



Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Programa de Pós-Graduação em Engenharia Elétrica

Classificação do Estado de Sonolência para Motoristas com Base em Eletroencefalograma, Redes Neurais Artificiais e Algoritmos Genéticos

Felipe Porge Xavier

Dissertação de Mestrado apresentada à Coordenadoria do Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal de Campina Grande - Campus de Campina Grande como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia Elétrica.

Área de Concentração: Processamento da Informação

Angelo Perkusich, D.Sc.

Orientador

Campina Grande, Paraíba, Brasil

©Felipe Porge Xavier, 8 de agosto de 2018

X3c

Xavier, Felipe Porge.

Classificação do estado de sonolência para motoristas com base em eletroencefalograma, redes neurais artificiais e algoritmos genéticos / Felipe Porge Xavier. - Campina Grande, 2018.

60 f. : il. color.

Dissertação (Mestrado em Engenharia Elétrica) - Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2018.

"Orientação: Prof. Dr. Angelo Perkusich".

Referências.

1. Eletroencefalograma. 2. Sonolência - Motoristas. 3. Sonolência - Trânsito. 3. I. Perkusich, Angelo. II. Título.

CDU 004.934:616.8-009.836.12(043)

**"CLASSIFICAÇÃO DO ESTADO DE SONOLÊNCIA PARA MOTORISTAS COM BASE EM
ELETROENCEFALOGRAMA, REDES NEURAIS ARTIFICIAIS E ALGORITMOS
GENÉTICOS"**

FELIPE PORGE XAVIER

DISSERTAÇÃO APROVADA EM 08/08/2018



ANGELO PERKUSICH, D.Sc., UFCG
Orientador(a)



JOSÉ SÉRGIO DA ROCHA NETO, D.Sc., UFCG
Examinador(a)



JAIDILSON JÓ DA SILVA, D.Sc., UFCG
Examinador(a)

CAMPINA GRANDE - PB

Dedicatória

Dedico este trabalho a minha família e a todos aqueles que vivem seus dias na busca por novas formas de salvar vidas ou de levar a esperança àqueles que se sentem inferiores por problemas físicos, psicológicos ou cognitivos.

Agradecimentos

Agradeço aos professores Angelo Perkusich, Taciana Saad Rached e Carlos Danilo Miranda Regis pelo apoio durante o desenvolvimento deste trabalho, pela incansável orientação e colaborações sem as quais não seria possível realizar esse trabalho.

Deixo também meu singelo agradecimento aos meus familiares, os quais sempre me apoiaram diante de todos os desafios que enfrentei durante o decorrer da preparação deste trabalho. Deixo um agradecimento especial a Stephany Mackyne da Silva Vieira, por sempre me ajudar a manter a calma diante dos desafios enfrentados e por me apoiar plenamente diante de todas as mudanças que a vida me reservou. Agradeço a Lucas Gabriel de Araújo Silva por ter me dado um grande apoio e não ter me deixado faltar esperança diante dos problemas e a todos os meus amigos que me apoiaram para que eu nunca desistisse dos meus objetivos. Também agradeço ao CNPq que proporcionou o suporte financeiro necessário para viabilizar a realização deste trabalho, bem como ao Comitê de Ética em Pesquisa da UFCG por autorizar a realização desta pesquisa.

Resumo

O cérebro humano está, na maior parte do tempo, processando informações para reagir de acordo com os estímulos recebidos pelo conjunto sensorial do corpo humano. A fadiga mental é um estado de sonolência e baixa atenção que aumenta o tempo de reação do indivíduo. No trânsito, o baixo tempo de reação é crucial para evitar acidentes, o que torna a fadiga mental um fator de risco para os motoristas, principalmente ao trafegar em rodovias, as quais normalmente permitem velocidades mais altas. Neste trabalho, é descrito um método de classificação de sinais de eletroencefalograma (EEG) em sonolência, utilizando redes neurais artificiais otimizadas utilizando algoritmos genéticos. Os parâmetros de entrada foram calculados para grupos de 256 amostras (janelas de 1 segundo) do canal AF7 de um *headset* de EEG portátil denominado *Muse*. A aplicação do método proposto resultou em 13,42% de erro na classificação das amostras (confusão), 14,49% de erro quadrático médio, 85,21% de sensibilidade e 87,95% de especificidade, a partir da utilização de dados adquiridos durante sessões em um simulador de direção.

Palavras-chave: Sonolência, Eletroencefalograma, Motoristas, Trânsito.

Abstract

Most of the time, the human brain is processing information to react according to the stimuli received through the sensory nervous system. The mental fatigue is a state of drowsiness and low attention that increases the reaction time of an individual. In the traffic, the short reaction time is crucial to avoid accidents, what means that mental fatigue is a risk factor for drivers, especially when driving through highways in which higher speeds are normally allowed. This work describes a method to classify EEG signals in drowsiness by using artificial neural networks optimized by genetic algorithms. The input parameters were calculated for groups of 256 samples (1 second window) of channel AF7 of a Muse portable EEG headset. The application of the proposed method resulted in 13.42% of classification error (confusion), 14.49% of mean squared error, 85.21% of sensitivity and 87.95% of specificity, using data acquired during sessions in a driving simulator.

Keywords: Drowsiness, Electroencephalography, Drivers, Traffic.

Sumário

1	Introdução	1
1.1	Eletroencefalograma e Fadiga Mental	2
1.2	Delimitação da Pesquisa	4
1.3	Descrição do Problema	5
1.4	Hipótese	5
1.5	Relevância	5
1.6	Objetivo Geral	6
1.7	Objetivos Específicos	6
1.8	Organização do Trabalho	6
2	Fundamentação Teórica	8
2.1	O Cérebro Humano	8
2.1.1	Estruturas e Funções do Cérebro	9
2.1.2	Mecanismos da Atenção e a Fadiga Mental	10
2.2	Sinais Cerebrais	13
2.2.1	Sinapses Nervosas e Eletroencefalografia	13
2.2.2	Aquisição de Sinais Cerebrais	16
2.2.3	Nomenclatura e Posicionamento dos Eletrodos	16
2.2.4	<i>Headsets</i> Portáteis de EEG Não-Invasivos	17
2.3	Processamento de Sinais	21
2.3.1	Análise de Componentes Independentes - ICA	22
2.3.2	<i>Wavelets</i> e Transformada <i>Wavelet</i> Discreta	22
2.4	Medidas Estatísticas	24

2.4.1	Média Aritmética	25
2.4.2	Desvio Padrão	25
2.4.3	Erro Quadrático Médio	25
2.5	Validação Estatística de Métodos de Classificação	26
2.5.1	Sensitividade	26
2.5.2	Especificidade	26
2.5.3	Energia	26
2.5.4	Entropia Aproximada	27
2.6	Classificadores	27
2.6.1	Support Vector Machine (SVM)	28
2.6.2	Método dos K-Vizinhos Próximos (KNN)	28
2.6.3	Redes Neurais Artificiais	29
2.7	Algoritmos Genéticos	31
2.8	Síntese	32
3	Método	34
3.1	Aquisição	34
3.2	Pré-processamento	35
3.3	Processamento	36
3.4	Classificação	38
3.5	Síntese	40
4	Experimentos Realizados	41
4.1	Recrutamento e Roteiro	41
4.1.1	Aplicativo <i>Android</i>	43
4.1.2	Aquisição e <i>Feedback</i> do Motorista	43
4.2	Síntese	45
5	Resultados Experimentais	47
5.1	Resultados	47
5.2	Síntese	50

6 Conclusão	51
6.1 Considerações	51
6.2 Trabalhos Futuros Sugeridos	52
Referências bibliográficas	53

Lista de Tabelas

2.1	Especificações do <i>Headset Muse</i> de EEG [55]	20
2.2	Especificações do <i>Headset Emotiv Epoc</i> de EEG [56]	21
3.1	Decomposição do sinal EEG com <i>wavelet Daubechies 4</i> [45]	36

Lista de Figuras

2.1	Representação da estrutura interna do cérebro [28].	9
2.2	Representação dos Lobos do cérebro [30]. (B) Representação dos Giros e sulcos cerebrais [28]	10
2.3	Mapa funcional do cérebro [31].	11
2.4	Representação da estrutura de um neurônio [39].	14
2.5	Variação na permeabilidade iônica de uma célula após um estímulo [39].	15
2.6	Colocação de sensores - EEG Invasivo [51]	17
2.7	O Sistema Internacional 10-20 visto pela esquerda (A) e por cima da cabeça (B). A = Lobo auricular, C = central, Pg = Nasofaringial, P = Parietal, F = Frontal, Fp = Frontal Polar e O = Occipital [53]. (C) Localização e nomenclatura dos eletrodos intermediários em 10%, conforme padronizado pela Sociedade Americana de Eletroencefalografia [54].	18
2.8	Ilustração do <i>Headset Muse</i> [55].	19
2.9	Posicionamento dos eletrodos do <i>Headset Muse</i> segundo o Sistema Internacional 10-20 [55].	19
2.10	Exemplo de colocação do <i>Muse</i> [55].	20
2.11	(A) Ilustração do <i>Headset Emotiv Epoc</i> . (B) Posicionamento dos eletrodos do EPOC [56].	21
2.12	Representação gráfica de uma <i>wavelet Daubechies 4</i> [64].	24
2.13	Ilustração do modelo simplificado de um neurônio humano [74].	29
2.14	Representação gráfica da organização e interação dos neurônios de uma Rede Neural Artificial <i>Perceptron</i> com múltiplas camadas [74].	30

2.15	Representação gráfica das etapas de um Algoritmo Genético. Elaborada pelo autor.	32
3.1	Fluxograma com as fases do método e os passos necessários. Elaborada pelo autor.	35
3.2	Estrutura da Rede Neural Artificial <i>Perceptron</i> Multicamadas. Elaborada pelo autor.	39
4.1	Euro Truck Simulator 2, <i>software</i> simulador de direção [88].	42
4.2	Estrutura do simulador de direção utilizado nas sessões. Elaborada pelo autor.	42
4.3	Formulário digital respondido pelos participantes no dia dos experimentos. Elaborada pelo autor.	44
4.4	Formulário digital respondido pelos participantes sobre o período. (A) Dados pessoais anônimos. (B) Quantização das habilidades. (C) Quantização do estado do indivíduo naquele período. Elaborada pelo autor.	45
4.5	Tela exibida para o participante durante a aquisição. Elaborada pelo autor.	46
5.1	Ilustração do sinal adquirido pelo <i>Muse</i> antes do pré-processamento com escala de $130\mu V$ por divisão. Elaborada pelo autor.	47
5.2	Ilustração do sinal adquirido pelo <i>Muse</i> depois do pré-processamento com $130\mu V$ por divisão. Elaborada pelo autor.	48
5.3	Matriz de confusão com os resultados apresentados pela ANN treinada e otimizada. Elaborada pelo autor.	49

Capítulo 1

Introdução

Tem sido amplamente declarado que as sociedades industrializadas modernas tornaram-se privadas de sono. Alguns estudos sugeriram que a duração média do sono diminuiu nas últimas décadas [1].

A fadiga é um estado de sonolência, tipicamente resultante da exaustão física ou mental, que implica na falta de foco para qualquer tipo de esforço, além da redução da eficiência ao trabalhar por conta da diminuição do nível de atenção e da capacidade de processar informações [2–4].

A sonolência leva à deterioração do desempenho do motorista e das habilidades de manuseio dos veículos [5]. A fadiga é considerada um dos fatores mais críticos que afeta motoristas, reduzindo o nível de atenção e aumentando o tempo de reação, o que resulta em uma menor aptidão para dirigir [6]. Estudos recentes mostram que 50% dos acidentes nas rodovias brasileiras ocorridos em 2016 foram causados pelo sono [7].

Um estudo realizado em 2016 pela Forbes apontou que cerca de 5000 pessoas morreram por acidentes de trânsito causados pelo sono nos Estados Unidos em 2015 e mais de 83,6 milhões de motoristas dirigiram diariamente em privação de sono [8].

A sonolência em motoristas foi identificada como a causa de mais de 20% de acidentes que resultaram em ferimentos e mortes globalmente [5]. Segundo um estudo realizado em 2011 por Bacchieri et al. [9], aproximadamente 1,2 milhão de pessoas em todo o mundo morrem vítimas dos acidentes de trânsito a cada ano e mais de 90% dessas mortes ocorrem em países de baixa e média renda. Surge, então, a necessidade de mensurar o nível de atenção

e fadiga mental de um indivíduo para detecção, avaliação de desempenho e monitoramento de atividades rotineiras, como dirigir [10].

Neste trabalho propõe-se o desenvolvimento de um método de classificação do estado de sonolência de motoristas, com base em Eletroencefalograma, Redes Neurais Artificiais e Algoritmos Genéticos.

1.1 Eletroencefalograma e Fadiga Mental

Diversos sistemas de detecção de fadiga são baseados em Eletroencefalograma (EEG), um método para avaliar a atividade elétrica cerebral. O EEG é utilizado na busca pela relação entre as mudanças na dinâmica cerebral e a fadiga de funções neurológicas [11].

Estudos relacionados a detecção de níveis de fadiga e sonolência em motoristas têm demonstrado que o EEG é bastante efetivo para a análise do estado de vigiância de um indivíduo [12, 13].

Existem várias abordagens diferentes sobre o uso do EEG para análise de fadiga mental. O requisito crucial deste procedimento é a escolha da melhor e mais relevante área do cérebro cujos sinais serão adquiridos. As áreas mais utilizadas para análise de fadiga são: o lobo parietal, cíngulo, córtex frontal inferior, córtex temporal superior, cerebelo e vérmis cerebelar [14]. Existem, por exemplo, trabalhos que fazem a análise da atividade das ondas Teta (4-8 Hz) na linha mediana frontal e das ondas Alfa (8-13 Hz) no lobo parietal [15]. A estrutura do cérebro é detalhada na Seção 2.1.1.

Samsami et al. [16] descreveram um sistema no qual os canais F3, F4, C3, C4, P3, P4, O1 e O2 são utilizados em um método que trata os sinais de EEG como imagens. A intensificação das atividades nas ondas Alfa são consideradas um sinal de fadiga a partir de dois métodos testados: o método de Contorno de Atividade de *Chan-Vese* e por meio da Regressão de Processo Gaussiano. As posições padronizadas dos eletrodos de EEG são detalhadas na Seção 2.2.3.

Na pesquisa de He et al. [17], é utilizado o *Headset EEG MindWave* para adquirir os sinais de EEG do lobo pré-frontal esquerdo, dados estes que são processados para a estimativa dos níveis de atenção e meditação. Os autores propõem a correlação entre o níveis de atenção e meditação, e a variação dos sinais EEG. A classificação é feita pelo método dos k-vizinhos

próximos, apresentando em média 68,31% de sensibilidade e 90,43% de especificidade.

Yang et al. [18] descreveram que foram realizados diversos testes de atenção em estudantes que estavam sendo monitorados quanto a atividade cognitiva, por meio do uso de EEG. A classificação dos níveis de atenção foi realizada utilizando a Máquina de Vetor de Suporte (do Inglês, *Support Vector Machine*). O sinal de EEG foi decomposto em 5 bandas primárias (*Alfa*, *Beta*, *Gama*, *Teta* e *Delta*) utilizando *wavelets*, com 5 parâmetros estatísticos na banda primária (incluindo entropia aproximada, variação total, energia, assimetria e desvio padrão). Foi utilizado um algoritmo genérico para melhorar os resultados e a precisão alcançada foi de 90,39%.

Ghassemi et al. [19] descreveram um método para análise de nível de atenção de um usuário, além de um sistema que chama a atenção do usuário continuamente, mantendo-o focado na atividade. A precisão alcançada na classificação do nível de atenção foi 81%.

Hamandicgaref et al. [10] descreveram um trabalho onde são extraídos, selecionados e aprendidos alguns padrões espectro-espaciais dos sinais de EEG com o objetivo de avaliar os níveis de atenção para o diagnóstico da condição do distúrbio de hiperatividade e déficit de atenção em crianças. A precisão obtida foi de 89,4% no procedimento que foi efetuado com 5 jovens.

Borghinia et al. [20] descreveram em seu trabalho que foi descoberto um padrão na distribuição das atividades das ondas Alfa durante o estado de fadiga do motorista devido ao aumento na potência espectral no lobo occipital durante situações simuladas de direção monótona. O aumento da atividade das ondas Delta e Teta também foi mencionado, mas a atividade na banda Alfa é mais evidente.

Na abordagem de Barwick et al. [21], são descritos alguns indicadores de um aumento significativo na potência das ondas Alfa em zonas centrais durante atividades neuropsicológicas. Essa condição foi nomeada de interferência *Stroop*.

Nas pesquisas realizadas por Lal et al. [12], foi encontrado um padrão comum na atenuação da atividade das ondas Alfa no lobo occipital, causada pelo estado de sonolência, seguido por um aumento na potência das ondas Alfa nas zonas central e frontal do cérebro.

1.2 Delimitação da Pesquisa

Devido a grande importância na determinação dos níveis de vigiância e fadiga, diversas metodologias foram propostas. Dentre os autores comentados neste trabalho, o método mais comumente utilizado é a análise dos sinais de EEG do córtex pré-frontal e no lobo occipital, zonas que estão diretamente ligadas aos níveis de atenção, fadiga e concentração dos seres humanos [14, 16, 17]. Existem alguns trabalhos que descreveram aplicações do uso de EEG na detecção do estado de sonolência em motoristas.

Ko et al. [22] desenvolveram um dispositivo de único canal de EEG para efetuar a análise do nível de sonolência de um motorista. O dispositivo trabalha em conjunto com um *smartphone*. Nos testes, foi utilizado um ambiente de realidade virtual para simular a atividade do motorista. A abordagem obteve 90,15% de precisão em testes realizados com 15 pessoas, por meio do uso de um modelo de predição baseado em Regressão Linear, e o nível de fadiga é exibido em um aplicativo para dispositivos móveis que se conecta via *Bluetooth* com o dispositivo de EEG desenvolvido.

