendo elas correspondentes, dado que a comparativa se torna insustentável quanto Q assume uma média de 25% de pontos de interesse em relação ao conjunto

de pontos do sinal de origem. Já a mínima para Q pontos em relação ao conjunto de origem é satisfeita em um intervalo onde, $Q = [6, 25] \%$.

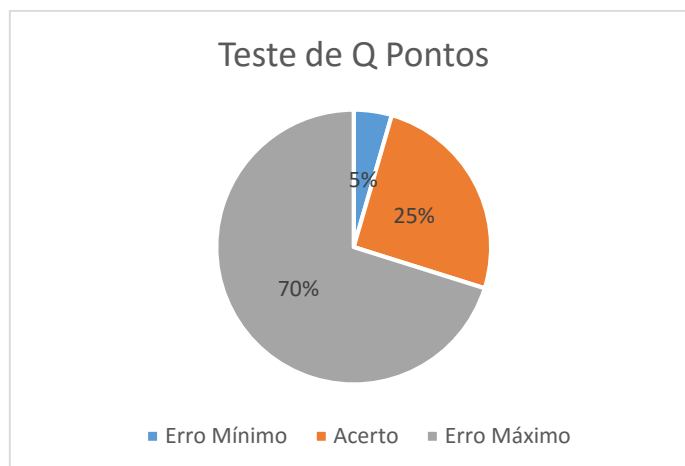


Figura 19: Teste de Q Pontos

4.3 Resultados de Similaridade

Os processos nas fases de treinamento das RNA - PMC foram executados de quatro (04) maneiras, a fim de realizar o comparativo entre as rotinas aplicadas.

a) *Treinamento PIP e execução desenvolvido:*

Utilizando o vetor de coeficientes angulares PIP como entrada para a RNA PMC na fase de aplicação obteve-se como resultado o acerto de 98,8%, do total de 500 (quinhentas) amostras, das quais 126 eram a saída desejada (piscada), em um total de 339 épocas e utilizando como critério de parada a precisão de $\varepsilon = 0,01$, na fase de treinamento.

b) Treinamento PIP e execução Keras

Utilizando o vetor de coeficientes angulares PIP como entrada para a RNA - PMC integrada a biblioteca *Python Keras*, na fase de aplicação, obteve-se o acerto de 95,2%, do total de 500 (quinhentas) amostras, das quais 126 eram a saída desejada (piscada), em um total de 321 épocas e utilizando como critério de parada a precisão de $\varepsilon = 0,01$, na fase de treinamento.

c) Treinamento e execução desenvolvidos

Utilizando o sinal EEG como entrada para a RNA PMC na fase de aplicação obteve-se o acerto de 92,8%, do total de 500 (quinhentas) amostras, das quais 126 eram a saída desejada (piscada), em um total de 640 épocas e utilizando como critério de parada a precisão de $\varepsilon = 0,01$, na fase de treinamento.

d) Treinamento e execução Keras

Utilizando o sinal EEG como entrada para a RNA PMC na fase de aplicação obteve-se o acerto de 93,2%, do total de 500 (quinhentas) amostras, das quais 126 eram a saída desejada (piscada), em um total de 625 épocas e utilizando com critério de parada a precisão de $\varepsilon = 0,01$, na fase de treinamento.

4.4 Resultados Visuais das etapas de Limpeza do sinal

Gráfico referente ao sinal eletroencefalográfico, exemplificado pelo eletrodo Fp1, registrado no arquivo original.tst, sem a aplicação de técnica de pós-processamento (figura 20):




Figura 20: Gráfico do comportamento oscilatório total do eletrodo Fp1 original.

Gráfico referente aos primeiros 5,5 segundos do sinal eletroencefalográfico (eletrodo Fp1), registrado no arquivo (original.tst), sem a aplicação de técnica pós-processamento (figura 21):

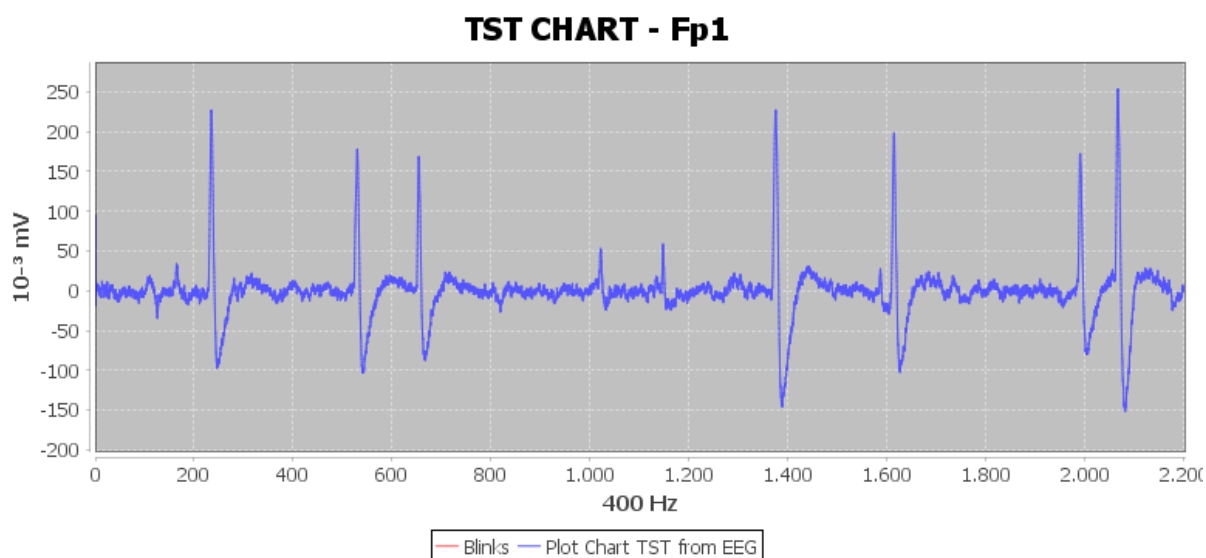


Figura 21: Gráfico do comportamento oscilatório dos primeiros 5,5 segundos do eletrodo Fp1.

