



UNIVERSIDADE FEDERAL DO PARÁ  
CAMPUS UNIVERSITÁRIO DE ALTAMIRA  
FACULDADE DE MEDICINA

**JULIANO MATEUS DE ALMEIDA**

**REDE NEURAL ARTIFICIAL PARA DETECÇÃO DO ESTADO OCULAR  
USANDO SINAL DE EEG.**

**ALTAMIRA  
2023**



UNIVERSIDADE FEDERAL DO PARÁ  
CAMPUS UNIVERSITÁRIO DE ALTAMIRA  
FACULDADE DE MEDICINA

**JULIANO MATEUS DE ALMEIDA**

**REDE NEURAL ARTIFICIAL PARA DETECÇÃO DO ESTADO OCULAR  
USANDO SINAL DE EEG.**

Trabalho de conclusão de curso apresentado para obtenção do título de Médico pela Universidade Federal do Pará, campus Altamira.

Professor Orientador: Msc. Denis Vieira Gomes Ferreira.

Examinador:

Nota:

Data:

Examinador:

Nota:

Data:

**ALTAMIRA  
2023**

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD  
Sistema de Bibliotecas da Universidade Federal do Pará  
Gerada automaticamente pelo módulo Ficat, mediante os dados fornecidos pelo(a)  
autor(a)

---

A447r Almeida, Juliano Mateus.  
REDE NEURAL ARTIFICIAL PARA DETECÇÃO DO  
ESTADO OCULAR USANDO SINAL DE EEG / Juliano  
Mateus Almeida. — 2023.  
55 f. : il. color.

Orientador(a): Prof. Me. Denis Vieira Gomes Ferreira  
Trabalho de Conclusão de Curso (Graduação) -  
Universidade Federal do Pará, Campus Universitário de  
Altamira, Faculdade de Medicina, Altamira, 2023.

1. Sistema nervoso. 2. Rede Neural Artificial do tipo  
Perceptron de Múltiplas Camadas (MLP). 3. EEG. 4.  
Interface cérebro-computador. I. Título.

CDD 616.027

---

## RESUMO

Este trabalho aborda a aplicação de redes neurais artificiais na detecção do estado ocular através do sinal de Eletroencefalograma (EEG). O objetivo foi descrever a neurofisiologia, bem como o funcionamento de um sistema de interface cérebro-computador, utilizando uma Rede Neural do tipo Perceptron de Múltiplas Camadas (MLP - Multi Layer Perceptron) para prever o estado ocular, distinguindo entre olhos abertos e fechados com base nos sinais de EEG. Para isso, empregou-se uma base de dados contendo leituras de 2 minutos de EEG obtidas em diferentes experimentos nos quais os participantes mantiveram os olhos fechados e abertos. Posteriormente, esses dados foram tratados, tabulados estatisticamente e visualizados em gráficos utilizando a linguagem de programação Python para facilitar a interpretação. O desenvolvimento da Rede Neural foi realizado em linguagem de programação no Python, utilizando as bibliotecas Scikit-learn, TensorFlow e NumPy. A arquitetura da rede MLP consistiu em 5 neurônios na camada de entrada, 2 camadas ocultas (a primeira com 20 neurônios e a segunda com 35 neurônios) e foi treinada ao longo de 100 épocas. Como resultado o modelo alcançou uma acurácia de 94,77%, validando efetivamente a rede neural artificial na classificação do estado ocular. Ao examinar a matriz de confusão, destacam-se os verdadeiros positivos (TP) e verdadeiros negativos (TN), registrando 6822 casos corretamente identificados para olhos fechados e 6825 para olhos abertos. Contudo, houve 453 casos em que o modelo previu erroneamente que os olhos estavam fechados quando estavam abertos, e vice-versa, em 300 ocasiões. Consequentemente, a pesquisa confirmou a eficácia do modelo por meio de métricas como acurácia e análise da Matriz de Confusão. No entanto, essa análise não exaure as oportunidades de aplicar métodos adicionais para explorar diferentes abordagens de validação do modelo proposto. Valendo ainda ressaltar que muitas vezes, compreender os resultados obtidos e buscar uma arquitetura mais eficaz para a resolução do problema proposto tornar-se desafiador.

**Palavras-chave:** Sistema nervoso. Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas (MLP). EEG. Interface cérebro-computador.

## ABSTRACT

This research delves into the application of artificial neural networks for detecting ocular states through Electroencephalogram (EEG) signals. The primary objective was to elucidate neurophysiology and expound upon the operation of a brain-computer interface system. A Multi-Layer Perceptron (MLP) Neural Network was employed to predict ocular states, distinguishing between open and closed eyes based on EEG signals. To achieve this, a dataset comprising 2-minute EEG readings from diverse experiments, wherein participants maintained either open or closed eyes, was utilized. Subsequently, this data underwent processing, statistical tabulation, and visualization through graphing, facilitated by the Python programming language to enhance interpretability. The development of the Neural Network was conducted in Python, utilizing the Scikit-learn, TensorFlow, and NumPy libraries. The architecture of the MLP network featured 5 neurons in the input layer, along with 2 hidden layers (the first comprising 20 neurons and the second, 35 neurons). The network underwent training over 100 epochs, culminating in a model accuracy of 94.77%. This effectively validated the artificial neural network's competence in classifying ocular states. Upon scrutinizing the confusion matrix, notable instances of true positives (TP) and true negatives (TN) were observed, with 6822 cases accurately identified for closed eyes and 6825 for open eyes. Nevertheless, there were 453 instances where the model erroneously predicted closed eyes when they were open, and vice versa, transpiring on 300 occasions. In conclusion, the research affirmed the efficacy of the model through metrics such as accuracy and the analysis of the Confusion Matrix. However, it is imperative to acknowledge that this analysis does not exhaust the opportunities for applying supplementary methods to explore diverse approaches in validating the proposed model. Furthermore, it is noteworthy that comprehending the obtained results and endeavoring to formulate a more effective architecture for addressing the proposed problem can be a formidable challenge.

**Keywords:** Nervous system. Multilayer Perceptron Artificial Neural Network (MLP). EEG. Brain-computer interface.

## LISTA DE FIGURAS

Figura 01 — Divisão Do SN Com Base Em Critérios Anatômicos.....	10
Figura 02 — Visão geral funcional do sistema nervoso.....	11
Figura 03 — Cérebro e sua divisão em Lobos.....	12
Figura 04 — Medula Espinal.....	12
Figura 05 — Visão geral funcional do sistema nervoso.....	13
Figura 06 — Sistema Nervo Periférico.....	13
Figura 07 — Neurônio e suas estruturas.....	16
Figura 08 — Parte de um Neurônio.....	16
Figura 09 — Categorias funcionais.....	17
Figura 10 — Canais iônicos dos neurônios.....	18
Figura 11 — Potencial de ação.....	19
Figura 12 — Potencial de ação neuronal.....	20
Figura 13 — Transmissão sinápticas.....	21
Figura 14 — Tipos de circuitos neurais.....	22
Figura 15 — Etapas da Interface Cérebro- Computador.....	23
Figura 16 — Comparação entre Controle Por BCI e Controle Normal.....	24
Figura 17 — Frequências de ondas cerebrais.....	27
Figura 18 — Sistema Internacional 10-20.....	28
Figura 19 — Representação gráfica do método Transformada de Wavelet.....	30
Figura 20 — Etapas de processamento, extração de característica e classificação dos sinais de EEG em um sistema BCI.....	31
Figura 21 — Modelo básico de um neurônio artificial.....	31
Figura 22 — Modelo RNA MLP com 1 camada oculta.....	32
Figura 23 — Modelo RNA MLP com 2 camada oculta.....	32
Quadro 01 — Funções de ativação e seus respectivos gráficos.....	33
Figura 24 — Modelo básico RNN.....	34

Figura 25 — Modelo básico Redes Neurais Convolucionais.....	35
Figura 26 — Etapas da pesquisa.....	36
Figura 27 — Posição dos eletrodos no sistema 10-10.....	27
Tabela 01 — Arquivos dos experimentos de cada participante em CSV.....	40
Figura 28 — Serie temporal do sinal de EEG indivíduo 9, experimento olhos abertos.....	
Figura 29 — Serie temporal do sinal de EEG indivíduo 9, experimento olhos fechados.....	42
Figura 30 — Comportamento Sinal de EEG indivíduo 9 por canal: Estado Ocular.....	42
Figura 31 — Leitura dos dados em formato Csv do indivíduo 9.....	44
Figura 32 — Instalando bibliotecas.....	45
Figura 33—Novo arquivo com coluna “ESTADOS DOS OLHOS” adicionada.	45
Figura 34 — Fase de treinamento 10 épocas.....	46
Figura 35 — Fase de treinamento 100 épocas, 2 camadas ocultas com 20 e 35 neurônios.....	47
Figura 36 — Parâmetros finais da MLP.....	48
Figura 37 — Matriz de confusão.....	49
Figura 38 — Relação Acurácia pelo N° de épocas de treinamento.....	50

## SUMÁRIO

<b>1 INTRODUÇÃO.....</b>	<b>07</b>
<b>2 JUSTIFICATIVA.....</b>	<b>08</b>
<b>3 OBJETIVOS.....</b>	<b>09</b>
3.1. OBJETIVO GERAL .....	09
3.2 OBJETIVO ESPECIFICOS.....	09
<b>4 REFERENCIAL TEÓRICO.....</b>	<b>10</b>
4.1 MACRO VISÃO DO SISTEMA NERVOSO.....	10
4.2 MICRO VISÃO DO SISTEMA NERVOSO.....	14
<b>4.2.1 Comunicação Elétrica Dos Neurônio.....</b>	<b>16</b>
<b>4.2.2 Transmissão Sináptica.....</b>	<b>19</b>
<b>4.2.3 Circuitos Neurais.....</b>	<b>20</b>
4.3 PRINCÍPIOS DA INTERFACE CÉREBRO-COMPUTADOR.....	21
<b>4.3.1 Classificação das ICCs.....</b>	<b>23</b>
4.4 ELETROENCEFALOGRAMA.....	24
<b>4.4.1 Técnica de medição do EEG.....</b>	<b>26</b>
4.5 FUNCIONAMENTO DE ICC BASEADO EM EEG.....	27
4.6 REDES NEURAIS ARTIFICIAIS.....	30
<b>5 METODOLOGIA DA PESQUISA.....</b>	<b>36</b>
5.1 DESENHO DO ESTUDO.....	36
5.2 BASE DE DADOS.....	36
5.3 CONFIGURAÇÃO DA REDE PARA DETECÇÃO DO ESTADO OCULAR...38	
5.4 RECURSOS.....	39
<b>6 RESULTADOS E DISCUSSÕES.....</b>	<b>40</b>
6.1 APRESENTAÇÃO DOS DADOS OBTIDOS.....	41
6.2 PROGRAMAÇÃO DA REDE NEURAL ARTIFICIAL EM PYTHON.....	44
6.3 FASE DE TREINAMENTO DO MODELO DA REDE MLP.....	46
6.4 FASE DE VALIDAÇÃO DO MODELO DE REDE MLP.....	47
6.5 AVALIAÇÃO DA PERFORMACE E PREDIÇÕES DA RNA MLP.....	48
<b>7 CONSIDERAÇÕES FINAIS.....</b>	<b>51</b>
<b>REFERÊNCIAS BIBLIOGRÁFICA</b>	

## 1 INTRODUÇÃO

O avanço das neurociências desde os anos 1970, quando o termo “neurociência” emergiu, tem sido notável em nossa sociedade moderna, e desassociá-lo do cotidiano parece ser uma tarefa impossível. Esta área de estudo busca compreender de forma interdisciplinar o funcionamento do sistema nervoso, permeando campos como medicina, biologia, fisioterapia, física, química e psicologia (BRITTO; BALDOS, 2007).

Através desses estudos, foi consolidado o entendimento de que o sistema nervoso opera por meio de impulsos eletroquímicos. Com avanços tecnológicos, tornou-se viável rastrear a atividade neuronal, mapeando como diferentes áreas do cérebro desempenham funções diversas no corpo humano, como aquelas relacionadas à motricidade, afetividade e cognição, por exemplo (SOUZA; WANDERLEY; DÓRIA, 2015).

Nesse contexto, as interfaces cérebro-máquina/computador (ICM/ICC) emergem como sistemas inovadores que possibilitam a interação entre o usuário e/ou pacientes com graus de perda motora ou sensorial, conectando-os à realidade em que estão inseridos, utilizando sinais de controle gerados pela atividade elétrica das células neurais (MUSSATTO E SILVA, 2014).

Conseqüentemente, com o advento das ICC, surge uma crescente demanda para classificar os padrões desses sinais captados da atividade neural, bem como desenvolver modelos eficazes para prever esses padrões a partir desses dados. Diversos estudos indicam que as redes neurais artificiais, associadas a métodos estatísticos, desempenham um papel relevante na solução de problemas de classificação de dados sequenciais, visando à identificação e previsão de movimentos motores. Assim, essas redes são fundamentais para o desenvolvimento de qualquer interface cérebro-computador (MCMAHAN et al., 2015).

## 2 JUSTIFICATIVA

Segundo o último Censo Demográfico de 2022 do IBGE, mais de 24 milhões de brasileiros, o equivalente a aproximadamente 24% da população, relataram enfrentar algum tipo de problema motor. Para mitigar essa significativa questão de saúde, é crucial o surgimento de terapias inovadoras capazes de promover a plasticidade neural e se adaptar aos diferentes níveis de complicações neuro motoras, sejam eles crônicos ou agudos.

As redes neurais artificiais (RNAs) são ferramentas cruciais na medicina, revolucionando o diagnóstico, tratamento e pesquisa de doenças das mais variadas fisiopatologias. Seu impacto é particularmente significativo na interface cérebro-computador (ICC), uma área em expansão que visa superar limitações físicas, especialmente aquelas relacionadas a algum tipo de deficiência motor (Pan et al., 2014).

Entre as aplicações das (RNAs) está incluindo o uso de imagens de ressonância magnética (RM) e tomografia computadorizada (TC) para prever déficits motores, cognitivos e sensoriais em pacientes que sofreram um acidente vascular encefálico (AVE). Além disso, destacam-se iniciativas como a integração de RNAs com Interface Cérebro-Computador (ICC) para o controle de cadeiras de rodas e a gestão de dispositivos em residências inteligentes (SILVA; CARRO; COSTA, 2019).

O desenvolvimento e aplicações dessas tecnologias é um avanço crucial para melhorar a qualidade de vida desses pacientes, possibilitando uma atenuação das restrições de interação e contribuindo significativamente para sua inclusão e bem-estar. As redes neurais aliado ao desenvolvimento de interfaces cérebro-computador representam uma promissora fronteira na busca por soluções inovadoras na área médica, especialmente no que diz respeito à superação das limitações impostas por deficiências físicas por exemplo (McMahan et al., 2015).

### 3 OBJETIVOS

#### 3.1. OBJETIVO GERAL

O propósito essencial desta pesquisa é descrever os fundamentos da neurofisiologia, o funcionamento básico de uma interface cérebro-computador, além de fornecer uma visão sucinta sobre a temática das redes neurais artificiais. Posteriormente, visa-se utilizar a ferramenta das redes neurais artificiais para desenvolver um programa capaz de identificar o estado ocular por meio da análise de sinais de eletroencefalograma.