Dey et al. [5] descreveram um método para detectar automaticamente o nível de sonolência em amostras de EEG, testando 4 diferentes classificadores: Método dos k-Vizinhos próximos, Análise Discriminante Linear, Árvore de Decisão Simples e *Support Vector Machine* (SVM). O melhor resultado foi obtido com o uso da SVM, com 85,7% de acertos na detecção de alerta e sonolência.

Awais et al. [23] descreveram uma análise no uso de EEG para detecção da sonolência em motoristas utilizando coerência. Foi utilizado um dispositivo de 19 canais para aquisição dos sinais de EEG durante um experimento realizado em simulador. Os resultados apontaram que os pares de eletrodos localizados em F3-F4 e F7-F8 se mostraram promissores na diferenciação entre os estados de alerta e sonolência com base nas bandas alfa (F3-F4) e beta (F7-F8). Os autores não citaram a taxa de acertos.

Song et al. [24] propuseram um sistema de detecção de sonolência em motoristas com base em um canal de EEG (AF7). Foi utilizada a potência média nas bandas de EEG (alfa, beta, gama, delta e teta) e *Support Vector Machine* como classificador. O dispositivo foi testado com 5 indivíduos e apresentou 84,86% de acerto na detecção da sonolência.

1.3 Descrição do Problema

Segundo estudo realizado no Brasil, dos acidentes de trânsito que ocorrem, 50% são causados pelo sono, chegando anualmente a mais de 360 mil acidentes, o que é alarmante [7]. Nos EUA, 5000 pessoas morreram por acidentes de trânsito causados pelo sono em 2015 [8]. Mais de 90% das mortes em acidentes de trânsito ocorrem em países de baixa e média renda, que normalmente tem sistemas de saúde pública inferiores se comparados aos países desenvolvidos e de alta renda [6, 9].

Com base nos dados apresentados, o problema considerado para o desenvolvimento deste trabalho foi: “Como detectar se um motorista está sob situação de risco iminente ao dirigir por conta do sono, de modo a tentar evitar possíveis acidentes de trânsito?”

1.4 Hipótese

Considerando o problema abordado neste trabalho, é considerada a hipótese de que: “É possível detectar o estado de sonolência do motorista por meio da análise dos sinais de Eletroencefalograma, permitindo a criação de sistemas que notifiquem o motorista sobre situações de risco ao dirigir por conta do sono.”

1.5 Relevância

O nível de sonolência de um indivíduo é ponto crítico ao dirigir devido a diminuição da eficiência e do aumento no tempo de reação. Desta forma, o monitoramento dos sinais cerebrais por meio do EEG tradicional pode ser utilizado para caracterizar estados de baixa atenção causados pelo sono, permitindo o desenvolvimento de sistemas para tentar minimizar o risco para o motorista e para as pessoas que circulam ao seu redor.

Neste trabalho é proposto um método de classificação de sinais de EEG em estados de sonolência por meio da utilização de Redes Neurais Artificiais (RNAs), cujos pesos individuais das entradas foram otimizados por Algoritmos Genéticos. As principais contribuições deste trabalho são: (i) proposição de um novo método de classificação de sinais de EEG em sonolência; (ii) a validação do método de classificação de sinais de EEG em sonolência

que utiliza as Redes Neurais Artificiais do tipo *Perceptron* Multicamadas, que são aproximadores universais bastante flexíveis e largamente utilizadas; (iii) a validação da detecção da sonolência a partir de sinais de EEG adquiridos por dispositivos portáteis, não-invasivos, com poucos canais, os quais costumam ser mais baratos; (iv) os resultados obtidos foram baseados apenas em métricas calculadas a partir do canal AF7, sem a necessidade da utilização de sinais de Eletro-oculograma (EOG) e/ou câmeras.

1.6 Objetivo Geral

O objetivo geral definido para este trabalho foi o desenvolvimento de um método baseado em EEG para avaliar se o motorista está ou não em condições de continuar dirigindo, a partir da detecção da sonolência por meio da utilização dos sinais de Eletroencefalograma.

1.7 Objetivos Específicos

Os objetivos específicos definidos para este trabalho foram:

- revisar a literatura sobre os sistemas conexos existentes, no contexto de motorista;
- propor um método que seja efetivo na detecção do estado de sonolência de um indivíduo;
- realizar testes para demonstrar a efetividade do método.

1.8 Organização do Trabalho

Neste Capítulo foi apresentada uma breve contextualização do trabalho e foi descrita a importância de monitorar se um motorista está em uma situação de risco iminente por conta do sono. Além disso, foi apresentada uma delimitação da pesquisa, seguida pela descrição do problema, hipótese levantada e os objetivos definidos para este trabalho.

No Capítulo 2, é apresentada uma base teórica importante para o desenvolvimento deste trabalho. Inicialmente, são descritos alguns aspectos do cérebro humano, além das características fisiológicas dos estados de atenção, fadiga e vigília. Em seguida são abordados

os sinais cerebrais, descrevendo as técnicas de aquisição e o dispositivo *Muse* (*headset de EEG*) utilizado. Por último, são descritas algumas técnicas de processamento de sinais e classificação de padrões.

No Capítulo 3, são descritas as etapas do método: aquisição, pré-processamento, processamento e classificação.

Em seguida, no Capítulo 4, são descritos os experimentos realizados para a aquisição dos dados necessários para validação do método descrito neste trabalho.

Já no Capítulo 5, estão descritos os resultados obtidos com base na validação do método proposto, a partir dos dados adquiridos durante o experimento realizado.

Por fim, no Capítulo 6, são feitas as considerações finais sobre o trabalho e sugeridos alguns trabalhos futuros a partir do método descrito.

Capítulo 2

Fundamentação Teórica

Neste capítulo são descritas algumas características importantes do cérebro humano, além de uma base contextual sobre o procedimento de Eletroencefalograma, bem como uma breve introdução sobre alguns métodos de processamento de sinais e classificação.

2.1 O Cérebro Humano

O cérebro humano é a estrutura viva mais complexa conhecida no universo. Este constitui cerca de 80% da massa total do encéfalo, sendo considerada a maior e mais evidente estrutura encefálica [25, 26].

O cérebro humano está, na maior parte do tempo, processando informações para reagir de acordo com o conjunto sensorial do corpo humano (sistemas auditivo, visual, etc.) e está associado com controle de funções de alta ordem, como o comportamento voluntário, pensamento, percepção, planejamento e compreensão linguística [10, 25, 26].

A organização do cérebro baseia-se em redes complexas que dão suporte para várias funções cognitivas [27]. Esta capacidade de criar uma rede de conexões que supera qualquer rede social e armazena mais informação que um supercomputador, torna os humanos capazes de alcançar conquistas incríveis [26].

2.1.1 Estruturas e Funções do Cérebro

O cérebro humano está dividido em dois hemisférios (esquerdo e direito) que são interligados por uma estrutura chamada de corpo caloso (Figura 2.1), situado na parte inferior da fissura que há entre os hemisférios. Os hemisférios possuem uma fina camada externa de substância cinzenta (o córtex cerebral), que contém os neurônios. Abaixo do córtex cerebral encontra-se uma camada de substância branca, que contém feixes de axônios neurais recobertos por uma bainha de mielina, uma substância “gordurosa” que isola a membrana celular, que lhe confere uma aparência branca [25].

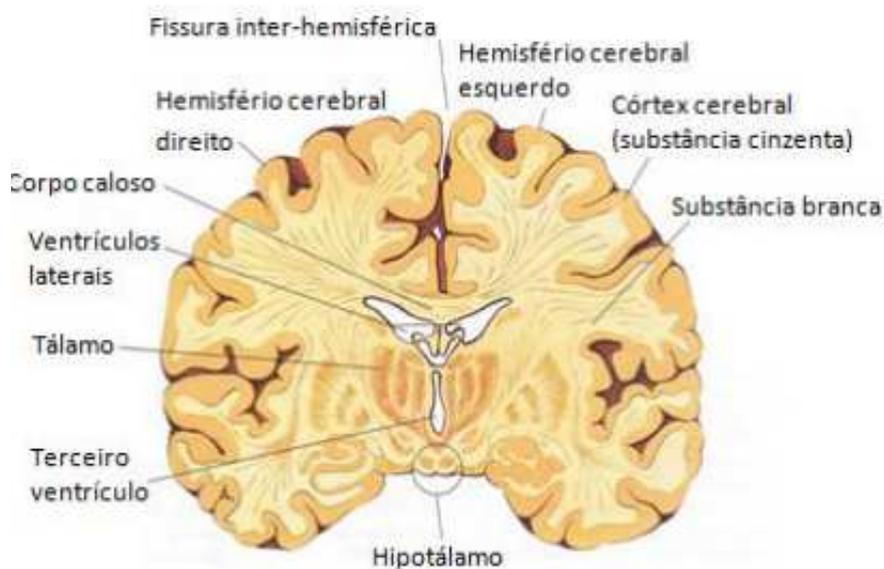


Figura 2.1: Representação da estrutura interna do cérebro [28].

Em cada hemisfério são considerados quatro lobos (Figura 2.2A): lobo frontal, parietal, occipital e temporal. Cada lobo tem circunvoluções características e dobras. As cristas das circunvoluções são denominadas giros. As ranhuras são chamadas sulcos ou fissuras. Os giros e sulcos mais eminentes são semelhantes entre um indivíduo e outro e têm nomes específicos (Figura 2.2B): giro pré-central, sulco central e giro pós central [28].

Cada lobo está relacionado a funções específicas. O lobo frontal está relacionado a elaboração do pensamento, planejamento, programação das necessidades individuais e emoção. O lobo parietal tem relação com as sensações de dor, tato, gustação, temperatura e pressão. O lobo temporal está relacionado ao sentido de audição, com reconhecimento de tons específicos e intensidades sonoras. O lobo occipital é responsável pelo processamento da

informação visual [29].

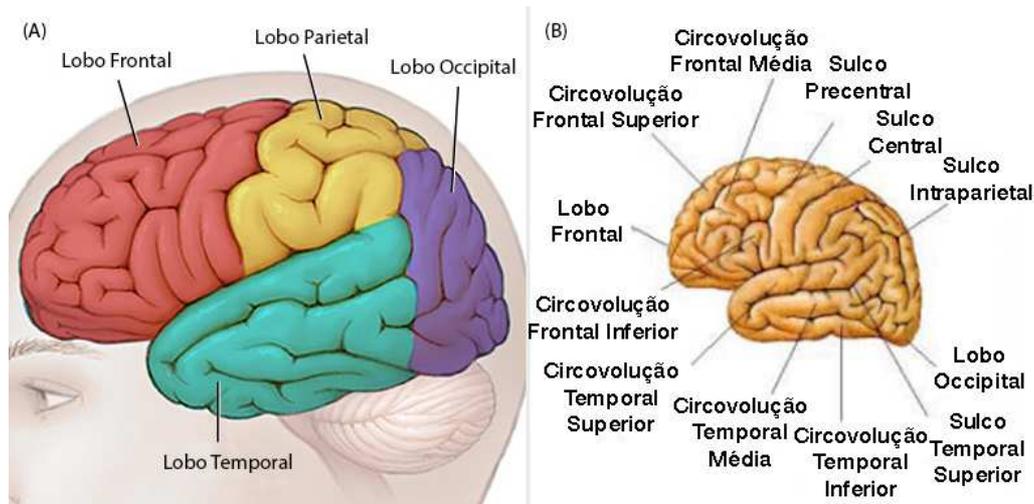


Figura 2.2: Representação dos Lobos do cérebro [30]. (B) Representação dos Giros e sulcos cerebrais [28]

Desde o início do século XX, os neurocientistas buscam correlacionar algo da estrutura cortical que possa caracterizar as diferentes funções do córtex. Esperava-se que áreas específicas pudessem ser relacionadas com funcionalidades específicas. Porém, não foi assim: embora se tenha conseguido identificar áreas com características estruturais específicas, geralmente histológicas, não foi possível estabelecer uma correlação direta com cada função.

Observando a Figura 2.3, é possível analisar algumas funções cerebrais cuja responsabilidade foi direcionada a algumas zonas cerebrais em específico, porém, a correlação entre o mapa histológico e este mapa funcional só se sustenta para as regiões primárias, isto é, aquelas que recebem informação sensorial ou emitem os comandos motores [31].

2.1.2 Mecanismos da Atenção e a Fadiga Mental

A atenção está diretamente relacionada ao processamento preferencial de determinadas informações sensoriais [32]. Segundo Brandão [33], a atenção pode ser descrita como a capacidade do indivíduo responder predominantemente os estímulos que lhe são significativos em detrimento de outros, onde, nesse processo, o sistema nervoso é capaz de manter um contato seletivo com as informações que chegam através dos órgãos sensoriais, dirigindo a atenção para aqueles que são relevantes e garantindo uma interação eficaz com o meio.

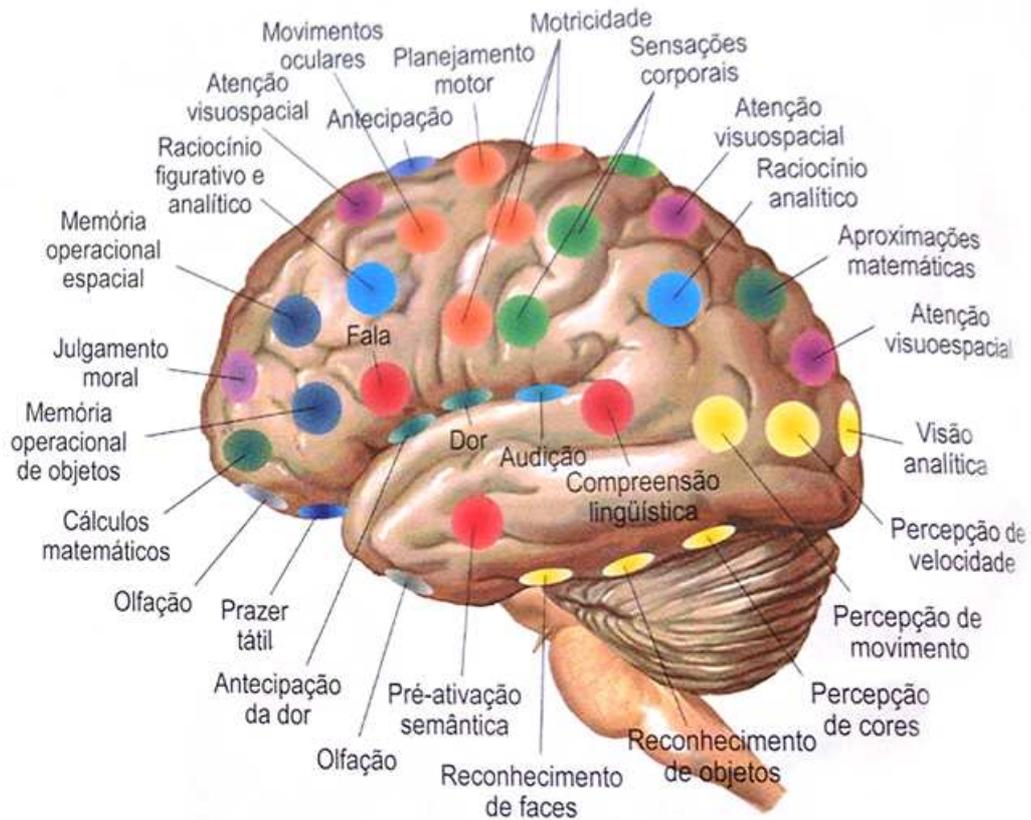


Figura 2.3: Mapa funcional do cérebro [31].

Os mecanismos da atenção atuam de um modo dinâmico, selecionando os estímulos que chegam pelas diferentes vias sensoriais e organizando os processos mentais [32].

Aquilo que os seres humanos percebem depende diretamente de onde a atenção está sendo dirigida. O ato de prestar atenção, independente da modalidade sensorial, aumenta a sensibilidade perceptual para a discriminação do alvo e reduz a interferência causada por outros estímulos [34].

Em contrapartida, esgotamentos físicos e mentais por conta da carga excessiva de atividades, juntamente com condições emocionais preocupantes, podem levar um indivíduo a um estado de fadiga mental. Este estado é considerado bastante preocupante e de difícil conceituação, interpretação e aferição, por ser um estado global relacionado a diversos sistemas do organismo [35].

Além de ser um fenômeno que causa mal-estar, a fadiga provoca alterações no estado psicológico e no comportamento do indivíduo, podendo ser encarada como resultante de

esforço físico e/ou mental associado às condições ambientais e psicológicas, individuais e de trabalho [36].

Segundo Oliveira et al. [35], a estrutura do trabalho (longas jornadas, pressão, falta de autonomia, curto descanso e férias insuficientes) e condições como alternância de turnos, riscos físicos, complexidade da atividade, postura durante a execução, entre outras, favorecem o aparecimento da fadiga, a qual pode manifestar-se em trabalhadores de diferentes tipos de atividade, desde os operários até os profissionais da saúde. Do mesmo modo, também as formas de manifestação desta vão se dar em diferentes níveis, a depender da relação do indivíduo com a atividade nociva.

Durante a jornada cotidiana, a necessidade de movimentar-se é indiscutível. Muitos trabalhadores residem distantes dos seus locais de trabalho, ou, até mesmo, trabalham no trânsito.

A atenção é um processo psíquico fundamental no trânsito, principalmente para o condutor, ao dirigir, por este se encontrar em um ambiente com muitos estímulos, como pedestres, ciclistas, sinalizações, sons diversos [37].

