

CLASSIFICAÇÃO DE IMAGÉTICA MOTORA EM SINAIS ELE- TROENCEFALOGRÁFICOS: uma abordagem baseada em in- terface cérebro máquina e aprendizagem profunda

CLASSIFICATION OF MOTOR IMAGES IN ELECTROENCEPHALO-
GRAPHIC SIGNALS: an approach based on brain-machine interface and
deep learning

Camila Tiodista de Lima

camilatiodista@gmail.com

Bruno Gomes Moura de Oliveira

bruno@pesqueira.ifpe.edu.br

Wellington Pinheiro dos Santos

wellington.santos@ufpe.br

RESUMO

Pacientes com traumas neurológicos ou portadores de deficiências motoras podem ter sua qualidade de vida melhorada com dispositivos assistidos controlados por interfaces cérebro-máquina que interpretam sinais de eletroencefalograma para predição de movimentos imaginários. O objetivo do presente Trabalho de Conclusão de Curso é desenvolver protótipos baseados em arquiteturas de redes neurais profundas para a extração de características, selecionar automaticamente os atributos mais relevantes através de algoritmos baseados em Computação Evolucionária e construir uma máquina de aprendizado para classificação de sinais imaginados. Foi utilizada a base de dados BCI Competition IV 2a. A partir de resultados da literatura, o primeiro experimento foi realizado com o terceiro indivíduo, nele foram testadas 12 configurações, os extratores de características: descritores explícitos, *InceptionV3* e VGG16, combinados aos classificadores: J48, RF100, RF500 e SVM. A melhor configuração foi a VGG16+RF500 que foi aplicada a todos os indivíduos com o objetivo de identificarmos o melhor indivíduo para nosso contexto. Para nosso problema, o indivíduo com melhor desempenho foi o segundo, com ele foi realizada a extração de características com o Algoritmo Genético e a Otimização por Enxames de Partículas, sendo o segundo mais eficiente e com resultados de classificação superiores. Por fim, foi comparado o desempenho do sistema com e sem a seleção de características, o que resultou em uma redução em três vezes do tempo de treinamento e manutenção da acurácia média em torno de 75%. Dessa forma, os objetivos propostos foram alcançados e novos testes deverão ser realizados em trabalhos futuros.

Palavras-chave: Imagética Motora. EEG. Aprendizado Profundo

ABSTRACT

Patients with neurological trauma or people with motor disabilities can have their quality of life improved with assisted devices controlled by brain-machine interfaces that interpret electroencephalogram signals to predict imaginary movements. The objective of this final project of the course is to develop prototypes based on deep neural network architectures for cleaning features, automatically selecting the most relevant attributes through algorithms based on Evolutionary Computing and building a learning machine for classifying imagined signals. The BCI Competition IV 2a database was used. Based on the literature results, the first experiment was carried out with the third individual, 12 configurations were tested, the feature extractors: explicit descriptors, *InceptionV3* and VGG16, combined with the classified ones: J48, RF100, RF500 and SVM. The best configuration was VGG16+RF500, which was applied to all individuals with the aim of identifying the best individual for our context. For our problem, the individual with the best performance was the second, with him the deterioration of characteristics was carried out with the Genetic Algorithm and Particle Swarm Optimization, the second being more efficient and with superior classification results. Finally, the performance of the system was compared with and without feature selection, which resulted in a three-fold reduction in training time and maintenance of average accuracy at around 75%. In this way, the proposed objectives were achieved and new tests should be carried out in future projects.

Keywords: Motor Imagery. EEG. Deep Learning.

1 INTRODUÇÃO

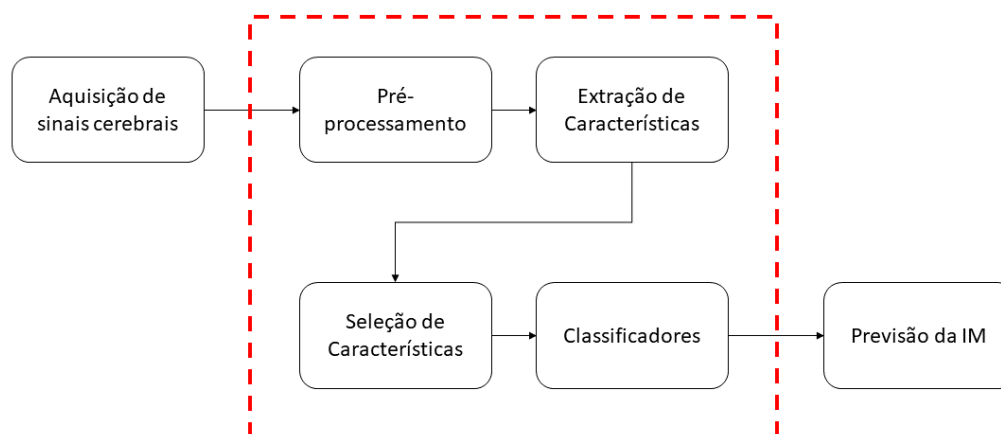
Pacientes com traumas neurológicos ou portadores de deficiências motoras ainda são muito dependentes. Em muitos desses casos, os sinais cerebrais não sofrem alterações quando os movimentos são imaginados, mesmo com a perda da mobilidade física. Esses sinais podem ser monitorados através do Eletroencefalograma (EEG) e servem como alimentação para Interfaces Cérebro-Máquinas, sendo essa tradução dos estímulos cerebrais útil e promissora para aplicações como controle de dispositivos assistivos, reabilitação, reconhecimento de emoções, etc.

Segundo Costa e Oliveira (2012), as interfaces cérebro-máquina (do inglês *Brain-computer interfaces*, BCI) interpretam sinais de EEG para realizar a interação do cérebro com o ambiente externo através de máquinas, traduzindo pensamentos conectados aos movimentos sem necessariamente ocorrer a realização do movimento. Para Gomes (2023), a imaginação do movimento sem sua realização é chamada de Imagética Motora (IM). Um diagrama em blocos simplificado para a implementação de uma BCI pode ser visto na Figura 1, os blocos dentro do quadrado vermelho correspondem as etapas abordadas neste trabalho.

Tendo em vista a importância do avanço desses sistemas, este Trabalho de Conclusão de Curso tem como objetivo geral desenvolver uma arquitetura de rede neural profunda com complexidade de tempo e de espaço minimizadas e desempenho maximizado de detecção e classificação dos movimentos imaginados usando um sistema

de aquisição de 22 eletrodos EEG. Também será proposta uma metodologia para seleção de características a partir de atributos implícitos que contenham informações mais relevantes para detecção dos movimentos imaginários.

Figura 1 – Diagrama em blocos BCI.



Fonte: A Autora.

Este projeto tem os seguintes objetivos específicos:

1. Desenvolver protótipos baseados em arquiteturas de redes neurais profundas de pesos aleatórios para extração de características em sinais não estacionários;
2. Desenvolver métodos baseados em Computação Evolucionária para seleção automática de características;
3. Construir uma máquina de aprendizado para classificação de sinais eletroencefalográficos de movimentos reais e imaginados.

2 FUNDAMENTAÇÃO TEÓRICA

Neste tópico, será visto conceitos necessários para a compreensão dos experimentos realizados neste TCC.