#### 3.2 OBJETIVOS ESPECÍFICOS

- ❖ Investigar a neurofisiologia do sistema nervoso humano e o funcionamento essencial de um sistema interface cérebro-computador.
- ❖ Implementar uma Rede Neural do tipo Perceptron de Múltiplas Camadas (MLP - Multi Layer Perceptron) para previsão do estado ocular, distinguindo entre olhos abertos e fechados, com base em sinais de eletroencefalograma.
- ❖ Avaliar o desempenho e eficácia da Rede Neural Artificial implementada durante o processo de treinamento e na fase de teste.

## 4 REFERENCIAL TEÓRICO

### 4.1 MACRO VISÃO DO SISTEMA NERVOSO

Alguns estudiosos dividem o sistema nervoso humano (SN) por critérios anatômicos, embriológicos e funcionais. Abordaremos pela divisão anatômica, segundo essa divisão o sistema nervoso é composto pelo sistema nervoso central (SNC) e sistema nervoso periférico (SNP) como demonstra a Figura 01 (MACHADO, 2014).

**Figura 01— Divisão Do SN Com Base Em Critérios Anatômicos**



Fonte: Machado, 2014.

O sistema nervoso central (SNC) que consiste no encéfalo e medula espinhal é responsável por integrar, processar e coordenar a chegada de estímulos sensitivos e a saída de estímulos motores. Alguns autores o consideram como a sede de funções superiores como a inteligência, a memória, o aprendizado e as emoções (Figura 02).


**Figura 02 — Visão geral funcional do sistema nervoso.**



Fonte: Martini, 2009.

O sistema nervoso central (SNC), é composto pelo encéfalo (Figura 3) e pela medula espinal (Figura 4). O encéfalo que é constituído do Cérebro, Troco Encefálico e Cerebelo é a parte do SNC que está localizada na calota craniana e contém cerca de 85 bilhões de neurônios (BEAR, 2019).

**Figura 03 — Cérebro e sua divisão em Lobos**

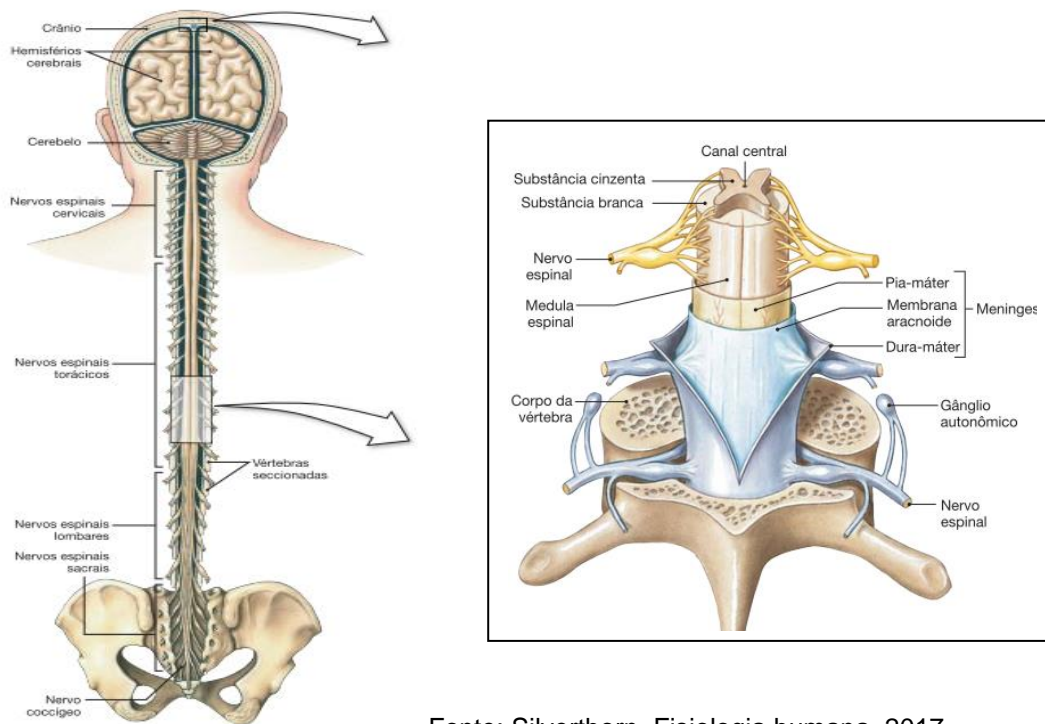


Fonte: Bear, Mark F, 2009.

O cérebro anatomicamente pode ser dividido em 5 principais Lobos, sendo esse: Lobo Frontal, Lobo Temporal, Lobo Parietal, Lobo Occipital e Lobo

Insular. A medula espinal se conecta com o encéfalo por meio do forame magno do occipital e está envolvida pelos ossos da nossa coluna vertebral (BEAR, 2016).


**Figura 03 — Medula Espinal**



Fonte: Silverthorn, Fisiologia humana, 2017.

Já o sistema nervoso periférico (SNP) é composto por neurônios sensoriais (aférentes) e neurônios eferentes que fornece informações sensitivas ao SNC e conduz informações motoras do SNC para sistemas e tecidos periféricos. Ou seja, a divisão aferente do SNP conduz informações sensitivas ao SNC, e a divisão eferente conduz estímulos motores para músculos e glândulas como demonstra a Figura 05 a seguir.

**Figura 05 — Visão geral funcional do sistema nervoso.**



**Fonte:** Tortora, 2016.

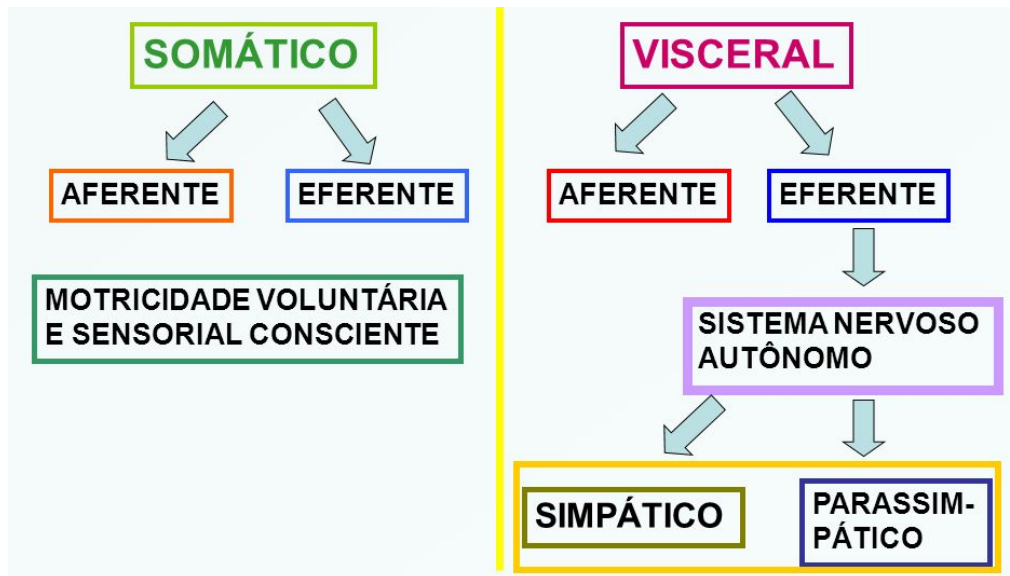
Os componentes do sistema nervoso periférico incluem os nervos, os gânglios, os plexos entéricos e os receptores sensíveis. Pode-se citar exemplos de receptores sensíveis: táteis da pele, os fotorreceptores do olho e os receptores olfatórios do nariz.

O SNP é dividido em sistema nervoso somático (SNS), sistema nervoso autônomo (SNA) e sistema nervoso entérico (SNE). O SNS é composto por (1) neurônios sensíveis que transmitem informações para o SNC a partir de receptores somáticos na cabeça, no tronco e nos membros e de receptores para os sentidos especiais da visão, da audição, da gustação e do olfato, e por (2) neurônios motores que conduzem impulsos nervosos do SNC exclusivamente para os músculos esqueléticos (MARTINI, 2009).

Como estas respostas motoras podem ser controladas conscientemente, a ação desta parte do SNP é voluntária. Já a divisão autônoma do sistema nervoso ou SNA é formado por (1) neurônios sensíveis que levam informações de receptores sensíveis autônomos – localizados especialmente em órgãos

viscerais como o estômago e os pulmões – para o SNC, e por (2) neurônios motores que conduzem os impulsos nervosos do SNC para o músculo liso, o músculo cardíaco e as glândulas. Como suas respostas motoras não estão, de modo geral, sob controle consciente, a atuação do SNA é involuntária. (TORTORA, 2016).

**Figura 06 — Sistema Nervo Periférico**



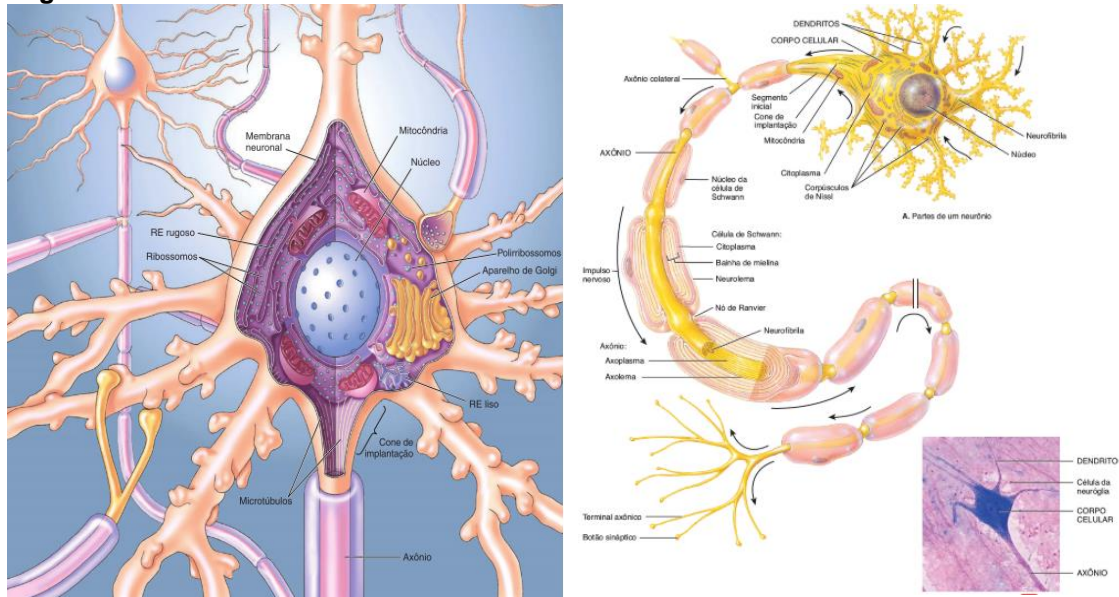
FONTE: [www.anatomia-papel-e-caneta.com](http://www.anatomia-papel-e-caneta.com)

#### 4.2 MICRO VISÃO DO SISTEMA NERVOSO

Basicamente pode afirmar-se que o neurônio é a base funcional de todo o sistema nervoso. Resumidamente essas células especializadas do SN tem a função de codificar informações, conduzi-las, por vezes por distâncias consideráveis, e as transmitem então a outros neurônios ou a tecidos não neurais como músculos ou células glandulares no nosso organismo (MARTINI, 2009).

A constituição microscópica do sistema nervoso consiste basicamente em dois tipos de células: os neurônios, sendo esses, as unidades sinalizadoras básicas do sistema nervoso e as células de suporte, conhecidas como neuroglia como mostra a Figura 07.


**Figura 07 — Neurônio e suas estruturas.**



Fonte: Bear, Mark F, 2009.

Silverthorn (2017), mostra que o neurônio é constituído pelo o núcleo ou soma onde se encontra as organelas. Possui prolongamentos que se estendem a partir do corpo celular constituem a única característica estrutural comum de todos os neurônios, essa estrutura que é denominado de axônio. Pelo axônio a celular nervosa transmite impulsos do corpo celular para um terminal especializado denominado fenda sinapse. No geral, os neurônios possuem muitos dendritos, isto é, prolongamentos mais curtos que transmitem impulsos da periferia em direção ao corpo celular como mostra a Figura 08 a seguir:

**Figura 08 — Parte de um Neurônio**




Fonte: Silverthorn, 2017.

Quanto a funcionalidade há 3 tipos básicos de neurônios no sistema nervoso: 1-Sensoriais ou aferentes, 2-Motores ou eferentes e os interneurônios que possuem a função de detectarem as alterações nos ambientes como exemplifica a Figura 09.

Os neurônios sensitivos possuem receptores sensitivos em suas extremidades distais ou podem estar localizados após receptores sensitivos que são células separadas. Quando há um estímulo ativa-se o receptor sensitivo, ele gera um potencial de ação em seu axônio que é transportado para o SNC por nervos cranianos ou nervos da medula espinhal. Possuem como característica estrutural, ser um neurônio unipolar (BEAR, 2019).

Neurônios motores (estruturalmente multipolares) têm a finalidade de transportarem potenciais de ação para fora do SNC em direção aos músculos e glândulas por meio de nervos cranianos ou da coluna espinhal. Já os Interneurônios localizam-se principalmente no SNC, entre os neurônios motores e sensitivos fazendo a integração das informações sensitivas captadas por neurônios sensitivos e então promovem uma resposta motora.

**Figura 09 — Categorias funcionais**



**Fonte:** Silverthorn, Fisiologia humana, 2017.

#### 4.2.1 Comunicação Elétrica dos Neurônio

Os neurônios comunicam-se utilizando 2 principais sinais elétricos. Sendo eles os potenciais graduados para pequenas distâncias e os potenciais de ação para comunicação em grandes distâncias no organismo humano (MACHADO, 2014).

Os potenciais graduados e os potenciais de ação ocorrem porque as membranas das células nervosas possuem tipos diferentes de canais iônicos que se abrem ou se fecham de acordo com alguns estímulos. A membrana plasmática de um neurônio é constituída de uma bicamada lipídica que apresenta algumas vias em que a corrente elétrica pode passar, denominado de canais iônicos. Esses canais iônicos que possuem basicamente portões de


influxo de ânions e cátions podem ser dividido em 3 principais categoria (Figura 10) de acordo com seu mecanismo de abertura, sendo eles: Canal mecanoativado, canal ativado por ligante e canal dependente de voltagem

Os canais iônicos controlados mecanicamente são encontrados em neurônios sensoriais e se abrem em resposta a forças físicas, como pressão ou estiramento.

Os canais iônicos dependentes de ligante da maioria dos neurônios respondem a uma grande variedade de ligantes, como neurotransmissores e neuromoduladores extracelulares ou moléculas sinalizadoras intracelulares.