O ato de dirigir envolve um complexo processo de interação das funções neurais, pois, conduzir um veículo envolve memória, atenção, tomada de decisões em um ambiente repleto de informações, como tráfego de pedestres, de outros veículos, diversidade de sons e imagens [37].

O comportamento dos condutores é considerado uma causa relevante na ocorrência de acidentes de trânsito, pois, muitas vezes, o fator humano é considerado o principal responsável por eles [38]. Além disso, os motoristas, algumas vezes, dirigem influenciados psicologicamente por condições de risco iminente, como a baixa iluminação e a chuva forte.

A fadiga mental em união com a carga psicológica a qual o motorista está submetido, representa um fator de alto risco para o trânsito, por influenciar diretamente no tempo de resposta e no nível de atenção do motorista, o que pode impedi-lo de contornar acidentes que poderiam ser evitados por meio de técnicas de direção defensiva.

2.2 Sinais Cerebrais

Os sinais cerebrais são resultado de interações entre as células que compõem o tecido nervoso, seja ele do encéfalo, da medula espinal ou dos nervos periféricos. Existem dois tipos de células no tecido nervoso: os neurônios e as células de suporte (ou de isolamento) [39,40].

Os neurônios conduzem os sinais do sistema nervoso. As células de isolamento mantêm os neurônios em suas posições e evitam que os sinais sejam dispersados entre os neurônios e suas estruturas intercelulares. O conjunto de células de isolamento é chamado de Neuroglia [41].

Na Figura 2.4 é possível observar a representação da estrutura de um neurônio. Os componentes principais de um neurônio são: o corpo celular, responsável pela nutrição do neurônio; os dendritos, principais partes receptoras dos neurônios; o axônio, também conhecido como fibra nervosa, são responsáveis por transmitir sinais neurais para a célula seguinte do cérebro ou da medula espinal; e as sinapses, juntamente com os terminais dos axônios, responsáveis por transmitir ou refugar os sinais neurais de um neurônio para outro [41].

2.2.1 Sinapses Nervosas e Eletroencefalografia

Para as células de mamíferos, considera-se que o Na^+ , o K^+ e o Cl^- são os três íons que influenciam o potencial de membrana nas células em repouso, onde a contribuição de cada íon é proporcional a sua habilidade de cruzar a membrana e o movimento dos íons gera sinais elétricos de uma célula. Cada célula muda a sua permeabilidade iônica abrindo e fechando os canais de movimentação na sua membrana [39].

Os neurônios contêm uma grande variedade de canais iônicos com portões que abrem e fecham, dependendo das condições intracelulares e extracelulares. O estímulo mínimo para a abertura de um canal varia de um tipo de canal para outro [39].

As mudanças na permeabilidade dos canais geram sinais elétricos de dois tipos: potenciais graduados, que são sinais de força variável e percorrem distâncias curtas, perdendo força a medida que percorrem a célula; e os potenciais de ação, que são grandes despolarizações muito breves que percorrem longas distâncias por um neurônio sem perder força. Os potenciais graduados refletem a intensidade do estímulo recebido pelo neurônio [39].

Na Figura 2.5 é possível observar as alterações na permeabilidade iônica de uma célula

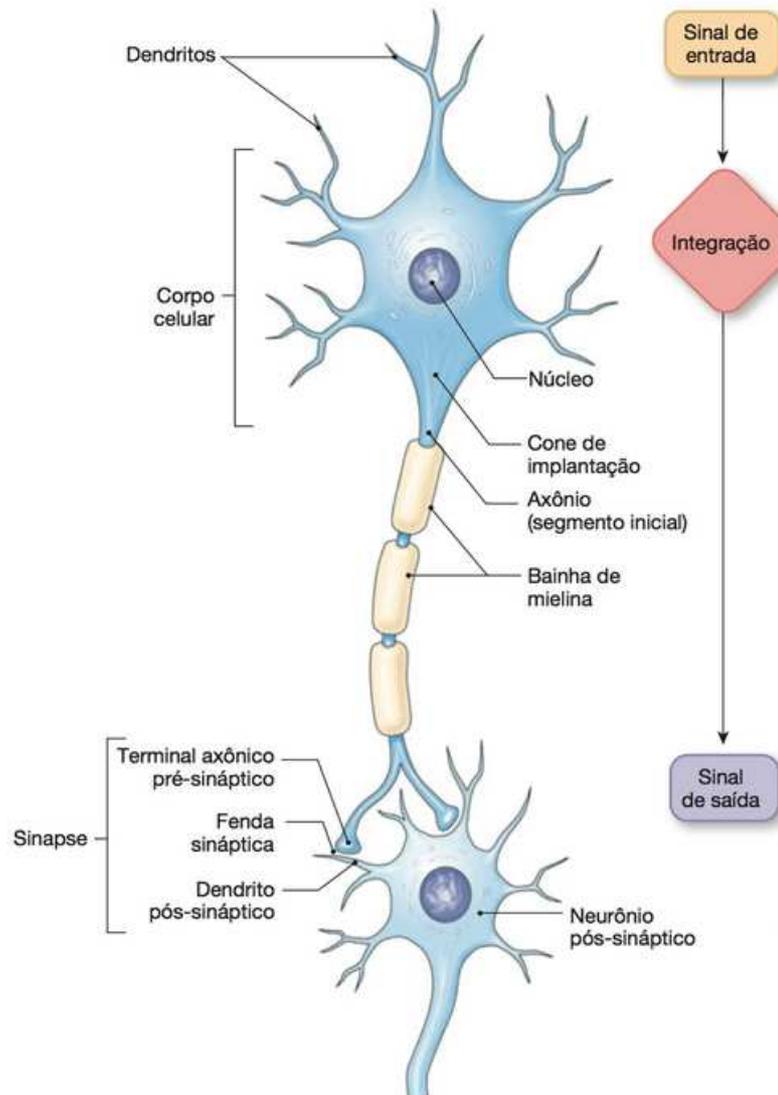


Figura 2.4: Representação da estrutura de um neurônio [39].

e sua conexão com o sinal que está percorrendo a mesma, desde a chegada do estímulo até a transmissão do estímulo para a próxima célula. Durante a passagem do estímulo, no qual tem duração de aproximadamente dois milissegundos, a tensão entre o interior e o exterior da célula varia de -60mV até $+20\text{mV}$ [40].

Um cérebro adulto contém em torno de 100 bilhões de neurônios interconectados e cada um deles gera descargas elétricas enquanto o cérebro trabalha. A soma de todas essas pequenas cargas elétricas contribui com a geração de um campo elétrico com potenciais elétricos flutuantes, na faixa de μV , em torno de nosso couro cabeludo. Essas flutuações

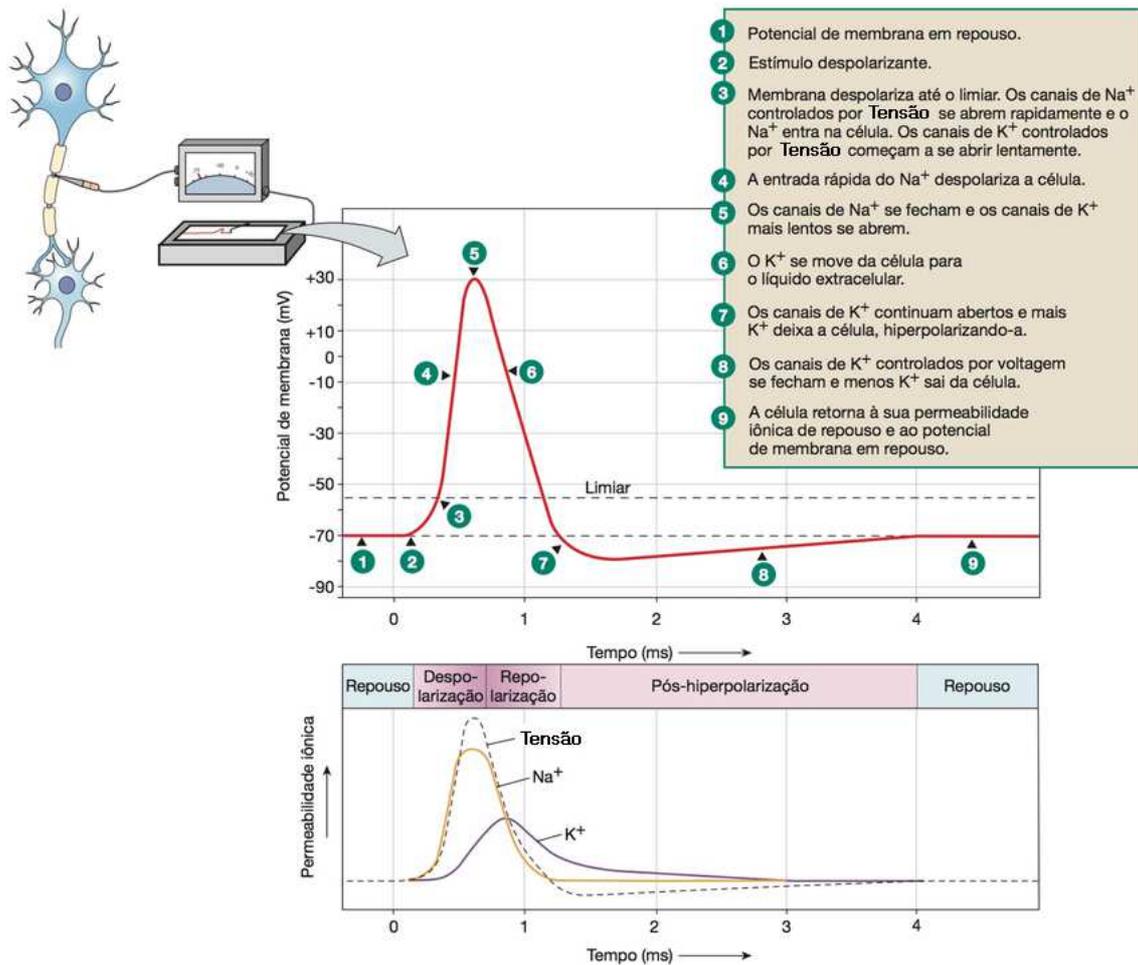


Figura 2.5: Variação na permeabilidade iônica de uma célula após um estímulo [39].

podem ser medidas utilizando sensores [42].

O procedimento de medição dos potenciais elétricos entre dois ou mais pontos, chamados eletrodos ou sensores, em diferentes localidades do couro cabeludo, de acordo com alguns padrões de configurações, é chamado de Eletroencefalografia (EEG). Por conta disso, as ondas cerebrais também podem ser chamadas de sinais EEG [42].

A atividade elétrica dos neurônios no córtex cerebral, ou seja, mais próximos do crânio e, conseqüentemente dos eletrodos, é observada mais claramente no EEG, enquanto que a atividade elétrica gerada em estruturas cerebrais mais profundas não pode ser observada diretamente com o uso do EEG [40]. A tensão da atividade dos neurônios varia na faixa dos mV, entretanto, o sinal medido pelo EEG é atenuado pelos tecidos e ossos existentes entre os eletrodos e o córtex cerebral do indivíduo, o que resulta em potenciais com amplitude na

ordem de μV [43].

Os sinais de EEG possuem amplitudes entre 10 e 100 μV e frequências que variam de 1 a 100 Hz, divididas em 5 bandas: gama (32Hz+), beta (16-32Hz), alfa (8-16Hz), teta (4-8Hz) e delta (1-4Hz)[44, 45].

A atividade em cada banda está ligada a diferentes estados do indivíduo. A atividade em alfa indica um estado de relaxamento. A atividade em beta é originada principalmente do lobo frontal e está associada à consciência normal de vigília e alerta [18].

A atividade em gama está relacionada a percepção gestáltica¹ e a algumas funções cognitivas como a atenção, o aprendizado, a percepção e a memória. Alguns estudos sugerem que a atividade em gama está relacionada a seletividade da atenção [46–48].

A atividade em teta ocorre principalmente nos lobos parietal e temporal, e é mais predominante durante os estados de meditação, sonolência e ao dormir. Já a atividade em delta está associada com o estágio de sono profundo, falta de oxigenação, inconsciência e sensação de anestesia [18].

2.2.2 Aquisição de Sinais Cerebrais

A aquisição dos sinais cerebrais pode ser realizada a partir de diversas técnicas que são divididas em dois grupos: métodos invasivos e não-invasivos [49]. Os métodos invasivos necessitam de uma intervenção cirúrgica para a aplicação direta de eletrodos ao cérebro e são mais precisos por conta da aquisição ser realizada diretamente do cérebro [50]. Na Figura 2.6 está ilustrada a colocação de sensores EEG do método invasivo.

Os métodos não-invasivos utilizam eletrodos que não necessitam de aplicação por meio de intervenção cirúrgica e podem ser usados na realização de testes em humanos sem comprometer a saúde destes [52].

2.2.3 Nomenclatura e Posicionamento dos Eletrodos

Conforme descrito anteriormente, na Seção 2.1.1, cada região do cérebro desempenha diferentes funções. O posicionamento dos eletrodos de EEG partem dessa afirmação e seguem

¹Para se compreender as partes, é preciso, antes, compreender o todo.

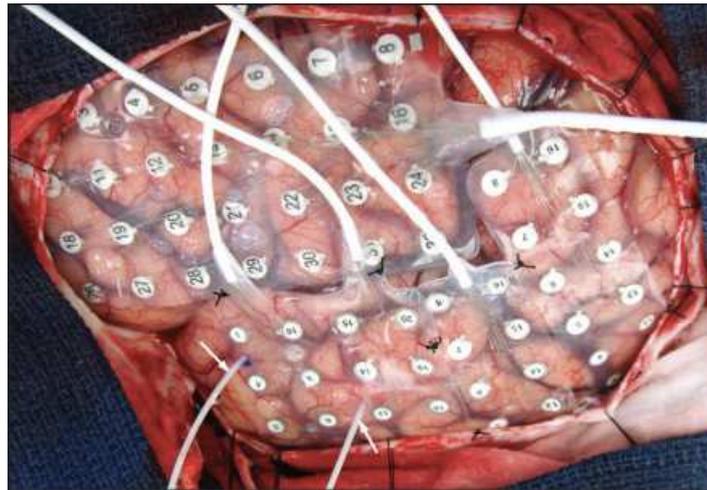


Figura 2.6: Colocação de sensores - EEG Invasivo [51]

as especificações do Sistema Internacional 10-20, que especifica os locais dos eletrodos (Figura 2.7) para facilitar comparações entre diferentes estudos.

A nomenclatura utilizada pelo Sistema Internacional para identificar as posições dos eletrodos utiliza letras e números, onde as letras representam a estrutura anatômica do cérebro sob a qual o eletrodo será fixado (Sulco Central e os lobos Frontal, Parietal, Temporal e Occipital), enquanto os números representam o posicionamento com base na linha sagital, onde os números ímpares correspondem a posições no hemisfério esquerdo e os pares ao hemisfério direito. Os eletrodos que encontram-se na linha sagital central são representados com a letra “z” ao invés dos números [54].

2.2.4 *Headsets* Portáteis de EEG Não-Invasivos

Existem diversos dispositivos capazes de fazer a aquisição dos sinais de EEG, variando apenas o tipo de eletrodos utilizados (a seco ou molhado), o número de canais, o tipo de circuito de pré-processamento utilizado, conectividade, autonomia, entre outros aspectos.

Dois *headsets* não-invasivos e portáteis de EEG, bastante populares são o *Muse* e o EPOC da *Emotiv*.

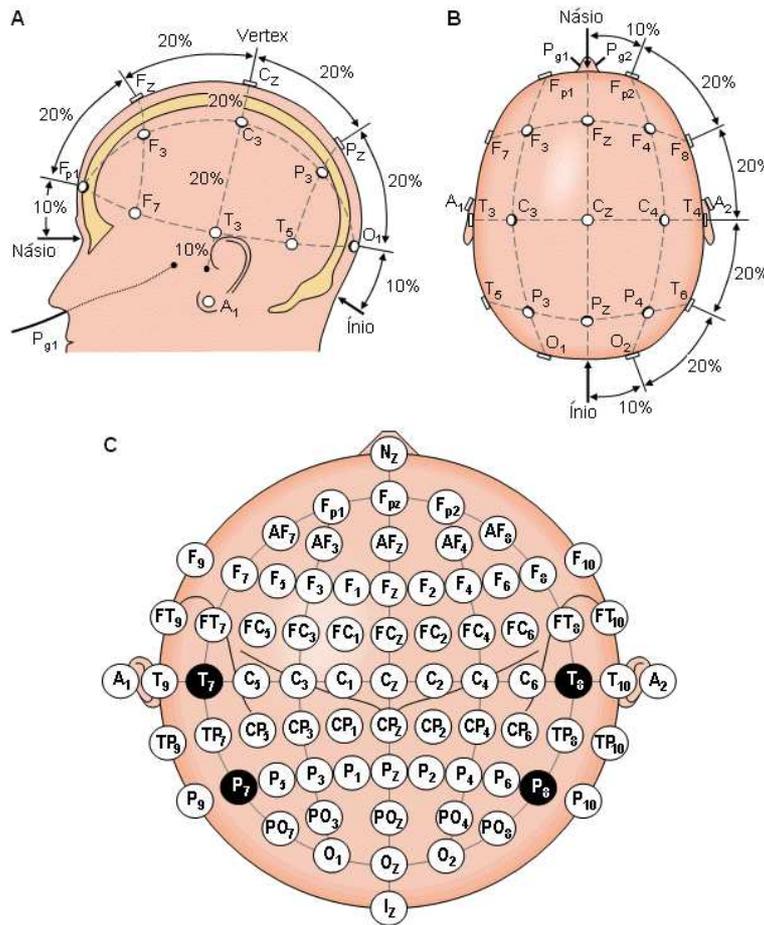


Figura 2.7: O Sistema Internacional 10-20 visto pela esquerda (A) e por cima da cabeça (B). A = Lobo auricular, C = central, Pg = Nasofaringial, P = Parietal, F = Frontal, Fp = Frontal Polar e O = Occipital [53]. (C) Localização e nomenclatura dos eletrodos intermediários em 10%, conforme padronizado pela Sociedade Americana de Eletroencefalografia [54].