2.1 Aquisição dos dados

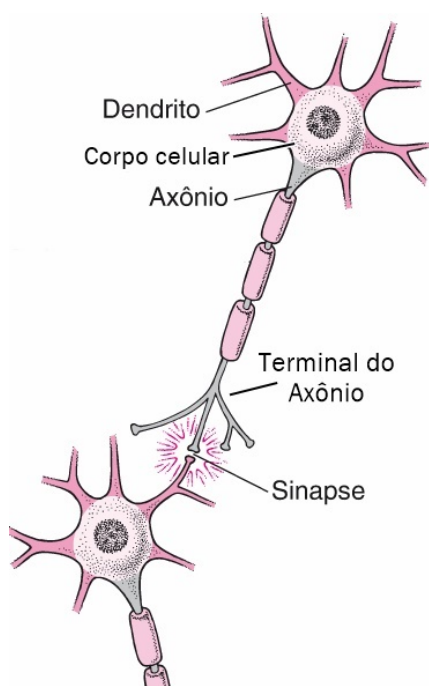
O estágio inicial do desenvolvimento de uma Interface Cérebro-Computador (BCI) compreende a aquisição de dados, sendo assim, este tópico apresenta conceitos essenciais para compreender o funcionamento do cérebro e o registro dos seus sinais.

2.1.1 Bases fisiológicas do EEG

Os neurônios são células responsáveis por converter diversos tipos de estímulos em sinais elétricos, esses sinais são chamados de potenciais de ação ou impulsos nervosos. Também são responsáveis por conduzir esses potenciais para outros neurônios, para o tecido muscular ou para glândulas. Devido a capacidade de geração dos potenciais de ação, os neurônios são considerados células excitáveis, visto que exibem excitabilidade elétrica (TORTORA; DERRICKSON, 2016).

Na Figura 2 pode-se ver as partes principais do neurônio para o entendimento do presente trabalho. Segundo Mendonça (2016) os dendritos e axônios são expansões do corpo celular, na Figura 2, o axônio é único e longo e os dendritos são ramificações curtas e numerosas quando comparados ao axônio. O corpo da célula possui o núcleo e suas organelas, sendo responsável pelo metabolismo celular.

Figura 2 – Estrutura de um neurônio



Fonte: Adaptado de MSD (2023).

O neurônio recebe os estímulos pelos dendritos e são transmitidos pelo axônio para outros dendritos, corpo celular de outro neurônio, ou células de outros tecidos. O ponto de contato entre dois neurônios é chamado de sinapse, e este possui dois lados: o pré-sináptico e pós-sináptico. O fluxo de informações habitual, ou transferência sináptica, ocorre do lado pré para o pós-sináptico e o espaço entre as membranas é chamado de fenda sináptica. Em uma sinapse, a terminação do axônio é definida como pré-sináptica e o dendrito como pós-sináptico (MENDONÇA, 2016; BEAR; CONNORS; PARADISO, 2017).

Além do potencial de ação, também chamado de potencial pós-sináptico inibitório (IPSP), as mudanças no potencial da membrana neuronal podem acontecer de forma lenta devido à ativação sináptica, podendo o último fenômeno ser definido como potencial pós-sináptico excitatório (EPSP) (MOTA GOMES, 2015).

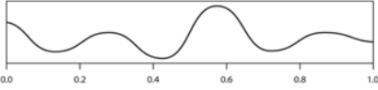
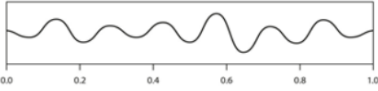
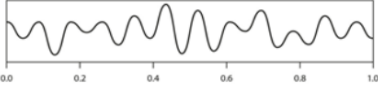
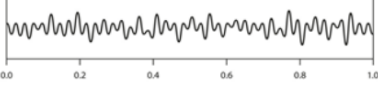
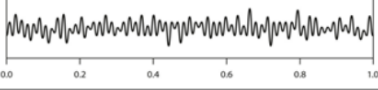
2.1.2 Sinais Eletroencefalográficos

O EEG funciona como um registrador das ondas causadas pelo fluxo de corrente das EPSP somadas às IPSP. Sendo uma medida de atividade elétrica a partir do escalpo (couro cabeludo) do paciente, que permite visualizar a atividade generalizada do córtex cerebral. A amplitude do sinal do Eletroencefalograma depende da sincronia da atividade dos neurônios, visto que a atividade de um único neurônio é incapaz de chegar até o eletrodo disposto no escalpo do paciente (MOTA GOMES, 2015; BEAR; CONNORS; PARADISO, 2017).

Normalmente, a amplitude do sinal de EEG, com eletrodos no escalpo, está entre 0 e $300\mu\text{V}$ e sua frequência entre 0,5 e 100Hz. As frequências presentes em um EEG variam por diversos fatores, por exemplo: estados do comportamento como atenção, sono ou vigília; presença de patologias; idade, entre outros (BLINOWSKA; DURKA, 2006 apud GOMES, 2023).

Nos momentos em que estamos relaxados, a atividade neuronal tende a sincronizar, portanto, no EEG temos maiores amplitudes, o oposto disso ocorre quando estamos acordados ou em estado de alerta. Devido à variação de frequência do sinal, o EEG pode ser categorizado de acordo com a Figura 3, vê-se, além do ritmo e faixa de frequência, o formato da onda e estado comportamental (BLINOWSKA; DURKA, 2006 apud GOMES, 2023).

Figura 3 – Principais ritmos cerebrais.


Ritmo cerebral	Faixa de frequência	Formato da onda	Estado comportamental
Delta	0,5 – 4 Hz		Sono profundo e reparador, perda de consciência corporal
Teta	4 – 8 Hz		Meditação profunda, sono REM, sonhos, consciência reduzida
Alfa	8 – 13 Hz		Relaxamento mental e físico, vigília com olhos fechados
Beta	13 – 32 Hz		Estado de consciência normal, acordado, pensando
Gama	32 – 100 Hz		Intensa atividade mental, alta concentração, resolução de problemas

Fonte: Gomes (2023).

Tratando-se de Imagética Motora, os sinais cerebrais utilizados são chamados de ritmos sensório-motores e o momento em que tem-se as maiores amplitudes dos sinais é chamado de Sincronização Relacionada a Evento (do inglês *Event-related Synchronization* - ERS), enquanto a diminuição da amplitude, devido à assincronia dos sinais, recebe o nome de Dessincronização Relacionada a Evento (do Inglês *Event-related Desynchronization* - EDR). Quando há a intenção de execução de um movimento, as atividades cerebrais são propagadas de diferentes maneiras no córtex cerebral, onde é possível observar alterações nas seguintes ondas cerebrais: μ , β e γ . O ritmo μ é similar a frequência α , porém, tem maior atividade nas áreas motoras e somatossensoriais (BEAR; CONNORS; PARADISO, 2017; NEUPER et al., 2009; GRAIMANN; ALLISON; PFURTSCHELLER, 2010 apud VAZ, 2016)

Segundo Otoni (2019), a coleta dos potenciais é feita por eletrodos metálicos localizados nas regiões de interesse que são dispostos de acordo com padrões, a exemplo do proposto pela *International Federation of Societies for Electroencephalography and Clinical Neurophysiology* (IFSECN) conhecido por Sistema Internacional 10-20. De acordo com esse sistema, os eletrodos deverão estar posicionados em intervalos de 10% a 20% da distância entre pontos de referência na cabeça, násis, íonion e pré-auriculares, como mostrado na Figura 4.