Os canais iônicos dependentes de voltagem respondem a mudanças no potencial de membrana da célula. Os canais de  $\text{Na}^+$  e  $\text{K}^+$  dependentes de voltagem possuem um importante papel na inicialização e na condução dos sinais elétricos ao longo do axônio. (SILVERTHORN, 2014, p. 239)

**Figura 10 — Canais iônicos dos neurônios**

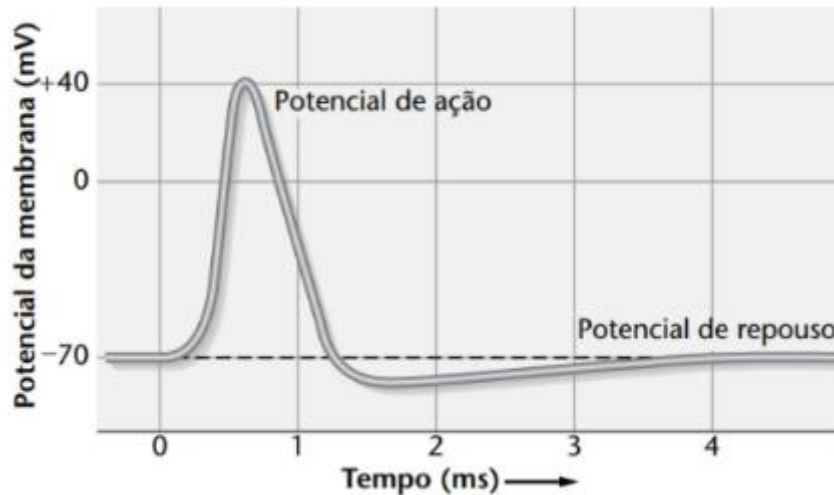


**Fonte:** Tortora, 2016.

De acordo com Silverthorn (2017), a compreensão do potencial de membrana das células nervosas é fundamental para entender a fisiologia subjacente ao impulso nervoso. Este potencial, presente quando a célula está em repouso, resulta de um acúmulo de íons negativos no citosol, ao longo da

parte interna da membrana plasmática, e um acúmulo correspondente de íons positivos no líquido extracelular. O potencial de membrana em repouso varia entre 40 e  $-90$  mV, sendo  $-70$  mV um valor comum, conforme ilustrado na Figura 11.

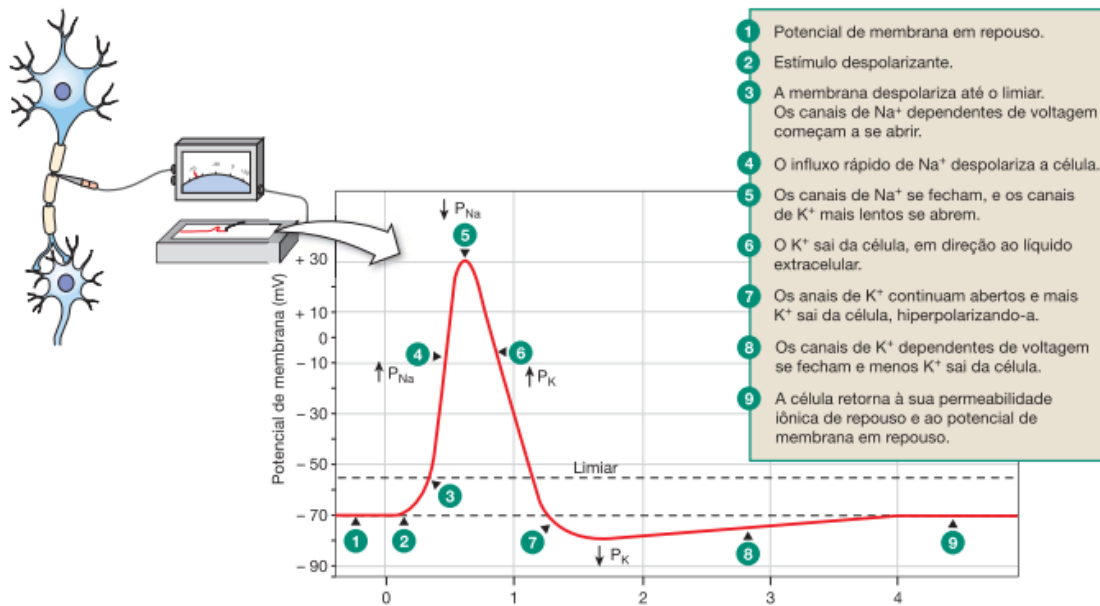
**Figura 11 — Potencial de ação.**



Fonte: Atkinson, 2018

Partindo desse ponto, torna-se mais acessível compreender como ocorrem os potenciais de ação, conhecidos popularmente como impulsos nervosos. O potencial de ação de um neurônio representa uma sequência ágil de eventos que rapidamente alteram e reestabelecem o potencial de membrana, retornando-o ao seu estado de repouso. Em outras palavras, quando um estímulo é aplicado, as mudanças na permeabilidade iônica ao longo do axônio desencadeiam um fluxo de íons, resultando em variações na voltagem, como ilustrado na Figura a seguir. Um potencial de ação consiste em duas fases principais: a despolarização e a hiperpolarização (TORTORA, 2016).

**Figura 12 — Potencial de ação neuronal.**



Fonte: Silverthorn, 2017.

Graficamente, tem-se a demonstração que a formação de um potencial de ação está condicionada à capacidade de um estímulo específico em elevar o potencial até seu limiar. Contudo, somente haverá resposta a um estímulo se este for suficiente para ultrapassar o limiar crítico (acima de  $-55$  mV), desencadeando a despolarização da membrana e, conseqüentemente, o impulso nervoso.

#### 4.2.2 Transmissão Sináptica


A comunicação entre as células nervosas ocorre entre si ocorrem basicamente por sinapses. Imparato (2020) explica que esse termo, sinapse, refere-se a uma configuração espacial e estrutural. Essa configuração ocorre entre neurônios, um neurônio e outro tipo de célula efetora, como células musculares ou glândulas por exemplos. Isso possibilita a transmissão direta ou indireta de um sinal elétrico ou química da primeira célula (pré-sináptica) para a célula seguinte (pós-sináptica).

A maioria das sinapses ocorre em junções especializadas (fenda sinapse) entre neurônios. Ocorre também entre o axônio e um dendrito, já outras são entre um axônio e uma célula ou até mesmo entre dois axônios. As principais

estruturas envolvidas são: vesículas sinápticas, fenda sináptica, membrana sináptica e membrana pós-sináptica.

Sinapse química ocorrem libertadas substâncias químicas (neurotransmissores) na fenda sináptica, adjacente à células seguinte. No final da transmissão os neurotransmissores são eliminados da fenda sináptica estando a sinapse novamente disponível para outro impulso. Já a sinapse elétrica as membranas pré e pós-sinápticas estão muito mais próximas, cerca de 2-3 nm, e entre as membranas das células existem junções comunicantes em que ocorre o fluxo de íons. Os impulsos nervosos se propagam mais rápido através das sinapses elétricas (PROTACHEVICZ, 2020).

**Figura 13 — Transmissão sinápticas**



Fonte: Protachevicz, 2020.

#### 4.2.3 Circuitos Neurais

Circuitos ou redes neuronais são definidos como um grupo de neurônios interconectados com funções específicas. Esse circuito pode ser difuso, envolvendo neurônios e várias regiões do cérebro, ou localizada, com todos os neurônios em uma única região do SNC como no encéfalo ou da medula espinhal por exemplo. Podem ainda serem definidas de acordo com suas funções e especificidades anatômicas (IMPARATO, 2020).


Os circuitos neurais ou nervosos se apresentam como um sistema de divergência, convergência, reverberante, e em paralelo de pós-descarga como

mostrado na Figura 14. Basicamente no circuito de divergência os impulsos nervosos são disseminados a partir de um neurônio para vários outros neurônios

No circuito de convergência, vários neurônios pré-sinápticos fazem sinapse com apenas um neurônio pós-sináptico assim sendo esse neurônio constitui uma via final comum de vários impulsos nervosos que podem chegar de diferentes regiões do SNC.

Já nos circuitos reverberantes os impulsos nervosos se propagam e retornam, ou seja, ocorre um auto reforço a propagação do impulso excitatório na cadeia, ocorrendo assim um feedback positivo no sistema. Agora quando vários neurônios ou redes processam a mesma informação e ocorre várias respostas diferente, esse sistema é definido como circuito neural em paralelo (TORTORA, 2016).

**Figura 14 — Tipos de circuitos neurais**



Fonte: Tortora, Gerard J, 2016.

#### 4.4 PRINCÍPIOS DA INTERFACE CÉREBRO-COMPUTADOR

Ramadan *et al.*, (2015) argumenta que a Interface cérebro máquina ou Interface Cérebro computador (Brain Computer Interface, do original em Inglês), corresponde basicamente ao estabelecimento de uma conexão direta entre um computador e o cérebro humano. Basicamente a interface cérebro-computador (ICC) baseia-se na atividade cerebral. Essa atividade é adquirida por métodos que quantificam a atividade do sistema nervoso, como: eletroencefalografia

(EEG); magnetoencefalografia (MEG); imagem de ressonância magnética funcional (fMRI) e tomografia por emissão de pósitron (PET) por exemplo.

Nesse aspecto Pinto e Melo (2011) descrevem que após os registros da atividade elétrica do córtex cerebral, a Interface transforma esse padrão neuronal em um comando externo qualquer, e isso ocorre em quatro principais etapas: 1- aquisição de sinais, 2-extração de característica, 3-classificação e 4-comando de dispositivo externo como exemplificado no Figura 15.

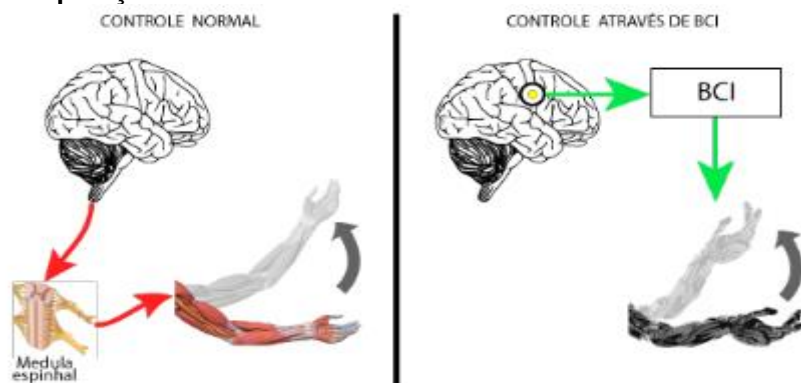
**Figura 15 — Etapas da Interface Cérebro- Computador**



Fonte: Adaptado de Silva, 2019.

Segundo Grandini (2017), pode-se afirmar que os sistemas de ICCs correspondem a um sistema de comunicação. Esse sistema independente dos caminhos normais de saída do cérebro para nervos e músculos periféricos do corpo humano. Cujo o objetivo geral das interfaces cérebro computador corresponde a fornecerem uma comunicação direta e não-muscular, estabelecendo um canal de controle entre o cérebro humano e um computador como exemplifico a Figura 16.

**Figura 16 — Comparação entre Controle Por BCI e Controle Normal**



Fonte: Grandini, 2017.

Já Menezes (2014) discorre sobre os 4 principais requisitos básico para se constituir uma ICC, sendo eles:

- Deve existir pelo menos um sensor para detectar e capturar a atividade cerebral;
  - O sistema de processamento de sinal deve traduzir os sinais resultantes em mensagens ou comandos;
  - A informação gerada deve ser enviada para um aplicativo ou dispositivo, como um navegador web, monitor ou um sistema de movimento mecânico e;
  - Deve haver uma interface de aplicação ou um ambiente operacional que determine a forma como o sistema agirá ou dará o feedback.
- (MENEZES, 2014, p. 37)

#### 4.4.1 Classificação das Interface Cérebro-Computador

Nicolelis e Lebedev (2017) uns dos pioneiros nos estudos de ICCs, fazem a seguinte classificação. De maneira geral, para esses autores, as tecnologias de ICCs são divididas em 3 principais categorias sendo elas:

- Nível de invasão;
- Função;
- Origem neural

Quanto ao nível de Invasão, tem-se os métodos não invasivos e os invasivos. Sendo o primeiro, não invasivo, caracterizado pelo posicionamento de eletrodos de EEG na superfície do couro cabeludo não havendo a necessidade de quaisquer procedimentos cirúrgicos (HU et al., 2019).

Por outro lado, como explicam Nasser e Honh (2015) nos métodos invasivos, pode-se citar os baseados em eletrocorticografia (ECoG) no qual a

atividade elétrica do cérebro é registrada a partir da superfície do córtex cerebral sendo os eletrodos implantados intra cranial por métodos neurocirúrgicos.

Em relação a função das ICCs, Sanchez e Principe (2007), relata a seguinte classificação:

- Sensoriais, que ativam o sistema sensorial humano;
- Cognitivas, que buscam restabelecer a comunicação de neurônios; e
- Motoras, que por meio da atividade cerebral executa comandos de controle para um dispositivo externos

Nicolelis e Lebedev (2017) adicionam mais um tipo de interface cérebro-computador nessa classificação, as Brainets, que por sua vez, são interfaces que envolvem múltiplas pessoas, nas quais as ICC utilizam a atividade elétrica de seus cérebros simultaneamente.

Para esses, mesmos estudiosos, em relação a origem neural, a área mais comum que é utilizada para estudos de ICCs, é a M1, área motora primária, que está relacionada a diversos parâmetros de movimentos e a região pré-motora utilizada para controlar os movimentos e sinais preparatórios gerados antes da execução dos mesmos.

#### 4.5 ELETROENCEFALOGRAMA

O Eletroencefalograma (EEG) consiste em um método para monitorar e registrar as atividades cerebrais. Essa avaliação ocorre mediante as tensões emitidas pelas excitações sinápticas dos dendritos dos neurônios que é captado por meios de eletrodos posicionados no couro cabeludo de forma não invasiva.

Assim de maneira geral obtém-se os sinais, e a depender do equipamento, pode possuir baixa qualidade dos sinais. Isso deve-se à dificuldade de adquirir essa variação elétrica em decorrência do couro cabeludo, o crânio, dura-máter, aracnoide, espaço subaracnóidea, pia-máter até a camada mais superficial do encéfalo (LOTTE; BOUGRAIN; CLERC, 2015).

Fisiologicamente os neurônios comunicam-se entre si através de impulsos elétricos. No EEG os eletrodos são colocados em diversos pontos do couro

cabeludo para medir a diferença de potencial, conseqüentemente a amplitude e a frequência dos impulsos elétricos que ocorrem entre um ponto do cérebro e outro.