Muse

A empresa *Muse* dispõe de um dispositivo portátil e leve, ilustrado na Figura 2.8 para aquisição de sinais de EEG com 4 canais (TP9, AF7, AF8 e TP10, conforme ilustrado na Figura 2.9) com eletrodos a seco, peso de 60g, bateria com duração de até 10 horas, conectividade *Bluetooth* 4.0 LE e taxa de amostragem de 256Hz [55].

O *Muse* tem a forma de uma tiara com abertura ajustável e fácil colocação. O indivíduo apenas precisa posicionar a tiara pouco acima das sobrancelhas e os apoiadores por trás das orelhas, conforme ilustrado na Figura 2.10. Não é necessário o uso de soluções salinas, tendo em vista que os sensores do *Muse* são a seco.



Figura 2.8: Ilustração do *Headset Muse* [55].

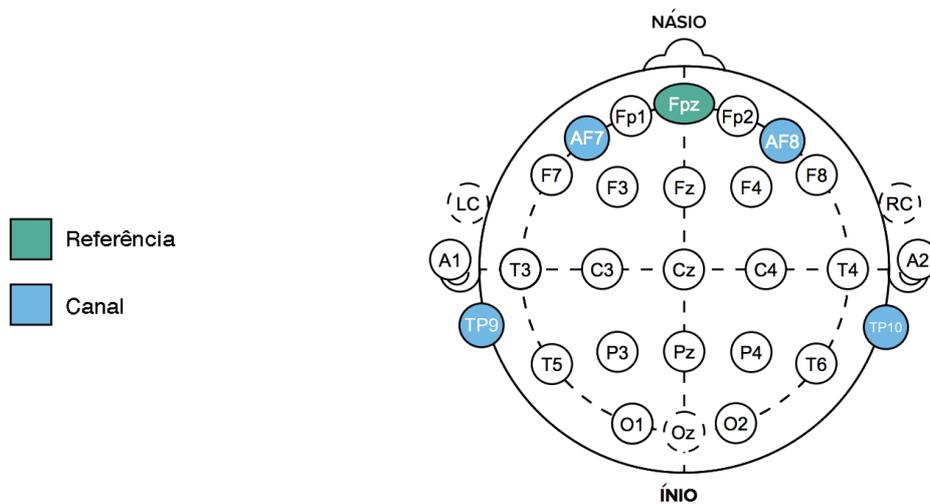


Figura 2.9: Posicionamento dos eletrodos do *Headset Muse* segundo o Sistema Internacional 10-20 [55].

Na Tabela 2.1 estão descritas especificações técnicas detalhadas do dispositivo *Muse*, modelo 2016, o qual foi usado neste trabalho. Este foi elegido por ser não-invasivo, ter um custo reduzido (em torno de US\$ 200), fácil manuseio e sensores a seco. Em seguida é descrito o *Emotiv EPOC*, outra alternativa sugerida que possui sensores que necessitam ser umedecidos com solução salina.

Figura 2.10: Exemplo de colocação do *Muse* [55].Tabela 2.1: Especificações do *Headset Muse* de EEG [55]

Muse 2016	
Característica	Especificação
Número de Canais	4 canais
Nomenclatura	TP9, AF7, AF8 e TP10 a seco Referência FPz (CMS/DRL)
Método de Amostragem	Sequencial (Conversor AD único)
Taxa de Amostragem	256 amostras por segundo
Resolução	12 bits
Filtragem	DKR - REF <i>feedback</i> com $2\mu\text{V}$ (RMS) de limiar de ruído
Filtro Notch	Não incluído
Conectividade	<i>Bluetooth</i> 4.0 BTLE
Alimentação	Bateria de Li-Ion
Autonomia da Bateria	Até 10 horas

Emotiv Epoc

O *Emotiv Epoc* (Figura 2.11A) é um *headset* de EEG não invasivo, com eletrodos de aquisição com contato molhado, produzido pela empresa *Emotiv*, que custa em torno de US\$ 799. Algumas especificações técnicas do *Epoc* estão descritas na Tabela 2.2.

O *Epoc* possui 14 canais de aquisição dos sinais elétricos gerados pelos neurônios e dois canais de referência CMS e DLR - *Common Mode Sense e Driven Right Leg* nos terminais P3 e P4. De acordo com o sistema Internacional 10-10, os eletrodos estão posicionados em AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 e AF4 [56]. Na Figura 2.11B estão ilustradas as posições dos eletrodos utilizados no *headset Emotiv Epoc*.

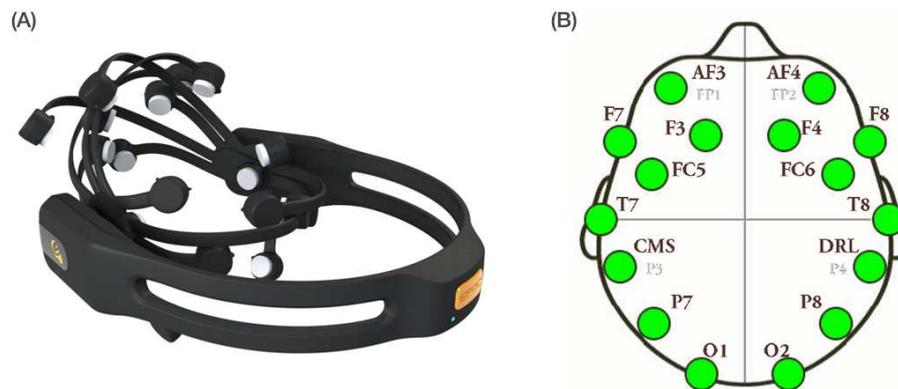


Figura 2.11: (A) Ilustração do *Headset Emotiv EPOC*. (B) Posicionamento dos eletrodos do EPOC [56].

Tabela 2.2: Especificações do *Headset Emotiv EPOC* de EEG [56]

Emotiv EPOC	
Característica	Especificação
Número de Canais	14 canais com CMS e DRL nos terminais P3 e P4
Nomenclatura	AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8, AF4 com CMS em P3 e DLR em P4
Método de Amostragem	Sequencial (Conversor AD único)
Taxa de Amostragem	128 amostras por segundo
Resolução	14 bits, 1 LSB = 0,51uV (1 bit ADC, 2 bits descartados)
Largura de Banda	0,2 - 45Hz, digital notch filters em 50Hz e 60Hz
Filtragem	Filtro Digital de Quinta Ordem
Entrada	8400 μV (pp)
Modo de Acoplamento	Acoplamento AC
Conectividade	Conexão sem fio proprietária, banda de 2,4 GHz
Alimentação	Bateria de Lítio
Autonomia da Bateria	12 horas
Medição de Impedância	Qualidade de contato em tempo real

2.3 Processamento de Sinais

Para um melhor entendimento do método de processamento do sistema descrito neste trabalho, as técnicas utilizadas no processamento dos sinais de Eletroencefalograma serão descritas a seguir. Na Subseção 2.3.1 é apresentada a Análise de Componentes Independentes, utilizada neste projeto para remoção de artefatos do sinal de EEG. Na Subseção 2.3.2 são apresentadas as *wavelets*, incluindo a *wavelet Daubechies 4* utilizada para decomposição do sinal de EEG nas bandas alfa, beta, gama, delta e teta.

2.3.1 Análise de Componentes Independentes - ICA

A Análise de Componentes Independentes (ICA, do Inglês *Independent Component Analysis*) é uma técnica que tem como objetivo identificar e separar sinais estatisticamente independentes presentes em uma determinada mistura dos sinais originais. Vários algoritmos foram elaborados para automatizar o método ICA, dentre eles o mais utilizados são *JADE*, *Infomax* e *FastIca*. O *FastIca* apresentou o melhor desempenho na determinação de *outliers* em séries temporais multivariadas [57].

A técnica do ICA diz que dadas duas fontes originais de sinais s_1 e s_2 que foram misturadas por meio de uma matriz A , originando o sinal observado x , uma vez descoberta a matriz W que anula a mistura (*demixing*), é possível separar os sinais misturados nas respectivas aproximações das fontes originais y_1 e y_2 . O modelo de mistura consiste em n dados observáveis x_1, \dots, x_n que resultam em uma combinação linear de N variáveis aleatórias s_1, \dots, s_n independentes entre si, e pode ser descrito por meio da Equação 2.1, onde a_i representa os coeficientes da mistura e s_i as componentes independentes [58].

$$x = \sum_{i=1}^n a_i \cdot s_i \quad (2.1)$$

Após aproximar a matriz mistura A , torna-se possível obter as componentes independentes por meio da sua inversa W , conforme descrito na Equação 2.2.

$$s = W \cdot x \quad (2.2)$$

2.3.2 Wavelets e Transformada Wavelet Discreta

Uma função é uma *wavelet* caso satisfaça três condições: admissibilidade, expressa matematicamente pela equação 2.3, o que implica na função apresentar alguma oscilação; e que tenha energia infinita, expressa pela equação 2.4; regularidade, ou seja, as *wavelets* devem possuir decaimento exponencial, de modo que seus momentos das $n + 1$ primeiras ordens sejam iguais a zero. Assim, *wavelets* são funções pares oscilatórias atenuadas exponencialmente até a amplitude zero nas extremidades e com largura e amplitudes variadas [59].

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad (2.3)$$

$$\int_{-\infty}^{\infty} |\psi(t)|^2 dt = M < \infty \quad (2.4)$$

Uma *wavelet* é uma onda finita com um valor médio zero. Ao comparar ondas senoidais, as quais estão na base da análise de Fourier, com *wavelets* é possível analisar que as ondas senoidais são infinitas e regulares ao contrário das *wavelets* que são finitas, irregulares e assimétricas. A principal vantagem das *wavelets* em relação a outros métodos é que estas permitem a utilização de pontos de dados observados não detectáveis ao utilizar técnicas analíticas, como a tendência de degradação e os pontos de auto-similaridade. Essas particularidades das *wavelets* permitem a compressão dos sinais e a remoção de ruídos sem degradação considerável do sinal [60].

Dentre as *wavelets* mais conhecidas, podemos citar: *Haar*, a primeira e a mais simples de todas as funções *wavelet*; *Daubechies*, que são compactamente suportadas e adequadas para análise *wavelet* discreta; *Symlet*, uma simplificação das *wavelets Daubechies*; *Coiflet*; Biortogonal, família de *wavelets* que exhibe a propriedade de fase linear, portanto adequada ao processamento de sinais; *Meyer*; *Battle-Lemarie*; Chapéu Mexicano e *Morlet* [61].

Transformada Wavelet

A transformada *wavelet* é uma alternativa para uma análise em tempo-frequência, a qual é eficiente na localização de componentes do sinal no espaço tempo-frequência, cuja eficiência explora a dependência entre as componentes do tempo e frequência. O objetivo principal foi existir um tempo de coerência proporcional ao período de amostragem [45].

Para processar sinais digitais, uma aproximação discreta dos coeficientes *wavelet* é necessária. A Transformada *Wavelet* Discreta (DWT) respeita o teorema da amostragem se um sinal de banda limitada em frequência é processado [45].

A DWT corresponde a uma seleção de subconjuntos de escalas (a) e posições (b) da *wavelet* mãe $\psi(t)$, onde a realiza a dilatação e b o deslocamento da função ψ . Por meio da Equação 2.5 é possível construir uma *wavelet* de qualquer função por meio da dilatação da função $\psi(t)$ com um coeficiente 2^j e passando a função resultante em um *grid* cujo intervalo

de valores é proporcional a 2^{-j} [62].

$$\psi_{(a,b)}(t) = 2^{\frac{a}{2}} \psi(2^{\frac{-a}{2}}(t - b)) \quad (2.5)$$

Comprimindo e dilatando (esticando) a função *wavelet* é possível chegar a funções que batem com componentes de alta e baixa frequências sucessivamente. Assim, correlacionando o sinal original com diferentes tamanhos de funções *wavelet*, é possível obter detalhes do sinal em diferentes escalas. Essas correlações podem ser organizadas em um mapa hierárquico, chamado de decomposição multi-resolução, separando os detalhes do sinal em diferentes escalas, além de uma representação grosseira chamada de aproximação [63].

Wavelets em Sinais de EEG

A família de *wavelets Daubechies* foi descrita por Ingrid Daubechies, e são comumente escritas como dbN onde N é a ordem e db representa o nome da *wavelet* [64].

A *wavelet db4*, ilustrada na Figura 2.12, tem as características de suavizar o sinal e localizar de forma quase ótima o sinal no tempo e na frequência, o que torna esse tipo de *wavelet* adequada para detectar mudanças nos sinais de EEG [65–67].



Figura 2.12: Representação gráfica de uma *wavelet Daubechies 4* [64].

No trabalho realizado por Murugappan et al. [68], após a realização de alguns experimentos, foi observado que a *wavelet db4* apresentou o melhor desempenho na classificação dos sinais de EEG, por esse motivo essa *wavelet* foi utilizada neste trabalho.

2.4 Medidas Estatísticas

Nesta seção serão apresentadas as medidas estatísticas utilizadas como parâmetros de entrada na Rede Neural Artificial do método descrito neste trabalho, são elas: média, desvio

padrão, energia e entropia aproximada.

2.4.1 Média Aritmética

A média, ou média aritmética \bar{x} , é a soma de uma sequência de valores x_i , dividida pela quantidade de valores tomados n , conforme descrito na Equação 2.6. A média indica a tendência central de um conjunto de valores [69].

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i \quad (2.6)$$

2.4.2 Desvio Padrão

O desvio padrão estima o grau de dispersão de uma amostra. Assim, se o desvio padrão for significativo, os valores da amostra tendem a estar distantes da média, caso contrário, os valores da amostra tendem a estar próximos da média [69]. O desvio padrão pode ser calculado conforme descrito na Equação 2.7, onde μ é a média do conjunto de dados, x é um valor do conjunto de dados e N é o número de dados na população.

$$DP = \sqrt{\frac{\sum |x - \mu|^2}{N}} \quad (2.7)$$

2.4.3 Erro Quadrático Médio

O erro quadrático médio (MSE, do Inglês *Mean Squared Error*), também conhecido como desvio quadrático médio, de um procedimento de estimativa de uma quantidade não observável, mensura a média dos quadrados dos erros (ou desvios), ou seja, é a diferença entre o estimador e o que é estimado [70]. O MSE pode ser calculado por meio da Equação 2.8, onde i é o número de dados da população, y_i é o valor de saída do estimador e \hat{y}_i é o valor esperado na saída do estimador.

$$MSE = \sum_i \frac{(y_i - \hat{y}_i)^2}{n} \quad (2.8)$$

2.5 Validação Estatística de Métodos de Classificação

A validação de um método de testes avalia a capacidade deste em identificar corretamente o tipo de uma amostra dentro de uma população e pode ser estimada por duas medidas objetivas: sensibilidade e especificidade [71].

Essas grandezas são estimadas por meio do número de amostras com classificação real positiva (verdadeiros positivos) e do número de amostras que possuem classificação real negativa (verdadeiros negativos). Também são utilizados o número de amostras com classificação real negativa mas que tiveram resultado positivo no teste (falsos positivos) e o número de amostras com classificação real positiva mas que tiveram resultado negativo no teste (falsos negativos).

2.5.1 Sensibilidade

A sensibilidade representa a habilidade de identificar corretamente a parcela de uma população com a avaliação real positiva para uma característica em específico, sendo calculada por meio da equação:

$$\text{Sensibilidade} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Negativos}} \quad (2.9)$$

2.5.2 Especificidade

A especificidade representa a habilidade de identificar corretamente a parcela de uma população cuja avaliação real teve resultado negativo sendo calculada pela equação:

$$\text{Especificidade} = \frac{\text{Verdadeiros Negativos}}{\text{Verdadeiros Negativos} + \text{Falsos Positivos}} \quad (2.10)$$

2.5.3 Energia

A energia do sinal é uma medida que tem como objetivo analisar o tamanho de um sinal no decorrer do tempo, a partir da área debaixo de $x^2(t)$, a qual é sempre positiva, conforme a

equação 2.11. Esta medida é fácil de ser trabalhada matematicamente com a ideia de ser um indicativo da energia que pode ser extraída do sinal [72].

$$E_x = \int_{-\infty}^{\infty} |x(t)|^2 dt \quad (2.11)$$

2.5.4 Entropia Aproximada

A entropia aproximada é uma característica do sinal no domínio do tempo utilizada para quantizar a criação de informação em séries temporais, amplamente utilizada em processamento de sinais de EEG [18]. Para o cálculo da entropia no método descrito nesse projeto, foi utilizada a função *wentropy* do *Matlab*, utilizando o critério de Shannon, conforme a Equação 2.12, na qual s é o sinal e $(s_i)_i$ os coeficientes de s em uma base ortonormal [73].

$$E1(s) = - \sum_i s_i^2 \log(s_i^2) \quad (2.12)$$

2.6 Classificadores

Os classificadores têm como objetivo a utilização de um vetor de características para atribuir a um objeto uma categoria, a qual normalmente é atribuída com base na probabilidade de que um objeto seja parte desta [74].