Figura 4 – Sistema Internacional 10-20.



Fonte: Vicente (2022).

2.2 Extração de características

Segundo Murilo Coutinho Silva (2012), características são quaisquer valores, estatísticas, padrões ou variáveis que diferenciam duas ou mais classes de um determinado problema. Sendo assim, a extração de características são as "técnicas ou transformações que, aplicadas a um determinado conjunto de dados, produzem um outro conjunto formado por características". A escolha das características influenciam diretamente no desempenho do classificador.

Para este Trabalho, serão utilizadas as características explícitas baseadas em tempo e frequência do sinal (descritas no Tópico Metodologia) e as características implícitas, que são produto das saídas das Redes Neurais utilizadas.

2.2.1 Redes Neurais Artificiais


De acordo com Furtado (2016), uma Rede Neural Artificial (RNA) pode ser definida como uma estrutura conexionista cujo processamento é realizado por um grande número de pequenas unidades, também chamados de neurônios artificiais. Esses neurônios densamente interligados e procuram replicar a estrutura do neurônio biológico e suas funções.

Para Feltrin (2020), as RNAs são:

Uma classe de algoritmos usados para encontrar e processar padrões complexos a partir de bases de dados usando estruturas lógicas chamadas perceptrons. Uma rede neural possui uma estrutura básica de entradas, camadas de processamento, funções de ativação e saídas.

A Figura 5 mostra o neurônio de McCulloch e Pitts que apesar de simples, continua sendo utilizado. Quando se compara as RNAs com as funções biológicas do cérebro, temos que os dendritos são os sinais de entrada, onde suas ligações são realizadas através de canais de comunicação que possuem um determinado peso sináptico associado, simulando as sinapses. No neurônio é onde é realizada a soma ponderada dos sinais de entrada, resultando em um determinado nível de atividade. Caso o nível de atividade exceda um limiar, determinado pela função de ativação, a unidade processadora produz uma dada resposta $f(a)$ na saída (FURTADO, 2016).

Figura 5 – Esquema de Unidade Processadora de McCulloch e Pitts.



Fonte: Adaptado de Carvalho (2023).

O modelo da Figura 5 pode ser representado matematicamente pela Equação 1 e Equação 2 para a saída:

$$a = X_1 \times W_1 + X_2 \times W_2 + \dots + X_p \times W_p \quad (1)$$

Onde:

X_n : sinais de entrada;

W_n : pesos sinápticos;

a : entrada para a função de ativação.

$$y = f(a) \quad (2)$$

Onde:

y : saída;

$f(a)$: função de ativação.

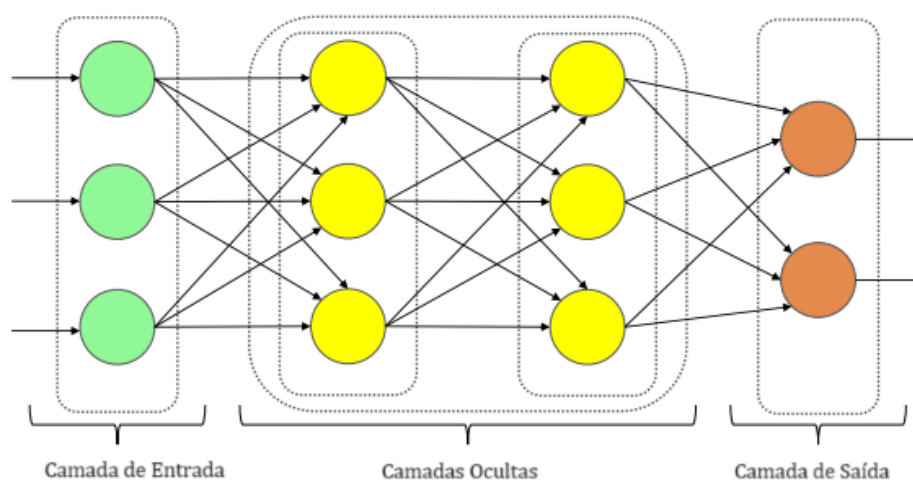
As camadas de processamento são as separações virtuais entre neurônios artificiais e suas conexões. As redes podem ter uma camada, mais de uma camada ou

camadas sobre camadas (*deep learning* ou aprendizado profundo). Em resumo, todos os modelos terão uma camada de entrada, alimentada pelo usuário ou pela base de dados, e camadas de saída, que representam o fim do processamento dos dados. Em alguns modelos de RNA, terão camadas ocultas aplicando funções de ativação ou filtrando as saídas das unidades de processamento. Quando houverem múltiplos neurônios em cada camada, a entrada da camada seguinte será a soma dos resultados de cada neurônio da camada anterior (FELTRIN, 2020).

2.2.2 Redes Profundas de Pesos Aleatórios

As Redes Neurais Profundas são baseadas em redes neurais artificiais, sendo assim, possuem o princípio básico explicado no tópico 2.2.1. O que diferencia uma RNA de uma rede profunda é a quantidade de camadas ocultas em sua arquitetura, como pode ser visto na Figura 6. Com as redes profundas é possível extrair atributos e reconhecer padrões implícitos da entrada (AQUINO BRÍTEZ et al., 2022).

Figura 6 – Arquitetura de uma Rede Profunda.



Fonte: Adaptado de Aquino Brítez et al. (2022).


Cada neurônio possui seu peso associado (visto na Figura 5) e uma das formas de inicialização desses pesos é a forma aleatória que evita a simetria dos pesos, fazendo com que os neurônios não executem o mesmo cálculo inicialmente, além de aumentar a precisão. Os pesos são inicializados em um valor muito próximo a zero (distribuição normal com duas casas decimais), porém, são pesos randômicos (ANANTHRAM, 2018).

2.2.3 Redes Neurais Convolucionais

As Redes Neurais Convolucionais (CNNs) são uma categoria de algoritmos baseados em RNA que possuem convolução em pelo menos uma de suas camadas. A Figura 7 é a representação de um dos primeiros projetos de redes convolucionais, a *LeNet*, utilizada para reconhecimento de caracteres. As redes neurais convolucionais são uma sequência de camadas com funções específicas na propagação do sinal de

entrada. Na entrada, tem-se imagens ou um conjunto delas e, na saída, a probabilidade da imagem da entrada pertencer a determinada classe no treinamento (ARAÚJO et al., 2017).

Figura 7 – Estrutura da *LeNet*.



Fonte: Araújo et al. (2017).

De acordo com Araújo et al. (2017), existem as seguintes camadas com suas respectivas funções:

1. **Camadas convolucionais:** extraem os atributos das entradas;
2. **Camadas de *pooling*:** reduzem a dimensionalidade das saídas das camadas convolucionais;
3. **Camadas totalmente conectadas:** propagam o sinal por meio da multiplicação ponto a ponto e fazem o uso da função de ativação.

As camadas convolucionais extraem informações sobre as relações entre pixels vizinhos de pequenas partes da imagem, a convolução (matematicamente $*$) pode ser definida como o somatório do produto entre duas funções, que nesse caso seria a entrada e o filtro de acordo com a Equação 3. O custo computacional está diretamente ligado à quantidade de multiplicações necessárias em seu processamento. (AQUINO BRÍTEZ et al., 2022)

$$s(x) = (f * g)[x] = \sum_{i=1}^n f(i) \times g[x - i] \quad (3)$$

Onde:

x : uma variável discreta;

n : tamanho do filtro;


$g(x)$: filtro;

$f(x)$: entrada.

