

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
CURSO DE GRADUAÇÃO EM ENGENHARIA ELÉTRICA

RAFAEL COIMBRA GUS

**DETECÇÃO DE ESQUIZOFRENIA POR
MEIO DE APRENDIZADO DE
MÁQUINA A PARTIR DA ANÁLISE DE
ERP EM DADOS DE EEG**

Porto Alegre
2023

RAFAEL COIMBRA GUS

**DETECÇÃO DE ESQUIZOFRENIA POR
MEIO DE APRENDIZADO DE
MÁQUINA A PARTIR DA ANÁLISE DE
ERP EM DADOS DE EEG**

Projeto de Diplomação apresentado ao Departamento de Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Engenheiro Eletricista.

ORIENTADOR: Prof. Dr. Tiago Oliveira Weber

Porto Alegre
2023

RAFAEL COIMBRA GUS

**DETECÇÃO DE ESQUIZOFRENIA POR
MEIO DE APRENDIZADO DE
MÁQUINA A PARTIR DA ANÁLISE DE
ERP EM DADOS DE EEG**

Projeto de Diplomação apresentado ao Departamento de Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Engenheiro Eletricista.

Orientador: _____
Prof. Dr. Tiago Oliveira Weber, UFRGS
Doutor pela Universidade de São Paulo – São Paulo, Brasil

Banca Examinadora:

Doutorando Guilherme Pedrollo, UFRGS
Graduado pela Pontifícia Universidade Católica do Rio Grande do Sul

Prof. Dr. Ivan Müller, UFRGS
Doutor pela Universidade Federal do Rio Grande do Sul

Prof. Dr. Tiago Oliveira Weber, UFRGS
Doutor pela Universidade de São Paulo – São Paulo, Brasil

Chefe do DELET: _____
Ivan Müller

Porto Alegre, setembro de 2023.

AGRADECIMENTOS

À minha Universidade, UFRGS, e aos professores e colaboradores, que fizeram toda minha jornada se tornar possível.

Ao meu orientador Tiago Oliveira Weber, pelo profissional e pessoa exemplar que é e por ter sido alguém tão importante nos meus últimos anos de graduação, me permitindo ser seu orientando nessa etapa tão importante.

À minha família, em especial aos meus pais, mães, irmãos e irmã, por estarem presentes ao longo de toda minha trajetória e por terem me dado todo o apoio sempre que necessário.

Às minhas cachorrinhas Fuji e Pipa, por sempre me passarem tranquilidade e um sentimento de que tudo vai dar certo.

À minha namorada Fabiane, que esteve comigo durante praticamente toda graduação, sendo peça fundamental em tantos momentos, e que agora será minha colega na profissão de Engenheiro.

Ao meu grande amigo Leomar, por ter fornecido o *hardware* necessário para elaborar este trabalho e por tantas outras ajudas ao longo do desenvolvimento.

Ao meu grande amigo Gabriel Bertaluci, que sempre me motivou a concluir o TCC, ajudando em tantos momentos de descontração com risadas e muitos cubos mágicos resolvidos.

Aos meus demais grandes amigos e futuros colegas de profissão (ou que optaram por seguir outras carreiras), que sem eles eu provavelmente não teria chegado até aqui.

À minha empresa Sicredi e aos meus e minhas colegas, pela extrema compreensão e apoio durante este período tão estressante e exigente.

RESUMO

A esquizofrenia é um transtorno que atinge mais de 27 milhões de pessoas ao redor do mundo, e tem no seu diagnóstico uma das maiores dificuldades para o tratamento. O uso da inteligência artificial e do aprendizado de máquina pode ser um grande aliado para auxiliar em um diagnóstico mais rápido, barato e assertivo. Através da análise de potenciais de eventos relacionados (ERP) durante exame de eletroencefalograma (EEG) com mais de 70 canais, 81 indivíduos tiveram suas atividades cerebrais medidas ao longo da execução de 3 tarefas distintas. Destes 81 indivíduos, 49 possuíam diagnóstico para esquizofrenia e 32 não, sendo chamados de controles saudáveis. Através da análise dos dados e extração de características dos sinais medidos, foi possível atingir uma taxa de acerto média de 70,58% para o método Árvore de Decisão, 64,70% para Redes Neurais Artificiais e Máquina de Vetores de Suporte e apenas 47,06% para o método Floresta Aleatória aplicando a análise de componentes principais (PCA). A técnica de PCA se mostrou promissora para redução de dimensionalidade, atingindo 88,41% de razão de variância explicada dos dados com apenas 5 componentes principais. A remoção de parâmetros por meio do estudo do coeficiente de correlação entre variáveis, apesar de obter êxito na redução desses parâmetros, apresentou resultados inferiores para todas topologias, com exceção das aplicando Redes Neurais. O desempenho dos modelos, porém, pode ser incrementado através do aumento do conjunto de dados, possibilitando um maior treinamento e uma validação dos resultados mais adequada, e através de outras combinações de métodos, hiperparâmetros, técnicas de extração de características e de pré-processamento dos dados.

Palavras-chave: Esquizofrenia, eletroencefalograma, potenciais de eventos relacionados, aprendizado de máquina, extração de características.

ABSTRACT

Schizophrenia is a disorder that affects over 27 million people worldwide, and its diagnosis poses one of the greatest challenges for treatment. The use of artificial intelligence and machine learning can be a significant ally in facilitating a quicker, more cost-effective, and accurate diagnosis. Through the analysis of event-related potentials (ERP) during electroencephalogram (EEG) exams with more than 70 channels, the brain activities of 81 individuals were measured during the execution of three distinct tasks. Out of these 81 individuals, 49 were diagnosed prior with schizophrenia, while 32 were considered healthy controls. Through data analysis and feature extraction from the measured signals, it was possible to achieve an accuracy of 70.58% using the Decision Tree method, 64.70% for Artificial Neural Networks and Support Vector Machines, and only 47.06% for the Random Forest method when applying Principal Component Analysis (PCA). The PCA technique showed promise for dimensionality reduction, reaching 88.41% of explained variance ratio with only 5 principal components. The removal of parameters through the study of the correlation coefficient between variables, while successful in reducing these parameters, yielded inferior results for all topologies except when applying Neural Networks. The performance of the models, however, can be improved by increasing the dataset samples, allowing for more extensive training and more appropriate result validation. Additionally, different combinations of methods, hyperparameters, feature extraction techniques and data preprocessing can improve performance.

Keywords: Schizophrenia, electroencephalogram, event-related potentials, machine learning, feature extraction.

LISTA DE FIGURAS

1	Percentagem de pessoas com Esquizofrenia no mundo desde 1990. . .	12
2	Percentagem de pessoas com Esquizofrenia no Brasil desde 1990. . .	12
3	Um dos primeiros eletroencefalogramas gerados por Berger.	15
4	Anotações feitas por Berger em seu diário.	16
5	Regiões do cérebro.	18
6	Exemplo de uma árvore de decisão.	23
7	Exemplo de uma floresta aleatória.	24
8	Curvas referentes às funções de ativação.	26
9	Modelo de um neurônio.	26
10	Modelo de uma rede neural artificial.	27
11	Exemplo do funcionamento da técnica de <i>kernel</i>	28
12	Esquema da aplicação do PCA.	30
13	Tipos de correlações.	31
14	<i>Heatmap</i> da correlação entre variáveis.	32
15	Diagrama da distribuição dos eletrodos durante EEG.	40
16	Fluxograma das etapas realizados ao longo do trabalho.	41
17	Esquema com os 9 eletrodos utilizados.	44
18	Distribuição dos 81 indivíduos quanto à presença de esquizofrenia. .	45
19	Distribuição dos 81 indivíduos quanto à idade e aos anos de educação.	46
20	Distribuição dos 81 indivíduos quanto ao sexo.	46
21	Curvas da média de 100 amostras para as 3 tarefas do Canal Fz. . . .	54
22	Curvas da média de 100 amostras para as 3 tarefas do Canal Cz. . . .	55
23	Curvas da média de 100 amostras para as 3 tarefas do Canal F8. . . .	55
24	Curvas da média de 100 amostras para as 3 tarefas do Canal P10. . .	56
25	<i>Scree plot</i> da análise por PCA.	59
26	<i>Scree plot</i> da análise por PCA com dados normalizados.	59
27	Mapa de Calor da correlação entre variáveis após remoção de parâ- metros.	60
28	Mapa de Calor da correlação entre variáveis.	61
29	Mapa de Calor da correlação entre as componentes principais após PCA.	62
30	Matriz de Confusão para DT.	67
31	Matriz de Confusão para RF.	68
32	Matriz de Confusão para ANN.	68
33	Matriz de Confusão para SVM.	69
34	Comparação da <i>accuracy</i> para os 4 modelos utilizando PCA.	69
35	Comparação da <i>accuracy</i> com demais trabalhos da literatura.	70

LISTA DE TABELAS

1	Valores para Esquizofrenia no mundo.	11
2	Valores para Esquizofrenia no Brasil.	12
3	Bibliotecas utilizadas em <i>Python</i>	39
4	Hiperparâmetros utilizados para Árvores de Decisão.	51
5	Hiperparâmetros utilizados para Floresta Aleatória.	51
6	Hiperparâmetros utilizados para Redes Neurais.	51
7	Hiperparâmetros utilizados para Máquina de Vetores de Suporte.	52
8	Valores dos Canais Fz, FCz e Cz para indivíduo 1.	57
9	Valores dos Canais FC3, C3 e CP3 para indivíduo 1.	57
10	Valores dos Canais FC4, C4 e CP4 para indivíduo 1.	57
11	Valores normalizados dos Canais Fz, FCz e Cz para indivíduo 1.	58
12	Desempenhos para conjunto validação sem técnicas de normalização, PCA e remoção de parâmetros através da correlação entre variáveis.	63
13	Topologias com melhor <i>accuracy</i> para conjunto validação sem técnicas de normalização, PCA e remoção de parâmetros através da correlação entre variáveis.	63
14	Desempenhos para conjunto validação com normalização.	63
15	Topologias com melhor <i>accuracy</i> para conjunto validação com normalização.	64
16	Desempenhos para conjunto validação com parâmetros removidos por correlação entre variáveis.	64
17	Topologias com melhor <i>accuracy</i> para conjunto validação com parâmetros removidos por correlação entre variáveis.	64
18	Desempenhos para conjunto validação com PCA.	64
19	Topologias com melhor <i>accuracy</i> para conjunto validação com PCA.	65
20	Desempenhos para conjunto teste sem técnicas de normalização, PCA e remoção de parâmetros através da correlação entre variáveis.	65
21	Desempenhos para conjunto teste com normalização.	66
22	Desempenhos para conjunto teste com parâmetros removidos por correlação entre variáveis.	66
23	Desempenhos para conjunto teste com PCA.	66

LISTA DE ABREVIATURAS

<i>EEG</i>	<i>Eletroencefalograma</i>
<i>IA</i>	<i>Inteligência Artificial</i>
<i>ML</i>	<i>Machine Learning</i>
<i>DT</i>	<i>Decision Tree</i>
<i>RF</i>	<i>Random Forest</i>
<i>ANN</i>	<i>Artificial Neural Network</i>
<i>CNN</i>	<i>Convolutional Neural Network</i>
<i>SVM</i>	<i>Support Vector Machine</i>
<i>PCA</i>	<i>Principal Component Analysis</i>
<i>ERP</i>	<i>Event-Related Potential</i>
<i>ADC</i>	<i>Analog-to-Digital Converter</i>

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Motivação	13
1.2	Objetivos	14
1.2.1	Objetivo Geral	14
1.2.2	Objetivos Específicos	14
1.3	Estrutura do Trabalho	14
2	FUNDAMENTAÇÃO TEÓRICA	15
2.1	Eletronecefalograma	15
2.1.1	Sinais de EEG e suas características	16
2.1.2	Sistema de aquisição dos sinais	17
2.2	Regiões do cérebro e suas funções	18
2.3	Esquizofrenia e aplicação de EEG	19
2.4	Inteligência Artificial	19
2.5	Aprendizado de Máquina	21
2.5.1	Métodos	22
2.5.2	Hiperparâmetros	29
2.6	Seleção de atributos	29
2.6.1	Análise de Componentes Principais	30
2.6.2	Coeficiente de correlação	30
2.7	Análise de desempenho	31
2.7.1	Matriz de confusão	32
2.7.2	Métricas	33
2.8	Trabalhos Relacionados e Estado da Arte	34

2.8.1	Estado da Arte e uso de ML na medicina	34
2.8.2	Esquizofrenia e aplicação de ML no estudo do transtorno	36
3	METODOLOGIA	38
3.1	Materiais e Ferramentas	38
3.1.1	Hardware e Software	38
3.1.2	Base de dados	38
3.2	Procedimento	41
3.2.1	Pré-processamento dos dados	42
3.2.2	Escolha dos Métodos de aprendizado de máquina	48
3.2.3	Otimização de hiperparâmetros	48
3.2.4	Estratégia de Treinamento, Validação e Teste	52
3.2.5	Comparação dos resultados	52
4	RESULTADOS	54
4.1	Pré-processamento dos dados	54
4.1.1	Extração de características dos sinais	56
4.1.2	Normalização	58
4.1.3	PCA	58
4.1.4	Correlação entre variáveis	60
4.2	Treinamento e Validação	62
4.3	Desempenho final de cada modelo	65
4.4	Comparação com trabalhos da literatura	70
5	CONCLUSÕES	72
5.1	Contribuições	73
5.2	Trabalhos Futuros	73
	REFERÊNCIAS	75

1 INTRODUÇÃO

A esquizofrenia é um transtorno mental que afeta o modo como uma pessoa pensa, sente e se comporta. Dentre os sintomas, pode-se citar alucinação, delírio, agitação e isolamento social.