Existem diferentes modelos de classificação e a seleção de um modelo dependerá das características da aplicação. Alguns exemplos de classificadores:

- Método do vizinho mais próximo;
- Método da média da classe mais próxima;
- Método dos k-Vizinhos Próximos*;
- Método da Bayesiana por maximização da probabilidade a posteriori;
- Redes Neurais Artificiais*;
- Support Vector Machines (SVMs)*;

- Particle Swarm Optimization (PSO);

Alguns dos classificadores (marcados com *) são considerados mais relevantes para este trabalho e serão brevemente descritos a seguir. A relevância de cada um deles está relacionada a precisão que cada um deles apresentou em algum dos estudos relacionados citados neste trabalho.

2.6.1 Support Vector Machine (SVM)

As SVM são classificadores lineares que mapeiam os vetores de descritores num espaço de maior dimensão (podendo até mesmo ter infinitas dimensões), de forma a conseguir um hiperplano de separação entre as classes. Este mapeamento é feito a partir dos conjuntos de treino [74].

SVM é um método bastante convencional de solucionar problemas de estimação de funções multidimensionais que vem sendo aplicado em diversas áreas, tais como classificação e regressão [75].

2.6.2 Método dos K-Vizinhos Próximos (KNN)

KNN é um classificador onde o aprendizado é baseado na analogia. O conjunto de treinamento é formado por vetores n-dimensionais e cada elemento deste conjunto representa um ponto no espaço n-dimensional [76].

Considera-se um conjunto de treino com N vetores característicos, representantes das diferentes classes. Obtêm-se os K vetores característicos do conjunto de treino mais próximos do vetor característico do elemento a classificar [74].

A classe que estiver em maioria nos K vetores de treino é selecionada. O uso deste método em classificação binária leva a resultados bastante positivos, podendo até mesmo ser atribuído um intervalo de confiança à decisão do vetor ser de uma classe C_i por meio da divisão do número de vetores de treino da classe C_i em K por K [74].

2.6.3 Redes Neurais Artificiais

As Redes Neurais Artificiais são baseadas no modelo simplificado de um neurônio humano, o qual está ilustrado na Figura 2.13, onde x são parâmetros de entrada do neurônio, W representa o peso de cada entrada, b representa o *bias* e y representa as saídas do neurônio, as quais podem estar conectadas as entradas de outro neurônio artificial [74]. Existem diversos tipos de Redes Neurais, entre elas as mais conhecidas são a Adaline, *Perceptron* de Camada Única e *Perceptron* Multicamada [77].

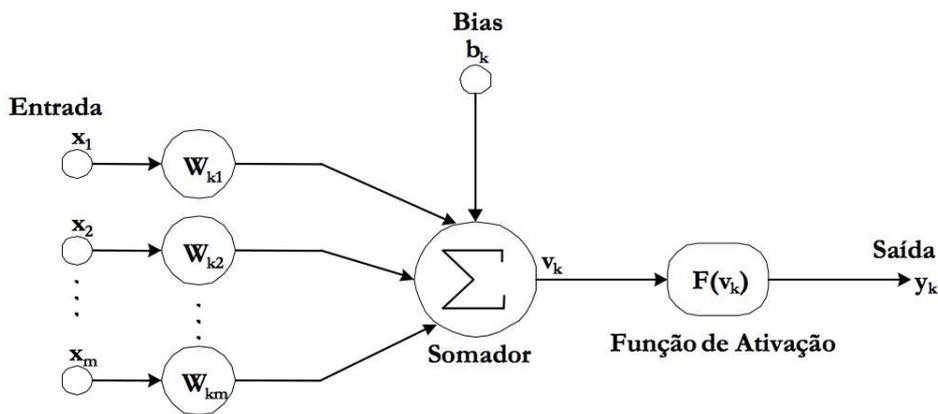


Figura 2.13: Ilustração do modelo simplificado de um neurônio humano [74].

Um neurônio artificial pode ser descrito por meio da Equação 2.13, onde x representa as entradas do neurônio, w representa os pesos sinápticos do neurônio k , b representa o *bias*, F a função de ativação e y_k a saída do neurônio [77].

$$y_k = F \left(\sum_{j=1}^m w_{kj} x_j + b_k \right) \quad (2.13)$$

Segundo Oliveira [77], os quatro elementos básicos do modelo que representa um neurônio artificial são:

- Sinapse: conexão caracterizada por um "peso". Uma sinapse m que está conectada a um neurônio k , recebe um sinal x_m que por sua vez é multiplicado pelo peso sináptico w_{km} . Os valores dos pesos podem ser positivos ou negativos, com base no tipo de sinapse (excitatória ou inibitória), onde estes determinam a importância dos sinais de determinada região;

- Somador: um combinador linear que soma as entradas do neurônio, ponderadas pelos respectivos pesos sinápticos;
- Função de ativação: restringe a amplitude do sinal de saída ao condicionar a ativação do sinal à ultrapassagem de um determinado limiar pelo valor da soma ponderada das entradas, tipicamente apresenta valores entre $[0, 1]$ e $[-1, 1]$;
- Bias: fator externo capaz de aumentar ou diminuir a entrada da função de ativação.

O incremento de mais camadas neurais implica em um aumento na capacidade de processamento não linear e generalização da rede neural, o que fez as redes *Perceptron* com múltiplas camadas superar as limitações para o modelo do *Perceptron* e *Adaline* propostos por Minsky e Papert em 1969 [78].

Na Figura 2.14, é possível observar uma representação gráfica da organização dos neurônios artificiais presentes em uma rede neural *Perceptron* multicamadas e as interações entre eles.

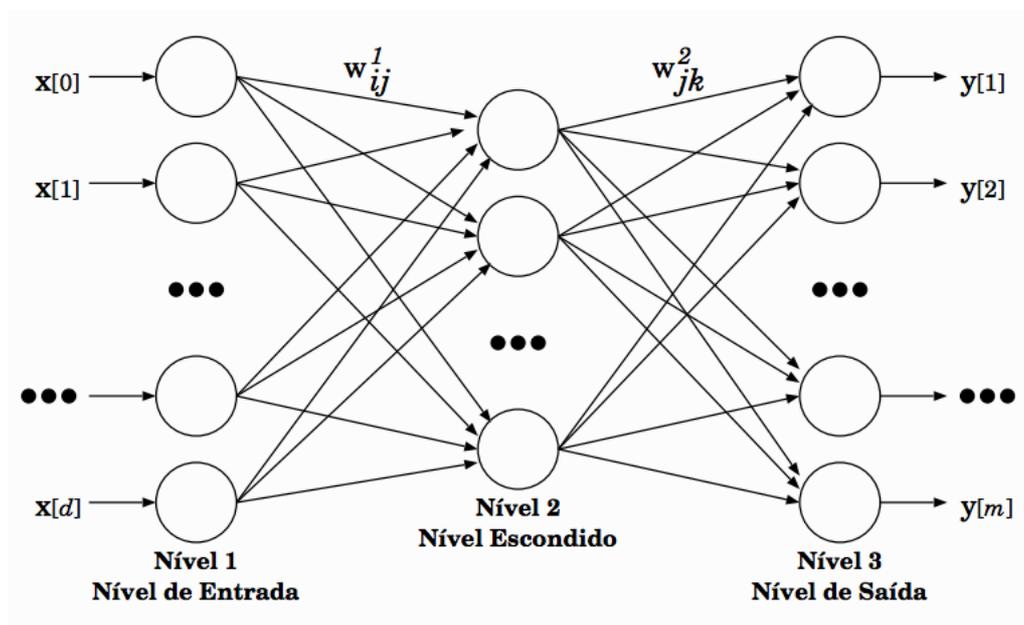


Figura 2.14: Representação gráfica da organização e interação dos neurônios de uma Rede Neural Artificial *Perceptron* com múltiplas camadas [74].

A rede *Perceptron* multicamadas (PMN) é composta por 1 camada de entrada, 1 camada de saída, sendo que entre essas podem estar contidas inúmeras camadas intermediárias

(camadas escondidas), cada uma delas formada por inúmeros neurônios artificiais cujas saídas são entradas da camada subsequente, com exceção da camada de saída da rede [78].

Neste tipo de rede não há retro-alimentação, pois a propagação do processamento neural é unidirecional. Para treinamento das redes PMC, é utilizado o treinamento supervisionado por meio do algoritmo *backpropagation*, onde dado um conjunto de treinamento com pares de entrada e saída conhecidos, o vetor de entrada é propagado camada a camada, até a camada de saída. O vetor de saída é, então, comparado ao vetor de saída desejado, sendo a diferença entre estes o erro de saída da rede, o qual será retro-propagado na rede com o objetivo de ajustar os pesos sinápticos para reduzir o erro da próxima interação [78].

O algoritmo de *backpropagation* é repetido até que a rede alcance um erro aceitável a depender da aplicação na qual a rede será utilizada.

2.7 Algoritmos Genéticos

Algoritmos genéticos são algoritmos de otimização global, que têm como base os mecanismos de seleção natural e da genética. A otimização é feita através de processos iterativos, onde cada iteração é chamada de geração, onde, durante cada iteração, os princípios de seleção e reprodução são aplicados a uma população de candidatos [79].

Na etapa de seleção, os indivíduos que deverão se reproduzir são determinados, gerando um número determinado de descendentes para a próxima geração, onde os indivíduos com maior aptidão têm maiores chances de se reproduzir. Desta forma, uma população de possíveis soluções para um problema evolui de acordo com operadores probabilísticos concebidos a partir de metáforas biológicas, de modo que há uma tendência de que, na média, os indivíduos representem soluções cada vez melhores à medida que o processo evolutivo continua [79].

Na Figura 2.15, é possível observar as etapas básicas de um algoritmo genético, demonstrando o funcionamento da seleção do indivíduo mais apto dentre os membros da população de entrada.

Os algoritmos genéticos procuram privilegiar indivíduos com melhores aptidões, com isto tentam dirigir a busca para regiões do espaço de busca onde é provável que os pontos ótimos estejam [79].

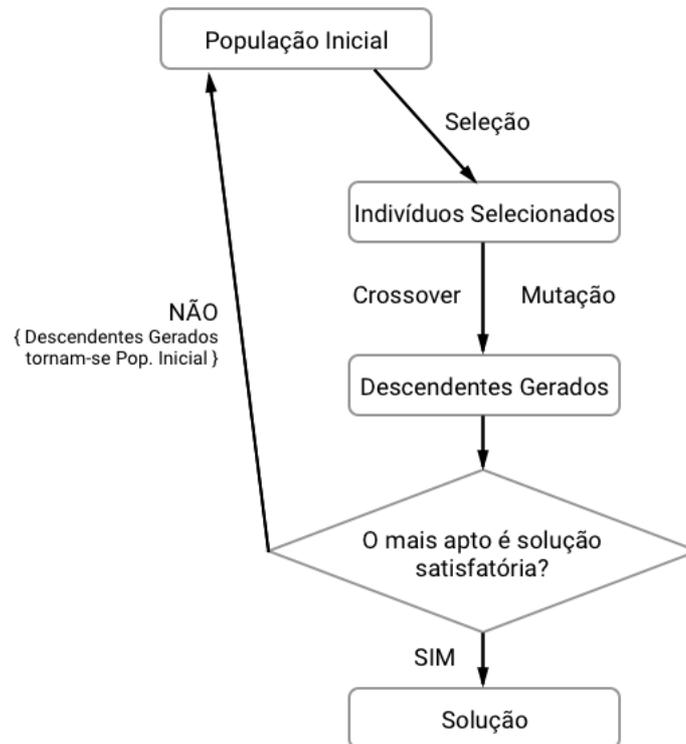


Figura 2.15: Representação gráfica das etapas de um Algoritmo Genético. Elaborada pelo autor.

2.8 Síntese

Neste Capítulo foram apresentados os conceitos e as tecnologias importantes para o entendimento do método descrito neste trabalho para a classificação do estado de sonolência de um motorista. Na Seção 2.1 foram descritas algumas características do cérebro humano, dos mecanismos da atenção, da fadiga mental e dos sinais cerebrais. Em seguida, na Subseção 2.2.2 foram discutidos os métodos de aquisição de sinais cerebrais invasivos e não-invasivos, a nomenclatura e o padrão de posicionamento dos eletrodos segundo o Sistema Internacional 10-20. Os dispositivos portáteis de EEG *Muse* e *Emotiv EPOC* também foram apresentados.

Na Seção 2.3 foram descritas as *wavelets* e algumas aplicações destas no processamento de sinais de EEG. Algumas medidas estatísticas (média, desvio padrão, erro quadrático médio, energia e entropia aproximada) utilizadas no processamento de sinais foram apresentadas na Seção 2.4.

Em seguida, na Seção 2.6, foram apresentadas algumas características de classificadores

comumente utilizados no processamento de sinais de EEG (SVM, K-Vizinhos próximos e Redes Neurais Artificiais).

Na Seção 2.7, foram descritas as etapas para a otimização com base nos mecanismos de seleção natural e da genética.

Capítulo 3

Método

Neste capítulo é descrito o método para a classificação do estado de sonolência com base em Eletroencefalograma, Redes Neurais Artificiais e Algoritmos Genéticos.

O método consiste em 4 fases: aquisição, pré-processamento, processamento e classificação, conforme ilustrado na Figura 3.1, que serão detalhadas nas seções a seguir.

Este método pode ser utilizado no desenvolvimento de sistemas que alertem o motorista sobre possível risco devido a um estado de sonolência, solicitando, por exemplo que o motorista estacione o carro para tomar um café ou descansar antes de prosseguir sua viagem.

3.1 Aquisição

Para o método descrito, a aquisição dos sinais cerebrais consiste no monitoramento não-invasivo da atividade cerebral do indivíduo por meio de eletrodos a seco.

Para aquisição, é sugerida a utilização de um dispositivo portátil e leve, como por exemplo o *headset* de EEG *Muse*, com o objetivo de não influenciar a tarefa de dirigir ou o estado cognitivo dos participantes. O *Muse* possui 4 canais (TP9, AF7, AF8 e TP10) com eletrodos a seco, peso de 60g, bateria com duração de até 10 horas, conectividade *Bluetooth* 4.0 LE e taxa de amostragem de 256Hz [55]. Outros detalhes mais específicos sobre o *Muse* podem ser encontrados na Seção 2.2.4. O dispositivo *Muse* não possui filtros incorporados a placa [55].

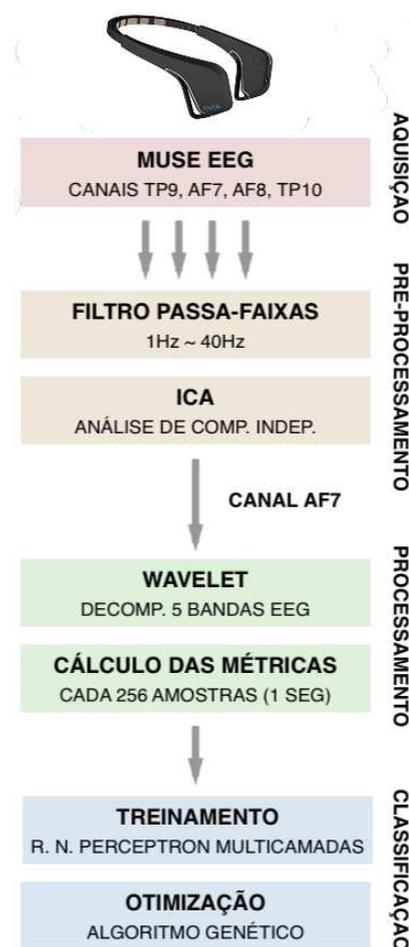


Figura 3.1: Fluxograma com as fases do método e os passos necessários. Elaborada pelo autor.

Outros dispositivos similares podem ser usados, contanto que possuam eletrodos posicionados nos canais (TP9, AF7, AF8 e TP10). Caso o dispositivo a ser utilizado possua mais ou menos canais, é sugerida a reavaliação dos métodos de pré-processamento para melhores resultados.

3.2 Pré-processamento

O pré-processamento é o processo de filtragem e adequação, com o objetivo de facilitar a extração e seleção de características dos sinais, além da minimização de ruídos [80]. O pré-processamento das amostras é realizado por meio de filtros digitais.

Na etapa de pré-processamento, é utilizado um filtro passa-faixa com as frequências de corte 1Hz e 40Hz para a remoção do ruído causado pela rede elétrica e de outros tipos de

ruídos de alta frequência. Este filtro também elimina o ruído entre 63 e 125 Hz, causado pelo motor dos veículos a combustão [81].

Em seguida, são removidas as componentes ICA relacionadas ao ruído e as distorções restantes. A remoção das componentes pode ser feita de forma manual, por meio de *softwares* de processamento de sinais. Devem ser removidas as componentes com influência similar em todos os canais, sendo possível efetuar uma análise visual com base nos picos de amplitude do sinal em cada canal.

A Análise de Componente Independente (ICA) é baseada na busca de uma representação linear de dados não-gaussianos, os quais são estatisticamente independentes. O método ICA permite a decomposição de um sinal em componentes e a eliminação dos artefatos e distúrbios [82]. É sugerida a utilização do algoritmo *FastIca* para automatizar a obtenção das componentes ICA, tendo em vista que este apresenta melhor desempenho na determinação de *outliers* em séries temporais multivariadas [57].

Há também a possibilidade de utilizar métodos automatizados para a seleção de componentes a serem removidas, como por exemplo o método descrito no trabalho de Radüntz et al. [83], que tem como base a utilização da Análise Discriminante Linear e apresentou 88% de precisão na detecção dos artefatos de sinais de EEG.

Neste trabalho, as componentes relacionadas aos artefatos e distúrbios foram removidas manualmente, mediante análise visual de zonas com grandes distúrbios.

3.3 Processamento

Na etapa de processamento, a *wavelet Daubechies 4* é utilizada para decompor o sinal nas 5 bandas do EEG [45], conforme descrito na Tabela 3.1.