$f(x)$: saída.

Existem diversas arquiteturas de redes neurais convolucionais, neste trabalho, foi usada a *InceptionV3* e VGG16, Figura 8 pode ser vista a configuração da rede *InceptionV3*, que alcançou mais de 78,1% de precisão quando treinada com o conjunto de dados ImageNet (GOOGLECLOUD, 2023).


Figura 8 – Estrutura da *InceptionV3*.



Fonte: GoogleCloud (2023).

A VGG16 tem por objetivo a classificação de imagens em categorias, e tem 92,7% no conjunto ImageNet, a Figura 9 traz a sua configuração (ROHINI, 2021).

Figura 9 – Estrutura da VGG16.



Fonte: Rohini (2021).

2.3 Seleção de Características com Computação Evolucionária

O EEG possui uma alta dimensionalidade, e diversas características de representação, quanto maior a quantidade de atributos maior custo computacional para treinamento dos modelos, resultando no uso de muita memória do sistema. Além disso, atributos irrelevantes podem afetar negativamente o desempenho do modelo. Portanto, a etapa de seleção de característica faz-se necessária para a minimização dos problemas citados (VARGAS, 2022).

A Computação Evolucionária tem como base os processos evolutivos observados na natureza, baseados na Teoria da Evolução Natural de Charles Darwin. Apesar da existência de muitos grupos de algoritmos evolucionários, o princípio é o mesmo: o ambiente tem recursos limitados e apenas os organismos mais aptos podem sobreviver. As mutações alteram a aptidão do organismo e podem (ou não) ser transmitidas aos organismos da próxima geração após a recombinação. A combinação desses fatores melhoram o desempenho de cada população (SANTA CATARINA, 2023; SILVA, R. F. P. E., 2021).

Existe uma categoria adicional de algoritmos evolucionários que se fundamenta predominantemente no comportamento social observado em animais, embora não se enquadre estritamente nos princípios estabelecidos por Charles Darwin. Apesar dessa distinção, essa abordagem ainda é reconhecida e classificada como computação evolutiva. Como o sucesso da espécie depende da interação entre os vários indivíduos, esses algoritmos são classificados como algoritmos de inteligência coletiva (SILVA, R. F. P. E., 2021).

2.3.1 Algoritmos Genéticos

Os Algoritmos Genéticos situam-se na categoria de algoritmos baseados na Teoria da Evolução Natural, onde, os indivíduos mais aptos sobrevivem mais tempo, aumentando a sua probabilidade de reprodução. Indivíduos com maior quantitativo tem mais chance de passarem seus códigos genéticos para a próxima geração. Computacionalmente, essa Teoria é simulada buscando a melhor solução para o problema através da evolução das populações de soluções codificadas a partir de cromossomas artificiais (PACHECO, 2004).

Segundo Pacheco (2004), a estrutura de dados que representa possíveis soluções para o problema é chamada de cromossomas artificiais. Por meio da seleção, recombinação e mutação, a população inicial evolui ao longo de gerações simuladas em direção a gerações com maior aptidão e, ao final, o indivíduo representa uma solução codificada, correspondente aos cromossomos na evolução natural, que é chamado de genótipo. O genótipo passa, enfim, por uma função de avaliação que determina seu desempenho (SANTA CATARINA, 2023).

A primeira geração de uma população é criada de forma aleatória, onde cada indivíduo possui uma possível solução para o problema, posteriormente, o indivíduo passa pela função de avaliação que, sem saber a resolução do problema, atribui uma nota ao indivíduo, ao final, o operador gera uma nova população baseada na geração anterior. Os principais operadores são: (SANTA CATARINA, 2023).

2.4 Classificadores

Nesta sessão, será definido o funcionamento dos seguintes classificadores: *Random Forest* (RF), J48 e Máquinas de Vetor de Suporte (SVM).


2.4.1 Árvores de Decisão

As árvores de decisão são estruturas que atuam classificando instâncias ordenando-as em sub-árvores. Cada nó avalia a instância em função de algum atributo, e cada ramo segue uma possível classificação do atributo (MENOTTI, 2018).

Um dos algoritmos que permite a criação de modelos de decisão em árvore é chamado de J48, as árvores são induzidas a partir da tecnologia *greedy*, sendo o modelo construído a partir da análise dos dados de treino e teste de dados não vistos anteriormente. A árvore é construída do topo para a base a partir da avaliação da significância do atributo para a classificação (MARTINS; MARQUES; COSTA, 2009).

Random Forest é um algoritmo que tem por objetivo de criar um conjunto de árvores de decisão usando subconjuntos de atributos aleatórios, os subconjuntos são usados em cada nó da RF e passam por uma avaliação onde é decidido qual subconjunto apresenta melhores regras para a classificação. A quantidade de árvores pode ser informada pelo usuário. Na Figura 11, vemos a estrutura básica de uma *Random Forest* (TELOKEN et al., 2016).

Figura 11 – Arquitetura da *Random Forest*.



Fonte: Teloken et al. (2016).

2.4.2 Máquinas de vetor de suporte


A SVM é um algoritmo com a capacidade de resolver problemas de classificação e regressão através da generalização, aprendida na etapa de treinamento do algoritmo. Uma função é obtida na etapa de treinamento para separação das instâncias. O objetivo final é utilizar essa função em um problema nunca visto pela rede e classificando

assim novas entradas. O classificador é construído com base em padrões do conjunto de treinamento (OLIVEIRA JUNIOR, 2010).


O treinamento do classificador tem por objetivo encontrar o hiperplano ótimo de separação das classes, que seria o hiperplano com a maior margem possível que separe as duas classes. Na Figura 12, vemos dois exemplos de hiperplanos de separação, na Figura 12a temos o hiperplano com uma margem pequena e na Figura 12b o hiperplano ótimo (OLIVEIRA JUNIOR, 2010).

Figura 12 – Exemplos de Hiperplanos.

(a) Hiperplano de separação com margem pequena.



(b) Hiperplano ótimo.




Fonte: Oliveira Junior (2010).

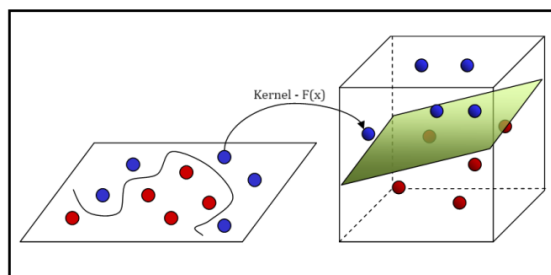
Na Figura 12, as classes são ditas linearmente separáveis, porém, na Figura 13a o conjunto de dados não é linearmente separável. Dessa forma, é necessário mapear os pontos da Figura 13a em uma dimensão maior, vista na Figura 13b. Depois do mapeamento, é possível separar as duas classes linearmente por um hiperplano. A função do mapeamento é chamado de *Kernel*, que pode ser de vários tipo, por exemplo: polinomial, gaussiano (ou RBF) e sigmoidal. O parâmetro *Kernel* é definido pelo usuário no momento da configuração da rede (NORONHA; FERNANDES, 2016; OLIVEIRA JUNIOR, 2010).