O diagnóstico do transtorno é realizado geralmente através da observação, por um profissional da área da saúde, dos sintomas e comportamentos do paciente, com auxílio de exames físicos e neurológicos. Esses exames servem, também, para descartar outras condições médicas (fisiológicas ou psíquicas) que possam estar causando os sintomas observados. Sendo assim, não existe um teste único que possa servir como diagnóstico para a esquizofrenia, fato esse que dificulta muito o trabalho dos profissionais na área. Apesar disso, ele é fundamental para o tratamento adequado e o controle dos sintomas do transtorno.

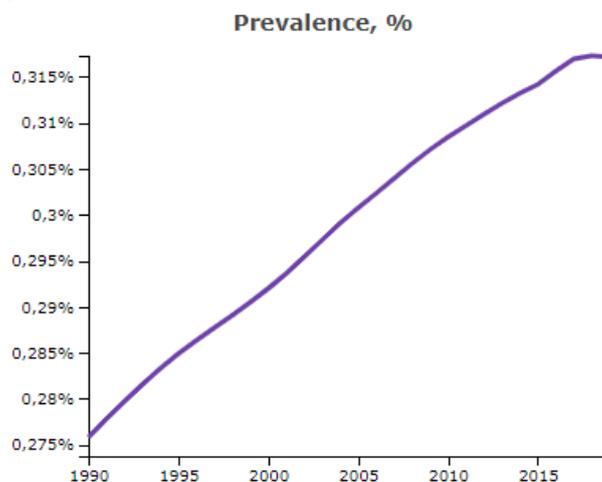
De acordo com dados do Instituto de Métricas e Avaliação em Saúde (IHME, 2023), em 2019, o número de pessoas com esquizofrenia ultrapassou 27 milhões em todo o mundo, o que representou 0,37% da população mundial naquele ano. Essa taxa cresceu em relação a 1990, quando era de 0,28% com 16 milhões de pessoas afetadas, como pode ser visto nos valores da Tabela 1 e no gráfico presente na Figura 1.

Tabela 1 – Valores para Esquizofrenia no mundo.

Local	Transtorno	Ano	Valor máximo
Global	Esquizofrenia	1990	16.475.374 (0,32%)
Global	Esquizofrenia	2019	27.150.677 (0,37%)

Fonte: IHME (2023)

Figura 1 – Percentagem de pessoas com Esquizofrenia no mundo desde 1990.



Fonte: IHME (2023)

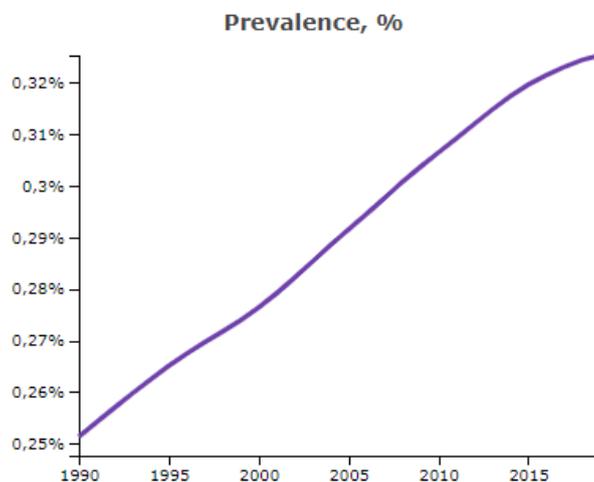
No Brasil, a tendência é a mesma. Em 1990, 416 mil pessoas foram diagnosticadas com o distúrbio, representando 0,29% da população nacional naquela época. Em 2019, esses números aumentaram para mais de 780 mil pessoas, representando 0,37% da população do país. A Figura 2 e os dados presentes na Tabela 2 apresentam esses valores.

Tabela 2 – Valores para Esquizofrenia no Brasil.

Local	Transtorno	Ano	Valor máximo
Brasil	Esquizofrenia	1990	416.734 (0,29%)
Brasil	Esquizofrenia	2019	780.904 (0,37%)

Fonte: IHME (2023)

Figura 2 – Percentagem de pessoas com Esquizofrenia no Brasil desde 1990.



Fonte: IHME (2023)

Em contrapartida ao aumento da quantidade de pessoas com o distúrbio ao redor do mundo, o uso da tecnologia no auxílio aos tratamentos e diagnósticos de doenças e transtornos também têm aumentado com o passar dos anos. Há poucos séculos, atividades médicas eram conduzidas exclusivamente com o conhecimento técnico dos profissionais envolvidos, sem a utilização de ferramentas tecnológicas, como computadores, ou de técnicas avançadas, como ressonância magnética, radiografia e ultrassom.

Atualmente, porém, essa realidade mudou significativamente, e a tecnologia está presente desde os exames e diagnósticos mais simples até cirurgias complexas e tratamentos extensivos. Esse progresso tem impulsionado o campo da medicina, permitindo um cuidado mais preciso, abrangente e acessível aos pacientes.

Um dos pilares desse avanço tecnológico é a crescente aplicação da Inteligência Artificial (IA). A IA desempenha um papel cada vez mais crucial no auxílio aos profissionais de saúde, pois é capaz de analisar enormes quantidades de dados médicos em um curto espaço de tempo, identificar padrões sutis e fornecer informações valiosas para a tomada de decisões clínicas. Os algoritmos de aprendizado de máquina são utilizados para aprimorar o diagnóstico médico, tornando-o mais rápido e preciso. Em exames de atividade cerebral, bastante utilizados no diagnóstico da esquizofrenia, a IA pode ajudar a detectar anomalias e sinais precoces do transtorno que poderiam passar despercebidos em uma análise feita por seres humanos.

O presente trabalho busca, a partir de um conjunto de dados, comparar diferentes métodos de aprendizado de máquina (*machine learning* ou ML) quanto aos seus desempenhos na detecção de esquizofrenia, para então identificar o melhor modelo. O conjunto de dados consiste em dados de Eletroencefalograma (EEG), exame realizado em diversos pacientes, alguns desses com esquizofrenia já diagnosticada.

1.1 Motivação

Apesar de um grande número de pessoas ser afetado pelo transtorno esquizofrênico, a maioria delas não recebe tratamento adequado para reduzir os sintomas associados. A falta de tratamento é, em grande parte, atribuída à dificuldade no diagnóstico, que muitas vezes tem um custo elevado, impossibilitando o acesso à uma parcela da população e agravando ainda mais as consequências do transtorno.

Os métodos de aprendizado de máquina têm sido amplamente utilizados em diversas áreas da saúde para aprimorar o diagnóstico e o tratamento de várias doenças e transtornos. Esses métodos podem ser aplicados para a detecção de padrões em conjuntos de dados clínicos, incluindo exames, histórico médico, dados genéticos e pessoais do paciente. Com isso, o uso de métodos de aprendizado de máquina para o diagnóstico da esquizofrenia pode levar a um diagnóstico mais rápido, preciso e barato.

1.2 Objetivos

1.2.1 Objetivo Geral

Desenvolver um modelo através de aprendizado de máquina para auxiliar na detecção de esquizofrenia a partir de sinais de EEG (no teste de Potencial de Eventos Relacionados - ERP) e de dados pessoais do paciente.

1.2.2 Objetivos Específicos

Os objetivos específicos consistem em analisar a base de dados e realizar extração de *features*; implementar métodos de ML como redes neurais e algoritmos baseados em árvores de decisão para previsão da esquizofrenia; reduzir a complexidade computacional do modelo; comparar com resultados da literatura que utilizaram o mesmo conjunto de dados e metodologias semelhantes para análises clínicas.

1.3 Estrutura do Trabalho

Essa monografia está dividida entre capítulos de forma a apresentar todo conteúdo através de um encadeamento organizado. No Capítulo 2, são explicados conceitos e práticas utilizadas ao longo de todo trabalho, bem como uma revisão bibliográfica de diversos artigos sobre a temática da Esquizofrenia e da utilização de *Machine Learning* em aplicações médicas. Após essa revisão, no Capítulo 3 é apresentada a metodologia aplicada no desenvolvimento do trabalho, bem como ferramentas e materiais utilizados. No Capítulo 4, os resultados obtidos são apresentados e comparados para diferentes métodos de ML. Por fim, são feitas conclusões sobre os resultados no Capítulo 5.

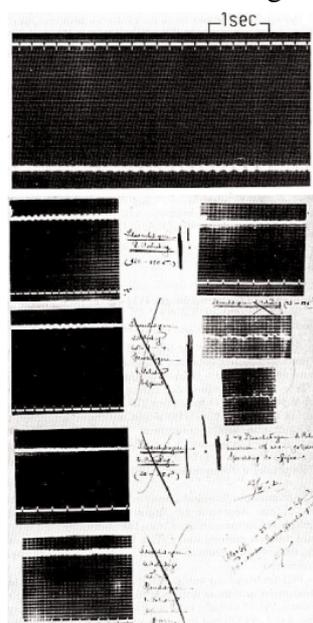
2 FUNDAMENTAÇÃO TEÓRICA

O presente capítulo discorre dos conceitos teóricos trabalhados ao longo da monografia e apresenta referências bibliográficas relevantes ao tema.

2.1 Eletroencefalograma

Em 1873, em uma pequena cidade no interior da Alemanha, nascia Hans Berger, neurologista responsável por registrar os primeiros eletroencefalogramas humanos, na década de 1920 (HAAS, 2003). Hans iniciou suas pesquisas na área muitos anos antes, quando ainda estava na faculdade de medicina, mas foi só em 1924 que conseguiu obter os primeiros registros da atividade cerebral humana através de eletroencefalograma, quando gerou imagens semelhantes às da Figura 3, provavelmente entre os anos 1925 e 1926.

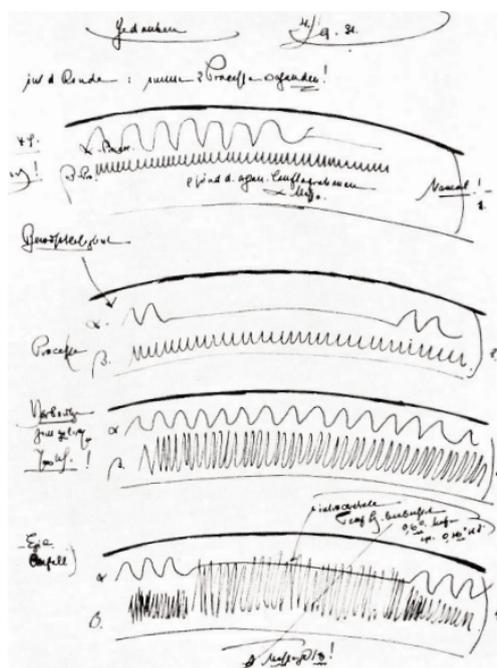
Figura 3 – Um dos primeiros eletroencefalogramas gerados por Berger.



Fonte: MILLETT (2001)

Através do uso de um galvanômetro, instrumento eletromecânico utilizado para medir correntes elétricas de baixa intensidade, e com uso de eletrodos no couro cabeludo de um paciente, foi possível capturar as fracas oscilações das correntes corticais. Berger sugeriu que o EEG era composto por duas formas de onda fundamentais: as ondas α , que foram relacionados com a atividade mental, e as ondas β , que foram associadas com as atividades metabólicas do tecido cortical. A Figura 4 apresenta desenhos feitos pelo próprio Hans, demonstrando seu estudo de ondas α e β .

Figura 4 – Anotações feitas por Berger em seu diário.



Fonte: MILLETT (2001)

Na década seguinte, Hans Berger publicou mais de 10 artigos científicos sobre o eletroencefalograma, que passou a ser muito utilizado para estudos do cérebro. Hoje em dia, o exame é muito importante em diversas áreas da medicina, como para diagnóstico de epilepsia e esquizofrenia, estudos sobre o sono e monitoramento do coma.

2.1.1 Sinais de EEG e suas características

Os sinais de EEG são ondas elétricas geradas em decorrência da comunicação de neurônios presentes no cérebro humano. O uso desses sinais têm se mostrado uma ferramenta valiosa na compreensão da atividade cerebral e no desenvolvimento de novas abordagens diagnósticas e terapêuticas para distúrbios neurológicos e psiquiátricos, como no caso da esquizofrenia.