Gráfico referente ao sinal eletroencefalográfico (eletrodo Fp1), registrado no arquivo (original.tst), após a identificação dos possíveis artefatos de piscada dos olhos (figura 22):

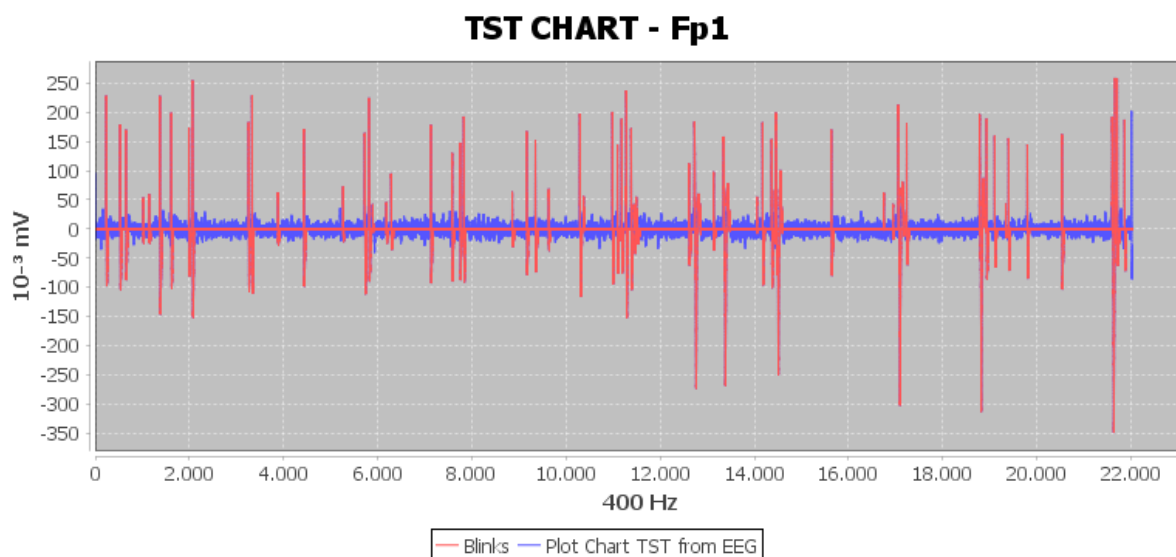


Figura 22: Gráfico do comportamento oscilatório total do eletrodo Fp1.

Gráfico dos primeiros 5,5 segundos do sinal eletroencefalográfico (eletrodo Fp1), registrado no arquivo (original.tst), após a identificação dos possíveis artefatos piscada dos olhos (figura 23):




Figura 23: Gráfico do comportamento oscilatório dos primeiros 5,5 segundos do eletrodo Fp1 pós processamento.

Gráfico referente aos primeiros 5,5 segundos do sinal eletroencefalográfico (eletrodo Fp1), registrado no arquivo (new.tst), após a remoção dos artefatos piscada dos olhos (figura 24):




Figura 24: Gráfico do comportamento oscilatório dos primeiros 5,5 segundos do eletrodo Fp1 sem artefato piscada de olho.

Gráficos referentes ao comparativo do sinal eletroencefalográfico, exemplificado pelo eletrodo Fp1, registrado no arquivo original.tst, após análise do avaliador 01, avaliador 02 e NitLab EEG Clear (figura 25):

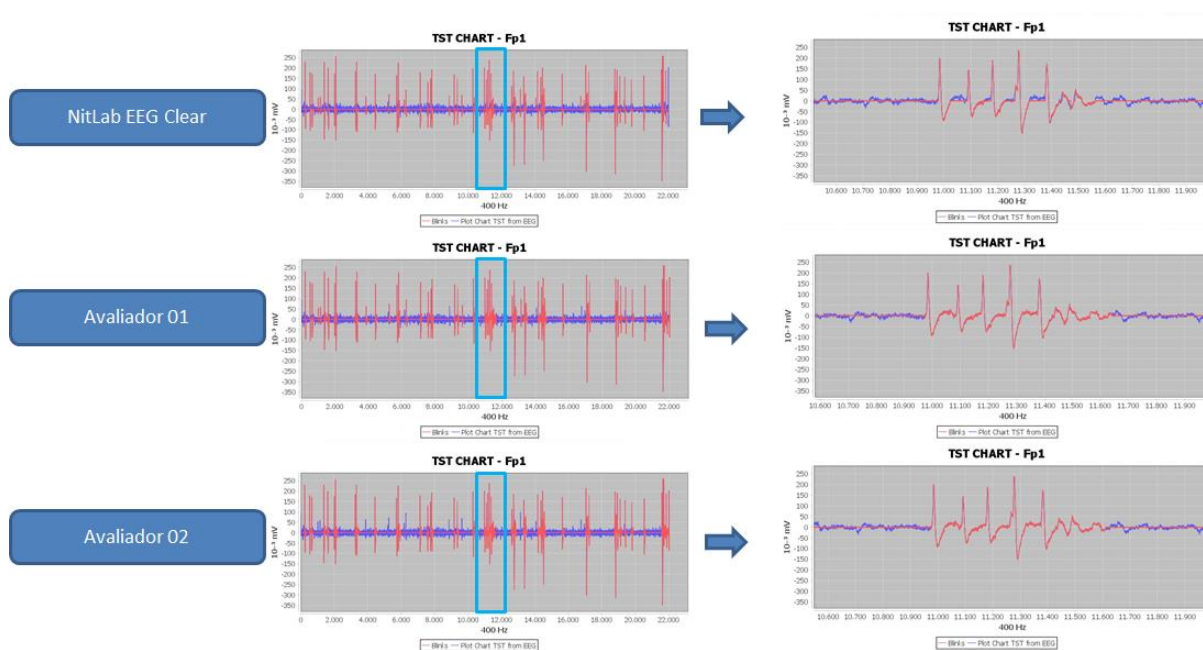


Figura 25: Comparativo em métodos de limpeza.