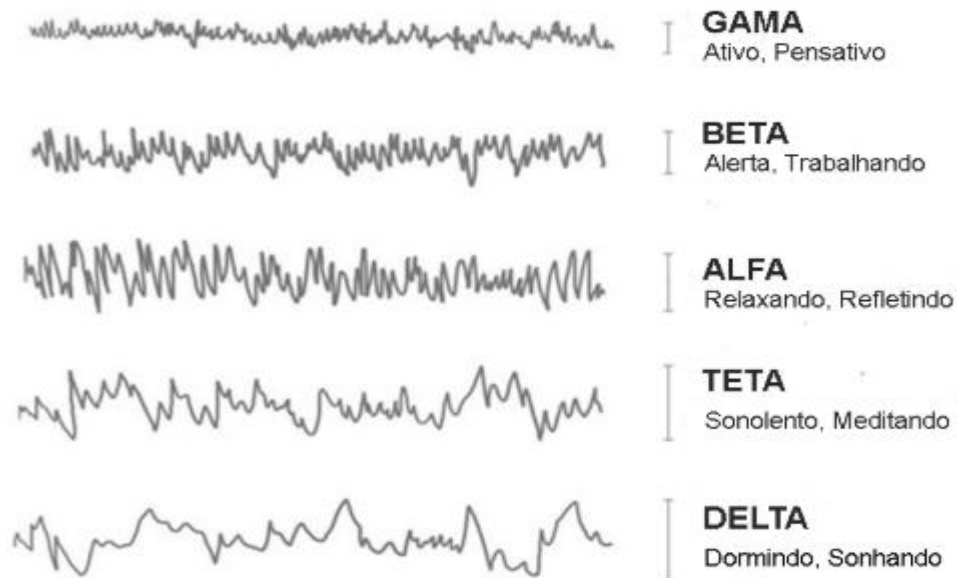
Vaid; Singh e Kaur (2015), explicam que a faixa de frequência destes impulsos cerebrais é tipicamente de 1 a 100Hz, e amplitude de 10  $\mu$ V a 100  $\mu$ V. Contudo podem alterar-se devido a influências de fatores. Esses fatores podem ser: interferências elétricas musculares, estímulos externos e até mesmo estados mentais dos pacientes e conseqüentemente a observação destes sinais é extremamente variável.

Os sinais registrados pelo EEG são um conjunto de ondas cerebrais, eletromagnéticas, que podem ser classificadas através de suas frequências (PASCALIS; VECCHIO; CIRILLO, 2020). São divididas em bandas de frequências. São chamadas de:

- ❖ Delta (abaixo de 3,5 Hz)
- ❖ Teta (3,5 a 8 Hz)
- ❖ Alfa (8 a 12 Hz)
- ❖ Beta (13 a 30 Hz); e
- ❖ Gama (30 a 70 Hz)

Sendo que cada frequência dessas possui uma característica, ritmo e padrões que as diferenciam nos processos cognitivos, estados emocionais e comportamentos de cada indivíduo, podendo, assim, sofrer uma abrupta mudança em uma pequena fração de tempo. Mudando desde estado de sono profundo, estado de vigia, concentração profunda até funções de percepções motoras como demonstra a Figura 17.

**FIGURA 17 — Frequências de ondas cerebrais**

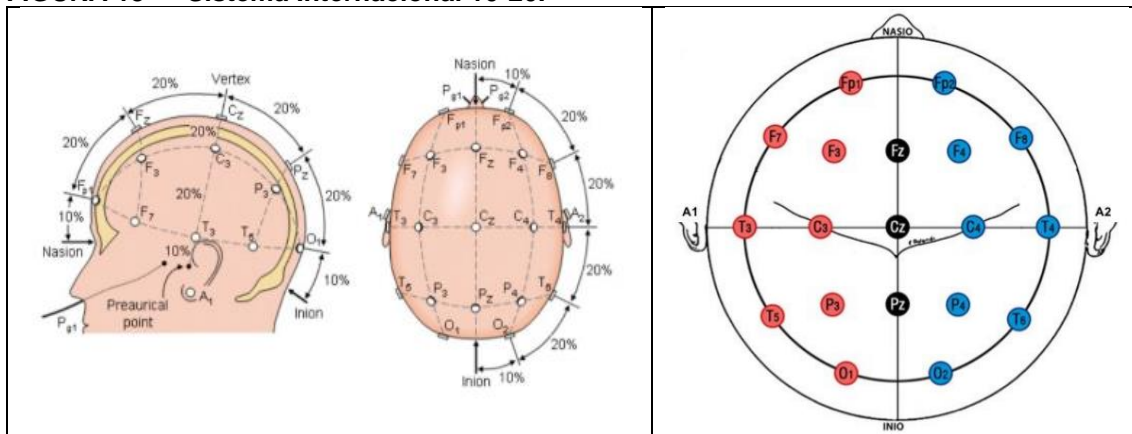


Fonte: Petrov, Stamenova e Petrov, 2016.

#### 4.5.1 Técnica de medição do EEG

Ramos *et al.*, (2020) explicam que os EEGs modernos adquirem os dados da atividade elétrica do cérebro por meios dos eletrodos. Estes eletrodos são acoplados, de forma alternada entre si, no couro cabeludo ou na região intracraniana a depender se a coleta vai ser invasiva ou não. Com isso o equipamento de EEG realiza a monitoração do campo elétrico pelos eletrodos, amplificação do sinal, filtragem e por fim a exibição e registro dos sinais.

Dessa maneira para se ter uma melhor captação de sinais elétricos pelo EEG segue-se a recomendação do posicionamento dos eletrodos do Sistema Internacional 10-20 padronizado pela American Electroencephalographic Society. Esse método de usa dois pontos de referência na cabeça: Násio e Inion, localizado na parte superior do nariz e na base do crânio, respectivamente, como mostrado na Figura 18 abaixo e os "10" e "20" referem-se 10% ou 20% da distância total da frente ou da direita e esquerda do crânio humano.

**FIGURA 18 — Sistema Internacional 10-20.**

Fonte: Sociedade Brasileira de Neurofisiologia Clínica, 2017.

O padrão utilizado constitui de 21 eletrodos. Em que se têm 20 eletrodos de gravação e um de referência. Os eletrodos são nomeados por letras que abreviam as diversas regiões do cérebro e índices numéricos, que representam os possíveis posicionamento lateral. O index Z representa o posicionamento dos eletrodos no eixo central como referência, e os números ímpares para o lado esquerdo e os pares para o lado direito (D. SANTOS, 2014). As referências e abreviações são:

- ❖ Letra Fp= Localização Frontal polar
- ❖ Letra F = Localização Frontal
- ❖ Letra Fz = Localização Frontal médio
- ❖ Letra Cz = Localização Central médio
- ❖ Letra T= Localização temporal
- ❖ Letra P = Localização Parietal
- ❖ Letra Pz= Localização Parietal médio
- ❖ Letra O = Localização Occipital

#### 4.6 FUNCIONAMENTO DE ICC BASEADO EM EEG

Minguillon; Lopez-Gordo e Pelayo (2017), argumentam que primeiro passo para o funcionamento de uma ICC baseado nos sinais de EEG consiste na aquisição do sinal. Essa fase é basicamente composta pelos eletrodos, amplificadores, multiplexadores e conversores analógico digitais para conseguir fazer a leitura dos sinais elétricos e magnéticos do cérebro do usuário.

Vale ressaltar que esses sinais sofrem alterações de acordo com os estado e estímulos em que indivíduo é submetido ou exposto isso se deve ao fato que podemos classificar os sinais elétricos oriundo dos neurônios como estocásticos e dinâmicos, isso influenciado por fatores biológicos e até mesmo da técnica de aquisição e fatores como ruídos de amplificadores, tipo e qualidade dos eletrodos e suas posições (MINGUILLON, LOPEZ-GORDO e PELAYO, 2017).


Já o processamento do sinal nada mais é que extrair as características dos sinais já adquiridos pelo EEG e então transformá-lo em um comando externo. Segundo Nicolas; Alonso e Gomezgil (2012), em seu trabalho, explica que a etapa de pré-processamento e extração é composto por três grandes categorias, sedo elas:

- métodos de redução dimensional de espaço;
- métodos de redução dimensional de tempo; e
- métodos de redução dimensional de frequência.

A redução dimensional tem como principal objetivo reduzir a dimensão dos dados de maneira a remover ou dado ou informações não relevantes. Já os métodos de tempo e frequência tem como finalidade identificar quando um sinal ocorre e em qual recorrência. Na redução dimensional de espaço objetiva-se oferecer as informações referente aos pontos de maior atividade e os de menores atividades cerebrais (DOMINGUES, 2016)

Para a extração de tempo e frequência que é específico para o sinal de EGG devido a sua característica de sinais não são estacionários, usa-se a transformada de continua de Wavelet (CWT) para uma representação flexível e simultânea das análises das frequências e tempo como demonstra a Figura 19.

**Figura 19 — Representação gráfica do método Transformada de Wavelet.**



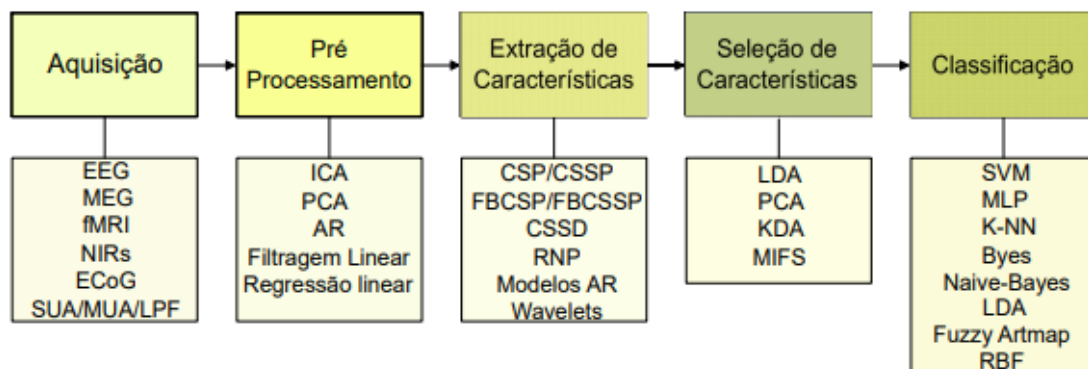
Fonte: Domingues, 2016.

No método de redução de dimensão usa-se principalmente a Análise de Componentes Principais (PCA) do Inglês Principal Component Analysis que é uma técnica de decomposição de dados correlacionados em um novo conjunto de componentes descorrelacionados sempre preservando a variância mais próxima possível dos dados originais (JUNIOR, 2021).

Nicolas e Gomez (2012) em suas pesquisas, demonstram que, a classificação de sinais é uma fase importante nas ICCs baseadas em EGG, pois, nessa fase há o estabelecimento dos padrões dos sinais já pré-processados e estes devem gerar uma saída coerente para a aplicação. Explicam ainda a utilização de modelos baseado em análise bayesianas lineares (Linear Discriminant Analysis -LDA) e não lineares ( Artificial Neural Network – ANN) e K Nearest Neighbour Classification - k-NNC, um classificador de K vizinhos próximos.

Assim fica claro que as etapas de aquisição dos sinais, pré-processamento, extração de características, seleção de características e classificação precisam ser bem definidas. Na Figura 20 mostra-se os principais métodos usados pelos pesquisadores nos últimos anos.

**Figura 20 — Etapas de processamento, extração de característica e classificação dos sinais de EEG em um sistema BCI.**



Fonte: Junior, 2021.

## 4.6 REDES NEURAIS ARTIFICIAIS

Consideradas uma forma de aprendizagem supervisionada, as Redes Neurais Artificiais (RNAs) utilizam conjuntos de dados rotulados para aprender a função que relaciona os dados aos rótulos correspondentes.

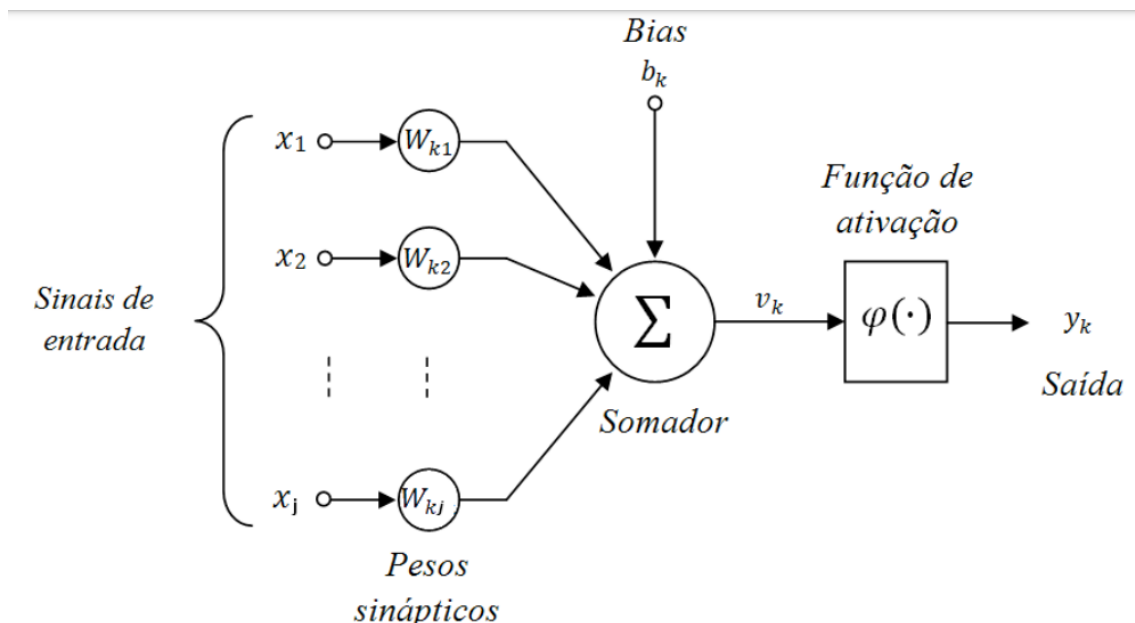
As RNAs são sistemas distribuídos de processamento paralelo, compostos por unidades neuronais (neurônios artificiais) que, ao trabalharem em conjunto, conseguem resolver problemas matemáticos complexos de natureza não-linear.

A arquitetura das RNAs é comparável à conectividade encontrada nos neurônios do cérebro humano. Ela segue um modelo hierárquico, assemelhando-se a uma estrutura em formato de funil que culmina em uma camada totalmente conectada, onde todos os neurônios estão interligados para processar a saída (NASCIMENTO; YONEYAMA, 2004; BRAGA; CARVALHO; LUDERMIR, 2007).

### 4.6.1 Neurônio artificial

Com base no funcionamento fisiológico do cérebro, onde estímulos são transmitidos por uma rede de neurônios, células funcionais do sistema nervoso, aplica-se o conceito de uma rede neural artificial (RNA). Carvalho (2018) explica que essa ideia se trata de um sistema de processamento de dados que se baseia na intercomunicação entre unidades denominadas neurônios artificiais, utilizando formulações matemáticas. Esses neurônios artificiais possuem características representadas na Figura 21 a seguir.

Figura 21 — Modelo básico de um neurônio artificial



Fonte: Silva, 2016.

Com isso destaca-se três elementos principais que constituem um neurônio artificial: as conexões sinápticas com pesos, o somador ponderado e a função de ativação. Esses elementos serão detalhados mais adiante.

- Conexões sinápticas com pesos: São conexões sinápticas com pesos individuais que ponderam sinais de entrada para um neurônio específico
- Somador ponderado: os sinais de entrada multiplicados pelos pesos das conexões sinápticas são somados. Esse somatório ponderado é fundamental para determinar a influência dos sinais de entrada na ativação do neurônio
- Função de ativação: define o limite ou a não-linearidade do sinal de saída do neurônio. Ocorrendo uma limitação do valor de saída do somador, comumente entre  $[0, 1]$  ou  $[-1, 1]$ , para normalizar os resultados e introduzir não-linearidades. A função de ativação é crucial para a capacidade do neurônio de aprender e representar padrões complexos nos dados.