De acordo com o valor da frequência f , os sinais podem ser classificados entre 5 tipos de ondas (BAŞAR *et al.*, 2001):

- Ondas Delta (δ): $f \implies$ de 0,5 até 3,5 Hz, observadas em estados de sono profundo ou em algumas condições patológicas;
- Ondas Theta (θ): $f \implies$ de 3,5 até 7,5 Hz, presentes em estágios iniciais do sono e em meditação;
- Ondas Alfa (α): $f \implies$ de 7,5 até 13 Hz, predominantes em estados de relaxamento;
- Ondas Beta (β): $f \implies$ de 13 até 30 Hz, associadas a estados de atenção, concentração e atividade mental;
- Ondas Gama (γ): $f \implies$ de 30 até 70 Hz, relacionadas à atividades cognitivas complexas.

Além da frequência, atributos como forma, amplitude e potência da onda são relevantes para a análise dos sinais de EEG.

2.1.2 Sistema de aquisição dos sinais

Uma parte fundamental do processo de um exame de eletroencefalograma é o sistema de aquisição dos sinais de EEG. Esse sistema é fundamental para capturar e gravar os sinais cerebrais, permitindo que sejam analisados e interpretados para fins clínicos ou de pesquisa.

Ele é composto por alguns componentes:

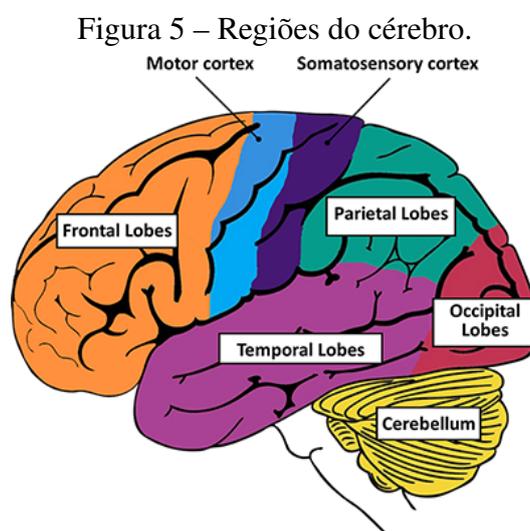
- Eletrodos: sensores colocados no couro cabeludo do paciente, são responsáveis por captar variações de tensão elétrica. Normalmente feitos de metais condutores;
- Amplificadores: sinais de EEG captados no cérebro humano são muito fracos, dificultando sua aquisição. Para isso, são usados amplificadores de sinal;
- Filtros: devido à variação da frequência, tanto de ondas como α e β , quanto de ruídos e interferências indesejadas, o uso de filtros para eliminar sinais fora de uma certa faixa desejada se torna de extrema importância;

- Conversores ADC: após as etapas de aquisição, amplificação e filtragem dos sinais, são utilizados conversores analógico-digitais para converter o sinal, antes analógico, em sinal digital para que ele possa ser processado e interpretado de forma adequada por um computador.

2.2 Regiões do cérebro e suas funções

O cérebro humano é dividido em diversas regiões, como pode ser visto na Figura 5, sendo cada região responsável por desempenhar papéis específicos em um ser humano. O lobo frontal está relacionado com a tomada de decisões, a regulação emocional e a personalidade. O lobo temporal, com a memória, a emoção, o reconhecimento facial e o processamento auditivo. O lobo parietal, por sua vez, desempenha papéis relativos à orientação e percepção espacial e à integração sensorial. Já o lobo occipital é dedicado ao processamento visual, permitindo a percepção de cores, formas, movimentos e profundidade. Crucial para a coordenação motora, equilíbrio, controle muscular fino e aprendizado motor, o cerebelo está localizado em uma região mais interna do cérebro, o que dificulta a medição da atividade cerebral em exames de EEG convencionais.

Por fim, os dois córtices estão localizados na região central do cérebro. O córtex motor é responsável pelo controle de movimentos voluntários do corpo humano, estando envolvido no planejamento e execução de movimentos musculares. O córtex somatossensorial está envolvido na percepção e interpretação das sensações táteis e sensoriais do corpo.



Fonte: NIH (2023)

2.3 Esquizofrenia e aplicação de EEG

Cada movimento feito por um animal é precedido por uma cópia eferente (*efferece copy*) do seu plano de movimento. A cópia eferente do plano motor é enviada ao córtex sensorial, gerando um efeito de descarga corolária (*corarally discharge*) da consequência sensorial esperada do ato motor. Durante um movimento, as sensações esperadas resultantes desse movimento são efetivamente subtraídas das sensações reais, resultando em uma “supressão de rede” (*net supression*). Quanto maior a correspondência entre as sensações esperadas e as sensações experimentadas, maior é a supressão da resposta. Assim, a cópia eferente e a descarga corolária formam as partes funcionais de um sistema motor-sensorial de previsão, em que as consequências das ações motoras são processadas de forma eficiente e econômica. Esses sistemas são essenciais para a sobrevivência, pois erros na previsão são custosos. (FORD *et al.*, 2014)

Durante alguma ação, como a fala, pessoas com esquizofrenia apresentam menos evidências de atividade prévia à ação e menos supressão do som gerado, o que é consistente com a disfunção da cópia eferente e da descarga corolária, respectivamente. Através de exames de EEG durante certa atividade, é possível fazer medições da atividade cerebral responsável por tais mecanismos e traçar vínculos com a presença do transtorno. Como não existe um diagnóstico direto para a esquizofrenia, essa pode ser uma forma de avaliar a presença do distúrbio em pacientes de uma maneira muito eficiente, contribuindo para o diagnóstico final.

2.4 Inteligência Artificial

O termo “Inteligência Artificial” foi introduzido pela primeira vez em 1956, durante uma conferência de verão realizada na Faculdade de Dartmouth, nos Estados Unidos. Nela, um grupo de pesquisadores e cientistas se reuniu com o objetivo de explorar a possibilidade de criar máquinas capazes de exibir comportamento inteligente. Dentre os estudiosos que participaram da reunião, estava John McCarthy, um dos autores do artigo MCCARTHY *et al.* (2006), no qual o termo é citado. Ele foi utilizado para descrever o campo de estudo que buscava desenvolver programas de computador capazes de realizar tarefas que requerem inteligência humana. Essas tarefas incluíam raciocínio, aprendizado, resolução de problemas e processamento de linguagem natural, entre outras.

O trecho a seguir, presente no artigo original de 1955, descreve o objetivo principal do encontro:

O estudo deve prosseguir com base na suposição de que cada aspecto do aprendizado ou qualquer outra característica da inteligência pode, em princípio, ser descrito tão precisamente que uma máquina possa ser feita para simulá-lo. Será feita uma tentativa de descobrir como fazer as máquinas utilizarem linguagem, formarem abstrações e conceitos, resolverem tipos de problemas atualmente reservados aos humanos e se aprimorarem.

Historicamente, porém, pesquisadores apresentaram diversas versões diferentes para o significado de IA. Alguns definem a inteligência em termos de fidelidade com comportamentos humanos, enquanto outros defendem uma definição mais formal, a racionalidade - fazer as coisas da “maneira certa”. Além disso, o processo pode se dar de duas formas distintas: através do ato de pensar ou de agir. Da combinação de **humano x racional** e **pensamento x comportamento**, temos 4 possíveis combinações:

- agir humanamente;
- pensar humanamente;
- pensar racionalmente;
- agir racionalmente.

A partir de cada uma dessas 4 possibilidades, é possível classificar o complexo mundo da IA em conjuntos e subconjuntos. Segundo RUSSELL; NORVIG (2021), o campo da IA pode ser praticamente todo dividido em 6 grandes áreas, sendo elas:

- Processamento de linguagem natural (NLP);
- Representação de conhecimento;
- Raciocínio automatizado;
- Aprendizado de máquina (ML);
- Visão computacional;
- Robótica.

Para agir humanamente, uma máquina deve ser capaz de se adaptar a novas (e as vezes inesperadas) circunstâncias e detectar e extrapolar padrões. Para isso, surge o conceito de Aprendizado de Máquina, uma das grandes áreas citadas por Stuart Russell e Peter Norvig.

2.5 Aprendizado de Máquina

O Aprendizado de Máquina é um ramo da Inteligência Artificial que concentra-se no uso de dados e algoritmos para imitar a maneira como os humanos aprendem. Baseado na experiência, estuda a habilidade de melhorar sua performance. De acordo com RUSSELL; NORVIG (2021), chamamos de Aprendizado de Máquina o contexto no qual o agente é um computador. Esse computador pode observar dados, criar um modelo baseado nesses dados e usar esse modelo tanto como uma hipótese sobre o mundo quanto como um *software* que pode resolver problemas.

Existem 3 tipos principais de Aprendizados de Máquina, que são determinados pela forma que o *feedback* acompanha os *inputs*:

- **Aprendizado Supervisionado:** utiliza conjuntos de dados rotulados para treinar algoritmos para classificar novos dados ou prever resultados com precisão. Necessita da interação humana através do fornecimento dos dados que farão o treinamento da máquina. Exemplos de métodos que utilizam Aprendizado Supervisionado são Árvores de Decisão, Floresta Aleatória, Redes Neurais, Máquina de Vetores de Suporte e *Gradient Boosting*;
- **Aprendizado Não Supervisionado:** para esse aprendizado, a máquina deve aprender padrões na entrada sem nenhum *feedback* explícito. Através de algoritmos, ela analisa e agrupa conjuntos de dados não rotulados, descobrindo padrões ocultos ou agrupamentos de dados sem a necessidade de intervenção humana. Alguns exemplos são Agrupamento *k-means* e Redes Adversárias Generativas (GAN's).
- **Aprendizado por Reforço:** modelo de aprendizado semelhante ao Aprendizado Supervisionado, o Aprendizado por Reforço baseia seu treinamento em tentativa e erro, e não através de conjuntos de dados rotulados. Através de recompensas, resultados positivos recebem um reforço para atingir o melhor algoritmo que resolva

dado problema. Da mesma forma, resultados negativos recebem uma punição, demonstrando para o algoritmo que aquela solução não foi bem aceita. Métodos que aplicam esse tipo de aprendizado são: Aprendizagem-Q (*Q-Learning*) e Processo de Decisão de Markov (*Markov Decision Process*).

Cada um dos 3 tipos citados acima, bem como cada método aplicado de cada tipo, possui uma melhor eficácia para diferentes problemas. Nesse trabalho, alguns métodos de Aprendizado Supervisionado serão trabalhados.

2.5.1 Métodos

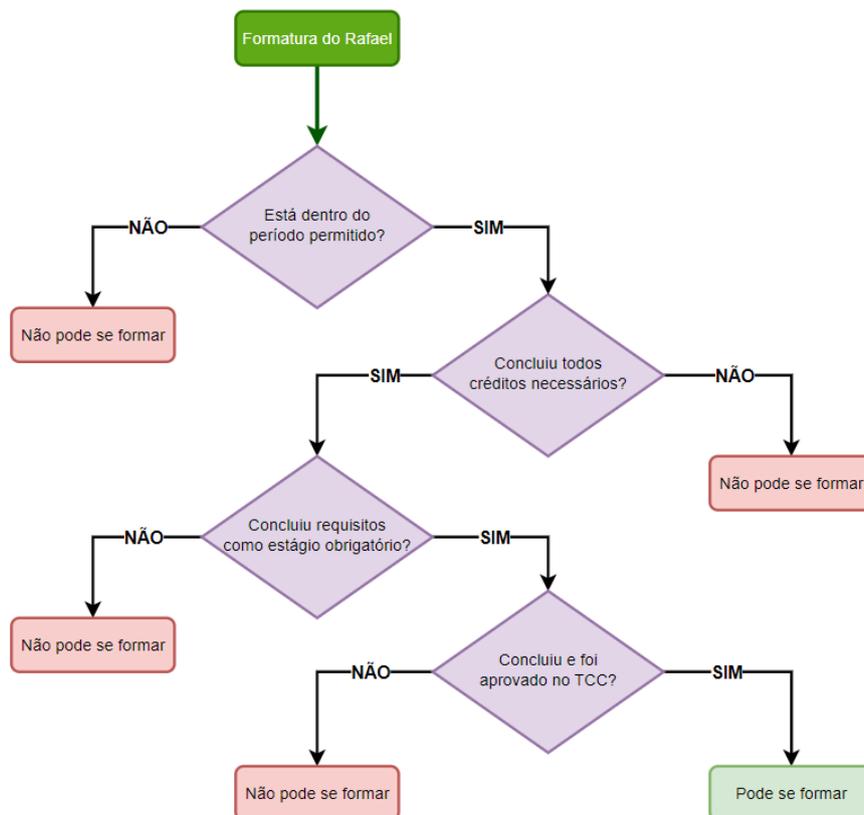
2.5.1.1 Árvore de Decisão

Árvore de Decisão (*Decision Tree* ou DT) é um método de aprendizado de máquina supervisionado que se destaca por sua simplicidade, porém com uma ótima eficácia em diversos casos. Esse método é classificado como um algoritmo explicável (também conhecido como *Explainable Artificial Intelligence* (X-AI) ou modelo de caixa branca), pois é possível verificar as condições utilizadas para tomar cada decisão e como será feita uma nova previsão. As Árvores de Decisão podem ser empregadas tanto em problemas de regressão, nos quais a saída é um valor numérico, quanto de classificação, onde temos classes definidas de saída. Sua versatilidade e transparência tornam-as uma escolha popular em diversas aplicações.