Tabela 3.1: Decomposição do sinal EEG com *wavelet Daubechies 4* [45]

Componente	Banda	Frequência
A4	Delta	1 até 4Hz
D4	Teta	4 até 8Hz
D3	Alfa	8 até 16Hz
D2	Beta	16 até 32Hz
D1	Gama	32Hz+ (considerada até 40Hz)

Os estudos realizados por Yang et al. [18] e Lin & John [84] apontaram métricas asso-

ciadas aos níveis de atenção, concentração e relaxamento do indivíduo, calculadas a partir de sinais de EEG adquiridos por meio de eletrodos no córtex pré-frontal. Com base na experimentação das métricas apontadas nesses estudos, foram elegidas 5 delas, as quais resultaram na melhor performance do método, quando calculadas com base em janelas de 1 segundo, com 256 amostras de EEG por segundo, para o canal AF7:

- Entropia Aproximada (gama);
- Energia (beta);
- Desvio padrão (teta);
- Desvio padrão (alfa + beta + teta)
- Média (alfa + teta)

Conforme descrito na Seção 2.2.1, a atividade na banda de frequência "beta" (16 a 32Hz) está relacionada à consciência normal de vigília e ao estado de alerta do usuário, ou seja, em momentos de sonolência ou baixa alerta é apresentada uma sutil diminuição na incidência das ondas beta, o que influencia os valores de energia e desvio padrão [18].

A atividade em gama (considerada entre 32 e 40Hz) está relacionada a percepção, memória e atenção [46–48]. A entropia aproximada é uma técnica utilizada para quantificar a regularidade e imprevisibilidade de flutuações, permitindo detectar possíveis variações na incidência das ondas gama e no nível de atenção do indivíduo [85].

A atividade em teta é mais predominante durante estados de meditação, sonolência e ao dormir [18]. Portanto, a análise do desvio padrão em teta contribui com a identificação de possíveis variações no nível de sonolência do indivíduo.

As somas "alfa + beta + teta" e "alfa + teta" contribuem com a identificação de variações entre as bandas citadas, tendo em vista que os resultados destas somas têm ligação linear com a variação na amplitude em cada uma das bandas. No trabalho apresentado por Lin & John [84], estas somas são relacionadas aos estados de meditação e relaxamento neurológico. A média e o desvio padrão auxiliam na identificação de tendências, distorções e variações na amplitude desses sinais [69].

O canal AF7 foi utilizado para melhor aproximar aos resultados obtidos pelos trabalhos de Yang et al. [18] e Lin & John [84]. Outros canais posicionados no córtex pré-frontal, mais especificamente nos arredores do canal AF7, não foram testados, mas possivelmente também apresentariam resultados satisfatórios.

3.4 Classificação

Na etapa de classificação, cada conjunto de parâmetros obtidos a partir de uma janela de 1 segundo de sinal de EEG é classificada em: "com sonolência" ou "sem sonolência". Para isto, as 5 métricas citadas anteriormente na Seção 3.3 devem ser utilizadas como entradas para uma Rede Neural Artificial (ANN) do tipo *Perceptron* Multicamadas.

As ANNs são estruturas de mapeamento não-lineares baseadas na função do cérebro humano e vêm demonstrando serem aproximadores universais bastante flexíveis, além de serem largamente utilizadas como classificadores. Qualquer função pode ser aproximada por uma *Perceptron* Multicamadas com uma quantidade suficiente de elementos de processamento (neurônios artificiais) na camada escondida [86]. Para o método, a ANN *Perceptron* Multicamadas deve possuir 1 camada escondida com 5 neurônios e 1 camada de saída, cuja estrutura está ilustrada na Figura 3.2.

O número de neurônios da camada escondida que demonstrou melhor resultado durante os testes realizados foi 5, que é a mesma quantidade de entradas. A RNA utilizada durante os testes foi criada por meio do comando *patternnet* do *Matlab*, o qual cria uma rede indicada para reconhecimento de padrões, na qual os neurônios utilizam a função de transferência *tansig* [87].

Para a obtenção dos resultados apresentados na Seção 5, foram utilizados 12616 conjuntos de valores (cada um deles composto pelas 5 métricas citadas na Seção 3.3), nos quais 50% apresentam sonolência e 50% não apresentam sonolência. Estes foram utilizados em ordem aleatória durante o treinamento. Após o treinamento inicial, os pesos individuais das entradas da rede são otimizados por meio de Algoritmos Genéticos.

Algoritmos genéticos são algoritmos de otimização global, que têm como base os mecanismos de seleção natural e da genética. A otimização é feita através de processos iterativos, em que cada iteração é chamada de geração, onde, durante cada iteração, os princípios de

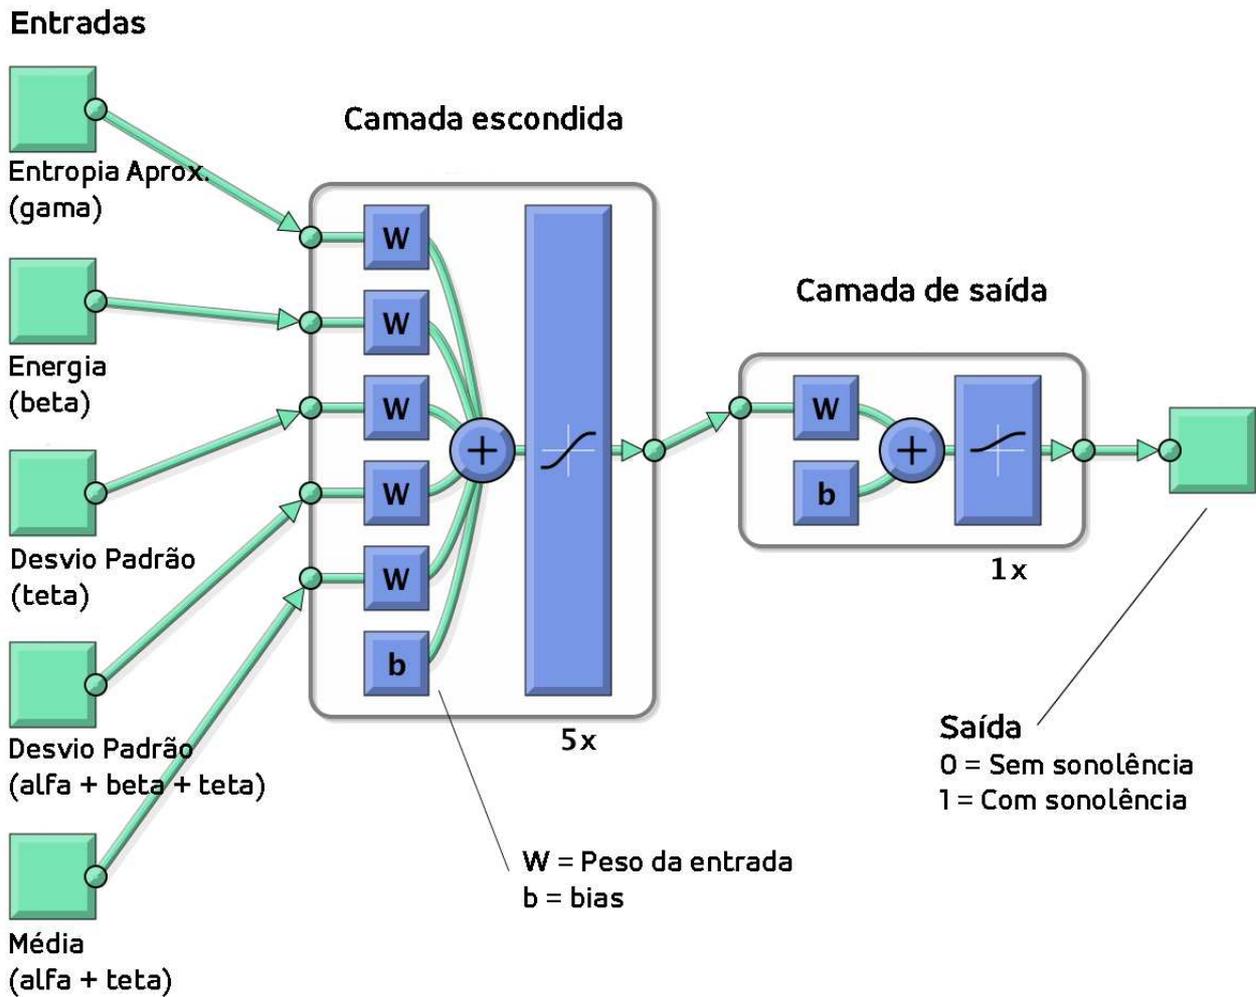


Figura 3.2: Estrutura da Rede Neural Artificial *Perceptron* Multicamadas. Elaborada pelo autor.

seleção e reprodução são aplicados a uma população de candidatos [79].

Os algoritmos genéticos procuram privilegiar indivíduos com melhores aptidões [79]. Na etapa de seleção, os indivíduos que deverão se reproduzir são definidos, gerando um número determinado de descendentes para a próxima geração, onde os indivíduos com maior aptidão têm maiores chances de se reproduzir. Desta forma, uma população de possíveis soluções para um problema evolui de acordo com operadores probabilísticos concebidos a partir de metáforas biológicas, de modo que há uma tendência de que, na média, os indivíduos representem soluções cada vez melhores à medida que o processo evolutivo continua [79].

A aptidão das redes geradas pelo algoritmo genético é estimada com base no cálculo

do erro quadrático médio. É sugerida uma tolerância em torno de 10^{-8} . Para o número máximo de gerações cuja diferença média entre as aptidões (*fitness* é menor que a tolerância estabelecida, ou seja, o número máximo de *Stall generations*, é sugerido o valor 50. Também é sugerido o limite de gerações em 5000. Esses valores foram obtidos a partir de vários testes realizados com os dados obtidos no experimento detalhado no Capítulo 4.

3.5 Síntese

Neste capítulo foram descritas as etapas do método, incluindo a obtenção dos parâmetros de entrada da rede, bem como a otimização da RNA por meio do algoritmo genético.

Na Seção 3.1 foram descritos os dispositivos sugeridos para aquisição não-invasiva dos sinais de EEG e os canais utilizados.

O filtro passa-faixa utilizado e a remoção das componentes ICA relacionadas a distorções dos sinais foram descritos na Seção 3.2.

Na Seção 3.3, foram discutidas os seguintes passos: decomposição do sinal nas 5 bandas do EEG (alfa, beta, gama, delta e teta) utilizando a *wavelet Daubechies 4*; métricas elegidas para classificação dos sinais; e a relação entre as métricas e o estado de sonolência.

Na Seção 3.4, foram apresentadas as características da Rede Neural Artificial que utiliza-se para a classificação e a otimização por meio de Algoritmos Genéticos.

Capítulo 4

Experimentos Realizados

Neste capítulo é descrito o experimento realizado para a construção do banco de dados e para validação do método para classificação do estado de sonolência com base em Eletroencefalograma. O experimento consistiu no monitoramento de 24 motoristas durante sessões em um simulador de direção, onde estes foram solicitados a indicar os momentos que estavam se sentindo em situação de risco por conta do sono.

4.1 Recrutamento e Roteiro

Neste trabalho foi realizado um experimento para aquisição dos sinais cerebrais dos participantes durante a realização da tarefa de controlar um simulador de direção monótona, com o objetivo de validar o método descrito na Seção 3. Foi utilizado o *software Euro Truck Simulator 2*, ilustrado na Figura 4.1, que reproduz a visão e tarefa de um motorista de caminhão durante percursos rodoviários [88]. Este experimento foi aprovado pelo comitê de ética em pesquisa, projeto de pesquisa com CAAE número 82475417.9.0000.5182 e com o parecer de número 2.539.795.

No plano de recrutamento, foi utilizado como critério para inclusão no experimento a aptidão dos participantes em utilizar computadores e simuladores de direção, similares ao *Euro Truck*. Como critérios de exclusão foram considerados o desconhecimento da tarefa, a idade inferior a 18 anos e o desconhecimento do uso de computador. Vinte e quatro indivíduos foram recrutados para participar do experimento.

Antes de iniciar o experimento, os participantes assinaram termos concordando em participar do teste e responderam um questionário com perguntas para definição do perfil do usuário, bem como questões para avaliação subjetiva do nível de fadiga.



Figura 4.1: Euro Truck Simulator 2, *software* simulador de direção [88].

A estrutura do simulador utilizado está ilustrada na Figura 4.2. Os indivíduos dirigiram por rodovias longas, com percurso de aproximadamente 130 quilômetros, com poucas curvas e sem trânsito. Além disso, os participantes foram instruídos a se comportar normalmente, sem a preocupação com relação as piscadas ou a movimentação da cabeça, de forma a simular uma situação real.



Figura 4.2: Estrutura do simulador de direção utilizado nas sessões. Elaborada pelo autor.

Algumas informações sobre o estado psicológico atual do participante (estressado, relaxado, calmo, motivado, etc.) foram coletadas antes do experimento por meio de formulários digitais presentes em um aplicativo *Android* desenvolvido, que será detalhado a seguir. O horário do experimento não foi restringido, dependendo apenas da disponibilidade do participante.

Para o plano de recrutamento, foram utilizados como critérios para inclusão no experimento a aptidão dos participantes em dirigir e o tempo desde a primeira Carteira Nacional de Habilitação (CNH). Além disso, a idade também foi usada como critério para o recrutamento, sendo necessário que o candidato fosse maior de idade. Como critério de exclusão foi considerado o desconhecimento da tarefa, tempo desde a primeira CNH inferior a 5 anos, a idade inferior a 18 anos e o desconhecimento do uso de um *smartphone* com sistema operacional *Android*.

4.1.1 Aplicativo *Android*

Antes de iniciar o experimento, os participantes assinaram termos concordando em participar do teste e responderam questionário com perguntas para definição do perfil do usuário, bem como com questões para avaliação subjetiva do nível de fadiga.

Um aplicativo *Android*, foi desenvolvido para armazenar as informações dos formulários com questões sobre o estado do indivíduo em relação ao mês e ao dia do experimento, com o objetivo de entender como estava o participante no período e no dia do experimento. O formulário sobre o período está ilustrado na Figura 4.4. O formulário preenchido no dia do experimento está ilustrado na Figura 4.3.

4.1.2 Aquisição e *Feedback* do Motorista

O aplicativo desenvolvido se comunica com o *Muse* via *Bluetooth* para receber 256 amostras a cada 1 segundo e armazená-las em um banco de dados presente na memória interna dos *smartphones* utilizados durante o experimento. As amostras adquiridas não passaram por nenhum tipo de processamento durante o experimento.

Durante a aquisição, a tela ilustrada na Figura 4.5 foi exibida para o participante e o aplicativo manteve a tela do *smartphone* sempre ligada. Na tela de aquisição, o participante

Tempo em que o voluntário está acordado:

8 horas

Estado psicológico do voluntário:

Nível de Ansiedade:
 Baixo Médio Alto

Nível de Tranquilidade:
 Baixo Médio Alto

Nível de Estresse:
 Baixo Médio Alto

Nível de Relaxamento:
 Baixo Médio Alto

Nível de Sonolência:
 Baixo Médio Alto

Figura 4.3: Formulário digital respondido pelos participantes no dia dos experimentos. Elaborada pelo autor.

pôde acompanhar a qualidade do sinal para cada eletrodo e até mesmo saber se ele precisava ajustar os eletrodos do *Muse* por conta de possíveis problemas de colocação do dispositivo. Cada eletrodo (TP9, AF7, AF8 e TP10) foi representado por uma cor e uma imagem ao lado dos valores indicou a localização do eletrodo no *Muse* para auxiliar o indivíduo no ajuste do dispositivo. Caso os valores adquiridos de um dos sensores ficasse fora do intervalo entre 750 e 950 μ V, a cor do valor foi exibida em vermelho para notificar um possível problema no contato entre o eletrodo e a pele do participante.

Ainda na tela de aquisição, o participante pôde pressionar 2 botões: o primeiro foi nomeado de "Marcar Sonolência" e foi utilizado em caso de situação de risco devido ao sono; o segundo foi nomeado de "Marcar bocejo" e deveria ser utilizado para notificar o aplicativo sobre os momentos que o indivíduo bocejou. O *smartphone* foi posicionado estrategicamente no simulador antes do experimento, por meio de um suporte alongado, em uma posição na qual o participante não precisasse tirar a atenção da pista para pressionar os botões e nem se esticar muito para alcançar o *smartphone*.

Os momentos marcados como sonolência foram utilizados no treinamento e validação da

The figure displays three sequential screenshots of a mobile application titled 'Cadastrar Voluntário' (Register Volunteer). The interface is divided into three main sections: PESSOAL (Personal), HABILIDADES (Skills), and PSICOLÓGICO (Psychological).

- Screenshot (A):** Shows the 'PESSOAL' section. It includes fields for 'Identificador' (DV-0007), 'Iniciais' (with a placeholder 'Type something'), 'Gênero' (radio buttons for Masculino, Feminino, and Outro), 'Idade' (a numeric input field set to 20), and 'Horas de sono (média diária)' (a numeric input field set to 8). A red bar at the bottom contains a white circle with the letter 'A'.
- Screenshot (B):** Shows the 'HABILIDADES' section. It contains six rows of radio button options for skill levels: 'Nível de habilidades em dirigir', 'Capacidade de organização e planejamento', 'Capacidade de gestão de tempo', 'Capacidade de analisar e antecipar situações', and 'Capacidade de tomar decisões'. Each row has three options: Baixo, Médio, and Alto. In all cases, the 'Médio' option is selected. A red bar at the bottom contains a white circle with the letter 'B'.
- Screenshot (C):** Shows the 'PSICOLÓGICO' section. It contains six rows of radio button options for psychological states: 'Nível de ansiedade', 'Nível de tranquilidade', 'Nível de estresse', 'Nível de relaxamento', and 'Nível de motivação'. Each row has three options: Baixo, Médio, and Alto. The selected options are Baixo for 'Nível de estresse' and 'Nível de relaxamento', and Médio for 'Nível de ansiedade' and 'Nível de motivação'. A red bar at the bottom contains a white circle with the letter 'C'.