4.5 Tempo para Aplicação

O comparativo da variável tempo para a realização completa da limpeza do sinal foi aplicado entre soluções candidatas e a proposta.

Modelos	Tempo (Segundos)
NitLab EEG Clear	6,2
ICA	11,5
Avaliador 01	758,2
Avaliador 02	969,4

Para os testes de modelos computacionais foram utilizados um computador com as seguintes configurações de hardware e software:

Processador	Memória RAM	Armazenamento	Sistema Operacional
Intel Core i7 6700	32 GB	SSD Kingston 500 GB	Windows 10

4.6 Análise estatística

Os resultados demonstraram que quando é realizada a comparação entre as classes avaliador e a ferramenta NitLab EEG Clear, o nível de heterogeneidade das respostas aos intervalos de tempo da piscada é menor, o que acarreta menor precisão nas respostas ao intervalo de tempo das piscadas. Os resultados evidenciaram que o índice Kappa é de 0,777, quando feita a comparação interclasses Avaliador e NitLab EEG Clear é alto.

4.6.1: Kappa Entre Profissionais

Overall Kappa

	Kappa	Asymptotic Standard Error	Z	P Value	Lower 95% Asymptotic CI Bound	Upper 95% Asymptotic CI Bound
Overall	,863	,204	4,229	,000	,463	1,263

4.6.2: Profissional e ICA

Overall Kappa

	Kappa	Asymptotic Standard Error	Z	P Value	Lower 95% Asymptotic CI Bound	Upper 95% Asymptotic CI Bound
Overall	,619	,289	2,144	,032	,053	1,185

4.6.3: Profissional e NitLab Clear EEG

Overall Kappa

	Kappa	Asymptotic Standard Error	Z	P Value	Lower 95% Asymptotic CI Bound	Upper 95% Asymptotic CI Bound
Overall	,777	,204	3,805	,000	,377	1,177

5 DISCUSSÃO

No presente estudo foi proposto avaliar o uso de RNA do tipo PMC associada técnica de pós-processamento matemático PIP na identificação de padrões de artefatos do EEG. O modelo adotou como referência a piscada de olhos, ao entender que esse é o artefato comumente encontrado no sinal do EEG.

Os processos de treinamento e aplicação dos classificadores de padrão foram igualmente repetidos nos cenários desenvolvidos. Foi observado que a construção de um vetor dos coeficientes angulares, resultante do pós-processamento dos PIPs, reflete positivamente na identificação de artefatos e interfere no número de acertos classificatórios de artefatos e na redução de épocas em cada etapa de treinamento. Este fato está relacionado ao tempo médio computacional de execução destinado para a identificação dos artefatos. Durante a última década, poucos métodos foram propostos na área de limpeza de artefatos eletroencefalográficos, além das clássicas abordagens existentes, tais como regressão (PHAN et al., 2011), ou na aplicação de filtros matemáticos aonde o nível de exatidão é baixo, devido a tentativa direta de aproximação em relação aos artefatos (CROFT et al., 2000). Além disso, os resultados demonstraram eficácia em relação às técnicas de Separação de Sinal Cego (SSC), onde o sinal a ser destacado ou o conjunto do mesmo está em meio a outros sinais não desejáveis. Este fato não ocorreu no modelo aqui proposto, pois a separação sem ou com pouca informação do sinal alvo, não causou algumas falhas em relação o nível de acerto da técnica (JAMES et al.,2004; VIGARIO et al.,2008).

Outra técnica comumente utilizada é a Análise de Componentes Morfológicos (ACM), sendo um bom método para a remoção de artefatos, mas requer como característica das formas dos artefatos a similaridade estrutural (MATIKO et al., 2013; YONG et al., 2009), que muitas não são localizadas, dadas as diferenças individuais de diversas piscadas ao decorrer da coleta. Isto, pode levar a não interpretação do artefato o que demonstra uma limitação no processo de treinamento. Porém, o modelo desenvolvido neste estudo, com a RNA PMC proposta com os parâmetros de entrada fornecidos pelos CA PIP de várias amostras supera esta lacuna.

Kong et al. (2013), apresentaram uma solução por meio da Análise do Componente Independente (ICA), a qual tem sido amplamente utilizada para minimizar os artefatos do sinal do EEG. Neste caso, a ICA verifica o sinal por meio da decomposição das épocas, separando os possíveis artefatos piscada dos olhos dos demais pulsos elétricos oriundos da atividade cortical, que de fato representam quantitativamente o sinal desejado. Esse modelo de identificação, não permite grande acurácia, haja vista que o artefato piscada está em função não linear do tempo, variando quanto a sua duração e constância. Então, o modelo desenvolvido neste estudo preenche a lacuna da ICA, já que a principal variável levada em consideração é a sequência total de coeficientes angulares do vetor resultante PIP.

Sato et al, (2012), ao realizarem o reconhecimento do padrão de piscada no EEG, observaram que a grande presença de falsos positivos apresentados como artefatos reais, descaracteriza o pós-processamento do sinal. Desse modo, o modelo desenvolvido pode suprir o não reconhecimento de falsos positivos, ou seja, artefatos indesejáveis. Isso ocorre porque o modelo tem como característica a análise em tomada de decisão diretamente ligada a descida do gradiente e aos pesos finais obtidos pelos processos sinápticos da RNA. Neste contexto, esse desenvolvimento

amplia a visão em relação a acurácia, promovendo maior taxa de acerto, refletida na confiabilidade do método.