Um exemplo de uma Árvore de Decisão pode ser visto na Figura 6. Ela é composta por diversos blocos, denominados de nós. Um nó pode ser raiz, pai, filho ou folha, dependendo de sua posição em relação aos demais nós. O nó-raiz, como o nome presume, é o nó inicial de uma árvore, de onde toda ramificação começa. Existe apenas 1 nó-raiz em uma DT, os demais nós serão sempre nó-pai, nó-filho ou nó-folha. Quando um nó possui uma ramificação abaixo de si, ele é denominado de nó-pai, e os nós abaixo viram nós-filhos. Caso o nó-filho não tenha nenhum outro nó abaixo, passa a ser chamado de nó-folha ou nó-terminal.

A profundidade de uma árvore é calculada a partir do caminho mais longo do nó-raiz para um nó-folha. No caso abaixo, a profundidade da árvore é 4, pois temos 3 nós-pais em uma mesma ramificação, além dos últimos nós-folhas. Os nós-folhas são os blocos em vermelho e verde, que representam o final da árvore para cada respectiva ramificação.

Figura 6 – Exemplo de uma árvore de decisão.



Fonte: do Autor

Quando uma nova entrada é inserida em uma árvore, ela irá percorrer cada nó, indo para a ramificação adequada, até chegar em um nó-folha. Esse nó terminal vai representar qual é a saída para a entrada, podendo ser um valor numérico ou uma classe. O desempenho então pode ser medido comparando os resultados obtidos de saída para cada entrada com os valores reais de saída.

Existem algumas formas para otimizar o desempenho de uma Árvore de Decisão. Uma técnica muito utilizada é a técnica de poda (*pruning*), onde são removidas partes da árvore que não afetem negativamente o resultado final, de acordo com o objetivo pretendido. A poda em Árvores de Decisão é especialmente importante, devido a sua grande tendência de sobreajuste (*overfitting*) dos dados, fenômeno esse que ocorre quando um modelo consegue um desempenho muito bom apenas para um conjunto específico de dados, não conseguindo uma boa generalização para novas entradas.

A poda pode ser dividida em duas partes: a pré-poda (*pre-pruning*), onde existem alguns parâmetros definidos para a árvore antes mesmo de ela ser gerada de fato, e a pós-poda (*post-pruning*), onde são removidas partes da árvore depois de sua criação.

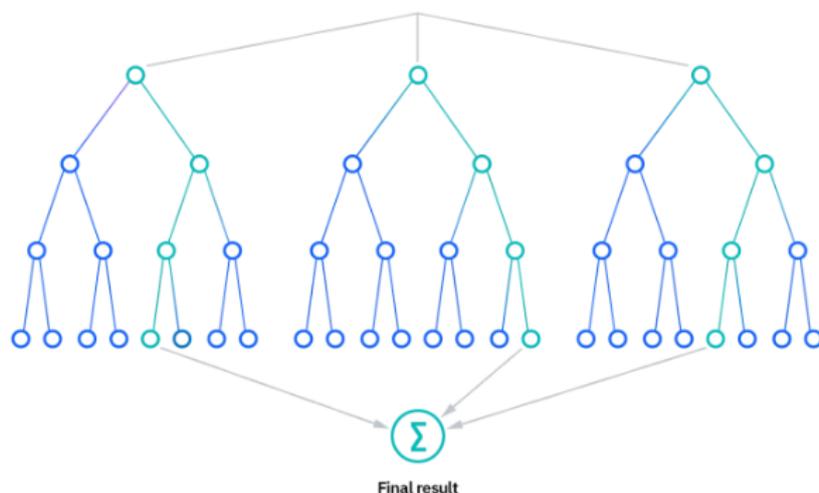
2.5.1.2 Floresta Aleatória

Idealizado por BREIMAN (2001), o método Floresta Aleatória (*Random Forest* ou RF) é basicamente um conjunto de árvores de decisão que formam um único modelo. De acordo com Leo Breiman, florestas aleatórias são uma combinação de preditores de árvores de decisão, de modo que cada árvore depende dos valores de um vetor aleatório amostrado independentemente e com a mesma distribuição para todas as árvores na floresta. O erro de generalização para florestas aleatórias converge quase certamente para um limite à medida que o número de árvores na floresta se torna grande, dependendo também da força de cada árvore individualmente e a da correlação entre elas.

Embora as árvores de decisão sejam algoritmos de aprendizado supervisionados comuns, elas podem estar propensas a problemas, como viés e sobreajuste (*overfitting*). No entanto, quando várias árvores de decisão formam uma combinação no algoritmo de floresta aleatória, elas preveem resultados mais precisos, principalmente quando as árvores individuais não estão correlacionadas entre si. (IBM, 2020a)

A Figura 7 apresenta uma floresta composta por 3 árvores, que podem ser distinguidas facilmente. Para uma tarefa de regressão, as árvores de decisão individuais terão suas médias calculadas, e, para uma tarefa de classificação, a variável categórica mais frequente produzirá a classe prevista.

Figura 7 – Exemplo de uma floresta aleatória.



Fonte: IBM (2020a)

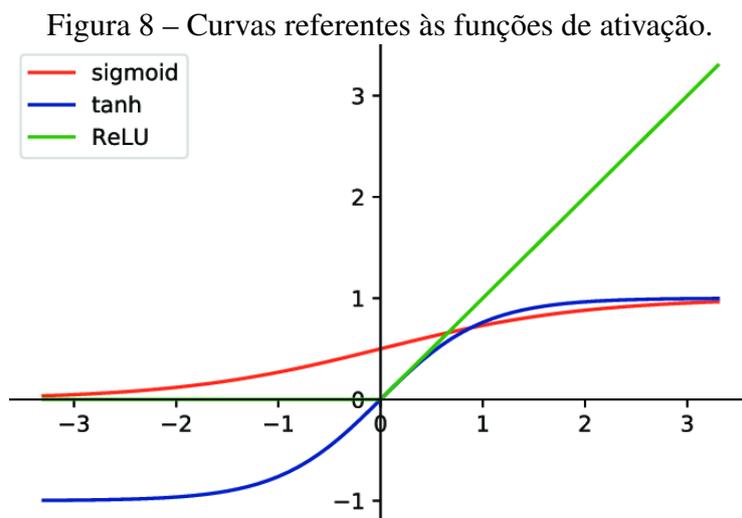
2.5.1.3 Rede Neural Artificial

A Rede Neural Artificial (*Artificial Neural Network* ou ANN) é um método de aprendizado supervisionado inspirado no funcionamento de neurônios biológicos presentes no corpo humano. Diferente das Árvores de Decisão, essas redes são consideradas modelos de caixa preta, onde é muito complexa a verificação do que levou o método a dada saída e de como será feita uma nova previsão.

Uma rede neural clássica, baseada no *perceptron* (ROSENBLATT, 1958), é composta de uma camada de entrada, uma ou mais camadas ocultas e uma camada de saída (caso seja uma rede de camada única, não existem camadas ocultas). A camada de entrada é composta pelas entradas da rede, com suas ligações para a próxima camada. As camadas ocultas e a camada de saída possuem neurônios em seu interior, que são as unidades de processamento da rede. Esse neurônio é composto por três partes: as sinapses, o somador e a função de ativação. As sinapses são ligações entre camadas ou neurônios. Cada ligação possui um peso que é modificado ao longo de treinamento visando diminuir o erro e melhorar o desempenho da rede. O somador, como seu nome sugere, soma as sinapses ponderadas pelos seus pesos e um viés interno. A função de ativação é a função responsável por decidir se um neurônio deve ou não ser ativado. Normalmente, essa função é não linear para os neurônios das camadas ocultas e linear para as camadas de saída, e tem como entrada a saída do somador. Existem diversas funções de ativação distintas, como a Sigmoides, Tangente-Hiperbólica e a Unidade Linear Retificada (*Rectified Linear Unit - ReLu*), como mostra a Figura 8. O eixo x representa a entrada da função de ativação e o eixo y representa a saída do neurônio.

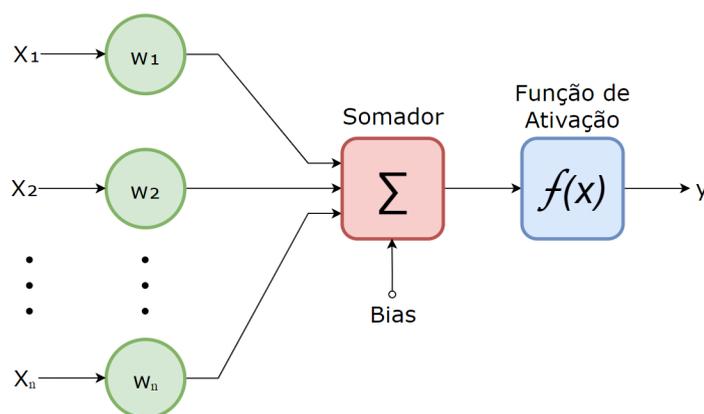
Uma representação de um neurônio dentro de uma rede pode ser visto na Figura 9. Para n entradas x , há um peso w referente. O bloco somador recebe todas essas entradas já ponderadas e adiciona um bias para cada uma, antes de aplicar em uma função de ativação $f(x)$ para obter o valor de saída y do neurônio. Para calcular o valor dessa saída, pode-se aplicar a Equação 1, na qual o somatório das entradas ponderadas mais o viés (*bias*) é aplicado à função de ativação escolhida.

$$y = f\left(\sum_{i=1}^n x_i w_i + bias\right) \quad (1)$$



Fonte: GAO *et al.* (2019)

Figura 9 – Modelo de um neurônio.



Fonte: do Autor

O estudo da arquitetura de redes neurais teve alguns momentos marcantes ao longo de sua história. Um deles ocorreu em 1969, com a publicação do livro intitulado *Perceptrons: An Introduction to Computational Geometry* (MINSKY; PAPERT, 1969), de autoria de Marvin Minsky e Seymour Papert, dois cientistas norte-americanos e estudiosos de redes neurais. Nessa publicação, eles mostraram que um *perceptron* de camada única não conseguia resolver problemas não linearmente separáveis, como o caso da função lógica XOR, fato que causou um sentimento negativo entre os cientistas que estudavam a temática na época.

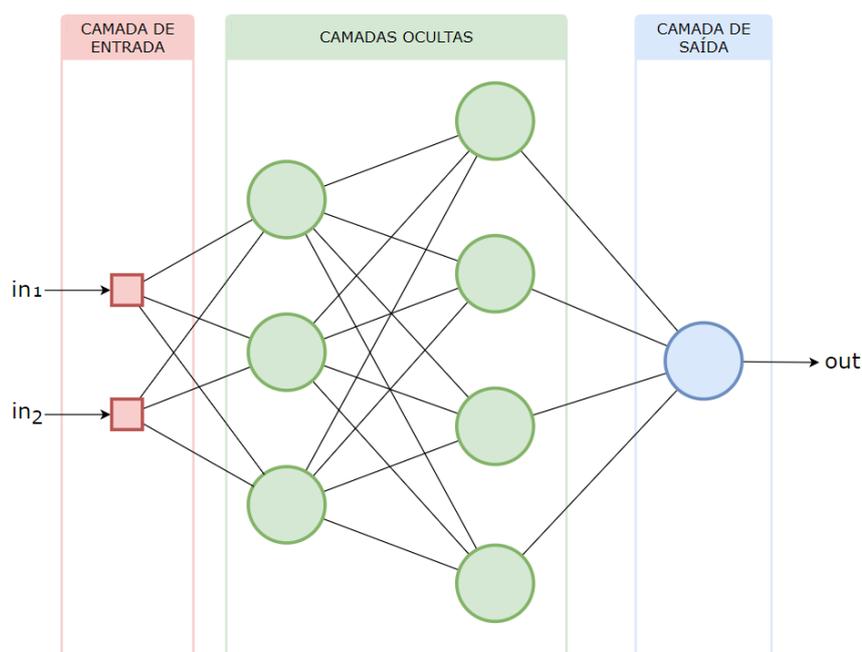
Outro acontecimento, muito decisivo para o avanço na área, ocorreu menos de duas décadas depois. Em 1985, o algoritmo *backpropagation* (RUMELHART *et al.*, 1985) é apresentado, reascendendo um grande interesse em redes neurais. Esse algoritmo conse-

guia, de forma muito eficiente computacionalmente, encontrar pesos para os neurônios dentro das redes, ajudando a resolver problemas de otimização. Através dos erros encontrados para uma dada saída, os valores dos pesos para neurônios de camadas ocultas podem ser atualizados utilizando *backpropagation*. O algoritmo é composto por 2 fases:

1. Fase *Forward*: nessa primeira fase, o efeito das entradas se propagam pela rede até a saída, com os pesos fixos durante esse processo;
2. Fase *Backward*: aqui, como o nome sugere, ocorre o caminho inverso. A partir do erro da rede na saída, ele é propagado para trás até os neurônios da camada de entrada e das camadas ocultas, tendo seus pesos atualizados.