No neurônio artificial representado na Figura 20, é observado um componente chamado bias, representado por  $b_k$ . Esse componente

desempenha o papel de ajustar a entrada total da função de ativação, podendo aumentá-la ou diminuí-la dependendo do seu valor, seja ele positivo ou negativo.

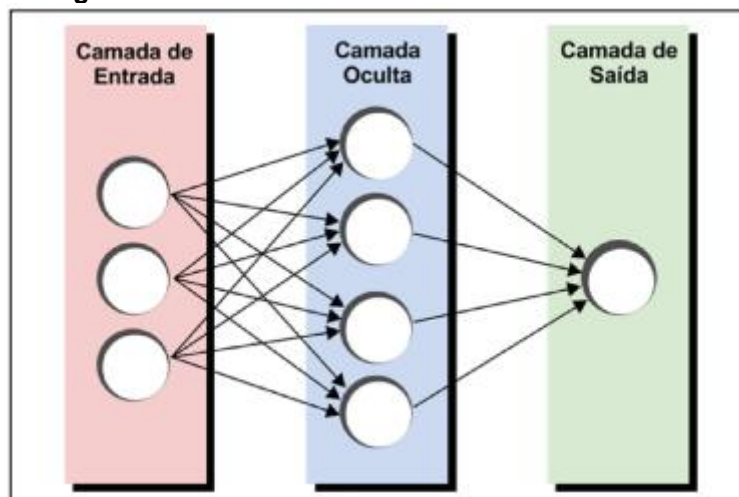
#### 4.6.2 Arquiteturas de redes neurais

No desenvolvimento de uma RNA para resolução de problemas de classificação por exemplo, a escolha da arquitetura é crucial. Essa arquitetura define como os neurônios artificiais são organizados em relação uns aos outros, e principalmente através da direção das conexões sinápticas (LOBO, 2017).

As três principais arquiteturas, que incluem a disposição dos neurônios, a forma como eles se interconectam e a configuração das camadas, serão discutidas a seguir.


- ❖ Redes Neurais Feedforward (FNN - Feedforward Neural Networks): Um dos modelos feed-forward mais comuns é a Rede Perceptrons multicamadas (multilayer Perceptron - MLP). Sua estrutura já é definida previamente. A passagem de informação na rede acontece em uma direção única, partindo da camada de entrada em direção à camada de saída, conforme ilustrado na Figura 22 e 23 abaixo (MONTEIRO et al., 2022).

Figura 22 — Modelo RNA MLP com 1 camada oculta.



Fonte: Monteiro et al., 2022.

Figura 23 — Modelo RNA MLP com 2 camada oculta.



Fonte: Carvalho, 2018.

Cada neurônio calcula sua saída com base na soma ponderada de todas as suas entradas multiplicadas pelos pesos das conexões de entrada usando uma função de ativação. Existem diferentes tipos de funções de ativação, como limiar, linear por partes, sigmoide, tangente-hiperbólica e Gauss como demonstrado na Quadro 01 abaixo.


Quadro 01 — Funções de ativação e seus respectivos gráficos

Função de ativação	Gráfico da função de ativação
Rampa simétrica $\varphi(v) = \begin{cases} a, & \text{se } v_k > a \\ v, & \text{se } a \leq v_k \leq a \\ -a, & \text{se } v < a \end{cases}$	<p>(a) Gráfico de ativação rampa simétrica.</p>
Limiar $\varphi(v) = \begin{cases} 1, & \text{se } v_k \geq 0 \\ 0, & \text{se } v_k < 0 \end{cases}$	<p>(b) Gráfico de ativação degrau bipolar.</p>
Sigmóide $\varphi(v) = \frac{1}{1 + \exp(-av)}$	<p>(c) Gráfico de ativação logística.</p>
Tangente hiperbólica $\varphi(v) = \frac{1 - \exp(-av)}{1 + \exp(-av)}$	<p>(d) Gráfico de ativação tangente hiperbólica.</p>

Fonte: Silva, 2015.

- ❖ Redes Neurais Recorrentes (RNN - Recurrent Neural Networks): São redes neurais que possuem pelo menos uma conexão de retroalimentação, podendo ou não ter camadas ocultas. A presença desses loops de retroalimentação tem um impacto significativo na capacidade de aprendizado e no desempenho da rede neural. Esses loops de retroalimentação envolvem o uso de conexões específicas ligadas a elementos que atrasam o sinal, resultando em um processamento dinâmico de informações.

Figura 24 — Modelo básico RNN.



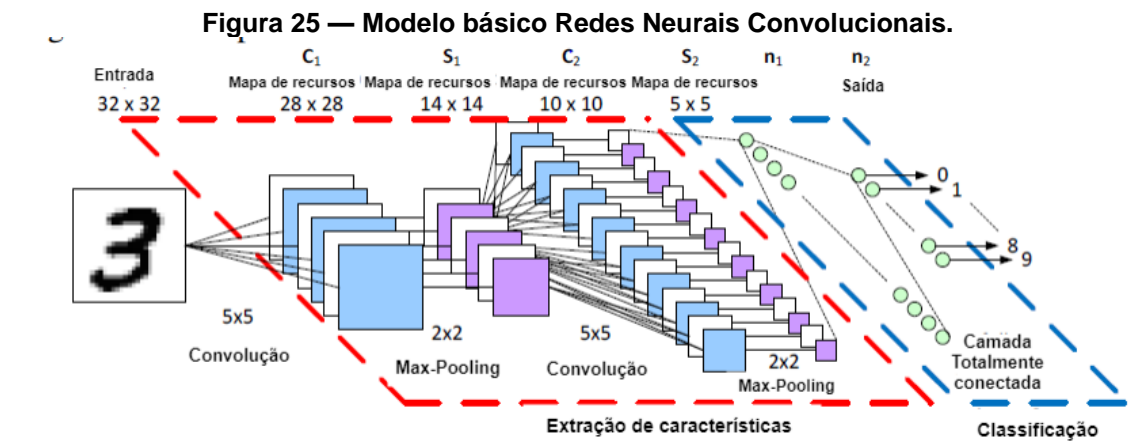
Fonte: Gonçalves *et al.*, 2019.

Por meio desses loops de retroalimentação, as Redes Neurais Recorrentes (RNN) geram saídas atuais considerando também os valores das saídas anteriores. Isso implica que a rede mantém uma memória do estado anterior graças ao feedback positivo. Essa capacidade de feedback possibilita que a rede aprenda e reconheça padrões temporais.

- ❖ Redes Neurais Convolucionais (CNN - Convolutional Neural Networks): são um tipo de arquitetura de rede neural especialmente desenvolvida

para processar dados que possuem uma estrutura em grade, imagens, por exemplo. Essas redes utilizam camadas convolucionais para identificar padrões locais e compartilhar pesos entre elementos, o que resulta na redução da complexidade computacional (RASCHKA; MIRJALILI, 2017).

De acordo com Peemen et al., esse modelo de RNA se destaca pela sua eficiência na extração e aprendizado de características hierárquicas em dados multidimensionais. Elas são comumente aplicadas em tarefas de visão computacional, reconhecimento de padrões e processamento de imagens, como ilustrado na Figura 25 abaixo.



Fonte: Adaptado de: Peemen et al. (2011)

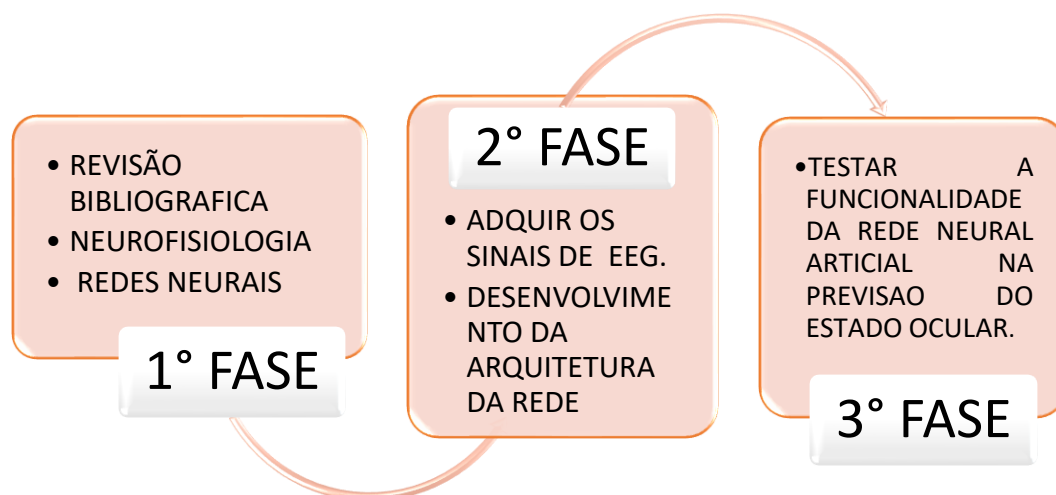
## 5 METODOLOGIA DA PESQUISA

### 5.1 DESENHO DO ESTUDO

O desenvolvimento desse trabalho no que corresponde a sua natureza, abordagem do problema e procedimentos técnicos, é uma pesquisa de natureza estudo aplicado. Que visou o desenvolvimento de sistema de detecção por meio de rede neural artificial do estado ocular partir de sinais de EEG.

A sua abordagem caracteriza-se como exploratória e de descrição. Como procedimento técnico e metodológico, é caracterizada como uma análise de dados qualitativos por meio de busca na literatura atual sobre a temática como demonstra a Figura 26.

**Figura 26 — Etapas da pesquisa.**



Fonte: Autor, 2023.

### 5.2 BASES DE DADOS

Para a realização desse trabalho, a base de dados consiste em um conjunto de dados biométricos de potencial evocado auditivo EEG publicado em 2021 de acesso livre. Esse conjunto de dados consiste em mais de 240 registros de EEG obtidos de 20 voluntários.

Os voluntários foram convidados a sentar e relaxar em uma cadeira confortável. A gravação foi realizada em um único dia, com a mesma ordem de

tarefas. A gravação envolve a aquisição do sinal eletroencefalográfico da seguinte forma:

- I. Três minutos de estado de repouso, olhos abertos para três sessões.
- II. Três minutos de estado de repouso, olhos fechados por três sessões.
- III. Três minutos em estado de repouso, olhos abertos por três sessões usando fone de ouvido com isolamento de ruído
- IV. Três minutos em estado de repouso, olhos abertos por três sessões usando fone de ouvido com isolamento de ruído
- V. Três minutos ouvindo uma música em seu idioma nativo usando fones de ouvido.
- VI. Três minutos ouvindo uma música em um idioma não nativo usando fones de ouvido.
- VII. Três minutos ouvindo música neutra usando fones de ouvido.
- VIII. Três minutos ouvindo uma música em seu idioma nativo usando fones de ouvido condutores de ossos.
- IX. Três minutos ouvindo uma música em um idioma não nativo usando fones de condução óssea.
- X. Três minutos ouvindo música neutra usando fones de condução óssea.

Os dados são disponibilizados nos formatos .csv e WFDB, com as gravações seguindo a nomenclatura sXX\_exXX\_sXX, onde "s" representa o número do indivíduo, "ex" indica o número do experimento, e "s" denota o número da sessão. Por exemplo, s03\_ex02\_s01 refere-se ao Indivíduo 3, Experimento 2, Sessão 1.

Esses dados estão organizados em três pastas:

1. Dados Brutos: cada registro contém o conjunto de dados original, sem segmentação ou filtragem.

2. Dados Segmentados: cada registro abrange dois minutos dos sinais de EEG, minimizando o ruído. São dados obtidos durante períodos em que o sujeito apresentava menor movimentação e piscava menos. A segmentação foi realizada manualmente, e os pontos de início e término de cada segmento
3. Dados Filtrados: Cada registro engloba dois minutos dos sinais de EEG provenientes dos dados segmentados, após passarem por um filtro Butterworth de 1ª ordem de 1 a 40 Hz, além de um filtro notch de 50 Hz com um fator de qualidade de 30

As ferramentas de gravação que foram usadas:

- OpenBCI Ganglion Board, taxa de amostragem de 200 Hz, quatro canais: T7, F8, Cz e P4.
- Eletrodos de copo de ouro.
- Ten20 Pasta Condutora.
- Software: OpenBCI GUI - v5.0.3

### 5.3 CONFIGURAÇÃO DA REDE NEURAL PARA DETECÇÃO DO ESTADO OCULAR

Para o desenvolvimento dessa pesquisa adotou-se a arquitetura de rede Neural Multilayer Perceptron (MLP). Essa estrutura possui vantagens e características específicas, sendo um tipo de rede neural artificial composta por várias camadas de neurônios organizadas em três tipos principais: camada de entrada, camadas ocultas e camada de saída.

Os parâmetros estabelecidos para a Rede Neural Multilayer Perceptron nessa pesquisa foram os seguintes:

- Camada de Entrada: Composta por 5 neurônios, onde cada neurônio representa uma característica ou atributo do conjunto de dados. Neste caso, os neurônios estão associados aos seguintes atributos: Índice de amostra e os 4 canais de EEG.
- Camadas Ocultas: Duas camadas posicionadas entre a entrada e a saída da rede. A primeira camada é composta por 20 neurônios, e a segunda por 35 neurônios. Cada neurônio nessas camadas está conectado a todos

os neurônios da camada anterior e posterior, formando uma rede densamente conectada.

- Camada de Saída Composta por 1 neurônio de saída que apresenta o resultado final da rede neural para a classificação binária dos "ESTADOS DOS OLHOS", onde 1 representa olhos abertos e 0 representa olhos fechados.
- Épocas de Treinamento: O algoritmo de treinamento foi repetido por 100 épocas, cada uma consistindo em um ciclo completo de apresentação dos dados de entrada à rede MLP. Durante cada época, a rede calcula sua saída, compara com a saída desejada e ajusta os pesos para minimizar a diferença entre os valores reais e os preditos.

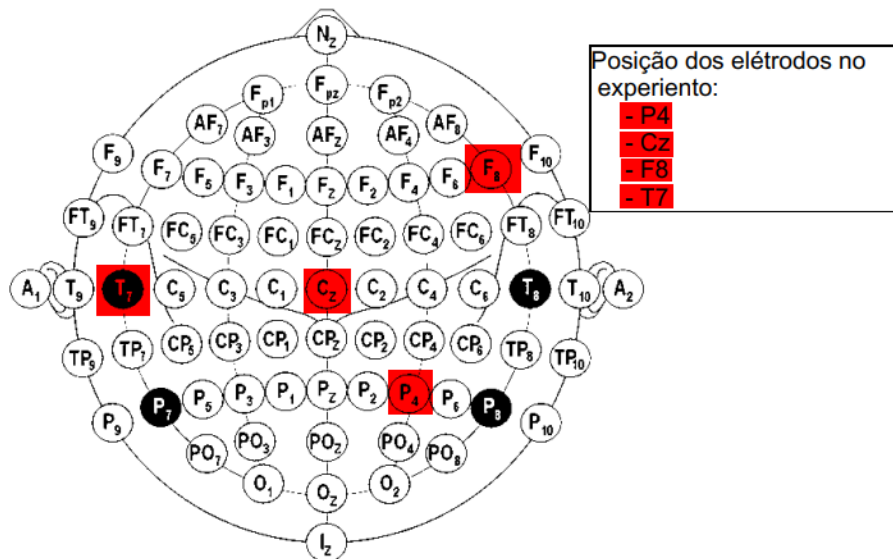
#### 5.4 RECURSOS

No decorrer da pesquisa, os recursos empregados desempenharam um papel crucial. Utilizou-se de um Notebook Acer modelo Aspire 3. Este dispositivo, equipado com um processador Intel Core i5-7200U de 3.1GHz, exibiu um bom desempenho. A plataforma de programação escolhida para a tabulação, processamento dos dados e desenvolvimento da rede neural artificial foi o Python. Tal plataforma de programação, livre, é conhecida por sua versatilidade e eficiência nesse contexto.