Figura 13 – Conjunto não linear

(a) Conjunto de dados



(b) Transformação com a função de Kernel

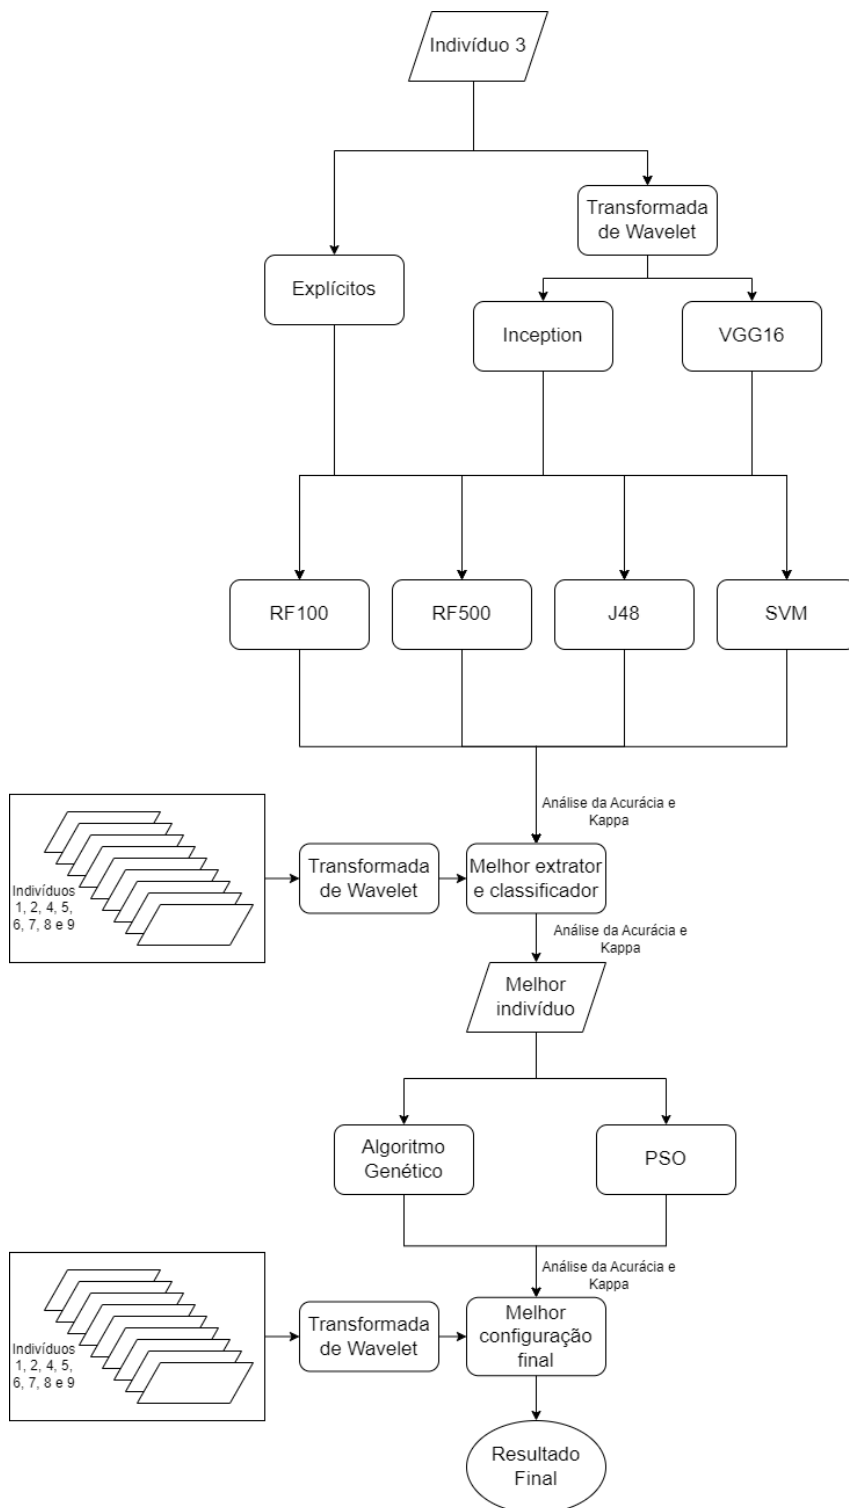


Fonte: Adaptado de Noronha e Fernandes (2016).

3 METODOLOGIA

A Figura 14 apresenta o fluxograma da metodologia do Trabalho que será detalhado nos parágrafos seguintes.


Figura 14 – Metodologia dos Experimentos.



Fonte: A Autora.

Como visto anteriormente na Figura 1, a primeira etapa de uma BCI é a aquisição dos dados. Dessa forma, para realização desse trabalho utilizou-se sinais de EEG da base de dados BCI Competition IV 2a (IV, 2008), que possui sinais de 9 indivíduos distribuídos em 4 classes de movimento: mão direita, mão esquerda, pés e língua. Cada indivíduo realizou 6 execuções (*Run*) de imagética motora, cada uma com 12 ensaios para cada classe, totalizando 48 ensaios de IM. No início de cada sessão foi realizada uma etapa de movimento dos olhos para estimar a influência deste durante a realização da IM. Na Figura 15, pode-se verificar como foi realizada a divisão de ensaios em cada sessão.


Figura 15 – Esquema de uma sessão.



Fonte: Brunner et al. (2008).

A Figura 16 apresenta como foi realizado cada ensaio, onde inicialmente é acionado um beep, seguido de uma cruz de fixação no monitor, onde posteriormente aparece uma seta indicando qual movimento deverá ser realizado. No terceiro momento foi realizado o registro da imagética motora seguido de um intervalo.

Figura 16 – Esquema de uma sessão.



Fonte: Brunner et al. (2008).

A base de dados contém 25 eletrodos, 22 referentes a sinais de EEG e 3 de sinais de eletrooculograma (EOG). Porém, utilizou-se apenas os 22 eletrodos referentes ao EEG, a influência do EOG será determinada em trabalhos futuros. A frequência de amostragem do sinal utilizada 250Hz. Os arquivos disponibilizados pela base são do tipo ".gdf" e foram extraídos com o *software* GNU Octave, resultando em arquivos ".m" (vetores) divididos por ensaios, classes, eletrodos e indivíduos.


Tomando como referência Ang et al. (2012) e Almeida (2021), a primeira etapa de extração e treinamento foram realizadas com o terceiro indivíduo, pois este apresentou melhores resultados em seus experimentos. A etapa de extração de características foi dividida em três tipos: características extraídas diretamente dos vetores, extraídas a partir das redes profundas pré-treinadas *Inception* e VGG16. Cada tipo de extração gerou um arquivo do tipo ARFF a ser usado posteriormente.

Os descritores explícitos foram extraídos usando o algoritmo desenvolvido por Gomes (2023), no GNU Octave, o qual tem como atributos os seguintes itens: mudança média de amplitude, *difference absolute deviation*, *integrated absolute value*, detector logarítmico, valor médio absoluto, *mean logarithm Kernel*, erro médio quadrático, curtose, *slope sign changes*, *simple square integral*, variância, comprimento de onda, detector de passagem por zeros, terceiro momento, quarto momento, quinto momento, desvio padrão, valor médio, amplitude máxima, densidade espectral de potência, frequência de pico, potência média, frequência média, frequência mediana, potência total, variância da frequência central, primeiro momento espectral, segundo momento espectral, terceiro momento espectral, assimetria, parâmetro de atividade de Hjorth, parâmetro de mobilidade de Hjorth e parâmetro de complexidade de Hjorth,

Para a extração de características com as redes profundas utilizou-se como entrada imagens da transformada de Wavelet dos sinais no arquivo ".m", esse processo foi realizado usando o *Python*. Na Figura 17, pode-se ver um exemplo de imagem de entrada.