A Figura 10 apresenta um modelo de rede neural artificial composto por 4 camadas: a camada de entrada, que possui 2 entradas; 2 camadas ocultas, contendo 3 e 4 neurônios respectivamente; e a camada de saída, formada por 1 neurônio. Essa rede neural pode ser descrita pela notação 2-3-4-1. O uso dessa notação em redes mais complexas facilita o entendimento, pois o diagrama pode ficar muito complicado.

Figura 10 – Modelo de uma rede neural artificial.



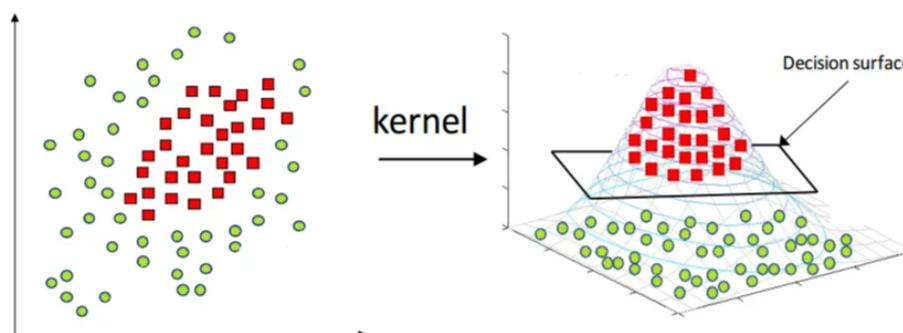
Fonte: do Autor

2.5.1.4 Máquina de Vetores de Suporte

Máquina de Vetores de Suporte (*Support Vector Machine* ou SVM) é um método de aprendizado supervisionado utilizado tanto para problemas de regressão quanto de classificação. Busca, através de um hiperplano (superfície ou espaço vetorial de dimensão $n - 1$, sendo n a dimensão do espaço em questão), dividir em grupos as classes de saída ou valores, para casos de regressão.

Na sua forma original, consegue resolver apenas problemas que sejam linearmente separáveis. Porém, aplicando o conceito de *kernel*, é possível resolver também casos não linearmente separáveis. A técnica de *kernel* consiste em realizar uma transformação não linear do espaço, como pode ser visto no exemplo da Figura 11, de forma a possibilitar a divisão das entradas com um hiperplano. Esse hiperplano é escolhido de forma que maximize a margem entre as duas classes, ou seja, a maior distância possível entre o hiperplano e os pontos de cada classe. Os vetores de suporte representam o vetor entre o hiperplano e cada ponto de entrada.

Figura 11 – Exemplo do funcionamento da técnica de *kernel*.



Fonte: ZHANG (2018)

O SVM é bastante eficiente em conjuntos de dados de alta dimensionalidade, o que o torna útil em muitas aplicações do mundo real, como reconhecimento de padrões, processamento de imagens, bioinformática e aplicações biomédicas. Também, por realizar otimização a partir dos vetores de suporte, não sofre muita influência de pequenos ruídos nos dados de entrada. Entretanto, assim como a rede neural artificial, é considerado um modelo de caixa preta, o que dificulta a interpretação e visualização do que está ocorrendo.

2.5.2 Hiperparâmetros

São denominados hiperparâmetros os atributos de um modelo de aprendizado de máquina que podem ser definidos por quem está construindo uma topologia, sendo responsáveis por controlar de que forma o treinamento será realizado. A definição de hiperparâmetros na construção de um modelo é de extrema importância. Uma boa escolha desses atributos pode aumentar muito a eficácia na generalização de um algoritmo de ML. Em contrapartida, uma escolha inadequada pode levar o modelo ao *overfitting*, impossibilitando sua correta aplicação.

Em árvores de decisão, podem ser definidas a quantidade de nós-folhas e a profundidade da árvore. Quantas árvores de decisão irão compor uma floresta aleatória é um hiperparâmetro desse modelo. Em redes neurais artificiais, a quantidade de camadas ocultas e quantos neurônios irão estar presentes em cada camada podem ser escolhidos. Por fim, em Máquina de Vetores de Suporte, o tipo do *kernel* utilizado pode ser escolhido através da definição de hiperparâmetros. Todas essas configurações de um modelo visam otimizar o desempenho da topologia, seja através da taxa de acerto ou do custo de processamento.

2.6 Seleção de atributos

Etapa muito importante no aprendizado de máquina, a seleção de atributos (*features*) consiste no processo da escolha de um subconjunto relevante, informativo e representativo de características, a partir do conjunto de dados original, para treinar um modelo preditivo.

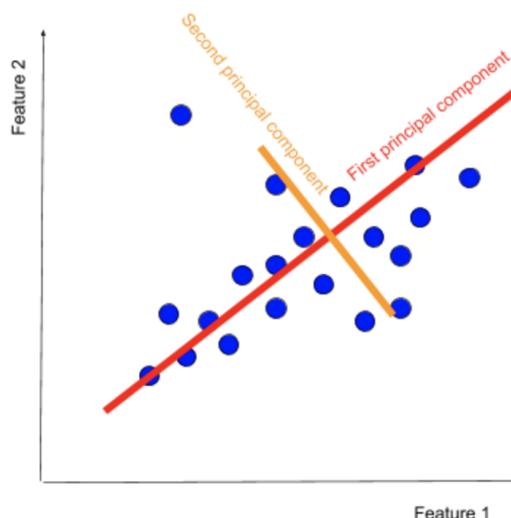
Principalmente em *datasets* extensos, nem todos os dados são necessários para um bom treinamento do modelo. Alguns desses dados, além de não contribuírem positivamente para o resultado final, podem inclusive prejudicar o desempenho do método. Com isso, a etapa de seleção de atributos se torna necessária, podendo ter outros benefícios como a redução no custo computacional e a melhora na interpretabilidade do modelo.

Existem diversas técnicas para realizar essa seleção. Dependendo do tipo de dado, da quantidade e de outros fatores, uma técnica é aconselhada em detrimento de outra. Pode-se, inclusive, aplicar múltiplas técnicas em cima do mesmo conjunto de dados, sempre tendo cuidado com fatores indesejados, como queda de desempenho e *overfitting*.

2.6.1 Análise de Componentes Principais

Análise de Componentes Principais (*Principal Component Analysis* ou PCA) é uma das técnicas mais utilizadas em ML para redução de dimensionalidade e identificação de padrões de um conjunto de dados. Através de combinações lineares, o PCA busca componentes principais (vetores) que representem as maiores variações nas características originais dos dados, como pode ser visto na Figura 12. O primeiro componente principal é definido como o componente que mais capturou essa variação. O segundo, a segunda variação, e assim por diante. O objetivo é encontrar um conjunto menor de dimensões que ainda explique a maior parte da variabilidade presente nos dados originais.

Figura 12 – Esquema da aplicação do PCA.



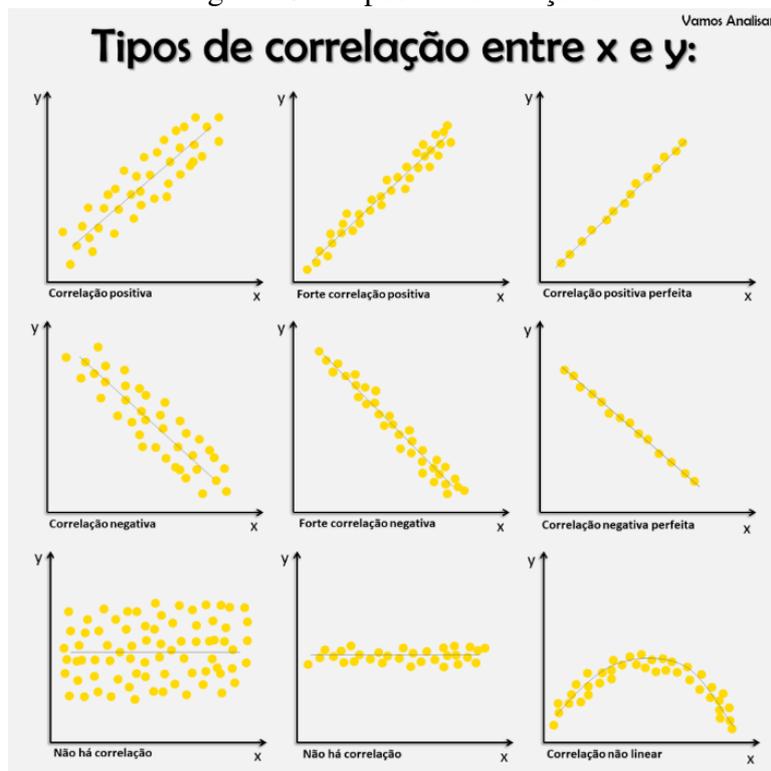
Fonte: KEBOOLA (2022)

2.6.2 Coeficiente de correlação

O coeficiente de correlação é uma medida numérica que quantifica a intensidade e a direção da relação linear entre duas variáveis em um conjunto de dados. É uma métrica importante na análise de correlação entre variáveis, sendo muito utilizada principalmente pela sua facilidade de visualização, podendo ser através de gráficos de dispersão como os mostrados na Figura 13.

O coeficiente de correlação varia entre -1 e 1. Quanto maior for esse valor, em módulo, maior será o grau de relação linear entre as variáveis, podendo representar uma correlação positiva forte (próximo de 1) ou negativa forte (próximo de -1). Valores próximos de 0 representam uma correlação fraca.

Figura 13 – Tipos de correlações.



Fonte: ANALISAR (2019)

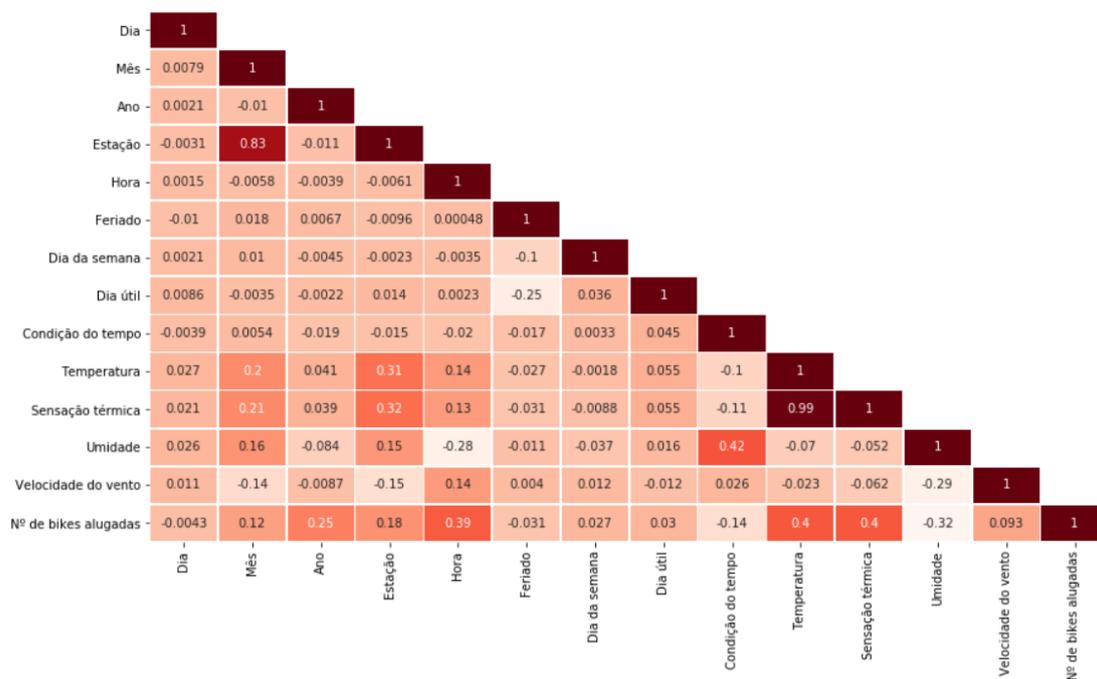
A aplicação de um mapa de calor (*heatmap*), como o apresentado na Figura 14, traz uma visualização importante na seleção de atributos principalmente em problemas com grande número de entradas numéricas. Nesse caso, é feito um estudo sobre a quantidade de bicicletas alugadas em uma cidade da Europa. Podemos tirar diversas conclusões desse mapa, reduzindo a quantidade de dados a serem treinados durante o aprendizado de máquina.

É importante ressaltar, porém, que o coeficiente de correlação mede apenas a relação linear entre as variáveis, não capturando outras formas de associação, como relações não lineares ou causais. Com isso, nem sempre pode-se aplicar essa técnica de forma isolada, pois poderia trazer resultados indesejados ao sistema.

2.7 Análise de desempenho

A eficiência de um modelo de aprendizado de máquina depende do seu desempenho. Para poder avaliar esse desempenho de um modelo treinado, são utilizadas diversas métricas diferentes, que variam de acordo com o tipo de problema e o objetivo do aprendizado de máquina. A correta escolha da métrica a ser utilizada é de suma importância.

Figura 14 – Heatmap da correlação entre variáveis.