Os resultados demonstraram que a utilização de PIP como estratégia de pós-processamento na entrada de uma RNA PMC, se mostrou eficiente quando comparada a média da taxa de precisão. De fato, Hasasneh et al. (2018), quando aplicaram Redes Neuras Artificias em séries temporais biológicas, como EEG e ECG, para identificar e caracterizar artefatos oculares e cardíacos, obtiveram uma taxa de precisão de 94,4%. Embora os autores tenham utilizado RNA PMC, o modelo utilizado é diferente do abordado neste estudo, haja vista a utilização dos PIPs como entrada para a RNA, que levou a interferi positivamente e diretamente nos resultados dos acertos.

O índice de correlação Kappa foi menor, quando realizado a comparação entre classes dos avaliadores e o NitLab EEG Clear. Entende-se que isso ocorreu devido o critério de avaliação da ferramenta ser realizada em blocos de piscadas, enquanto os avaliadores, realizaram a inpeção visual com a interpretação independente do artefato. Além disso, os avaliadores têm mais probabilidade de erro, pois inspecional a quantidade de dados coletados pelo EEG é uma tarefa demorada e aumenta a probabilidade de erro na análise (GOH et al., 2017).

Uma das limitações encontradas nesse trabalho, foi a não obtenção de mais bases de dados a serem utilizadas como amostras de treinamentos, aplicadas ao processo de classificação de grupos em diversos outros tipos de artefatos. Entretanto, foi possível obter uma excelente média de acerto, quanto ao artefato piscada dos olhos.

6 CONCLUSÃO E TRABALHOS FUTUROS

Este trabalho propõe a utilização de características advindas de técnicas de pós-processamento de séries temporais, com a utilização do vetor dos coeficientes angulares de dados PIP, como entrada para Redes Neurais Artificiais *Perceptron* de Multicamadas. Por meio do espectrograma do sinal do EEG, regiões candidatas como piscada de olhos são reconhecidas e os artefatos candidatos que não satisfizeram os critérios de identificação são eliminados. Desse modo, o modelo desenvolvido interfere e modifica o desempenho dos parâmetros classificadores de grupos, tornando-os uma solução para a identificação de padrões em ST genéricas. Assim, a utilização de *vetor perceptually important points* como entrada para classificação de padrões aplicada à rede neural artificial *multi layer perceptron* mostra-se como um caminho promissor a ser explorado com mais amplitude para análise dos diversos tipos de artefatos do EEG.

Como trabalhos futuros, planeja-se realizar experimentos para avaliar e aperfeiçoar o modelo. Além disso, o modelo pode evoluir para a análise de outros artefatos do sinal do EEG e outras ferramentas com séries temporais. O modelo computacional desenvolvido neste estudo, também pode expandir para identificação de eventos característicos das diversas tarefas utilizadas por neurocientistas. Isso poderá ser realizado tanto nas investigações da sensibilidade, motricidade e da cognição. Neste contexto, o modelo também poderá expandir para a remoção de casos indesejados ou utilizado como um gatilho estimulatório para a execução de

outras tarefas. Outro caminho futuro será comparar o modelo com os métodos existentes de identificação de artefatos.

Referências Bibliográficas

- ABDULKADER, Sarah N.; ATIA, Ayman; MOSTAFA, Mostafa-Sami M. Brain computer interfacing Applications and challenges. **Egyptian Informatics Journal**, v. 16, n. 2, p. 213-230, 2015.
- ABEYRATNE, UDANTHA R. et al. Artificial neural networks for source localization in the human brain. **Brain Topography**, v. 4, n. 1, p. 3-21, 1991.
- ABEYRATNE, UDANTHA R.; ZHANG, G.; SARATCHANDRAN, P. EEG source localization: a comparative study of classical and neural network methods. **International journal of neural systems**, v. 11, n. 04, p. 349-359, 2001.
- ALFARO-PONCE, Mariel; ARGÜELLES, A.; CHAIREZ, Isaac. Pattern recognition for electroencephalographic signals based on continuous neural networks. **Neural Networks**, v. 79, p. 88-96, 2016.
- ANDRAUS, Maria Emilia Cosenza; ANDRAUS, Cesar Fantezia; ALVES-LEON, Soniza Vieira. Periodic EEG patterns: importance of their recognition and clinical significance. **Arquivos de neuro-psiquiatria**, 2012, 70.2: 145-151.
- ANGHINAH, R. Análise da coerência do espectro do eletroencefalograma. **Rev. Neurociências**, v. 13, n. 1, p. 050-053, 2005.
- ARUNKUMAR, N.; KUMAR, K. Ram; VENKATARAMAN, V. Entropy features for focal EEG and non focal EEG. **Journal of Computational Science**, 2018.
- ASSENZA, G. et al. Wakefulness delta waves increase after cortical plasticity induction. **Clinical Neurophysiology**, v. 126, n. 6, p. 1221-1227, 2015.
- BALDWIN, Carryl L.; PENARANDA, B. N. Adaptive training using an artificial neural network and EEG metrics for within-and cross-task workload classification. **NeuroImage**, v. 59, n. 1, p. 48-56, 2012.
- BANGOR, A.; KORTUM, P. T.; MILLER, J. T. An Empirical Evoluacion of the System Usability Scale. *International Journal of Human-Computer Interection*, 24(6): 574-594, 2008.
- BARGIOTTI, S. et al. EEG signal compression based on ADPCM and neural network predictors. In: **14° Colloque sur le traitement du signal et des images, FRA, 1993**. GRETSI, Groupe d'Etudes du Traitement du Signal et des Images, 1993.
- BARRY, Robert J. et al. Resting-state EEG gamma activity in children with attention-deficit/hyperactivity disorder. **Clinical neurophysiology**, v. 121, n. 11, p. 1871-1877, 2010.