Para a extração da imagem da transformada de Wavelet, foi utilizada a biblioteca PyWavelets (LEE et al., 2019). Essas imagens correspondem a um eletrodo, no período total do evento, portanto, para um evento, foram obtidas 22 imagens. Foi utilizada a Wavelet Morlet, na Figura 17 os eixos não são indicados, para que as análises não sofram influência das bordas da imagem. O eixo x corresponde ao tempo, o y corresponde a frequência e a cor é função da potência daquela frequência naquele determinado instante de tempo.

Figura 17 – Exemplo de imagem da transformada de Wavelet.



Fonte: A Autora.

Desse conjunto de imagens, foram extraídos os atributos usando as redes pré-

treinadas *Inception* e VGG16, implementados no *software* Weka. Cada extração de características resultou em um arquivo ARFF com atributos e suas respectivas classes, o qual foi utilizado como entrada para o treinamento das seguintes redes: *Random Forest* com 100 e 500 árvores, J48 e SVM. Os experimentos foram feitos utilizando validação cruzada com 10 *folds* e 10 repetições para cada classificador.

Todos os resultados foram analisados a partir da avaliação da taxa de acerto da rede, chamada Acurácia definida a partir da Equação 4, e do Índice Kappa, que identifica o quanto o método acerta suas previsões, incluindo o acerto aleatório e pode ser definido a partir da Equação 5 (SANTANA et al., 2021).

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

Onde:

TP: quantidade de verdadeiros positivos;

TN: quantidade de verdadeiros negativos;

FP: quantidade de falsos positivos;

FN: quantidade de falsos negativos.

$$K = \frac{\rho_o - \rho_e}{1 - \rho_e} \quad (5)$$

Onde:

ρ_o : Acurácia;

ρ_e : taxa de concordância definida pela Equação 6.

$$\rho_e = \frac{(TP + FP)(TP + FN) + (FN + TN)(FP + TN)}{(TP + FP + FN + TN)^2} \quad (6)$$

Onde:

TP: quantidade de verdadeiros positivos;

TN: quantidade de verdadeiros negativos;

FP: quantidade de falsos positivos;

FN: quantidade de falsos negativos.

A melhor configuração de extração de características e classificação foi usada para todos os indivíduos. Selecionado o indivíduo com melhor desempenho para nossos experimentos, foram realizados os experimentos de seleção de características com o Algoritmo Genético e o PSO. Por fim, a partir do mais eficiente seletor, treinou-se a rede com todos os indivíduos em conjunto com o melhor extrator e seletor de características com o melhor classificador.

A etapa de extração de características foi realizada em um notebook com o processador AMD Ryzen 5-5600U com 8GB de memória RAM, as demais etapas foram

realizados em um notebook com o processador AMD Ryzen 5-5500U com 18GB de memória RAM.

4 RESULTADOS E DISCUSSÕES

Como citado na metodologia, o primeiro teste foi realizado utilizando o indivíduo 3 da BCI Competition, os extratores de características e classificadores estão descritos na Tabela 1. A melhor configuração desse experimento foi utilizando a extração de características com a rede profunda pré-treinada VGG16 e com o classificador *Random Forest* com 500 árvores.

Para a mesma extração de características, obteve-se um desempenho semelhante com o classificador SVM, porém, enquanto o RF500 teve um tempo médio de treinamento de 80722ms o SVM apresentou um tempo médio de 1011544.844ms, aproximadamente 12 vezes maior que o anterior.

Tabela 1 – Acurácia e Índice Kappa do desempenho do indivíduo 3 nas configurações descritas.

Indivíduo 3			
Extrator de Características	Classificador	Acurácia	Kappa
Descritores Explícitos	RF100	52,30% ± 0,95%	0,360 ± 0,013
	RF500	52,86% ± 0,92%	0,370 ± 0,012
	J48	48,31% ± 1,07%	0,310 ± 0,014
	SVM	34,8% ± 0,83%	0,130 ± 0,011
InceptionV3	RF100	51,80% ± 2,03%	0,357 ± 0,027
	RF500	56,40% ± 2,29%	0,418 ± 0,030
	J48	35,68% ± 1,66%	0,140 ± 0,022
	SVM	62,14% ± 1,80%	0,495 ± 0,024
VGG16	RF100	68,42% ± 1,86%	0,579 ± 0,020
	RF500	73,20% ± 1,83%	0,640 ± 0,024
	J48	43,75% ± 2,39%	0,250 ± 0,032
	SVM	72,34% ± 1,74%	0,630 ± 0,023

Fonte: A Autora.

Com a configuração VGG16 + RF500, foi realizado o treinamento de todos os indivíduos da base de dados, tendo como métricas os valores da Tabela 2, no presente trabalho, o indivíduo com melhor desempenho foi o 2, sendo este escolhido para a próxima etapa. A escolha do segundo indivíduo se deu devido à eficiência superior observada em seu ensaio de imagética, considerando as configurações específicas. É importante ressaltar que essa escolha não implica que o sistema seja ineficaz para os demais indivíduos. Cada pessoa pode apresentar variações singulares, e a seleção foi baseada na performance notável dentro dos parâmetros estabelecidos, mas não exclui a viabilidade do sistema para os demais participantes.

Tabela 2 – Acurácia e Índice Kappa do desempenho de todos indivíduos com VGG16 + RF500.

VGG16 + RF500		
Indivíduo	Acurácia	Kappa
1	74,00% ± 2,00%	0,650 ± 0,027
2	87,87% ± 1,62%	0,745 ± 0,022
3	73,20% ± 1,83%	0,640 ± 0,024
4	76,00% ± 1,58%	0,680 ± 0,021
5	83,00% ± 1,44%	0,776 ± 0,019
6	73,00% ± 1,90%	0,638 ± 0,026
7	75,00% ± 1,65%	0,669 ± 0,022
8	73,42% ± 2,05%	0,645 ± 0,027
9	67,45% ± 2,23%	0,564 ± 0,030

Fonte: A Autora.

Após o treinamento da rede com as configurações descritas na Tabela 2, realizou-se a seleção de características no indivíduo 2 usando o Algoritmo Genético e o PSO. O resultado dessa etapa pode ser visto na Tabela 3, onde verifica-se que o método de seleção de características com o maior desempenho baseado na Acurácia e Índice Kappa foi o PSO. A quantidade total de atributos extraídos pelas redes *InceptionV3* e VGG16 foi de 2049 e 4097, respectivamente. Após a seleção de características, foram obtidos 70 atributos com os algoritmos genéticos e 748 com o PSO.

Tabela 3 – Acurácia e Índice Kappa do desempenho do indivíduo 2 com a seleção de características.

Indivíduo 2 (VGG16 + RF500)		
Seletor de Características	Acurácia	Kappa
Algoritmo Genético	75,66% ± 1,67%	0,675 ± 0,022
PSO	82,94% ± 1,49%	0,773 ± 0,020

Fonte: A Autora.