## 6. RESULTADOS E DISCUSSÕES

A partir da base de dados onde obteve-se as leituras com base no modelo internacional 10/10 como demonstra a Figura 27 abaixo, utilizando os eletrodos no posições P4, Cz, F8, T7 de 20 participantes. Posteriormente esses dados foram lido em arquivo na extensão CSV com os dados obtido da leitura em cada fase do experimento como mostra a Tabela a seguir.

**Figura 27 — Posição dos eletrodos no sistema 10-10**



Fonte: Sociedade Brasileira de Neurofisiologia Clínica, 2017.

**Tabela 01 — Arquivos dos experimentos de cada participante em CSV.**

s01_ex01_s01	s04_ex06	s08_ex01_s02	s11_ex06	s15_ex01_s01
s01_ex01_s02	s04_ex07	s08_ex01_s03	s11_ex07	s15_ex01_s02
s01_ex01_s03	s04_ex08	s08_ex02_s01	s11_ex08	s15_ex01_s03
s01_ex02_s01	s04_ex09	s08_ex02_s02	s11_ex09	15_ex02_s01
s01_ex02_s02	s04_ex10	s08_ex02_s03	s11_ex10	15_ex02_s02
s01_ex02_s03	s05_ex01_s01	s08_ex05	s12_ex01_s01	15_ex02_s03
s01_ex05	s05_ex01_s02	s08_ex06	s12_ex01_s02	s15_ex05
s01_ex06	s05_ex01_s03	s08_ex07	s12_ex01_s03	s15_ex06
s01_ex07	s05_ex02_s01	s08_ex08	s12_ex02_s01	s15_ex07
s01_ex08	s05_ex02_s02	s08_ex09	s12_ex02_s02	s15_ex08
s01_ex09	s05_ex02_s03	s08_ex10	s12_ex02_s03	s15_ex09
s01_ex10	s05_ex05	s09_ex01_s01	s12_ex05	s15_ex10
s02_ex01_s01	s05_ex06	s09_ex01_s02	s12_ex06	s16_ex01_s01
s02_ex01_s02	s05_ex07	s09_ex01_s03	s12_ex07	s16_ex01_s02
s02_ex01_s03	s05_ex08	s09_ex02_s01	s12_ex08	s16_ex01_s03
s02_ex02_s02	s05_ex09	s09_ex02_s02	s12_ex09	s16_ex02_s01
s02_ex02_s03	s05_ex10	s09_ex02_s03	s12_ex10	s16_ex02_s02

s02_ex05	s06_ex01_s01	s09_ex05	s13_ex01_s01	s16_ex02_s03
s02_ex06	s06_ex01_s02	s09_ex06	s13_ex01_s02	s16_ex05
s02_ex07	s06_ex01_s03	s09_ex07	s13_ex01_s03	s16_ex06
s02_ex08	s06_ex02_s01	s09_ex08	s13_ex02_s01	s16_ex07
s02_ex09	s06_ex02_s02	s09_ex09	s13_ex02_s02	s16_ex08
s02_ex10	s06_ex02_s03	s09_ex10	s13_ex02_s03	s16_ex09
s03_ex01_s01	s06_ex05	s10_ex01_s01	s13_ex05	s16_ex10
s03_ex01_s02	s06_ex06	s10_ex01_s02	s13_ex06	s17_ex01_s01
s03_ex01_s03	s06_ex07	s10_ex01_s03	s13_ex07	s17_ex01_s02
s03_ex02_s01	s06_ex08	s10_ex02_s01	s13_ex08	s17_ex01_s03
s03_ex02_s02	s06_ex09	s10_ex02_s02	s13_ex09	s17_ex02_s01
s03_ex02_s03	s06_ex10	s10_ex02_s03	s13_ex10	s17_ex02_s02
s03_ex05	s07_ex01_s01	s10_ex05	s14_ex01_s01	s17_ex02_s03
s03_ex06	s07_ex01_s02	s10_ex06	s14_ex01_s02	s17_ex05
s03_ex07	s07_ex01_s03	s10_ex07	s14_ex01_s03	s17_ex06
s03_ex08	s07_ex02_s01	s10_ex08	s14_ex02_s01	s17_ex07
s03_ex09	s07_ex02_s02	s10_ex09	s14_ex02_s02	s17_ex08
s03_ex10	s07_ex02_s03	s10_ex10	s14_ex02_s03	s17_ex09
s04_ex01_s01	s07_ex05	s11_ex01_s01	s14_ex05	s17_ex10
s04_ex01_s02	s07_ex06	s11_ex01_s02	s14_ex06	s18_ex01_s01
s04_ex01_s03	s07_ex07	s11_ex01_s03	s14_ex07	s18_ex01_s02
s04_ex02_s01	s07_ex08	s11_ex02_s01	s14_ex08	s18_ex01_s03
s04_ex02_s02	s07_ex09	s11_ex02_s02	s14_ex09	s18_ex02_s01
s04_ex02_s03	s07_ex10	s11_ex02_s03	s14_ex10	s18_ex02_s02
s04_ex05	s08_ex01_s01	s11_ex05	s15_ex01_s01	s18_ex02_s03
s18_ex05	s19_ex01_s02	s19_ex07	s20_ex02_s01	s20_ex09
s18_ex06	s19_ex01_s03	s19_ex08	s20_ex02_s02	s20_ex10
s18_ex07	s19_ex02_s01	s19_ex09	s20_ex02_s03	
s18_ex08	s19_ex02_s02	s19_ex10	s20_ex05	
s18_ex09	s19_ex02_s03	s20_ex01_s01	s20_ex06	
s18_ex10	s19_ex05	s20_ex01_s02	s20_ex07	
s19_ex01_s01	s19_ex06	s20_ex01_s03	s20_ex08	


Fonte: Autor, 2023.

## 6.1 APRESENTAÇÃO DOS DADOS OBTIDOS

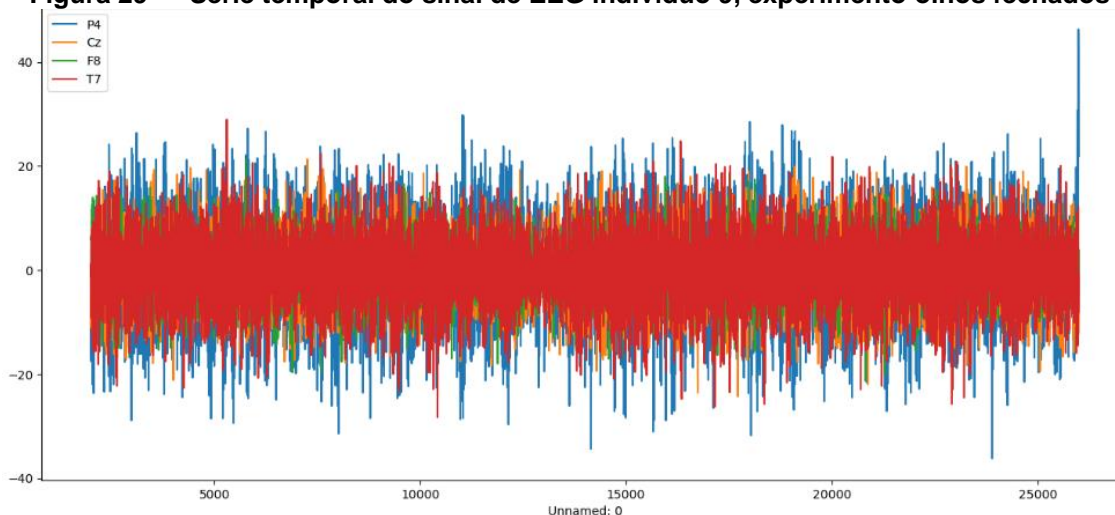
Diante da ampla quantidade de dados disponíveis, para este estudo, foi selecionado aleatoriamente o nono participante entre os 20 incluídos. A análise foi conduzida com base nos registros de EEG, coletados ao longo de um período de 2 minutos, com uma taxa de amostragem de 200 Hz. Esses registros detalham os estados de olhos abertos e fechados, oferecendo uma visão discreta do comportamento dos sinais captados nos quatro canais de EEG ao

longo do experimento de monitoramento do estado dos olhos, como demonstrado na série temporal apresentada nas Figuras abaixo.

**Figura 28 — Serie temporal do sinal de EEG indivíduo 9, experimento olhos abertos**

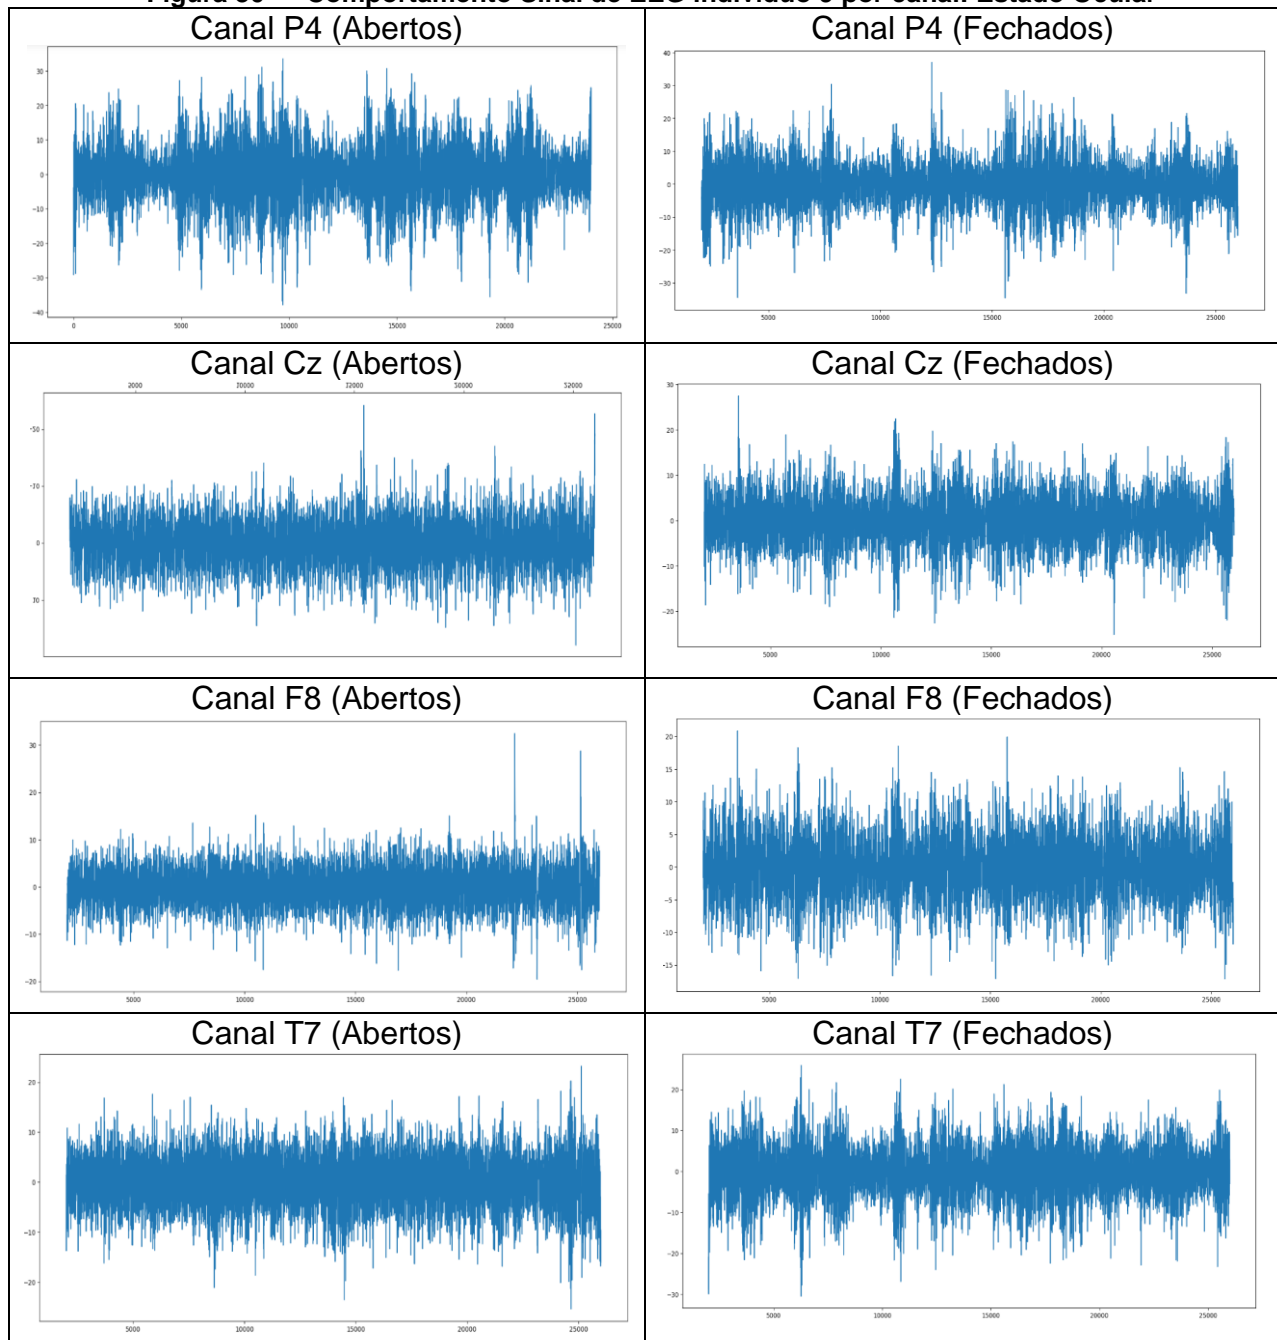


**Figura 29 — Serie temporal do sinal de EEG indivíduo 9, experimento olhos fechados**



Fonte: Autor, 2023.

A partir da representação gráfica anteriormente gerada e da programação em Python, extraiu-se as informações detalhadas sobre o comportamento dos sinais de EEG em cada fase do experimento, individualmente para os canais de gravação (P4, Cz, F8 e T7) individualmente. Isso é evidenciado pelas Figuras 30 apresentado abaixo, as quais retratam distintamente as fases de olhos abertos e fechados.

**Figura 30 — Comportamento Sinal de EEG indivíduo 9 por canal: Estado Ocular**

Fonte: Autor, 2023.

Essa análise possibilitou uma investigação detalhada dos padrões e das variações presentes nos sinais cerebrais capturados. Em cada etapa do experimento, realizou-se uma leitura individual das gravações da sessão experimental, resultando em um arquivo CSV composto por 5 colunas e 24.000 linhas. Esses dados foram posteriormente processados e organizados utilizando Python, visando proporcionar uma interpretação mais aprofundada das

informações. Esse processo foi complementado por análises estatísticas, conforme ilustrado na Figura 31 abaixo.