Fonte: do Autor

Em casos com dados desbalanceados, no qual há uma ocorrência muito maior de uma classe de saída em relação à outra, a escolha de uma métrica inadequada poderia apresentar um ótimo desempenho para um modelo que só conseguiu prever bem uma das possíveis saídas, circunstância que não é desejada.

2.7.1 Matriz de confusão

A matriz de confusão é uma tabela $n \times n$ que apresenta uma visualização dos resultados obtidos através da predição do método e dos valores reais. Para um caso onde as possíveis saídas são Verdadeiro (V) ou Falso (F), a matriz de confusão é representada na Equação 2, na qual os casos Verdadeiro Positivo (VP), Falso Positivo (FP), Falso Negativo (FN) e Verdadeiro Negativo (VN) compõem a matriz:

$$M = \begin{bmatrix} VP & FN \\ FP & VN \end{bmatrix} \quad (2)$$

Os resultados apresentados após o teste do modelo são inseridos nessa matriz na posição adequada. Caso a predição tenha dado Falso e o valor real fosse também Falso, esse caso seria um VN. Se o valor real fosse Verdadeiro, seria um FN. Dessa matriz preenchida, diversas métricas podem ser aplicadas.

2.7.2 Métricas

2.7.2.1 Accuracy

A *accuracy*¹, ou taxa de acerto, é uma das métricas mais comumente utilizadas, e representa simplesmente a taxa de acerto do modelo dentre as previsões feitas. O resultado é calculado pela soma dos resultados verdadeiros, dividido pelo total, como visto na Equação 3.

$$accuracy = \frac{VP + VN}{VP + VN + FP + FN} \quad (3)$$

Um ponto negativo dessa métrica é a possibilidade de apresentar resultados ilusórios se os dados estiverem desbalanceados. Caso a quantidade de dados de uma classe de saída seja predominante para o conjunto, e se apenas para essa classe de saída majoritária o modelo estiver tendo um ótimo desempenho, a *accuracy* poderia chegar a valores próximos de 100%, pois o numerador da equação se aproximaria do valor do denominador. Mas, na realidade, o modelo não estaria tendo um desempenho ideal, pois só conseguiria prever uma classe.

2.7.2.2 Precision e recall

As métricas de *precision*¹ e *recall*¹ se comportam melhor para avaliar problemas de desequilíbrio de classes (FOR DEVELOPERS, 2019), pois não colocam o mesmo peso para as diversas classes de saída.

A *precision* busca responder qual a proporção de previsões positivas estava correta, através da Equação 4. Já o *recall* responde qual proporção de Verdadeiros Positivos (VP) foi identificada corretamente, sendo calculado através da Equação 5.

$$precision = \frac{VP}{VP + FP} \quad (4)$$

$$recall = \frac{VP}{VP + FN} \quad (5)$$

¹Em aplicações de inteligência artificial, frequentemente os termos Accuracy, Recall e Precision são traduzidos para Acurácia, Sensibilidade e Precisão, respectivamente. No entanto, os termos traduzidos não estão de acordo com o VIM (Vocabulário Internacional de Metrologia), sendo optado pelo uso dos termos na língua inglesa.

2.7.2.3 *F1-Score*

O *F1-Score* faz um balanço entre as métricas de *precision* e *recall*. Para avaliar de fato a eficácia de um modelo, é importante aplicar essa abordagem, que realiza uma média harmônica entre as 2 métricas, como pode ser visto na Equação 6. Sendo assim, o resultado é dominado pela métrica com pior desempenho entre as duas (GOODFELLOW; BENGIO; COURVILLE, 2016).

$$f1_score = 2 \times \frac{precision \times recall}{precision + recall} \quad (6)$$

2.8 Trabalhos Relacionados e Estado da Arte

Essa seção traz uma análise sobre alguns trabalhos relacionados aos temas abordados nessa monografia, sendo dividida em 2 subseções: a 2.8.1, onde é analisado o Estado da Arte do aprendizado de máquina em aplicações médicas e resultados obtidos em temática diferente da esquizofrenia, e a 2.8.2, na qual o foco são trabalhos sobre esse transtorno, desde dados clínicos até aplicações de métodos de ML.

2.8.1 Estado da Arte e uso de ML na medicina

O crescimento da Inteligência Artificial está estimulando o uso de métodos de aprendizado de máquina em diversas áreas da medicina. Um entendimento sobre o Estado da Arte desses métodos em aplicações médicas se torna muito importante na exploração de novas utilizações.

Topologias aplicando Redes Neurais, Árvores de Decisão, Floresta Aleatória e Máquina de Vetores de Suporte são muito utilizadas na pesquisa sobre o câncer, como relata o estudo SHEHAB *et al.* (2022), que analisou dados de mais de 200 artigos científicos e trouxe uma revisão do Estado da Arte de métodos de ML em aplicações médicas. Para estudos do cérebro, métodos de aprendizado supervisionados também são recomendados, porém com a sugestão de aplicar estratégias de pré-processamento, como extração de características, e utilizar técnicas de IA em conjunto, de forma a ajudar no rastreamento adequado das regiões de interesse (ROI). Na área de química médica, métodos de ML foram utilizados para alcançar resultados satisfatórios, com a aplicação de técnicas como Support Vector Machine (SVM) e Rede Neural Profunda (DNN). Pode-se concluir que os métodos de aprendizado supervisionado são amplamente utilizados na área médica para

auxiliar a resolver desafios complexos, sendo considerados como importantes ferramentas de pesquisa.

O livro *Artificial Intelligence: A Modern Approach* (RUSSELL; NORVIG, 2021) traz um importante trecho (adaptado) sobre o Estado da Arte de IA na medicina:

Algoritmos de Inteligência Artificial agora igualam ou superam médicos especialistas no diagnóstico de muitas doenças, especialmente quando o diagnóstico é baseado em imagens. (...) Uma revisão sistemática e meta-análise (LIU *et al.*, 2019) constatou que o desempenho dos programas de IA, em média, foi equivalente aos dos profissionais de saúde. Um dos atuais destaques na IA médica é a facilitação de parcerias humano-máquina. Por exemplo, o sistema LYNA alcança uma *precision* geral de 99,6% no diagnóstico de câncer de mama metastático (melhor do que um especialista humano sem assistência), mas a combinação de ambos é ainda melhor (LIU *et al.* (2018); STEINER *et al.* (2018)). A adoção generalizada dessas técnicas agora é limitada não pela precisão do diagnóstico, mas pela necessidade de demonstrar melhoria nos resultados clínicos e garantir transparência, falta de viés e privacidade dos dados (TOPOL, 2019). Em 2017, apenas duas aplicações médicas de IA foram aprovadas pela FDA (*Food and Drug Administration*, uma agência federal do Departamento de Saúde e Serviços Humanos dos Estados Unidos), mas esse número aumentou para 12 em 2018 e continua a crescer.

É possível atingir resultados satisfatórios na decodificação e visualização de sinais de EEG aplicando Rede Neural Convolutacional com *Deep Learning*, subconjunto de *Machine Learning* (IBM, 2020b), como mostra o artigo SCHIRRMEISTER *et al.* (2017). Após testes realizados em diversas arquiteturas de redes neurais diferentes e aplicando estratégias para otimizar o desempenho, como normalização em lote e uso de funções de ativação através da Unidade Linear Exponencial (ELU, CLEVERT; UNTERTHINER; HOCHREITER (2015)), foi possível atingir uma *precision* de 84%, valor considerado pelo estudo tão bom quanto, ou até melhor, que outros métodos, como o algoritmo *Filter Bank Common Spatial Pattern*, que chegou a uma *precision* de 82,1%.

2.8.2 Esquizofrenia e aplicação de ML no estudo do transtorno

Uma revisão bibliográfica de diversos tópicos relacionados à esquizofrenia, como causas, sintomas, tratamentos e possíveis formas de prevenção do transtorno, é feita no artigo SILVA *et al.* (2016).

O estudo foi desenvolvido com base em 22 artigos publicados que cumpriram os seguintes critérios:

- artigos publicados em português;
- artigos e obras literárias publicadas entre 1998 e 2015;
- artigos que dispunham de texto completo;
- artigos que discorriam sobre o tema: Esquizofrenia.

A respeito do diagnóstico, a conclusão de todos os autores que aprofundam o tema em seus trabalhos foi que o diagnóstico precoce da esquizofrenia é fundamental para um tratamento eficaz. Quanto mais cedo o distúrbio for diagnosticado, maiores serão as chances de sucesso no tratamento e na redução dos efeitos negativos na qualidade de vida do paciente.

Resultados surpreendentes podem ser obtidos aplicando métodos de ML no diagnóstico de esquizofrenia através de imagens por ressonância magnética (MRI). Uma revisão sistemática sobre o tema, que incluiu, inicialmente, 2386 artigos, é apresentada no artigo DE FILIPPIS *et al.* (2019). Após uma série de critérios e validações, esse estudo reduziu para apenas 35 artigos, dos quais 26 usaram técnicas de neuroimagem funcional, 8 usaram técnicas de neuroimagem estrutural e 1 usou ambas. A partir disso, pode-se concluir que o método Máquina de Vetores de Suporte foi o mais frequente, atingindo *precision* próxima a 100% se associado a outras técnicas de ML. Sobre os exames de imagens, as regiões cerebrais do córtex pré-frontal e temporal demonstram ser as mais úteis para o diagnóstico da esquizofrenia. O artigo concluiu que a alta precisão demonstrada por esses modelos preditivos e os novos modelos resultantes da integração de múltiplas técnicas de ML serão cada vez mais decisivos para o diagnóstico precoce e avaliação da resposta ao tratamento e para estabelecer o prognóstico de pacientes com esquizofrenia.

O método de aprendizado de máquina denominado Aprendizado de Vários Kernels (do inglês, *Multiple Kernel Learning* ou MKL) pode ser utilizado para realizar a detecção

de esquizofrenia através de dados obtidos por exame de MRI, como relata o artigo ULAS *et al.* (2012). O conjunto de dados utilizado no estudo era composto por dados de 100 pessoas, sendo que 50 delas estavam em tratamento de esquizofrenia e outras 50 eram consideradas “saudáveis”, e não tinham nenhum indício de transtornos mentais. O estudo conseguiu classificadores mais otimizados utilizando MKL do que Máquina de Vetores de Suporte, alcançando uma diferença de 7% na *precision* entre os dois métodos. Foi possível atingir valores acima de 80% de *accuracy* para o conjunto de dados utilizado aplicando apenas um único método de aprendizado de máquina, o MKL.

Uma diferente abordagem no caso da utilização de ML para diagnóstico de esquizofrenia é tentar afirmar, com certa precisão, que dado paciente não possui o transtorno, sem necessariamente prever o contrário (presença da esquizofrenia). Essa abordagem pode ser útil quando se procura isentar alguém do transtorno (da Matriz de Confusão, os casos de Verdadeiro Negativo e Falso Negativo), não sendo ideal para diagnosticar de fato a presença de esquizofrenia (casos Falso Positivo e Verdadeiro Positivo). O artigo SCHLOSSER *et al.* (2019) utiliza um *dataset* com dados de 28 pessoas, 14 delas com esquizofrenia e 14 chamadas de controles saudáveis, ou seja, que não possuem nenhum indício do transtorno. O artigo aplica Floresta Aleatória com validação cruzada *10-fold*, com o modelo de ML passando ainda por um pré-processamento de 3 etapas: Análise de Componentes Independentes (ICA), análise espectral utilizando o método de banda de 99 frequências (RIEG *et al.*, 2019) e, por fim, normalização. Com isso, a *precision* alcançada foi de incríveis 100% para a exclusão da esquizofrenia. Aplicando esse modelo em combinação com diagnósticos diferenciados, os tratamentos em UTI's podem ser feitos com mais rapidez, maior precisão e custo reduzido.

Por fim, a mesma base de dados utilizada na presente monografia foi aplicada através de um classificador baseado no algoritmo Floresta Aleatória, sendo aplicado em diferentes combinações de conjuntos de características para a classificação, como pode ser visto no artigo ZHANG (2019). A *accuracy* atingida foi de 81,10% no caso mais otimizado, sendo constatado que a precisão da classificação pode ser melhorada ao adicionar características extraídas dos sinais de EEG.

3 METODOLOGIA

Nesse capítulo, a metodologia utilizada no trabalho é apresentada. A seção 3.1 traz os materiais e ferramentas utilizados, e, na seção 3.2, o procedimento aplicado é relatado.

3.1 Materiais e Ferramentas

3.1.1 Hardware e Software

O uso de sistemas computacionais como GPU (*Graphics Processing Unit*) torna a execução de rotinas de código muito mais rápida. O tamanho elevado do *dataset*, somado à complexidade que uma Rede Neural pode trazer ao processo, por exemplo, faz com que seja muito importante a presença de uma máquina com bastante recurso computacional. Para isso, o ambiente utilizado para o desenvolvimento dos códigos foi o *Google Colab*, que permite a utilização de GPU's otimizadas para IA de forma gratuita e facilita o uso de diversas bibliotecas importantes para a aplicação de ML.

A linguagem de programação utilizada foi o *Python* (versão 3.10.12), amplamente aplicado na ciência de dados e no aprendizado de máquina, e que pode ser executado através do *Google Colab*. As bibliotecas utilizadas estão apresentadas na Tabela 3.