Por fim, aplicou-se o PSO em toda a base de dados para verificação do desempenho geral, onde o resultado pode ser visto na Tabela 4. Comparando o desempenho das configurações, verifica-se uma redução entre os resultados da Tabela 2 e os da Tabela 4, porém, obteve-se uma redução em 3 vezes no tempo de processamento com a seleção de características. A tarefa de classificação leva, em média, 91070.94ms ao utilizar todos os atributos, enquanto a execução com apenas os atributos selecionados requer, em média, 28089.06ms.

Tabela 4 – Acurácia e Índice Kappa do desempenho de todos indivíduos com a seleção de características.

VGG16 + PSO + RF500		
Indivíduo	Acurácia	Kappa
1	72,69% ± 1,93%	0,636 ± 0,026
2	82,94% ± 1,49%	0,773 ± 0,020
3	72,66% ± 2,04%	0,635 ± 0,027
4	75,42% ± 1,87%	0,672 ± 0,025
5	82,42% ± 1,42%	0,765 ± 0,019
6	72,20% ± 1,95%	0,628 ± 0,026
7	74,63% ± 1,68%	0,660 ± 0,022
8	72,97% ± 1,95%	0,693 ± 0,026
9	66,79% ± 2,33%	0,555 ± 0,031

Fonte: A Autora.

Comparando os resultados obtidos nesse estudo com outros trabalhos que usaram a mesma base de dados, Almeida (2021) utilizou experimentos com 3 tipos de configuração: (a) a extração de características com o Padrão Espacial Comum (CSP), sendo classificada com o SVM; (b) a Decomposição de Modo Empírico (EMD), também classificada com o SVM; e (c) a CNN sem pré-treinamento. É possível observar a partir da Tabela 5 que os resultados do presente trabalho ficaram abaixo da primeira configuração, mas superaram as demais configurações de Almeida (2021).

Saputra, Setiawan e Ardiyanto (2019) também utilizaram a extração de características CSP associada aos classificadores *Deep Belief Network* (DBN) e *Long Short Term Memory* (LSTM). Comparando os resultados obtidos por Saputra, Setiawan e Ardiyanto (2019), observa-se que neste trabalho obteve-se resultados superiores com as arquiteturas testadas.

Tabela 5 – Comparação de desempenho com a literatura de acordo com a Acurácia.

Referência	Configuração	Acurácia Média
Almeida (2021)	CSP + SVM	0,82
	EMD + SVM	0,26
	CNN	0,61
Saputra, Setiawan e Ardiyanto (2019)	CSP + DBN	0,503
	CSP + LSTM	0,496
Presente trabalho	VGG16 + RF500	0,759
	VGG16 + PSO + RF500	0,747

Fonte: A Autora.

5 CONSIDERAÇÕES FINAIS

Este estudo propôs o desenvolvimento de uma arquitetura focada na minimização do tempo e do espaço, enquanto buscava maximizar o desempenho. Foram testados três tipos de extração de características: atributos explícitos, atributos extraídos com a rede profunda *InceptionV3* e *VGG16*, aplicados em quatro tipos de seletores: RF100, RF500, J48 e SVM. A melhor configuração encontrada foi *VGG16+RF500*, com estes resultados foram testados dois tipos de algoritmos de seleção de características: o algoritmo genético e o PSO. Tendo por fim, o PSO o de melhor desempenho entre os dois.

Com base nos resultados alcançados, é possível concluir que as configurações testadas para seleção de características demonstraram a capacidade comprovada de reduzir substancialmente o tempo de treinamento e a quantidade de atributos necessários. Tendo como resultado final a diminuição em cerca de 5,5 vezes na quantidade de atributos resultando em uma diminuição de aproximadamente 3 vezes no tempo médio de treinamento da rede. Isso foi alcançado mantendo a acurácia média em valores próximos, inicialmente com 75,88% de acerto e após a seleção de atributos com 74,75% de acerto.

Essas descobertas representam uma contribuição significativa para o avanço dos sistemas de Interface Cérebro-Computador (BCI). Os protótipos baseados em arquiteturas de redes neurais profundas de pesos aleatórios para extração de características em sinais não estacionários foram desenvolvidos com sucesso. Além disso, métodos baseados em Computação Evolucionária foram implementados para a seleção automática de características. Esses avanços culminaram na construção de uma máquina de aprendizado capaz de classificar sinais eletroencefalográficos de movimentos reais e imaginados.

Essa abordagem possibilita trabalhar com menos dados, resultando em tempos de processamento reduzidos, sem comprometer significativamente o desempenho. Esse aspecto é crucial para aprimorar a eficiência dos sistemas de BCI. O impacto positivo se estende à qualidade de vida de pacientes com traumas neurológicos ou deficiências motoras, promovendo sua independência e aprimorando suas condições de vida.

Em trabalhos futuros podem ser testados outros tipos de arquiteturas, com outros extratores de características e classificadores para a verificação do desempenho de novas configurações, objetivando a melhoria do desempenho e redução do tempo de treinamento e resposta. Outra análise que pode ser feita é sobre o tempo total de processamento em todas as etapas da BCI executadas em uma única máquina. Por fim, é necessário verificar os desempenhos de cada indivíduo, pois os padrões cerebrais dos indivíduos são diferentes entre si, e ainda no mesmo indivíduo, devido a neuroplasticidade.

REFERÊNCIAS

- ALMEIDA, Wallace Faveron de. **Técnicas de aprendizado de máquina para interfaces cérebro-computador baseadas em EEG**. 2021. Diss. (Mestrado) – Universidade de São Paulo.
- ANANTHRAM, Aditya. **Random Initialization For Neural Networks: A Thing Of The Past**. [S.l.: s.n.], 2018. Disponível em: <https://towardsdatascience.com/random-initialization-for-neural-networks-a-thing-of-the-past-bfcdd806bf9e>. Acesso em: 06 de novembro de 2023.
- ANG, Kai Keng et al. Filter Bank Common Spatial Pattern Algorithm on BCI Competition IV Datasets 2a and 2b. **Frontiers in Neuroscience**, v. 6, 2012.
- AQUINO BRÍTEZ, Diego Ariel et al. **Optimización multi-objetivo de arquitecturas de aprendizaje profundo para el procesamiento de señales EEG en plataformas de cómputo heterogéneas**. 2022. Tese (Doutorado) – Universidad de Granada, Granada.
- ARAÚJO, Flávio H. D. et al. **Redes Neurais Convolucionais com Tensorflow: Teoria e Prática**. III Escola Regional de Informática do Piauí: Livros Anais - Artigos e Minicursos, 2017.
- BEAR, Mark F; CONNORS, Barry W; PARADISO, Michael A. **Neurociências: desvendando o sistema nervoso**. [S.l.]: Artmed editora, 2017.
- BLINOWSKA, Katarzyna; DURKA, Piotr. Electroencephalography (eeg). **Wiley encyclopedia of biomedical engineering**, Citeseer, 2006.
- BRUNNER, Clemens et al. BCI Competition 2008–Graz data set A. **Institute for Knowledge Discovery (Laboratory of Brain-Computer Interfaces), Graz University of Technology**, v. 16, p. 1–6, 2008.
- CARVALHO, André Ponce de Leon F. **Redes Neurais Artificiais**. [S.l.: s.n.], 2023. Disponível em: <https://sites.icmc.usp.br/andre/research/neural/>. Acesso em: 03 de novembro de 2023.
- COSTA, Renato Carrasco; OLIVEIRA, Vanessa Mendes. **Um Estudo sobre Interface Cérebro-Computador**. 2012. Monografia (Graduação) – Universidade de Brasília, Brasília.
- EBERHART R, Kennedy J. New optimizer using particle swarm theory. **Proc Int Symp Micro Mach Hum Sci**, p. 39–43, 1995.
- FARIAS, AL et al. ESTUDO SOBRE A OTIMIZAÇÃO POR ENXAME DE PARTÍCULAS (PSO-PARTICLE SWARM OPTIMIZATION). **18o Seminário de Pesquisa & Iniciação Científica**, p. 58–62, 2020.
- FELTRIN, Fernando. **Redes Neurais Artificiais**. 1. ed. [S.l.]: Uniorg, 2020.
- FURTADO, Maria Inês Vasconcellos. **Redes Neurais Artificiais: Uma Abordagem Para Sala de Aula**. Ponta Grossa (PR): Atena, 2016.
- GOMES, Juliana Carneiro. **ASTERI: representação de sinais de eletroencefalografia em imagens para utilização de arquiteturas profundas baseadas em CNN**. 2023. Tese (doutorado em Engenharia da Computação) – UPE, Escola Politécnica, Recife.