Figura 4.4: Formulário digital respondido pelos participantes sobre o período. (A) Dados pessoais anônimos. (B) Quantização das habilidades. (C) Quantização do estado do indivíduo naquele período. Elaborada pelo autor.

Rede Neural Artificial utilizada. É importante destacar que neste trabalho foi considerado apenas o intervalo de 30 segundos antes do usuário pressionar o botão como um momento de sonolência com risco, tendo em vista que ao lembrar de pressionar o botão "Marcar sonolência", o indivíduo naturalmente despertava parcialmente da sonolência. Além disso, o principal objetivo foi identificar estados de sonolência que demonstrassem risco durante o ato de dirigir.

4.2 Síntese

Neste capítulo foi descrito o experimento realizado com 24 participantes para obtenção dos dados necessários para o treinamento da Rede Neural Artificial utilizada no método, além da validação deste.

Na Seção 4.1, foram descritos o processo de recrutamento e o roteiro do experimento realizado para aquisição dos sinais de EEG.



Figura 4.5: Tela exibida para o participante durante a aquisição. Elaborada pelo autor.

Na Seção 4.1.1, foram apresentadas as telas do aplicativo desenvolvido para se comunicar com o *headset Muse* de EEG para preparar o banco de dados de amostras.

Em seguida, na Seção 4.1.2, foram descritos o processo de aquisição das amostras de EEG e de *feedback* do motorista em relação aos momentos de direção sob risco iminente por conta do sono.

Capítulo 5

Resultados Experimentais

5.1 Resultados

Um dos grandes desafios ao processar dados reais é o nível de ruído, que normalmente são bem elevados. No caso dos sinais de EEG, os ruídos são causados pela movimentação do indivíduo e por interferência de rede elétrica ou de outras fontes de energia. Um trecho do sinal de EEG adquirido pelo *headset de EEG* antes da etapa de pré-processamento está ilustrado na Figura 5.1.

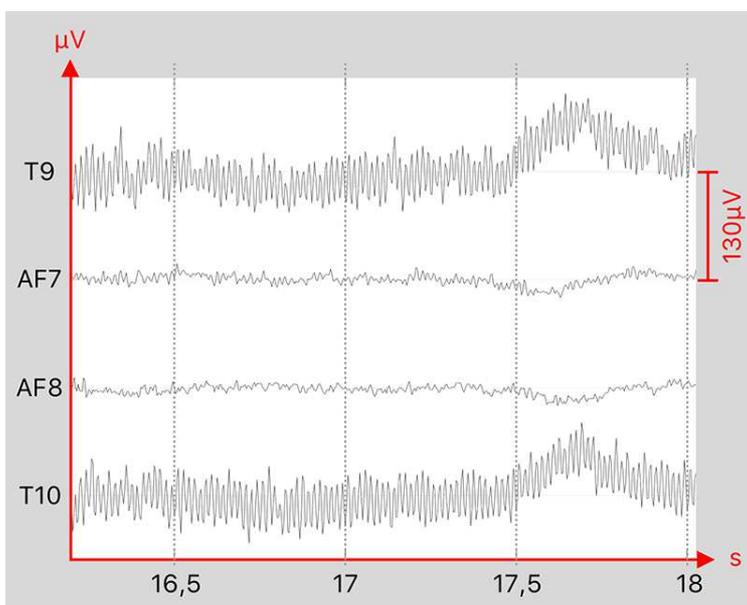


Figura 5.1: Ilustração do sinal adquirido pelo *Muse* antes do pré-processamento com escala de $130\mu V$ por divisão. Elaborada pelo autor.

A utilização de dados reais demanda uma etapa de pré-processamento eficiente e permite os pesquisadores analisarem e prepararem os sistemas com base nos dados adquiridos sob as condições reais de utilização dos sistemas. Um trecho do sinal após a etapa de pré-processamento do método proposto está ilustrado na Figura 5.2.

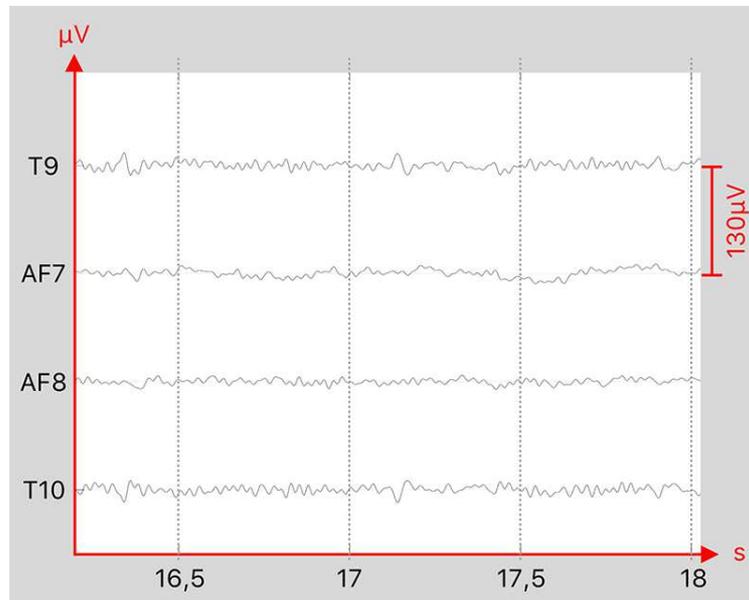


Figura 5.2: Ilustração do sinal adquirido pelo *Muse* depois do pré-processamento com $130\mu\text{V}$ por divisão. Elaborada pelo autor.

No total foram utilizados 12616 conjuntos de entrada, cada um deles sendo compostos pelos valores das 5 métricas descritas na Seção 3.3, metade deles (6308 conjuntos de entrada) apresentando sonolência e os demais sem sonolência.

As 5 métricas (Entropia Aproximada em gama, Energia em beta, Desvio padrão em teta, Desvio padrão de "alfa + beta + teta" e Média de "alfa + teta") foram calculadas para janelas de 1 segundo de sinal EEG e foram utilizadas como valores de entrada para a Rede Neural Artificial para a classificação do período de 1 segundo representado pelo conjunto que as continha.

Após o treinamento inicial e a otimização dos pesos das entradas por meio dos Algoritmos Genéticos, a ANN *Perceptron* Multicamadas descrita anteriormente conseguiu classificar corretamente 86,6% dos conjuntos, ou seja, obteve 13,42% de erro (confusão).

A sensibilidade da rede, ou seja, a habilidade em identificar corretamente os conjuntos que apresentam sonolência, foi de 85,21%. A especificidade, ou seja, a habilidade em

identificar corretamente os conjuntos que não apresentam sonolência, foi de 87,95%.

A rede conseguiu identificar corretamente 5548 conjuntos sem sonolência e 5375 conjuntos com sonolência. Desta forma, a rede apresentou 760 falsos positivos e 933 falsos negativos. Na Figura 5.3, estão ilustrados os números relacionados a confusão, onde as colunas indicam a avaliação real (sem sonolência e com sonolência, respectivamente) e as linhas indicam a saída apresentada pela rede.

Matriz de Confusão

Classificação na saída	0	5548 44,0%	933 7,4%	85,6% 14,4%
	1	760 6,0%	5375 42,6%	87,6% 12,4%
		88,0% 12,0%	85,2% 14,8%	86,6% 13,4%
		0	1	
		Classificação Correta		

Figura 5.3: Matriz de confusão com os resultados apresentados pela ANN treinada e otimizada. Elaborada pelo autor.

Os resultados foram obtidos a partir de uma rede da 5000a geração do Algoritmo Genético com erro quadrático médio de 14,49%.

Em um caso hipotético de um motorista dirigindo a 100km/h em uma rodovia, com um sistema que utiliza o método para avaliar se o motorista está em uma situação de risco monitorando-o continuamente, a cada 1 segundo o sistema terá uma chance de acerto de 86,6%. Em um carro a 100km/h, a distância percorrida em 1 segundo é de 27,78 metros. A sonolência é um processo gradativo e o objetivo definido para o método foi indicar que o motorista está entrando em um estado de risco por conta da sonolência para que sistemas baseados neste método possam alertar ao motorista que este deve fazer uma pausa para

descansar, antes de continuar dirigindo.

A sonolência é um estado que varia de indivíduo para indivíduo, por isso não foi definido o objetivo de quantizar a sonolência. A ideia base do método foi identificar momentos de risco em comum entre os participantes do experimento, momentos estes que foram indicados pelos próprios participantes por meio do botão "Marcar sonolência" do aplicativo *Android* utilizado no experimento.

5.2 Síntese

Neste capítulo foram discutidos os resultados da classificação dos conjuntos de amostras adquiridas durante o experimento descrito na Seção 4 por meio do método proposto. A seguir, serão apresentadas algumas conclusões e considerações finais, além das sugestões de possíveis trabalhos futuros a serem realizados.

Capítulo 6

Conclusão

Neste capítulo são apresentadas as considerações finais sobre o método proposto com base nos resultados obtidos e em outros trabalhos similares.

6.1 Considerações

O desempenho do método foi satisfatório tendo em vista que apenas 13,42% dos conjuntos (5 métricas calculadas a partir de 1 segundo de sinal de EEG) utilizados foram classificados de maneira incorreta. Em comparação com os trabalhos comentados na Seção 1.2, o método proposto apresentou 1,72% menos erros na detecção da sonolência em relação ao trabalho de Song et al. [24] e 0,88% em relação ao trabalho de Dey et al. [5].

Assim como no trabalho de Song et. al. [24], alguns outros trabalhos também utilizam sinais de EEG para classificar a sonolência de motoristas, porém, a maior parte deles utilizam outros classificadores, um maior número de canais, sinais de EOG ou câmeras para análise das piscadas do indivíduo [22, 23]. O método proposto utiliza um dispositivo com apenas 4 canais de EEG, que normalmente são mais baratos em comparação aos dispositivos com maior número de canais.

Outro diferencial do método proposto é que as métricas são estimadas com base em janelas de 1 segundo. Em um caso hipotético de um motorista dirigindo a 100km/h em uma rodovia, com um sistema que utiliza o método proposto para avaliar se o motorista está em uma situação de risco monitorando-o continuamente, a cada 1 segundo o sistema

terá uma chance de acerto de 86,58%. Em um carro a 100km/h, a distância percorrida em 1 segundo é de 27,78 metros. A sonolência é um processo gradativo e o objetivo definido para o método proposto foi indicar que o motorista está entrando em um estado de risco por conta da sonolência para que sistemas baseados neste método possam alertar ao motorista que este deve fazer uma pausa para descansar, antes de continuar dirigindo.

6.2 Trabalhos Futuros Sugeridos

Dois trabalhos futuros são sugeridos: a utilização de um dispositivo de apenas um canal (AF7), sendo necessárias algumas alterações na etapa de pré-processamento de modo a utilizar métodos mais efetivos na remoção de artefatos em um único canal, tendo em vista que o ICA não é recomendável para este caso; e o desenvolvimento de um sistema que utilize o método como base para notificar o motorista do seu nível de sonolência por meio de alertas visuais e sonoros.

Referências bibliográficas

- 1 YOUNGSTEDT, Shawn D.; GOFF, Eric E.; REYNOLDS, Alexandria M.; KRIPKE, Daniel F.; IRWIN, Michael R.; BOOTZIN, Richard R.; KHAN, Nidha; JEAN-LOUIS, Girardin. Has adult sleep duration declined over the last 50+ years? *Sleep Medicine Reviews*, Elsevier BV, v. 28, p. 69–85, aug 2016. Disponível em: <<https://doi.org/10.1016/j.smrv.2015.08.004>>.
- 2 NAZARI, N. A. A.; FAUZI, N. M.; ROSLI, N. F.; ZAKARIA, S. N.; JALIL, S. Z. A.; NOOR, N. M. Physiological studies of human fatigue using human electromagnetic radiation. In: *2017 IEEE International Conference on Signal and Image Processing Applications (ICSIPA)*. [S.l.: s.n.], 2017. p. 559–562.
- 3 OKOGBAA, O. Geoffrey; SHELL, Richard L.; FILIPUSIC, Davorka. On the investigation of the neurophysiological correlates of knowledge worker mental fatigue using the eeg signal. *Applied Ergonomics*, v. 25, p. 355–365, 1994. Disponível em: <https://goo.gl/sqQpQp>.
- 4 BOKSEM, Maarten A.S.; MEIJMAN, Theo F.; LORIST, Monique M. Effects of mental fatigue on attention: An erp study. *Cognitive Brain Research*, v. 25, p. 107–116, 2005. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0926641005001187>.
- 5 DEY, I.; JAGGA, S.; PRASAD, A.; SHARMILA, A.; BORAH, S. K.; RAO, G. Automatic detection of drowsiness in eeg records based on time analysis. In: *2017 Innovations in Power and Advanced Computing Technologies (i-PACT)*. [S.l.: s.n.], 2017. p. 1–5.
- 6 ZHAO, C.; ZHENG, C.; ZHAO, M.; LIU, J.; TU, Y. Automatic classification of driving mental fatigue with eeg by wavelet packet energy and kpca-svm. *International Journal of Innovative Computing Information and Control*, p. 1157–1168, 3 2011. Disponível em: <http://www.ijicic.org/09-1175-1.pdf>.
- 7 Observatório Nacional de Segurança Viária. *Sono e Cansaço são Responsáveis por até 50% dos Acidentes em Rodovias*. 2017. Disponível em: <https://goo.gl/FZcMkk>.
- 8 FORBES. *Around 5,000 People Were Killed Last Year Due to Drowsy Driving*. 2016. Disponível em: <https://goo.gl/PhcAyB>.
- 9 BACCHIERI, Giancarlo; BARROS, Aluísio J D. Rev saúde pública: Acidentes de trânsito no brasil de 1998 a 2010: muitas mudanças e poucos resultados. Pelotas-RS, Brasil, p. 949–963, 2011. Disponível em: <http://www.scielo.br/pdf/rsp/v45n5/2981.pdf>.

- 10 HAMADICHAREF, Brahim; ZHANG, Haihong; GUAN, Cuntai; PHUA, Chuan-chu Wang Kok Soon; TEE, Keng Peng; ANG, Kai Keng. Learning eeg-based spectral-spatial patterns for attention level measurement. *IEEE International Symposium on Circuits and Systems*, p. 1465–1468, 2009. Disponível em: <http://ieeexplore.ieee.org/document/5118043/>.
- 11 LAL, Saroj K. L.; CRAIG, Ashley; BOORD, Peter; KIRKUP, Les; NGUYEN, Hung. Development of an algorithm for an eeg-based driver fatigue countermeasure. *Journal of Safety Research* 34.3, p. 321–328, 2003. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0022437503000276>.
- 12 LAL, Saroj K. L.; CRAIG, Ashley. A critical review of the psychophysiology of driver fatigue. *Biology and Psychology*, v. 55, n. 3, p. 173–194, 2 2001. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0301051100000855>.
- 13 LIN, Chin-Teng; CHANG, Che-Jui; LIN, Bor-Shyh; HUNG, Shao-Hang; CHAO, Chih-Feng; WANG, I-Jan. A real-time wireless brain-computer interface system for drowsiness detection. *IEEE Transactions on Biomedical Circuits and Systems*, v. 4, n. 4, p. 214–222, 8 2010. Disponível em: <http://ieeexplore.ieee.org/document/5456232/>.
- 14 COOK, Dane B.; O'CONNOR, Patrick J.; LANGE, Gudrun; TEE, Jason Steffener Peng; ANG, Kai Keng. Functional neuroimaging correlates of mental fatigue induced by cognition among chronic fatigue syndrome patients and controls. *NeuroImage*, v. 36, p. 108–122, 5 2007. Disponível em: <http://www.sciencedirect.com/science/article/pii/S1053811907001279>.
- 15 TREJO, Leonard J.; KNUTH, Kevin; PRADO, Raquel; ROSIPAL, Roman; KUBITZ, Karla; KOCHAVI, Rebekah; MATTHEWS, Bryan; ZHANG, Yuzheng. Eeg-based estimation of mental fatigue: Convergent evidence for a three-state model. *Foundations of Augmented Cognition HCII*, p. 201–211, 2007. Disponível em: <https://goo.gl/rtIvC4>.
- 16 SAMSAMI, M. Mahdi; FIROOZABADI, Seyyed Mohammad P.; GOOYA, Ali. A morphological approach for mental fatigue assessment. *20th Iranian Conference on Biomedical Engineering*, p. 234–238, 12 2013. Disponível em: <http://ieeexplore.ieee.org/document/6782225/>.
- 17 HE, Jian; LIU, Dongdong; WAN, Zhijiang; HU, Chen. A noninvasive real-time driving fatigue detection technology based on left prefrontal attention and meditation eeg. *International Conference on Multisensor Fusion and Information Integration for Intelligent Systems*, 2014. Disponível em: <http://ieeexplore.ieee.org/document/6997673/>.
- 18 YANG, Shin-Min; CHEN, Chih-Ming; YU, Chih-Ming. Assessing the attention levels of students by using a novel attention aware system based on brainwave signals. *4th International Congress on Advanced Applied Informatics (IIAI-AAI)*, 7 2015. Disponível em: <http://ieeexplore.ieee.org/document/7373936/>.
- 19 GHASSEMI, Farnaz; MORADI, Mohammad Hasan; DOUST, Mahdi Tehrani; ABOOTALEBI, Vahid. Classification of sustained attention level based on morphological