BATTITI, R. et al. Neural compression: an integrated application to EEG signals. In: **Proc. International Workshop on Application of Neural Networks to Telecommunication**. 1995.

BELL, Martha Ann; CUEVAS, Kimberly. Using EEG to study cognitive development: Issues and practices. **Journal of Cognition and Development**, 2012, 13.3: 281-294.

BOCKBRADER, Marcia A. et al. Brain Computer Interfaces in Rehabilitation Medicine. **PM&R**, v. 10, n. 9, p. S233-S243, 2018.

CANTERO, Jose L.; ATIENZA, Mercedes; SALAS, Rosa M. Human alpha oscillations in wakefulness, drowsiness period, and REM sleep: different electroencephalographic phenomena within the alpha band. **Neurophysiologie Clinique/Clinical Neurophysiology**, v. 32, n. 1, p. 54-71, 2002.

CHANG, Won-Du et al. Detection of eye blink artifacts from single prefrontal channel electroencephalogram. **Computer methods and programs in biomedicine**, v. 124, p. 19-30, 2016.

CINCOTTI, Febo et al. Non-invasive brain-computer interface system: towards its application as assistive technology. **Brain research bulletin**, v. 75, n. 6, p. 796-803, 2008.

CLEMENS, B. et al. Theta EEG source localization using LORETA in partial epilepsy patients with and without medication. **Clinical Neurophysiology**, v. 121, n. 6, p. 848-858, 2010.

CROFT, Rodney J.; BARRY, Robert J. Removal of ocular artifact from the EEG: a review. **Neurophysiologie Clinique/Clinical Neurophysiology**, v. 30, n. 1, p. 5-19, 2000.

DAVEY, B. L. K. et al. Expert system approach to detection of epileptiform activity in the EEG. **Medical and Biological Engineering and Computing**, v. 27, n. 4, p. 365-370, 1989.

ELBERT T, Rockstroh B, Lutzenberger W and Birbaumer N 1980 Biofeedback of slow cortical potentials: I Electroencephalogr. **Clin. Neurophysiol.** 48 293–301

FARWELL L A and Donchin E 1988 Talking off the top of your head: toward a mental prosthesis utilizing event-related brain potentials Electroencephalogr. **Clin. Neurophysiol.** 70 510–23.

FREEMAN W J, Holmes M D, Burke B C and Vanhatalo S 2003 Spatial spectra of scalp EEG and EMG from awake humans **Clin. Neurophysiol.** 114 1053–68.

GARIPELLI, Gangadhar et al. The use of brain-computer interfacing in ambient intelligence. In: **European Conference on Ambient Intelligence**. Springer, Berlin, Heidelberg, 2007. p. 268-285.

GERLA, Václav et al. Automatic identification of artifacts and unwanted physiologic signals in EEG and EOG during wakefulness. **Biomedical Signal Processing and Control**, v. 31, p. 381-390, 2017.

GEORGOPOULOS, Apostolos P.; SCHWARTZ, Andrew B.; KETTNER, Ronald E. Neuronal population coding of movement direction. **Science**, v. 233, n. 4771, p. 1416-1419, 1986.

GOEL, Vaibhava et al. Dominant frequency analysis of EEG reveals brain's response during injury and recovery. **IEEE transactions on Biomedical Engineering**, v. 43, n. 11, p. 1083-1092, 1996.

GOH, Sim K.; ABBASS, Hussein A.; TAN, Kay C.; GUAN, C. **Automatic EEG Artifact Removal Techniques by Detecting Influential Independent Components**. *IEEE Transactions on Emerging Topics in Computational Intelligence*. V. 1, n. 4, p.270-279, 2017.

GANNOUS, Aiman S.; ELHADDAD, Younis R. Improving an artificial neural network model to predict thyroid bending protein diagnosis using preprocessing techniques. **WASET**, v. 50, p. 124-128, 2011.

GÖKSU, Hüseyin. BCI oriented EEG analysis using log energy entropy of wavelet packets. **Biomedical Signal Processing and Control**, v. 44, p. 101-109, 2018.

GLOVER, John R. et al. Context-based automated detection of epileptogenic sharp transients in the EEG: elimination of false positives. **IEEE Transactions on Biomedical Engineering**, v. 36, n. 5, p. 519-527, 1989.

GOTMAN, J.; GLOOR, P.; SCHAUL, N. Comparison of traditional reading of the EEG and automatic recognition of interictal epileptic activity. **Electroencephalography and clinical Neurophysiology**, v. 44, n. 1, p. 48-60, 1978.

GOTMAN, J. Automatic recognition of interictal spikes. **Electroencephalography and clinical neurophysiology. Supplement**, v. 37, p. 93-114, 1985.

GOTMAN, J.; WANG, L. Y. State-dependent spike detection: concepts and preliminary results. **Electroencephalography and clinical Neurophysiology**, v. 79, n. 1, p. 11-19, 1991.

GURESEN, Erkam; KAYAKUTLU, Gulgun. Definition of artificial neural networks with comparison to other networks. **Procedia Computer Science**, 2011, 3: 426-433.

JADHAV, Narendra; MANTHALKAR, Ramchandra; JOSHI, Yashwant. Effect of meditation on emotional response: An EEG-based study. **Biomedical Signal Processing and Control**, v. 34, p. 101-113, 2017.

JAFARIAN, Ahmad et al. On artificial neural networks approach with new cost functions. **Applied Mathematics and Computation**, v. 339, p. 546-555, 2018.