GOOGLECLOUD. **Guia avançado do Inception v3**. [S.l.: s.n.], 2023. Disponível em: <https://cloud.google.com/tpu/docs/inception-v3-advanced?hl=pt-br>. Acesso em: 13 de janeiro de 2024.

GRAIMANN, Bernhard; ALLISON, Brendan; PFURTSCHELLER, Gert. Brain-computer interfaces: A gentle introduction. **Brain-computer interfaces: Revolutionizing human-computer interaction**, Springer, p. 1–27, 2010.

IV, BCI Competition. Berlim: [s.n.], 2008. Disponível em: <https://bbci.de/competition/iv/>. Acesso em: 23 de dezembro 2023.

LEE, Gregory et al. PyWavelets: A Python package for wavelet analysis. **Journal of Open Source Software**, The Open Journal, v. 4, n. 36, p. 1237, 2019.

MARTINS, António Cardoso; MARQUES, MJ; COSTA, Paulo Dias. **Estudo comparativo de três algoritmos de machine learning na classificação de dados electrocardiográficos**. 2009. Diss. (Mestrado) – Universidade do Porto, Porto.

MENDONÇA, Vivian L. **Biologia: ecologia: origem da vida e biologia celular embriologia e histologia**. 3. ed. São Paulo: Editora AJS, 2016. v. 1.

MENOTTI, David. **Árvores de Decisão**. Paraná: UFPR, 2018. Disponível em: <https://www.inf.ufpr.br/menotti/ci171-182/slides/ci171-arvoresdecisao.pdf>. Acesso em: 11 de janeiro 2024.

MOTA GOMES, Marleide da. Bases fisiológicas do eletroencefalograma. **Revista Brasileira de Neurologia**, v. 51, n. 1, 2015.

MSD, Manual. **Estrutura típica de um Neurônio**. [S.l.: s.n.], 2023. Disponível em: <https://www.msmanuals.com/pt/casa/multimedia/figure/estrutura-t%C3%ADpica-de-um-neur%C3%B4nio>. Acesso em: 16 de outubro 2023.

NEUPER, Christa et al. Motor imagery and action observation: modulation of sensorimotor brain rhythms during mental control of a brain-computer interface. **Clinical neurophysiology**, Elsevier, v. 120, n. 2, p. 239–247, 2009.

NORONHA, Daniel H; FERNANDES, Marcelo AC. Implementação em fpga de máquina de vetores de suporte (svm) para classificação e regressão. **XIII Encontro Nacional de Inteligência Artificial e Computacional-ENIAC**, 2016.

OLIVEIRA JUNIOR, Gilson Medeiros. **Máquina de Vetores Suporte: estudo e análise de parâmetros para otimização de resultado**. 2010. Monografia (Graduação) – Universidade Federal de Pernambuco, Recife.

OTONI, Julliano da Silva. **Desenvolvimento de um aparelho de eletroencefalografia mobile de baixo custo**. 2019. Diss. (Mestrado) – Universidade Estadual Paulista "Júlio de Mesquita Filho", Instituto de Biociências de Botucatu.

PACHECO, Marco Aurélio Cavalcanti. **ALGORITMOS GENÉTICOS: PRINCÍPIOS E APLICAÇÕES**. [S.l.: s.n.], 2004.

ROHINI. **Everything you need to know about VGG16**. [S.l.]: Medium, 2021. <https://medium.com/@mygreatlearning/everything-you-need-to-know-about-vgg16-7315defb5918>.

SANTA CATARINA, Adair. **INTRODUÇÃO À COMPUTAÇÃO EVOLUTIVA**. [S.l.: s.n.], 2023.

SANTANA, Maíra Araújo et al. Identificação automática de emoções a partir de sinais fisiológicos periféricos e centrais. **Anais do V Simpósio de Inovação em Engenharia Biomédica - SABIO 2021**, Recife, p. 39–46, 2021.

SAPUTRA, Muhammad Fawaz; SETIAWAN, Noor Akhmad; ARDIYANTO, Igi. Deep learning methods for EEG signals classification of motor imagery in BCI. **IJITEE (International Journal of Information Technology and Electrical Engineering)**, v. 3, n. 3, p. 80–84, 2019.

SILVA, Murilo Coutinho. **Selecionador de Características para classificação de sinais de EEG e construção de Interfaces Cérebro-Máquina**. 2012. Diss. (Mestrado) – Universidade de Brasília, Brasília.

SILVA, Rui Filipe Pinto Esteves. **OTIMIZAÇÃO DO CONSUMO DE ENERGIA POR RECURSO A TÉCNICAS DE COMPUTAÇÃO EVOLUCIONÁRIA**. 2021. Diss. (Mestrado) – Universidade NOVA de Lisboa, Lisboa.

TELOKEN, Alex et al. Estudo Comparativo entre os algoritmos de Mineração de Dados Random Forest e J48 na tomada de Decisão. **Simpósio de Pesquisa e Desenvolvimento em Computação**, v. 2, n. 1, 2016.

TORTORA, Gerard J; DERRICKSON, Bryan. **Princípios de anatomia e fisiologia**. Traduzido por Ana Cavalcanti C. Botelho *et al.* Rio de Janeiro: Guanabara Koogan, 2016. v. 14.

VARGAS, Dionathan Luan de. **EXTRAÇÃO E SELEÇÃO DE CARACTERÍSTICAS DE SINAIS DE ELETROENCEFALOGRAMA PARA DIAGNÓSTICO DE CRISES EPILÉTICAS**. 2022. Diss. (Mestrado) – Universidade Tecnológica Federal do Paraná, Pato Branco.

VAZ, Yule. **Extração de características para a classificação de imagética motora em interfaces cérebro-computador**. 2016. Tese (Doutorado) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos.

VICENTE, Edrin. **Sistema 10-20 para localizar alvos terapêuticos em EMT**. [S.l.: s.n.], 2022. Disponível em: <https://www.kandel.com.br/post/como-localizar-os-pontos-de-estimulacao-para-estimulacao-magnetica-transcraniana>. Acesso em: 21 de outubro 2023.