**Figura 31 — Leitura dos dados em formato Csv do indivíduo 9**

```

      Unnamed: 0      P4      Cz      F8      T7
0      2000      -1.936715      -2.592594      -1.508414      1.389368
1      2001      -8.999415      -7.472474      -8.803582      -8.671378
2      2002     -10.019483     -8.042502     -11.369005     -13.722670
3      2003      -6.326766     -3.986108     -8.681918     -11.795298
4      2004     -4.238327     -0.462584     -5.891316     -8.449233
...      ...      ...      ...      ...      ...
23995     25995     -5.069517     -18.948177      2.908591     -12.856129
23996     25996     -5.393458     -18.964011      6.189627     -14.880091
23997     25997     -5.002499     -19.243227      7.620112     -16.062711
23998     25998     -5.071970     -17.115363      5.313767     -14.827980
23999     25999     -3.662568     -12.034539      2.238303     -9.575305

```

[24000 rows x 5 columns]

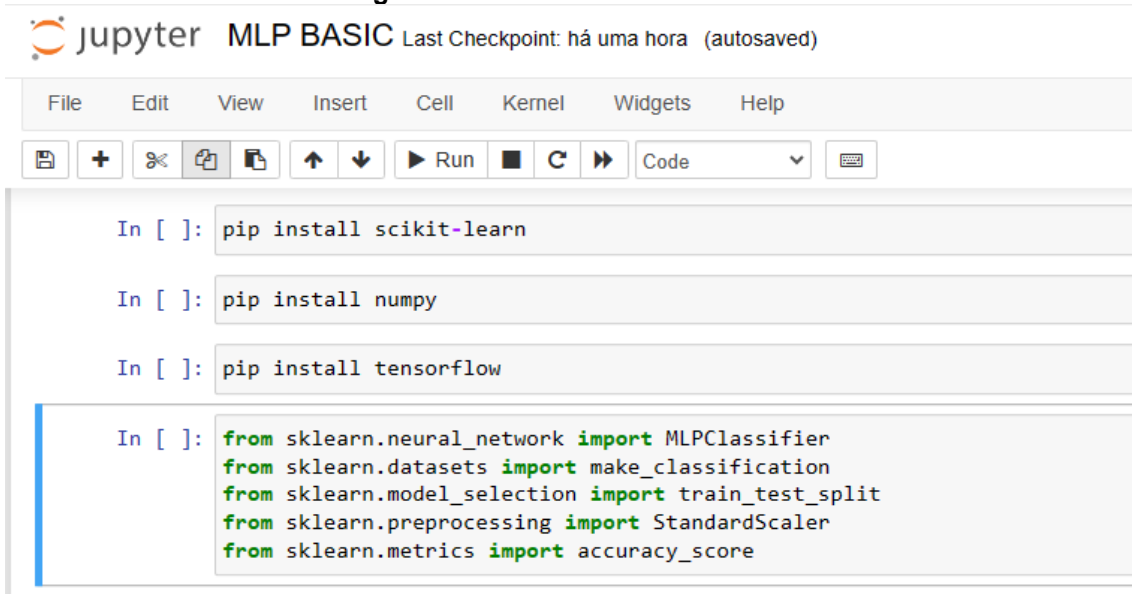
	Unnamed: 0	P4	Cz	F8	T7
<b>count</b>	24000.000000	24000.000000	24000.000000	24000.000000	24000.000000
<b>mean</b>	13999.500000	-0.009445	-0.033517	-0.007109	-0.024465
<b>std</b>	6928.347566	4.573030	3.926282	3.884278	4.766234
<b>min</b>	2000.000000	-27.204323	-24.281430	-19.545603	-25.354503
<b>25%</b>	7999.750000	-2.825914	-2.637670	-2.444436	-3.053484
<b>50%</b>	13999.500000	0.040528	-0.029998	0.003063	0.035792
<b>75%</b>	19999.250000	2.860977	2.563198	2.444539	3.057545
<b>max</b>	25999.000000	21.843478	17.839962	32.465042	23.205261

Fonte: Autor, 2023.

## 6.2 PROGRAMAÇÃO DA REDE NEURAL ARTIFICIAL EM PYTHON

Após explorar inicialmente os dados, foram empregadas bibliotecas fundamentais de aprendizado de máquina em Python para criar uma Rede Neural Artificial do tipo Perceptron de Múltiplas Camadas – MLP (Multi Layer Perceptron). Isso incluiu o uso de ferramentas essenciais, como Scikit-learn, TensorFlow e NumPy. Essas bibliotecas foram instaladas, juntamente com seus respectivos pacotes (funções), conforme exemplificado na Figura 32 a seguir.

Figura 32 — Instalando bibliotecas.



The screenshot shows a Jupyter Notebook titled "MLP BASIC" with a menu bar (File, Edit, View, Insert, Cell, Kernel, Widgets, Help) and a toolbar with icons for file operations and execution. The notebook contains four code cells:

```
In [ ]: pip install scikit-learn

In [ ]: pip install numpy

In [ ]: pip install tensorflow

In [ ]: from sklearn.neural_network import MLPClassifier
        from sklearn.datasets import make_classification
        from sklearn.model_selection import train_test_split
        from sklearn.preprocessing import StandardScaler
        from sklearn.metrics import accuracy_score
```

Fonte: Autor, 2023.

Para aprimorar a arquitetura da rede MLP, é crucial definir seus parâmetros iniciais de forma precisa. Isso não é um processo aleatório; ao contrário, depende das características dos dados e da natureza do problema de classificação que a rede neural artificial está destinada a resolver.

Assim, foi essencial realizar o pré-processamento dos dados originais. Uma etapa fundamental incluiu a criação de uma nova coluna, denominada "ESTADO DOS OLHOS", na qual foi estabelecido o valor 1 para representar o estado ocular aberto e o valor 0 para representar o estado ocular fechado como demonstra a Figura 33 abaixo:

Figura 33 — Novo arquivo com coluna "ESTADOS DOS OLHOS" adicionada.

	Unnamed: 0	P4	Cz	F8	T7	ESTADO DOS OLHOS
0	2000	-1.936715	-2.592594	-1.508414	1.389368	1
1	2001	-8.999415	-7.472474	-8.803582	-8.671378	1
2	2002	-10.019483	-8.042502	-11.369005	-13.722670	1
3	2003	-6.326766	-3.986108	-8.681918	-11.795298	1
4	2004	-4.238327	-0.462584	-5.891316	-8.449233	1
...	...	...	...	...	...	...
23995	25995	3.367580	6.347212	1.033786	-2.519973	0
23996	25996	0.994333	2.485867	2.835845	-2.973895	0
23997	25997	-1.505577	0.081627	5.358147	-2.343933	0
23998	25998	-3.944233	-0.916399	5.459586	-0.917605	0
23999	25999	-6.071044	-0.494940	3.968124	1.453907	0

	Unnamed: 0	P4	Cz	F8	T7	ESTADO DOS OLHOS
count	48000.000000	48000.000000	48000.000000	48000.000000	48000.000000	48000.000000
mean	11999.500000	-0.002345	-0.016009	0.003606	-0.008731	0.500000
std	6928.275394	6.973902	4.627100	4.347531	5.457573	0.500005
min	0.000000	-45.774460	-24.281430	-28.686553	-30.768529	0.000000
25%	5999.750000	-3.667096	-2.958284	-2.723082	-3.369999	0.000000
50%	11999.500000	0.113797	-0.004113	-0.016041	0.058526	0.500000
75%	17999.250000	3.817376	2.931149	2.712318	3.494186	1.000000
max	23999.000000	41.152378	22.365814	32.465042	26.803833	1.000000

Fonte: Autor, 2023.

Possibilitando assim, inclusão de novas informações, essenciais sobre o estado dos olhos. Resultando em um novo arquivo CSV contendo 6 colunas e 48.000 linhas. Esse passo fundamental simplificou consideravelmente o processo de treinamento e interpretação da rede neural.

Ao fazer isso, estabeleceu-se que os cinco neurônios de entrada correspondem às seguintes colunas: Unnamed: 0, P4, Cz, F8 e T7. Além disso, na última camada da rede neural, foram identificadas duas possíveis saídas: "ESTADOS DOS OLHOS", representando 1 para olhos abertos e 0 para olhos fechados delineando assim o problema de classificação para a rede neural artificial possa ser treinada e testada.

### 6.3 FASE DE TREINAMENTO DO MODELO DA REDE MLP

Nessa etapa, foram empregados 70% dos dados. As configurações iniciais para a fase de treinamento foram realizadas usando Python. Inicialmente, treinou-se o modelo por 10 épocas, obtendo uma taxa de acurácia variando entre 63% e 67%.

**Figura 34 — Fase de treinamento 10 épocas.**

```
Epoch 1/10
3/3 [=====] - 3s 391ms/step - loss: 2.6523e-04 - accuracy: 1.0000 - val_loss: 1.6079 - val_accuracy: 0.6333
Epoch 2/10
3/3 [=====] - 0s 27ms/step - loss: 1.9229e-04 - accuracy: 1.0000 - val_loss: 1.6800 - val_accuracy: 0.6667
Epoch 3/10
3/3 [=====] - 0s 29ms/step - loss: 1.8212e-04 - accuracy: 1.0000 - val_loss: 1.6406 - val_accuracy: 0.6333
Epoch 4/10
3/3 [=====] - 0s 96ms/step - loss: 1.5336e-04 - accuracy: 1.0000 - val_loss: 1.6342 - val_accuracy: 0.6333
Epoch 5/10
3/3 [=====] - 0s 79ms/step - loss: 1.5676e-04 - accuracy: 1.0000 - val_loss: 1.6737 - val_accuracy: 0.6667
Epoch 6/10
3/3 [=====] - 0s 21ms/step - loss: 1.4741e-04 - accuracy: 1.0000 - val_loss: 1.7160 - val_accuracy: 0.6667
Epoch 7/10
3/3 [=====] - 0s 21ms/step - loss: 1.2543e-04 - accuracy: 1.0000 - val_loss: 1.6764 - val_accuracy: 0.6333
Epoch 8/10
3/3 [=====] - 0s 25ms/step - loss: 1.1724e-04 - accuracy: 1.0000 - val_loss: 1.6910 - val_accuracy: 0.6333
Epoch 9/10
3/3 [=====] - 0s 24ms/step - loss: 1.0112e-04 - accuracy: 1.0000 - val_loss: 1.7296 - val_accuracy: 0.6667
Epoch 10/10
3/3 [=====] - 0s 29ms/step - loss: 9.2486e-05 - accuracy: 1.0000 - val_loss: 1.7539 - val_accuracy: 0.6667
```

Fonte: Autor, 2023

Assim para melhorar o nível de acurácia para o mesmo período de épocas, de treinamento optou-se por alterar o algum parâmetro que define a estrutura da rede neural. Como a escolha de duas camadas ocultas com 20 e 35 neurônios, respectivamente. Isso implica que a primeira camada oculta possui 20 neurônios e a segunda possui 35 neurônios e irão passar por 100 iterações (ou épocas) é que o modelo passará durante o treinamento com uma saída de resultado binário 1= olhos abertos e 0=olhos fechados, como mostra a Figura 35 abaixo:

**Figura 35 — Fase de treinamento 100 épocas, 2 camadas ocultas com 20 e 35 neurônios**

Época 1/100 - Precisão (Treino): 0.8862	Época 25/100 - Precisão (Treino): 0.9469
Época 2/100 - Precisão (Treino): 0.8911	Época 26/100 - Precisão (Treino): 0.9472
Época 3/100 - Precisão (Treino): 0.8992	Época 27/100 - Precisão (Treino): 0.9475
Época 4/100 - Precisão (Treino): 0.9067	Época 28/100 - Precisão (Treino): 0.9476
Época 5/100 - Precisão (Treino): 0.9141	Época 29/100 - Precisão (Treino): 0.9478
Época 6/100 - Precisão (Treino): 0.9207	Época 30/100 - Precisão (Treino): 0.9479
Época 7/100 - Precisão (Treino): 0.9224	Época 31/100 - Precisão (Treino): 0.9482
Época 8/100 - Precisão (Treino): 0.9261	Época 32/100 - Precisão (Treino): 0.9481
	Época 33/100 - Precisão (Treino): 0.9484
Época 66/100 - Precisão (Treino): 0.9493	Época 92/100 - Precisão (Treino): 0.9497
Época 67/100 - Precisão (Treino): 0.9492	Época 93/100 - Precisão (Treino): 0.9498
Época 68/100 - Precisão (Treino): 0.9492	Época 94/100 - Precisão (Treino): 0.9498
Época 69/100 - Precisão (Treino): 0.9493	Época 95/100 - Precisão (Treino): 0.9496
Época 70/100 - Precisão (Treino): 0.9493	Época 96/100 - Precisão (Treino): 0.9500
Época 71/100 - Precisão (Treino): 0.9493	Época 97/100 - Precisão (Treino): 0.9499
Época 72/100 - Precisão (Treino): 0.9493	Época 98/100 - Precisão (Treino): 0.9499
Época 73/100 - Precisão (Treino): 0.9494	Época 99/100 - Precisão (Treino): 0.9502
	Época 100/100 - Precisão (Treino): 0.9501

Fonte: Autor, 2023.

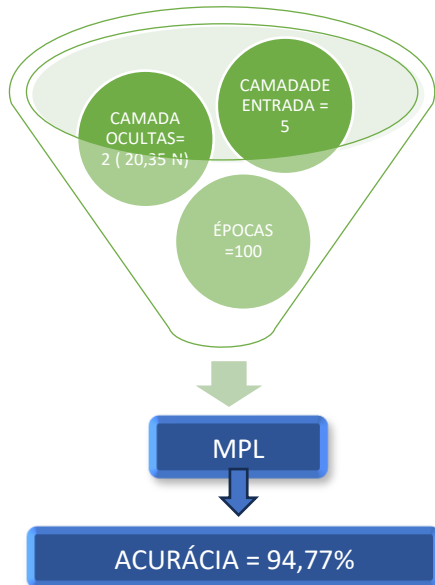
Nesta etapa, o modelo de rede neural apresentou um desempenho (precisão) de 91%, evidenciando uma acurácia de treinamento de 0,91. Isso indica que o modelo acertou corretamente cerca de 91% das amostras no conjunto de dados de treinamento. Sendo a acurácia uns dos parâmetros de avaliação da capacidade da rede neural em identificar e assimilar os padrões.

#### 6.4 FASE DE VALIDAÇÃO/TESTE DO MODELO DE REDE MLP

Nesse sentido a partir dos dados iniciais da rede obteve com esses parâmetros uma acurácia na faixa de 63- 67%. Deixando evidente a necessidade de alterações dos parâmetros e arquitetura geral da rede MLP. Assim sendo, a última, versão da fase de treinamento e teste foi com os parâmetros demonstrado

na Figura 36, obtendo um novo valor de acurácia do modelo de 94,77% validando a rede neural artificial para classificação do estado ocular.