JAMES, Christopher J.; HESSE, Christian W. Independent component analysis for biomedical signals. **Physiological measurement**, v. 26, n. 1, p. R15, 2004.

M. SATYANARAYANAN, B. Pervasive computing: Vision and challenges, **IEEE Pers. Commun.**, vol. 8, no. 4, pp. 10–17, Aug. 2001.

HARTMANN, M. M. et al. PureEEG: automatic EEG artifact removal for epilepsy monitoring. **Neurophysiologie Clinique/Clinical Neurophysiology**, v. 44, n. 5, p. 479-490, 2014.

HASASNEH, Ahmad et al. Deep Learning Approach for Automatic Classification of Ocular and Cardiac Artifacts in MEG Data. **Journal of Engineering**, v. 2018, 2018.

HASSABIS, Demis et al. Neuroscience-inspired artificial intelligence. **Neuron**, v. 95, n. 2, p. 245-258, 2017.

HOFFMANN, Sven; FALKENSTEIN, Michael. The correction of eye blink artefacts in the EEG: a comparison of two prominent methods. **PLoS One**, v. 3, n. 8, p. e3004, 2008.

HOLROYD, Clay B.; COLES, Michael GH. The neural basis of human error processing: reinforcement learning, dopamine, and the error-related negativity. **Psychological review**, v. 109, n. 4, p. 679, 2002.

JW, Britton; LC, Frey; JLET, Hopp. Electroencephalography (EEG) : An Introductory Text and Atlas of Normal and Abnormal Findings in Adults, Children, and Infants. Chicago: **American Epilepsy Society**, 2016. 95 p. v. 1.

KALKE, H.; LOEWEN, M. Support vector machine learning applied to digital images of river ice conditions. **Cold Regions Science and Technology**, v. 155, p. 225-236, 2018.

KAPPOR, Rahul; WALTERS, Stephen P.; AL-ASWAD, Lama A. The Current State of Artificial Intelligence in Ophthalmology. **Survey of ophthalmology**, 2018.

KRAJCA, V.; PRINCIPE, J. C.; PETRANEK, S. The dimensionality reduction and reconstruction of the multichannel EEG signals by self organized principal components analysis. In: **Signal analysis and prediction I, Eurasip**. ICT Press, Prague, 1997. p. 406-408.

KELMANN, Gizela; BERNARDO, Wanderley Marques. O eletroencefalograma com mapeamento cerebral é superior ao eletroencefalograma tradicional no diagnóstico de patologias neurológicas?. **Revista da Associação Médica Brasileira**, v. 58, n. 1, p. 10-10, 2012

KENNEDY, P. R.; BAKAY, R. AE. Restoration of neural output from a paralyzed patient by a direct brain connection. **Neuroreport**, v. 9, n. 8, p. 1707-1711, 1998.

KONG, Wanzeng et al. Automatic and direct identification of blink components from scalp EEG. **Sensors**, v. 13, n. 8, p. 10783-10801, 2013.

KUMAR, J. Satheesh; BHUVANESWARI, P. Analysis of Electroencephalography (EEG) signals and its categorization—a study. **Signal**, v. 25, p. 26, 2012.

LAL, Saroj KL; CRAIG, Ashley. A critical review of the psychophysiology of driver fatigue. **Biological psychology**, v. 55, n. 3, p. 173-194, 2001.

LAUBACH, Mark; WESSBERG, Johan; NICOLELIS, Miguel AL. Cortical ensemble activity increasingly predicts behaviour outcomes during learning of a motor task. **Nature**, v. 405, n. 6786, p. 567, 2000.

LAWHERN, Vernon et al. Detection and classification of subject-generated artifacts in EEG signals using autoregressive models. **Journal of neuroscience methods**, v. 208, n. 2, p. 181-189, 2012.

LEE, Jaewon et al. Differential resting-state EEG patterns associated with comorbid depression in Internet addiction. **Progress in Neuro-Psychopharmacology and Biological Psychiatry**, v. 50, p. 21-26, 2014.

LEWANDOWSKI, Achim; ROSIPAL, Roman; DORFFNER, Georg. Extracting more information from EEG recordings for a better description of sleep. **Computer methods and programs in biomedicine**, v. 108, n. 3, p. 961-972, 2012.

LODDER, Shaun S.; VAN PUTTEN, Michel JAM. Quantification of the adult EEG background pattern. **Clinical neurophysiology**, v. 124, n. 2, p. 228-237, 2013.

LOPEZ-GORDO, M. A. et al. Customized stimulation enhances performance of independent binary SSVEP-BCIs. **Clinical Neurophysiology**, v. 122, n. 1, p. 128-133, 2011.

LUGER, George F. **Inteligência Artificial-: Estruturas e estratégias para a solução de problemas complexos**. Bookman, 2004.

MAZUROWSKI, Maciej A. et al. Decision optimization of case-based computer-aided decision systems using genetic algorithms with application to mammography. **Physics in Medicine & Biology**, v. 53, n. 4, p. 895, 2008.

MATIKO, Joseph W.; BEEBY, Stephen; TUDOR, John. Real time eye blink noise removal from EEG signals using morphological component analysis. In: **2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)**. IEEE, 2013. p. 13-16.

MCCANE, Lynn M. et al. P300-based brain-computer interface (BCI) event-related potentials (ERPs): People with amyotrophic lateral sclerosis (ALS) vs. age-matched controls. **Clinical Neurophysiology**, v. 126, n. 11, p. 2124-2131, 2015.

MCCARTHY, John, et al. A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. **AI magazine**, 2006, 27.4: 12.

MICHELMANN, Sebastian, et al. Data-driven re-referencing of intracranial EEG based on independent component analysis (ICA). **Journal of neuroscience methods**, 2018, 307: 125-137.