- features of eeg's independent components. *ICME International Conference on Complex Medical Engineering*, 4 2009.
- 20 BORGHINIA, Gianluca; ASTOLFIA, Laura; VECCHIATO, Giovanni; MATTIAA, Donatella; BABILONIA, Fabio. Measuring neurophysiological signals in aircraft pilots and car drivers for the assessment of mental workload, fatigue and drowsiness. *Neuroscience & Biobehavioral Reviews*, v. 44, p. 58–75, 2012. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0149763412001704>.
- 21 BARWICK, Fiona; ARNETT, Peter; SLOBOUNOV, Semyon. Eeg correlates of fatigue during administration of neuropsychological test battery. *Clinical Neurophysiology*, v. 123, p. 270–284, 2012. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3206198/>.
- 22 KO, Li-Wei; LAI, Wei-Kai; LIANG, Wei-Gang; CHUANG, Chun-Hsiang; LU, Shao-Wei; LU, Yi-Chen; HSIUNG, Tien-Yang; WU, Hsu-Hsuan; LIN, Chin-Teng. Single channel wireless eeg device for real-time fatigue level detection. *International Joint Conference on Neural Networks (IJCNN)*, 10 2015. Disponível em: <http://ieeexplore.ieee.org/document/7280817/>.
- 23 AWAIS, M.; BADRUDDIN, N.; DRIEBERG, M. Eeg brain connectivity analysis to detect driver drowsiness using coherence. In: *2017 International Conference on Frontiers of Information Technology (FIT)*. [S.l.: s.n.], 2017. p. 110–114.
- 24 SONG, X.; YOON, S. C.; REX, E.; NIEVES, J.; MORETZ, C. Driver drowsiness detection using single-channel dry eeg. In: *2017 IEEE Signal Processing in Medicine and Biology Symposium (SPMB)*. [S.l.: s.n.], 2017. p. 1–3.
- 25 CHIRAS, D. *Human biology*. 6. ed. Estados Unidos da América: Jones & Barlett Publishers, 2008.
- 26 MORRISON, John; FARAH, Martha; GAZZALEY, Adam; JENSEN, Frances; ROSKAMS, Jane. *BrainFacts: A primer on the brain and nervous system*. [S.l.]: BrainFacts.org, 2012. Disponível em: <http://www.brainfacts.org/book>.
- 27 SOJOURI, Somayeh; DOYLE, John. Study of the brain functional network using synthetic data. *52nd Annual Allerton Conference on Communication, Control, and Computing (Allerton)*, 2014. Disponível em: <http://ieeexplore.ieee.org/document/7028476/>.
- 28 SANTOS, Rocilene Otaviano dos. *Estrutura e Funções do Córtex Cerebral*. Dissertação (Licenciatura em Ciências Biológicas) — Centro Universitário de Brasília: Faculdade de Ciências da Saúde, Brasília, 2002.
- 29 MACHADO, Angelo. *Neuroanatomia funcional - Biblioteca biomédica: Série morfológica*. 2. ed. Rio de Janeiro: Livraria Atheneu, 2000.
- 30 RIVERSIDEONLINE. *Nervous System*. 2017. Online. Disponível em: <https://goo.gl/zEh04O>.

- 31 LENT, Robert. *Neurociência da Mente e do Comportamento*. Rio de Janeiro: Guanabara Koogan, 2013.
- 32 BEAR, Mark F.; CONNORS, Barry W.; PARADISO, Michael A. *Neurociências: desvendando o sistema nervoso*. 2. ed. Porto Alegre: Artmed, 2002.
- 33 BRANDAO, Marcus L. *Psicofisiologia*. 3. ed. São Paulo: Ateneu, 1995.
- 34 PESSOA, Luiz; KASTNER, Sabine; UNGERLEIDER, Leslie G. Euroimaging studies of attention: From modulations sensory processing to top-down control. *Journal of Neuroscience*, 2003. Disponível em: <http://www.jneurosci.org/content/23/10/3990>.
- 35 OLIVEIRA, Juliana Roman dos Santos; VIGAN, Magna Gabriella; LUNARDELLI, Maria Cristina Frollini. Fadiga no trabalho: como o psicólogo pode atuar? *Psicologia em Estudo*, scielo, v. 15, p. 633 – 638, 09 2010. ISSN 1413-7372.
- 36 MARZIALE, Maria Helena Palucci; ROZESTRATEN, Reinier Johanés Antonius. Turnos alternantes: fadiga mental de enfermagem. *Revista Latino-americana de Enfermagem*, v. 3, p. 59–78, 1995.
- 37 BALBINOT, Amanda B.; ZARO, Milto A.; TIMM, Maria I. Funções psicológicas e cognitivas presentes no ato de dirigir e sua importância para os motoristas no trânsito. *Ciências & Cognição*, 2011. Disponível em: <https://goo.gl/d1mBd9>.
- 38 ROZESTRATEN, R.J. *Psicologia do trânsito, conceitos e processos básicos*. EPU/EDUSP, São Paulo, 1998.
- 39 SILVERTHORN, Dee Unglaub. *Fisiologia Humana - Uma Abordagem Integrada*. 5. ed. Porto Alegre: Artmed, 2010.
- 40 BOS, Danny Oude. *EEG-based Emotion Recognition The Influence of Visual and Auditory Stimuli*. 2006. Disponível em: <https://goo.gl/diUTDu>.
- 41 GUYTON, Arthur C. *Fisiologia Humana*. 6. ed. Rio de Janeiro: Guanabara Koogan, 1988.
- 42 SONI, Yashraj S.; SOMANI, S. B.; SHETE, V.V. Biometric user authentication using brain waves. *International Conference on Inventive Computation Technologies (ICICT)*, 2017. Disponível em: <http://ieeexplore.ieee.org/document/7824888/>.
- 43 DUBEY, R.; PATHAK, A. Digital analysis of eeg brain signal. *Webmed*, 2010. Disponível em: <https://goo.gl/HvDZ6h>.
- 44 NICOLAS-ALONSO, Luis Fernando; GOMEZ-GIL, Jaime. Digital analysis of eeg brain signal. *Molecular Diversity Preservation International*, 2012. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC3304110/>.
- 45 SANEI, S.; CHAMBERS, J. A. *EEG Signal Processing*. West Sussex, Inglaterra: John Wiley & Sons, 2007.

- 46 KAISER, J.; LUTZENBERGER, W. *Induced gamma-band activity and human brain function*. [S.l.]: Neuroscientist, 2003.
- 47 HERRMANN, C. S.; MECKLINGER, A. Gamma activity in human eeg is related to high-speed memory comparisons during object selective attention. *Visual Cognition*, 2001.
- 48 LEE, K. H.; WILLIAMS, L. M.; BREAKSPEAR, M.; GORDON, E. Synchronous gamma activity: A review and contribution to an integrative neuroscience model of schizophrenia. *Brain Research Reviews*, 2003.
- 49 NICOLAS-ALONSO, Luis Fernando; GOMEZ-GIL, Jaime. Brain computer interfaces, a review. *Sensors*, v. 12, n. 2, p. 1211–1279, 2012. ISSN 1424-8220. Disponível em: <<http://www.mdpi.com/1424-8220/12/2/1211>>.
- 50 LAL, TN.; HINTERBERGER, T.; WIDMAN, G.; SCHRÖDER, M.; HILL, J.; ROSENSTIEL, W.; ELGER, CE.; SCHÖLKOPF, B.; BIRBAUMER, N. Methods towards invasive human brain computer interfaces. In: MAX-PLANCK-GESELLSCHAFT. *Advances in Neural Information Processing Systems 17*. Cambridge, MA, USA: MIT Press, 2005. p. 737–744.
- 51 SHAH, A. K.; MITTAL, S. Invasive electroencephalography monitoring: Indications and presurgical planning. *Annals of Indian Academy of Neurology*, v. 17(Suppl 1), p. S89–S94, 2014.
- 52 SCHLÖGL, A.; BRUNNER, C. Biosig: A free and open source software library for bci research. *Computer*, v. 41, n. 10, p. 44–50, Oct 2008. ISSN 0018-9162.
- 53 GILMORE, R.L.; SOCIETY, American Electroencephalographic. *American Electroencephalographic Society Guidelines in Electroencephalography, Evoked Potentials, and Polysomnography*. Raven Press, 1994. (Journal of clinical neurophysiology). Disponível em: <<https://books.google.com.br/books?id=HncZHQAACAAJ>>.
- 54 SISTEMA Internacional 10-10. 1995. Online. Disponível em: <http://www.bem.fi/book/13/13.htm>.
- 55 MUSE. *Hardware Specifications - Muse Developers*. 2018. Online. Disponível em: <https://goo.gl/Xv6vLQ>.
- 56 EMOTIV. *Emotiv Epoc - Brain Computer Interface and Scientific Contextual EEG Specifications*. [S.l.], 2014.
- 57 BARAGONA, Roberto; BATTAGLIA, Francesco. Outliers detection in multivariate time series by independent component analysis. *Neural Comput.*, MIT Press, Cambridge, MA, USA, v. 19, n. 7, p. 1962–1984, jul. 2007. ISSN 0899-7667. Disponível em: <<http://dx.doi.org/10.1162/neco.2007.19.7.1962>>.
- 58 HYVÄRINEN, Aapo. Independent component analysis for time-dependent stochastic processes. In: NIKLASSON, Lars; BODÉN, Mikael; ZIEMKE, Tom (Ed.). *ICANN 98*. London: Springer London, 1998. p. 135–140. ISBN 978-1-4471-1599-1.

- 59 T., Tavares M. *Aquisição e Processamento de Sinais Biolétricos Neurofisiológicos Intraoperatórios*. Florianópolis: Universidade Federal de Santa Catarina, 2003. Tese (Doutorado em Engenharia Elétrica) - Programa de PósGraduação em Engenharia Elétrica.
- 60 BURRUS, C. S; GOPINATH, Ramesh A; GUO, Haitao. Book; Book/Illustrated. *Introduction to wavelets and wavelet transforms : a primer*. [S.l.]: Upper Saddle River, N.J. : Prentice Hall, 1998. Includes bibliographical references (pages 224-245) and index. ISBN 0134896009.
- 61 CUSTÓDIO, R. F. *Análise Não-Linear no Reconhecimento de Padrões Sonoros: estudo de caso para sons pulmonares*. Porto Alegre: Universidade Federal do Rio Grande do Sul, 1999. ESE (Doutorado em Ciência da Computação) – Programa de Pós-graduação em Ciência da Computação - PPGC.
- 62 MALLAT, S.G. A theory for multiresolution signal decomposition: The wavelet representation. *IEEE Trans. On Pattern Analysis and Machine*, 1989.
- 63 SHAKER, Maan M. Eeg waves classifier using wavelet transform and fourier transform. *World Academy of Science, Engineering and Technology*, 2007.
- 64 DAUBECHIES, Ingrid. *Ten Lectures on Wavelets*. Philadelphia, PA, USA: Society for Industrial and Applied Mathematics, 1992. ISBN 0-89871-274-2.
- 65 MURUGAPPAN, M.; RIZON, M.; NAGARAJAN, R.; YAACOB, S. Eeg feature extraction for classifying emotions using fcm and fkm. In: *Proceedings of the 7th WSEAS International Conference on Applied Computer and Applied Computational Science*. Stevens Point, Wisconsin, USA: World Scientific and Engineering Academy and Society (WSEAS), 2008. (ACACOS'08), p. 299–304. ISBN 978-960-6766-61-9. Disponível em: <<http://dl.acm.org/citation.cfm?id=1415743.1415793>>.
- 66 WANG, Xiao-Wei; NIE, Dan; LU, Bao-Liang. Emotional state classification from eeg data using machine learning approach. *Neurocomput.*, Elsevier Science Publishers B. V., Amsterdam, The Netherlands, The Netherlands, v. 129, p. 94–106, abr. 2014. ISSN 0925-2312. Disponível em: <<http://dx.doi.org/10.1016/j.neucom.2013.06.046>>.
- 67 SUBASI, Abdulhamit. Eeg signal classification using wavelet feature extraction and a mixture of expert model. *Expert Syst. Appl.*, Pergamon Press, Inc., Tarrytown, NY, USA, v. 32, n. 4, p. 1084–1093, maio 2007. ISSN 0957-4174. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2006.02.005>>.
- 68 MURUGAPPAN, M.; NAGARAJAN, R.; YAACOB, S. Appraising human emotions using time frequency analysis based eeg alpha band features. In: *2009 Innovative Technologies in Intelligent Systems and Industrial Applications*. [S.l.: s.n.], 2009. p. 70–75.
- 69 NAVIDI, William. *Probabilidade e Estatística para Ciências Exatas*. 1ª. ed. Porto Alegre: AMGH, 2012. 12-13 p. Tradução de José Lucimar do Nascimento. Título Original: *Principles of Statistics for Engineers and Scientists*.

- 70 LEHMANN, E.L.; CASELLA, G. *Theory of Point Estimation*. [S.l.]: Springer Verlag, 1998. ISBN 0387985026.
- 71 STOJANOVIC, Miodrag; APOSTOLOVIC, Marija; STOJANOVIC, Dijana; MILOSEVIC, Zoran; TOPLAOVIC, Aleksandra; LAKUSIC, Vesna Mitic; GOLUBOVIC, Mladan. Understanding sensitivity, specificity and predictive values. *Vojnosanit Pregl*, 2014.
- 72 LATHI, B. P. *Sinais e Sistemas Lineares*. 2. ed. São Paulo - SP: Bookman, 2007.
- 73 MATHWORKS. *Entropy (wavelet packet) - MATLAB wentropy*. 2018. Acesso em: maio de 2018. Disponível em: <<http://www.mathworks.com/products/matlab>>.
- 74 PINHEIRO, António M. Gonçalves. Análise e processamento de sinal e imagem: Introdução ao reconhecimento de padrões. Disponível em: <http://www.dfisica.ubi.pt/pinheiro/apsi05v2.pdf>. 2005.
- 75 LIN, Chin-Teng; CHUANG, Chun-Hsiang; HUANG, Chih-Sheng; TSAI, Shu-Fang; LU, Shao-Wei; CHEN, Yen-Hsuan; KO, Li-Wei. Wireless and wearable eeg system for evaluating driver vigilance. *IEEE Trans. On Biomedical Circuits and Systems*, 2014.
- 76 SILVA, Luiza Maria Oliveira da. *Uma Aplicação de Árvores de Decisão, Redes Neurais e KNN para a Identificação de Modelos ARMA Não-Sazonais e Sazonais*. Dissertação (Doutorado em Engenharia Elétrica) — PUC-Rio, Rio de Janeiro, 2005. Disponível em: <https://goo.gl/IRWAMU>.
- 77 OLIVEIRA, A. R. *Redes Neurais Artificiais Aplicadas na Detecção, Classificação e Localização de Defeitos em Linhas de Transmissão*. Juiz de Fora - MG: Universidade Federal de Juiz de Fora, 2005. Dissertação (Mestrado em Engenharia Elétrica) - Programa de PósGraduação em Engenharia Elétrica.
- 78 AGUIAR, Fernando Guimarães. *Utilização de Redes Neurais Artificiais para Detecção de Padrões de Vazamentos em Dutos*. Dissertação (Mestrado em Engenharia Mecânica) — Escola de Engenharia de São Carlos da Universidade de São Paulo, São Carlos, SP, 2010. Disponível em: <https://goo.gl/10HctZ>.
- 79 SILVA, Angelo José Moreira. *Implementação de um Algoritmo Genético Utilizando o Modelo de Ilhas*. Dissertação (Mestrado em Ciências em Engenharia Civil) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005. Disponível em: <https://goo.gl/yFY5s6>.
- 80 SCHALKOFF, R.J. *Pattern Recognition: Statistical, Structural and Neural Approaches*. John Wiley & Sons, 1992. (Wiley international edition). ISBN 9780471552383. Disponível em: <<https://books.google.com.br/books?id=czc2PwAACAAJ>>.
- 81 ROBERTS, Cedric. Low frequency noise from transportation sources. In: *20th International Congress on Acoustics*. [S.l.: s.n.], 2010. p. 23–27. Disponível em: <https://goo.gl/oyU1no>.

- 82 KACZOROWSKA, M.; PLECHAWSKA-WOJCIK, M.; TOKOVAROV, M.; DMYTRUK, R. Comparison of the ica and pca methods in correction of eeg signal artefacts. In: *2017 10th International Symposium on Advanced Topics in Electrical Engineering (ATEE)*. [S.l.: s.n.], 2017. p. 262–267.
- 83 RADÜNTZ, T.; SCOUTEN, J.; HOCHMUTH, O.; MEFFERT, B. EEG artifact elimination by extraction of ICA-component features using image processing algorithms. *Journal of Neuroscience Methods*, Elsevier BV, v. 243, p. 84–93, mar 2015. Disponível em: <<https://doi.org/10.1016/j.jneumeth.2015.01.030>>.
- 84 LIN, T. A.; JOHN, L. R. Quantifying mental relaxation with eeg for use in computer games. In: *in: International Conference on Internet Computing*. [S.l.: s.n.], 2006. p. 409–415.
- 85 PINCUS, S. M.; GLADSTONE, I. M.; EHRENKRANZ, R. A. A regularity statistic for medical data analysis. *Journal of Clinical Monitoring and Computing*, p. 335–345, 1991.
- 86 PRÍNCIPE, José C.; EULIANO, N.R.; LEFEBVRE, W.C. *Neural and adaptive systems: fundamentals through simulations*. Wiley, 2000. ISBN 9780471351672. Disponível em: <<https://books.google.com.br/books?id=jgMZAQAIAAJ>>.
- 87 MATHWORKS. *Create, Configure, and Initialize Multilayer Neural Networks - MATLAB & Simulink*. 2018. Acesso em: junho de 2018. Disponível em: <<http://www.mathworks.com/products/matlab>>.
- 88 Euro Truck Simulator 2. 2018. Online. Disponível em: <https://eurotrucksimulator2.com/>.