**Figura 36 — Parâmetros finais da MLP.**

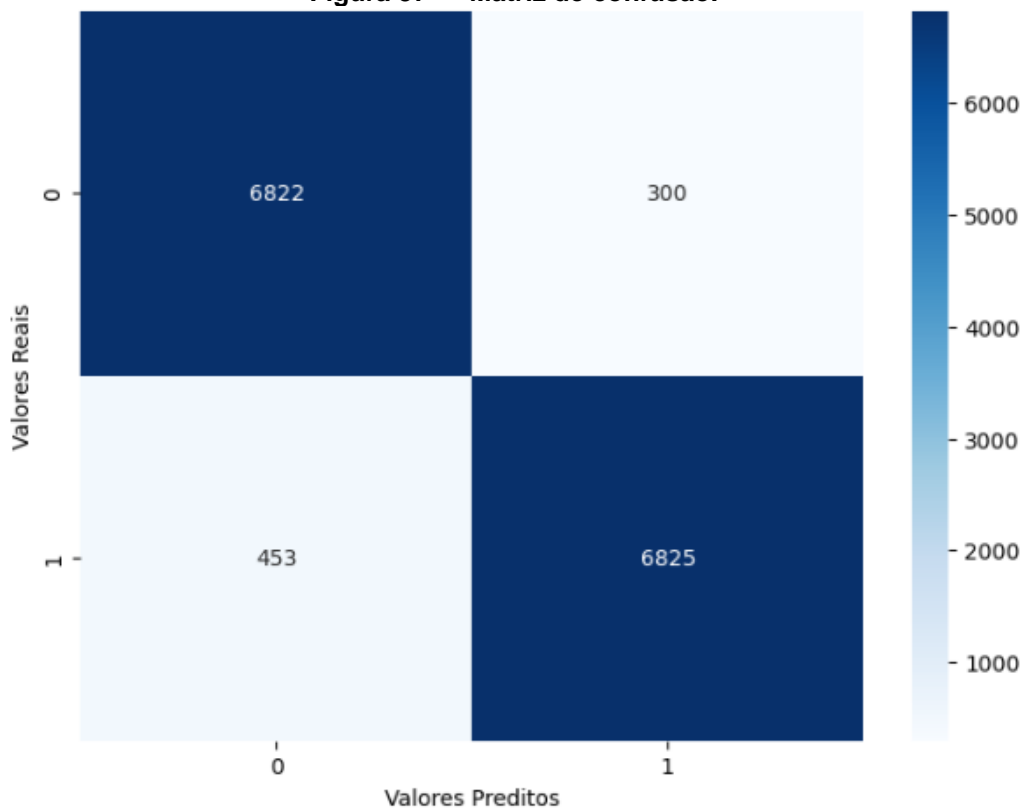


Fonte: Autor, 2023.

## 6.5 AVALIAÇÃO DA PERFORMANCE E PREDIÇÕES DA REDE NEURAL ARTIFICIAL MLP.

Uma das ferramentas para avaliação da performance do algoritmo de aprendizado supervisionado, caso da pesquisa, onde se têm um conjunto de dados já rotulados, consiste na avaliação da Matriz de confusão. Essa matriz é uma tabela que descreve o desempenho do nosso modelo de rede neural MPL de classificação, em termos de previsões feitas em comparação com as classes reais dos dados. Essa matriz confusão organiza as previsões do modelo em relação aos verdadeiros valores de classe em uma matriz, permitindo uma análise detalhada do desempenho do modelo para cada classe: 1 = olhos abertos e 0=olhos fechados como mostra a Figura 37.

Figura 37 — Matriz de confusão.



Fonte: Autor, 2023.


Nessa matriz, é possível notar que o número total de valores classificados equivale a 14.400, representando 30% da base de dados usada para fase de teste, conforme mencionado anteriormente. Nas células diagonais principais (em azul), encontramos os verdadeiros positivos (TP) e verdadeiros negativos (TN), registrando 6822 para olhos fechados e 6825 para olhos abertos. Esses números indicam as ocorrências em que o modelo previu corretamente a classe, totalizando uma taxa de precisão de 94%.

Por outro lado, destacam-se os falsos positivos (FP) e falsos negativos (FN), que representam as previsões equivocadas do modelo. Em 453 casos, o modelo previu que os olhos estavam fechados quando, na realidade, estavam abertos, e vice-versa em 300 ocasiões, quando o modelo indicou que os olhos estavam abertos, enquanto na base de dados estavam fechados.

Outra análise relevante a ser realizada em relação ao modelo de MLP desenvolvido na pesquisa, é avaliar o impacto do número de épocas no

treinamento, considerando a acurácia da rede neural artificial. Essa análise pode ser visualizada na Figura 38 apresentada a seguir.

**Figura 38 — Relação Acurácia pelo N° de épocas de treinamento.**



Observa-se que, a partir de 20 épocas, que representam o número de iterações em que o algoritmo percorre todo o conjunto de dados de treinamento durante o processo de aprendizado, até 100 épocas, não há uma variação substancial tanto na fase de treinamento quanto na fase de teste em relação à acurácia do modelo. Isso evidencia a importância de monitorar o desempenho do modelo ao longo das épocas para determinar o momento adequado de interromper o treinamento

## 7 CONSIDERAÇÕES FINAIS

Esta pesquisa visou integrar os conhecimentos da neurofisiologia com capacidade das redes neurais artificiais para a análise de sinais cerebrais com a finalidade de classificação do estado ocular usando técnicas de programação em Python, demonstrando assim convergência entre a área médica e a do aprendizado de máquina para previsão de sistemas biológicos.

Dessa forma, realizou-se uma revisão teórica abordando os conceitos essenciais para a compreensão do funcionamento de uma Interface Cérebro-Computador (ICC). Além disso, empregando um método de classificação de sinais de EEG por meio de uma rede neural do tipo Perceptron de Múltiplas Camadas – MLP. Este procedimento representa um passo inicial para demais pesquisas voltadas ao desenvolvimento e aprimoramento de ICCs

Todos os resultados obtidos demonstram que o modelo de RNA desenvolvido obteve sucesso em classificar corretamente as amostras dos banco de dados utilizado, apresentando predições satisfatória quando a classificação do estado ocular em abertos e fechados. É importante destacar que o presente trabalho verificou a eficiência do modelo por métricas como acurácia e análise de Matriz de confusão, porém não se esgota a possibilidade de mais métodos que possam ser utilizados, para explorar outros tipos de validação do modelo proposto.

É relevante ressaltar que a utilização de redes neurais constitui um trabalho complexo, uma vez que demanda a configuração de uma variedade de parâmetros, tais como o número de camadas ocultas, número de neurônios por camada e épocas de treinamento. Muitas vezes, compreender os resultados obtidos e buscar uma arquitetura mais eficaz para a resolução do problema proposto pode ser desafiador.

## REFERÊNCIAS BIBLIOGRÁFICAS

- ATKINSON, R. L. **Introdução à psicologia de Hilgard**. 16. ed. [S.l.]: Artmed, 2018.
- Bear, Mark F. Neurociências [recurso eletrônico] : **Desvendando o sistema nervoso** / Mark F. Bear, Barry W. Connors, Michael A. Paradiso; tradução Carla Dalmaç ... [et al.]. – 3. ed. – Dados eletrônicos.– Porto Alegre : Artmed, 2008.
- BRITTO, Luiz Roberto G.; BALDO, Marcus Vinícius C. Pensando o futuro da neurociência. **Revista USP**, n. 75, p. 32-41, 2007.
- DA SILVA, Z.A. L. **Controle de Prótese Mecânica Aplicado à Robótica Assistiva através de Eletromiografia**. Trabalho de Conclusão de Curso, Faculdade de Engenharia, Universidade Federal de Juiz de Fora, UFJF 2016.
- DOMINGUES, MO e cols. Explorando uma wavelet transformada continuamente. **Revista Brasileira de Ensino de Física** , v. 38, 2016.
- GOMES, Guilherme Gallo Costa et al. Construção de uma prótese mioelétrica de mão controlada por micromotores conectados a uma placa de arduino. **Brazilian Journal of Health Review**, v. 2, n. 1, p. 123-136, 2019.
- GRAIMANN, B.; ALLISON, B.; PFURTSCHELLER, G. **Brain-Computer Interfaces: A Gentle Introduction**. 2010.
- HU, S. et al. The statistics of eeg unipolar references: derivations and properties. **Brain topography**, Berlim, v. 32, n. 4, p. 696 – 703, 2019.
- IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA . **Censo Brasileiro de 2022**. Rio de Janeiro: IBGE, 2022.
- IMPARATO, Danilo Oliveira. **Receptores ionotrópicos como força motriz da origem das sinapses**. 2020. Trabalho de Conclusão de Curso. Universidade Federal do Rio Grande do Norte.
- KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. Imagenet classification with deeconvolutional neural networks. In: **Advances in neural information processing systems**. [S.l.:s.n.], 2015. p. 1097–1105.
- LAFLEUR, K. et al. Quadcopter control in three-dimensional space using a noninvasive motor imagery-based brain-computer interface. **Journal of Neural Engineering** 10, 2013.
- da Silva, I. N., Spatti, D. H. and Flauzino, R. A. (2016). **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**, 2edn, Artliber Editora Ltda, São Paulo, SP, Brasil
- LELIS, B. A. Utilização de Ondas Cerebrais para Controle de Componentes Eletrônicos. **Semana Acadêmica, Fortaleza**, v. 1, n. 52, 2014.
- LOTTE, F.; BOUGRAIN, L.; CLERC, M. **Electroencephalography (EEG)-based Brain-Computer Interfaces**. [S.l.: s.n.], 2015. ISBN 047134608X.
- Machado, Angelo B.M. Neuroanatomia funcional / Angeio B.M. Machado, Lucia Machado Haertel ; prefácio Gilberto Belisário Campos. -3. ed. - São Paulo : Editora Atheneu, 2014.

- Martini, Frederic H. **Anatomia humana** [recurso eletrônico] / Frederic H. Martini, Michael J. Timmons, Robert B. Tallitsch ; tradução Daniella Franco Curcio. – 6. ed. – Dados eletrônicos. – Porto Alegre : Artmed, 2009
- MCMAHAN, Timothy; PARBERRY, Ian; PARSONS, Thomas D. Modality specific assessment of video game player's experience using the Emotiv. **Entertainment Computing**, v. 7, p. 1-6, 2015.
- MINGUILLON, J.; LOPEZ-GORDO, M. A.; PELAYO, F. Trends in EEG-BCI for daily-life: Requirements for artifact removal. **Biomedical Signal Processing and Control**, Elsevier BV, v. 31, p. 407–418, jan 2017. Disponível em: <<https://doi.org/10.1016%2Fj.bspc.2016.09.005>>.
- NASEER, N.; HONG, K.-S. fnirs-based brain-computer interfaces: a review. **Frontiers in human neuroscience**, Lausanne, v. 9, p. 3 – 17, 2015.
- NAYYAR, Anand; PURI, Vikram. Uma revisão das placas Arduino, Lilypad e shields Arduino. In: **3ª Conferência Internacional de Computação para o Desenvolvimento Global Sustentável (INDIACom) 2016** . IEEE, 2016. pág. 1485-1492.
- NICOLAS-ALONSO, L. F.; GOMEZ-GIL, J. Brain computer interfaces, a review. *Sensors*, v. 12, n. 2, p. 1211–1279, 2012. ISSN 14248220. Disponível em: <https://doi.org/10.3390%2Fs120201211>
- PASCALIS, V. D.; VECCHIO, A.; CIRILLO, G. Resting anxiety increases eeg delta–beta correlation: Relationships with the reinforcement sensitivity theory personality traits. *Personality and Individual Differences*, Elsevier, v. 156, p. 109796, 2020.
- PEEMEN, M.; MESMAN, B.; CORPORAAL, H. Speed sign detection and recognition by convolutional neural networks. In: **Proceedings of the 8th International Automotive Congress**. [S.l.: s.n.], 2011. p. 162–170.
- SILVA BK, CARRO SA, COSTA MG. **Redes Neurais Aplicadas na Investigação de AVC por Tomografia Computadorizada**. *Colloquium Exactarum*. 2019;11(1):53–64.
- PETROV, B. B.; STAMENOVA, E. D.; PETROV, N. B. Brain-computer interface as internet of things device. In: **2016 XXV International Scientific Conference Electronics (ET)**. IEEE, 2016. Disponível em: <https://doi.org/10.1109%2Fet.2016.7753505>
- PROTACHEVICZ, P. R. **Padrões de disparos em redes neuronais**. 2020. Tese (Doutorado em Ciências/Física) - Universidade Estadual de Ponta Grossa, Ponta Grossa, 2020.
- RAMADAN, R. A. et al. Basics of brain computer interface. In: **Brain-Computer Interfaces**. Springer, 2015. p. 31–50. Disponível em: <[https://doi.org/10.1007%2F978-3-319-10978-7\\_2](https://doi.org/10.1007%2F978-3-319-10978-7_2)>.
- RAMOS, Camila Davi et al. Análise dos ritmos cerebrais de eletroencefalografia no processo de leitura. **Einstein (São Paulo)**, v. 18, 2020.
- RASCHKA, S.; MIRJALILI, V. **Python machine learning**. [S.l.]: Packt Publishing Ltd, 2017.
- Silva Pinto, M. A. (2011). **Estudo do potencial evocado visual em regime permanente baseado em LED para interface cérebro máquina**. publicado no site da Universidade Federal de Minas Gerais. <http://hdl.handle.net/1843/BUOS-8R3HN7>
- SILVA, Leonardo Pezenatto da. **Desenvolvimento preliminar de uma prótese de braço controlada por eletroencefalografia**. Florianópolis, SC, IFSC 2019. 129pg.

Silverthorn, Dee Unglaub. **Fisiologia humana: Uma abordagem integrativa**. 7ª edição, de autoria de Dee Silverthorn, publicado por Pearson Education, Inc., sob o selo Pearson. - Porto Alegre : Artmed, 2017.

SOUZA, J. R. M.; WANDERLEY, D. A.; DÓRIA, I. S.. A importância da robótica aplicada à neurociência como ferramenta utilizada na reabilitação de pacientes com deficiência locomotora: uma revisão teórica. **Engineering Sciences**, Aquidabã, v.3, n.1, p.6-18, 2015.

LOBO LC. Inteligência artificial e Medicina. **Rev Bras Educ Med**.2017;41(2):185-93.

Tortora, Gerard J. **Princípios de anatomia e fisiologia** / Gerard J. Tortora, Bryan Derrickson; tradução Ana Cavalcanti C. Botelho... [et al.]. – 14. ed. – Rio de Janeiro: Guanabara Koogan, 2016.

V.R.F. Miranda, R. Medeiros, L.A. Mozelli, A.C.S. Souza, A.A. Neto, A.S.V. Cardoso. Controle de um manipulador robótico via eletrooculografia: uma plataforma para tecnologia assistiva, XII Simpósio Brasileiro de Automação Inteligente (SBAI) Natal – RN, 25 a 28 de outubro de 2015.

VAID, S.; SINGH, P.; KAUR, C. EEG signal analysis for BCI interface: A review. **International Conference on Advanced Computing and Communication Technologies, ACCT**, v. 2015-April, p. 143–147, 2015. ISSN 23270659. Disponível em: <https://doi.org/10.1109%2Facct.2015.72>