MIRAGLIA, Francesca; VECCHIO, Fabrizio; ROSSINI, Paolo Maria. Brain electroencephalographic segregation as a biomarker of learning. **Neural Networks**, v. 106, p. 168-174, 2018.

MORAN, Daniel. Evolution of brain–computer interface: action potentials, local field potentials and electrocorticograms. **Current opinion in neurobiology**, v. 20, n. 6, p. 741-745, 2010.

O'REGAN, Simon; MARNANE, William. Multimodal detection of head-movement artefacts in EEG. **Journal of Neuroscience Methods**, v. 218, n. 1, p. 110-120, 2013.

OTERO, G. A. et al. QEEG norms for the first year of life. **Early human development**, v. 87, n. 10, p. 691-703, 2011.

PAN, Yunhe. Heading toward artificial intelligence 2.0. **Engineering**, v. 2, n. 4, p. 409-413, 2016.

PEREZ, Javier Andreu, et al. Artificial Intelligence and Robotics. **arXiv preprint arXiv:1803.10813**, 2018.

PFURTSCHELLER G, FLOTZINGER D and KALCHER J 1993 Brain–computer interface—a new communication device for handicapped persons **J. Microcomput. Appl.** 16 293–9

PHAM, Trieu TH et al. A test of four EOG correction methods using an improved validation technique. **International Journal of Psychophysiology**, v. 79, n. 2, p. 203-210, 2011.

QUAZI, M. H.; KAHALEKAR, S. G. Artifact's removal from EEG signal: FLM optimization-based learning algorithm for neural network-enhanced adaptive filtering. **Biocybernetics and Biomedical Engineering**, v. 37, n. 3, p. 401-411, 2017.

RADÜNTZ, T. et al. EEG artifact elimination by extraction of ICA-component features using image processing algorithms. **Journal of neuroscience methods**, v. 243, p. 84-93, 2015.

RAMADAN, Rabie A.; VASILAKOS, Athanasios V. Brain computer interface: control signals review. **Neurocomputing**, v. 223, p. 26-44, 2017.

RAMOS-AGUILAR, Ricardo; OLVERA-LÓPEZ, J. Arturo; OLMOS-PINEDA, Ivan. Analysis of EEG Signal Processing Techniques based on Spectrograms. **Applications of Language & Knowledge Engineering**, p. 151.

RICHHARIYA, B.; TANVEER, Muhammad. EEG signal classification using universum support vector machine. **Expert Systems with Applications**, v. 106, p. 169-182, 2018.

RIDOUH, A., Boutana, D., Benidir, M.: Comparative Study of Time Frequency Analysis Application on Abnormal EEG Signals. Recent Advances in Electrical Engineering and Control Applications, **Springer International Publishing**, Cham 355–368 (2017)

ROBERT, Claude; GAUDY, Jean-François; LIMOGÉ, Aimé. Electroencephalogram processing using neural networks. **Clinical Neurophysiology**, 2002, 113.5: 694-701.

ROSADO, André; ROSA, Agostinho C. Automatic Detection of Epileptiform Discharges in the EEG. **ArXiv preprint arXiv:1605.06708**, 2016.

SARMA, Parthana, et al. Pre-processing and Feature Extraction Techniques for EEG-BCI Applications-A Review of Recent Research. **ADBU Journal of Engineering Technology**, 2016, 5.1.

SCHALK G, McFarland DJ, Hinterberger T, Birbaumer N, Wolpaw JR: BCI2000: a general-purpose brain-computer interface (BCI) system. **IEEE Trans Biomed Eng** 2004, 51:1034–1043.

SCHNEIDER, Stefan et al. Changes in brain cortical activity measured by EEG are related to individual exercise preferences. **Physiology & behavior**, v. 98, n. 4, p. 447-452, 2009.

SCHNEIDER, Signe Luisa; ROSE, Michael. Intention to encode boosts memory-related pre-stimulus EEG beta power. **NeuroImage**, v. 125, p. 978-987, 2016.

SHAIN W et al 2003 Controlling cellular reactive responses around neural prosthetic devices using peripheral and local intervention strategies **IEEE Trans. Neural Syst. Rehabil. Eng.** 11 186–8

SINHA, Rakesh Kumar. An approach to estimate EEG power spectrum as an index of heat stress using backpropagation artificial neural network. **Medical engineering & physics**, v. 29, n. 1, p. 120-124, 2007

S. KERICK, A. Ries, K. Oie, T. P. Jung, J. Duann, J. C. Chou, L. Dai, and K. McDowell, B2010 **Neuroscience Director's Strategic Initiative**, Army Res. Lab., Tech. Rep. ARL-TR-5457, 2011.

SHARANREDDY, M.; KULKARNI, P. K. Automated EEG signal analysis for identification of epilepsy seizures and brain tumour. **Journal of medical engineering & technology**, 2013, 37.8: 511-519.

SUNNY, T. D. et al. Robotic Arm with Brain–Computer Interfacing. **Procedia Technology**, v. 24, p. 1089-1096, 2016.

SKUPCH, A. M. et al. EEG Artifact Detection Using Spatial Distribution of Rhythmicity. **APCBEE procedia**, v. 7, p. 16-20, 2013.

SRINIVASAN R, Nunez P L and Silberstein R B 1998. Spatial filtering and neocortical dynamics: estimates of EEG coherence **IEEE Trans. Biomed. Eng.** 45 814–26

SONG, Dong et al. Nonlinear dynamic modeling of spike train transformations for hippocampal-cortical prostheses. **IEEE Transactions on Biomedical Engineering**, v. 54, n. 6, p. 1053-1066, 2007.

SUN, Mingui; SCLABASSI, Robert J. The forward EEG solutions can be computed using artificial neural networks. **IEEE Transactions on Biomedical Engineering**, v. 47, n. 8, p. 1044-1050, 2000.