3.1.2 Base de dados

A base de dados utilizada pode ser encontrada no repositório de dados online *Kaggle*, denominada *EEG data from basic sensory task in Schizophrenia* (ROACH, 2013), e foi obtida como base para o estudo presente no artigo FORD *et al.* (2014), de mesma autoria. Ela é composta por dados pessoais e medições de 81 indivíduos, sendo 49 com diagnóstico positivo para esquizofrenia e 32 sem, chamados de “controles”. Os dados pessoais apresentados são o sexo, idade e anos de educação ao longo da vida de cada indivíduo.

Tabela 3 – Bibliotecas utilizadas em *Python*.

Nome	Versão	Descrição
pandas	v1.5.3	Utilizada para manipulação e análise de dados
numpy	v1.23.5	Para trabalhar com arrays, matrizes e funções matemáticas
sklearn	v1.2.2	Usada para aplicação dos métodos de aprendizado de máquina
matplotlib	v3.7.1	Permite a criação de gráficos e visualização de dados
seaborn	v0.12.2	Utilizada para criar o Heatmap
scipy	v1.10.1	Aplicada para cálculos como curtose e entropia

Fonte: do Autor

As medições dos dados de EEG são feitas através da análise de potenciais de eventos relacionados (*event-related potentials* ou ERP), na qual o indivíduo realiza alguma tarefa para que seja medida a atividade cerebral em decorrência desse estímulo externo. Nesse estudo, 3 tarefas são realizadas:

- Pressionar um botão e, após isso, um som é gerado;
- Som é reproduzido;
- Pressionar um botão apenas.

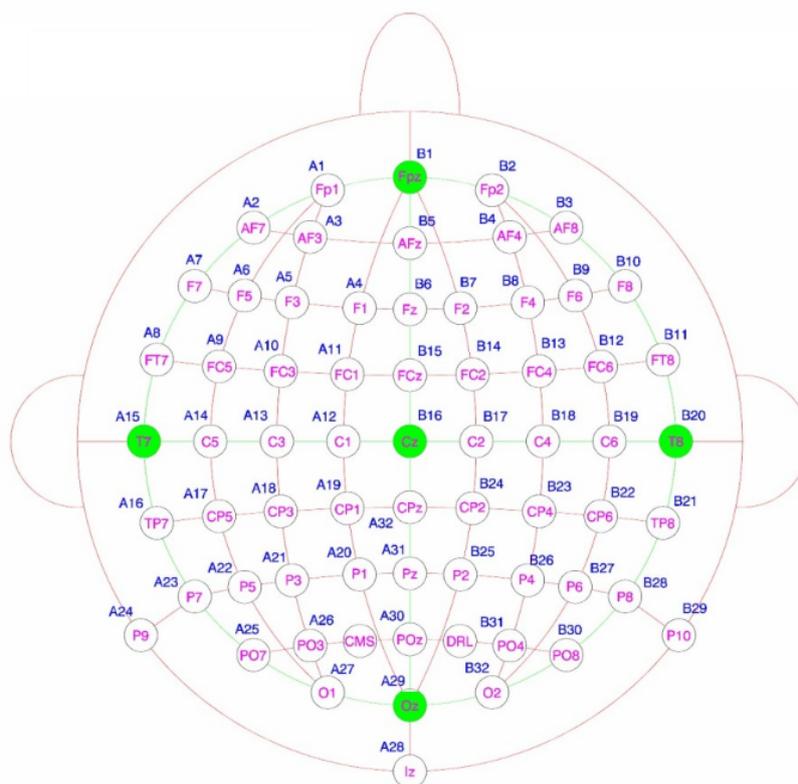
Para cada tarefa, são feitos 100 ensaios. No primeiro caso, o indivíduo deve pressionar o botão 100 vezes consecutivas, com um intervalo de aproximadamente 2s entre cada, e um som é gerado logo após o botão ter sido pressionado, sem nenhum atraso. Esse mesmo som é captado e então reproduzido na segunda tarefa, sem nenhum botão presente. Por fim, novamente o indivíduo pressiona o botão 100 vezes na sequência, porém dessa vez sem nenhum som sendo gerado.

Cada um dos 100 ensaios é dividido em intervalos de 3s, 1,5s antes e 1,5s depois do evento, com uma frequência de 1024 Hz. Sendo assim, existem 3072 medições para cada um dos 100 ensaios de cada uma das 3 tarefas realizadas por cada indivíduo. No total, são mais de 74 milhões de linhas com dados medidos considerando os 81 indivíduos.

Os eletrodos utilizados no eletroencefalograma podem ser vistos na Figura 15. Existem dois conjuntos de 32 canais, representados pelas letras A e B, com números de 1 a 32, totalizando 64 canais. Essa é uma representação utilizada pela empresa que fornece o equipamento aplicado no estudo, a *BioSemi*, disponível em BIOSEMI (2019). Os

eletrodos CMS (*Common Mode Sense*) e DRL (*Driven Right Leg*) são utilizados como referências, sendo o CMS a referência ativa utilizada para o cálculo da tensão nos 64 canais. Ambos eletrodos compõem o circuito de realimentação, desempenhando papéis importantes como na redução da impedância efetiva do eletrodo DRL, resultando no aumento da taxa de rejeição de modo comum (*common-mode rejection ratio* ou CMRR) do amplificador quando comparado ao uso de eletrodos *ground* convencionais, e na proteção ao indivíduo devido a corrente de retorno em caso de mal funcionamento do amplificador ou dos eletrodos, sendo essa limitada eletronicamente a $50 \mu A$, grandeza que não é nociva ao ser humano.

Figura 15 – Diagrama da distribuição dos eletrodos durante EEG.



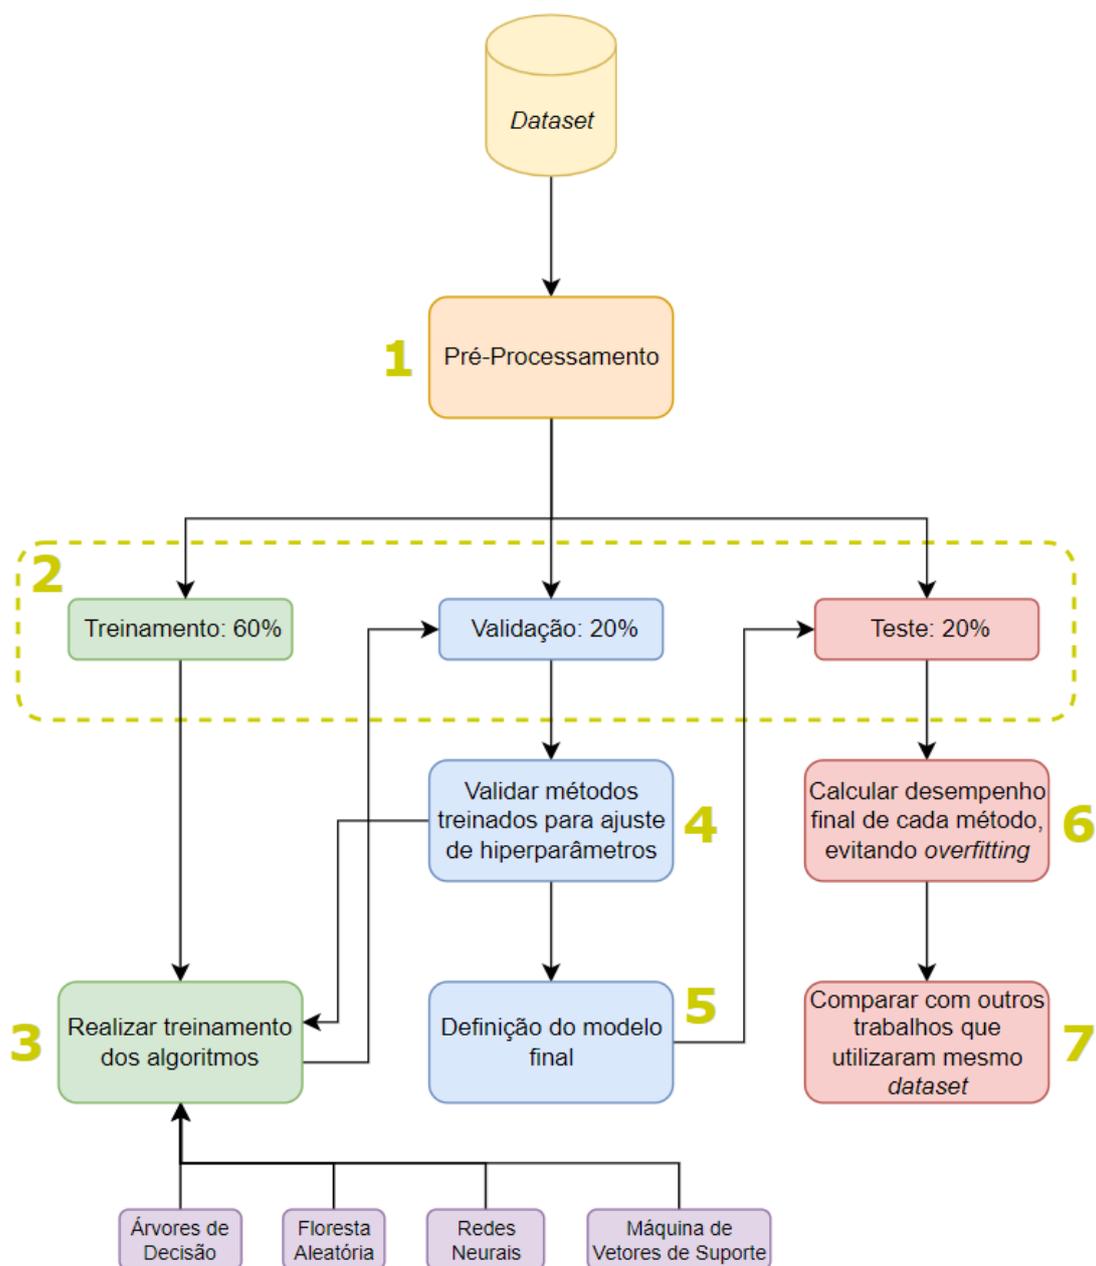
Fonte: ROACH (2013)

Os 64 canais são denominados a partir da nomenclatura padrão utilizada em EEG. Números pares indicam eletrodos no lado direito da cabeça do indivíduo, e números ímpares no lado esquerdo. Quanto maior o número, mais afastado do centro da cabeça está o eletrodo. A letra **I** corresponde ao ínio, a letra **C** à região central do córtex, a letra **A** à região anterior e a letra **z** ao eixo central, com as demais letras representando os lobos, sendo **F** para frontal, **T** para temporal, **P** para parietal e **O** para occipital.

3.2 Procedimento

Para que seja possível obter um modelo de aprendizado de máquina satisfatório, diversas etapas devem ser executadas, cada uma com um objetivo específico. A Figura 16 apresenta um fluxograma resumindo as etapas aplicadas no presente trabalho, a partir do conjunto de dados escolhido.

Figura 16 – Fluxograma das etapas realizadas ao longo do trabalho.



Fonte: do Autor

1. O conjunto de dados escolhido passa pela etapa de pré-processamento, onde o objetivo é reduzir a dimensionalidade e extrair as principais características dos dados. Nesse momento, além de ser feito um entendimento sobre a base buscando definir a melhor forma de tratar os dados, também são aplicadas as técnicas PCA, análise da correlação entre variáveis e normalização;
2. Nessa etapa, o *dataset*, após ter sido pré-processado, é dividido em 3 blocos, chamados de conjunto de treinamento, validação e teste. As percentagens definidas são de 60%, 20% e 20%, respectivamente;
3. Utilizando o mesmo conjunto de treinamento, os 4 modelos (DT, RF, ANN e SVM) são treinados;
4. Para cada método treinado, é utilizado o conjunto de validação para avaliar o desempenho dos algoritmos, através das métricas *accuracy*, *precision*, *recall* e *f1-score*. Nessa etapa, os hiperparâmetros dos modelos podem ser alterados, retornando para a etapa 3, onde são feitos novos treinamentos de cada modelo;
5. Nesse estágio, a topologia final de cada modelo é definida, após conclusão dos passos anteriores, seja pelo desempenho atingido ser satisfatório ou pelo fato de o desempenho não estar mais melhorando. A partir desse momento, os hiperparâmetros são definidos e não devem mais ser alterados;
6. O conjunto de teste, então, é utilizado para avaliar os modelos finais, através das mesmas métricas utilizadas para o conjunto de validação;
7. Por fim, os resultados de desempenho são apresentados e comparados com outros trabalhos presentes na literatura, bem como entre os 4 modelos aplicados.