SUTTER, E. E.; TRAN, D. Communication through visually induced electrical brain responses. **Schriftenreihe der Oesterreichischen Computer Gesellschaft**, v. 55, p. 279-288, 1990.

STAUB, Selva et al. Artificial neural network and agility. **Procedia-Social and Behavioral Sciences**, v. 195, p. 1477-1485, 2015.

STOFFEL, Marcus; BAMER, Franz; MARKERT, Bernd. Artificial neural networks and intelligent finite elements in non-linear structural mechanics. **Thin-Walled Structures**, v. 131, p. 102-106, 2018.

TAHA, Ibrahim; COOK, Gregory. Brain sources estimation based on EEG and computer simulation technology (CST). **Biomedical Signal Processing and Control**, v. 46, p. 145-156, 2018.

TAYLOR, Dawn; SCHWARTZ, Andrew. **Direct cortical control of 3d neuroprosthetic devices**. U.S. Patent Application n. 10/495,207, 30 dez. 2004.

TIWARI, Neha et al. Brain computer interface: A comprehensive survey. **Biologically Inspired Cognitive Architectures**, 2018.

VAN DE VELDE, Maarten; GHOSH, I. Robert; CLUITMANS, Pierre JM. Context related artefact detection in prolonged EEG recordings. **Computer Methods and Programs in Biomedicine**, v. 60, n. 3, p. 183-196, 2001.

VIDAL J J 1977 TAYLOR, Dawn; SCHWARTZ, Andrew. **Direct cortical control of 3d neuroprosthetic devices**. U.S. Patent Application n. 10/495,207, 30 dez. 2004. **IEEE Proc.** 65 633–64 (special issue on biological signal processing and analysis)

VAN HOEY, Gert et al. EEG dipole source localization using artificial neural networks. **Physics in Medicine & Biology**, v. 45, n. 4, p. 997, 2000.

VIDAL JJ: Towards direct brain-computer communication. **Annu Rev Biophys Bioeng** 1973, 2:157–180.

VIGARIO, Ricardo; OJA, Erkki. BSS and ICA in neuroinformatics: from current practices to open challenges. **IEEE Reviews in Biomedical Engineering**, v. 1, p. 50-61, 2008.

VIOLA, Filipa Campos et al. Semi-automatic identification of independent components representing EEG artifact. **Clinical Neurophysiology**, v. 120, n. 5, p. 868-877, 2009.

VLAANDEREN, M. J. Automated knowledge acquisition for expert systems. an overview. Technical Report, Faculty of Philosophy, **Erasmus University Rotterdam, Netherlands**, 1990.

VOLF, Nina V. et al. Gender differences in association between serotonin transporter gene polymorphism and resting-state EEG activity. **Neuroscience**, v. 284, p. 513-521, 2015.

WATERSTRAAT, Gunnar et al. Recording human cortical population spikes non-invasively—an EEG tutorial. **Journal of neuroscience methods**, v. 250, p. 74-84, 2015.

WEBBER, W. Robert S. et al. Automatic EEG spike detection: what should the computer imitate? **Electroencephalography and clinical neurophysiology**, v. 87, n. 6, p. 364-373, 1993.

WEBBER, W. R. S. et al. Practical detection of epileptiform discharges (EDs) in the EEG using an artificial neural network: a comparison of raw and parameterized EEG data. **Electroencephalography and clinical Neurophysiology**, v. 91, n. 3, p. 194-204, 1994.

WEI, Zuochen; ZOU, Junzhong; ZHANG, Jian. Automatic recognition of chewing noises in epileptic EEG based on period segmentation. **Neurocomputing**, v. 190, p. 107-116, 2016.

WILLIAMS, R. J. P. The biological chemistry of the brain and its possible evolution. **Inorganica chimica acta**, v. 356, p. 27-40, 2003.

WOLPAW JR, Birbaumer N, McFarland DJ, Pfurtscheller G, Vaughan TM: Brain-computer interfaces for communication and control. **Clin Neurophysiol** 2002, 113:767–791.

WOLPAW J R, McFarland D J, Neat G W and Forneris C A 1991 An EEG-based brain-computer interface for cursor control *Electroencephalogr. Clin. Neurophysiol.* 78 252-9

WOLPAW JR, Wolpaw EW. Brain-computer interfaces: something new under the sun in brain-computer interfaces: principles and practice. New York, NY: **Oxford University Press**; 2012:3-12.

WU, Dongrui et al. Identificação e classificação de excitação ideal para computação afetiva usando sinais fisiológicos: tarefa de stroop de realidade virtual. **IEEE Transactions on Affective Computing**.v. 1, n. 2, p. 109-118, 2010.

YANG, Banghua et al. Automatic ocular artifacts removal in EEG using deep learning. **Biomedical Signal Processing and Control**, v. 43, p. 148-158, 2018.

YONG, Xinyi; WARD, Rabab K.; BIRCH, Gary E. Artifact removal in EEG using morphological component analysis. In: **2009 IEEE International Conference on Acoustics, Speech and Signal Processing**. IEEE, 2009. p. 345-348.

YUASA, Motohiro et al. Localização da fonte EEG para dois dipolos por redes neurais. In: **Engenharia em Medicina e Biologia Society, 1998. Anais da 20ª Conferência Anual Internacional do IEEE**

XING-YU, Wang et al. Brain control: human-computer integration control based on brain-computer interface approach. **Acta Automatica Sinica**, v. 39, n. 3, p. 208-221, 2013.

ZHANG, Qinyu et al. Single dipole source localization from conventional EEG using BP neural networks. In: **Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE**. IEEE, 1998. p. 2163-2166.

ZHANG, Dan et al. Toward a minimally invasive brain-computer interface using a single subdural channel: a visual speller study. **Neuroimage**, v. 71, p. 30-41, 2013.