3.2.1 Pré-processamento dos dados

Como descrito na subseção 3.1.2, a dimensão dos dados é muito expressiva, o que traz diversos pontos negativos para a aplicação do aprendizado de máquina. Além de necessitar de um tempo elevado para realizar o treinamento de cada modelo, o desempenho também é afetado ao utilizar um conjunto extenso de dados sem antes passar por algumas técnicas de pré-processamento. O *dataset* disponibilizado no repositório *Kaggle* já havia sido submetido a alguns processos, como:

- Filtro passa-alta de 0,1 Hz: um filtro passa-alta é aplicado aos sinais de EEG para remover componentes de baixa frequência;
- Interpolação dos canais atípicos nos dados contínuos de EEG: canais de eletrodos que mostram atividade anômala são interpolados para preencher os dados faltantes ou com ruídos, com base em cálculos dos eletrodos vizinhos;
- Divisão dos dados contínuos em segmentos de ensaios individuais: os dados contínuos são segmentados em intervalos de tempo de 3s, sendo 1,5s antes e 1,5s do evento em questão. Isso permite uma análise específica para cada evento;
- Correção de linha de base de -100 a 0 ms: os valores de tensão nos sinais de EEG são corrigidos, de modo que o período de -100 a 0 milissegundos antes do evento se torne a nova linha de base;
- Análise de correlação canônica: análise usada para remover artefatos de músculos e ruído branco de alta frequência (*high-frequency white noises*) dos sinais de EEG, melhorando ainda mais a qualidade do sinal;
- Rejeição de ensaios individuais atípicos: ensaios individuais que contêm dados extremamente atípicos ou com ruídos são descartados, a fim de evitar que os modelos sejam treinados com dados que não representem adequadamente o comportamento esperado;
- Interpolação de canais atípicos dentro de ensaios individuais: similar ao segundo item, canais individuais dentro de ensaios que mostram atividade anormal são interpolados para melhorar a qualidade dos dados analisados.

3.2.1.1 Configuração de eletrodos utilizada

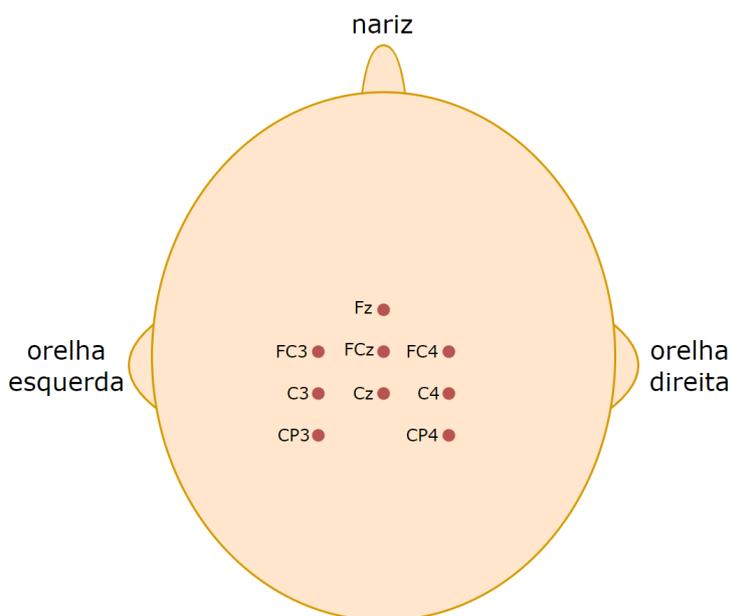
Além das etapas de pré-processamento feitas ao longo do estudo que originou o conjunto de dados, mais alguns tratamentos foram realizados. O primeiro deles focou na redução dos canais utilizados no exame.

Através de um entendimento básico da anatomia do cérebro e das funções principais de cada região, como relatado na seção 2.2, é possível concluir que o córtex motor e o córtex somatossensorial possuem bastante relação com as tarefas propostas nos eventos aplicados para adquirir o conjunto de dados. Atividades motoras voluntárias, como o

pressionamento de um botão, geram uma atividade cerebral relevante nos córtices motor e somatossensorial que podem ser medidas através de EEG. (LUFT; ANDRADE, 2006)

Por esses motivos, de forma a delimitar o escopo do trabalho focando em regiões de maior interesse, os eletrodos Fz, FCz, Cz, FC3, C3, CP3, FC4, C4 e CP4 foram selecionados. Esses 9 eletrodos estão localizados em regiões próximas aos dois córtices. A Figura 17 apresenta um desenho esquemático dessa configuração de eletrodos.

Figura 17 – Esquema com os 9 eletrodos utilizados.

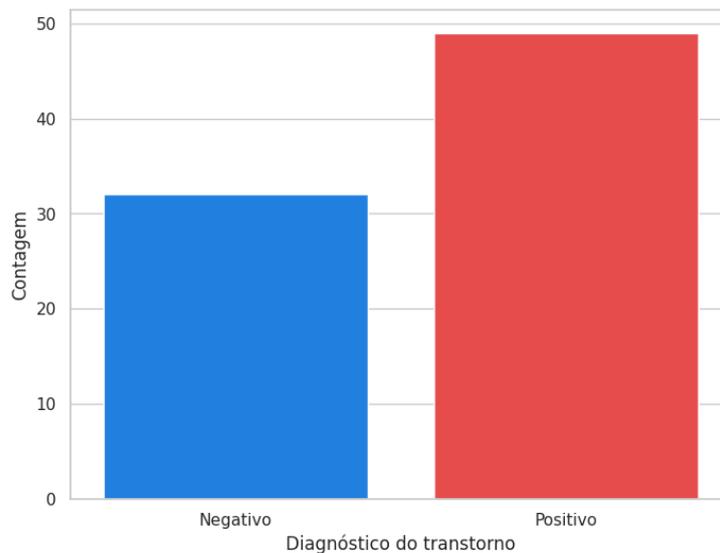


Fonte: do Autor

3.2.1.2 Análise estatística do conjunto de dados

O conjunto de dados, como descrito na subseção 3.1.2, é composto por dados pessoais e medições de 81 pessoas, sendo 49 delas diagnosticadas com esquizofrenia e 32 sem, como pode ser visto na Figura 18. Do total, 60,5% das pessoas possuem o transtorno, contra 39,5% que não, o que demonstra um conjunto de dados desbalanceado quanto às classes de saída. Esse ponto é importante de ser levado em conta ao fazer a divisão entre os conjuntos de treinamento, validação e teste, de forma a garantir que cada conjunto possua dados de ambas classes de saída.

Figura 18 – Distribuição dos 81 indivíduos quanto à presença de esquizofrenia.



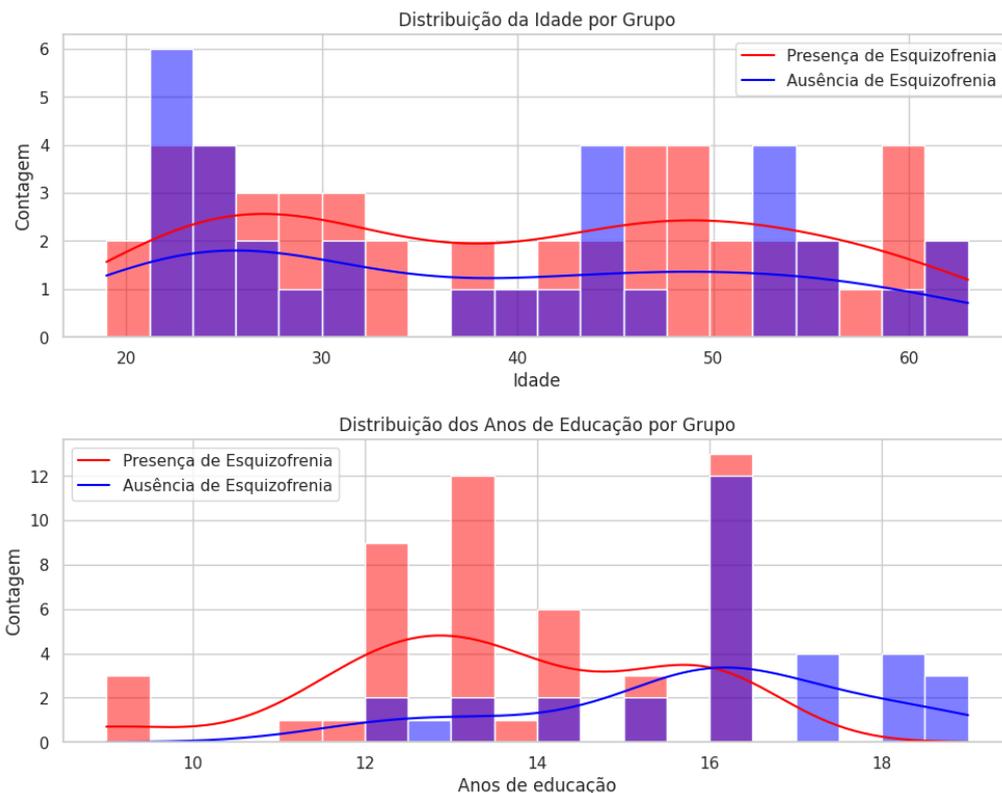
Fonte: do Autor

Quanto às informações de idade e anos de educação, a Figura 19 apresenta a distribuição desses dados. Apesar de as idades dos indivíduos que realizaram o exame de EEG estarem com uma boa distribuição, a quantidade de amostras para cada idade é muito pequena, chegando a no máximo 6 ocorrências em uma mesma faixa etária. As curvas traçadas representam a estimativa da função de densidade kernel (*Kernel Density Estimation* ou KDE), e auxiliam a identificar a maneira em que os dados estão distribuídos. As curvas não apresentam uma grande variação, o que contribui para afirmar que a idade não é uma característica relevante para afirmar sobre a presença ou não da esquizofrenia para esse conjunto de dados. Além disso, só existe uma classe de saída para diversas idades, o que prejudicaria o treinamento através do aprendizado de máquina.

A análise dos anos de educação de cada indivíduo leva a uma conclusão semelhante. As curvas de KDE apontam que a partir de uma certa quantidade de anos de educação, os casos de pessoas com esquizofrenia reduzem e de pessoas sem aumentam. Todavia, devido a baixa quantidade de amostras, considerar essa premissa uma verdade pode ser um equívoco. Além disso, os dados possuem uma distribuição ruim, o que pode causar inconsistências caso sejam levados em conta para o treinamento dos modelos.

A Figura 20 apresenta a distribuição quanto ao sexo dos indivíduos. De 81 pessoas, 67 são do sexo masculino e apenas 14 do sexo feminino, representando aproximadamente 17% do valor total. De acordo com dados do Instituto de Métricas e Avaliação em Saúde (IHME, 2023), no ano de 2019, mais de 23 milhões de pessoas apresentavam

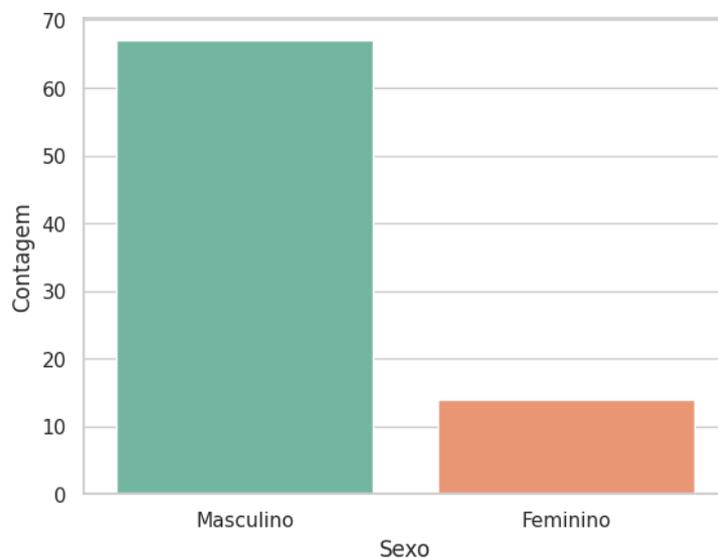
Figura 19 – Distribuição dos 81 indivíduos quanto à idade e aos anos de educação.



Fonte: do Autor

o transtorno, sendo 47,5% do sexo feminino e 52,5% do sexo masculino. Dessa forma, não é possível traçar uma relação direta do sexo com a presença do transtorno, ainda mais levando em conta um conjunto com poucas amostras, como é o caso.

Figura 20 – Distribuição dos 81 indivíduos quanto ao sexo.



Fonte: do Autor

Com base nesses fatores, os dados pessoais não foram considerados para realizar o treinamento dos modelos. Dessa forma, as medições dos canais utilizados durante o EEG compuseram, por completo, o *dataset* utilizado, após a realização de algumas técnicas que serão apresentadas na próxima seção.

3.2.1.3 Extração de características dos sinais

As medições feitas durante as 3 tarefas representam a tensão de cada eletrodo, medida em μV , pelo tempo, em segmentos de 3s. Com isso, é possível plotar os sinais em um gráfico de tensão x tempo. Dessas curvas, é possível extrair características que representem esses sinais. Foram escolhidos, então, os seguintes aspectos do sinal para os 9 eletrodos:

- Tensão Média;
- Tensão RMS;
- Desvio Padrão da Tensão;
- Potência de Banda;
- Curtose;
- Entropia.

3.2.1.4 Normalização das entradas

Uma técnica importante de pré-processamento é a normalização. Quando os dados usados como entrada de um modelo de ML possuem grandezas diferentes, normalizar essas entradas pode otimizar muito o desempenho dos modelos implementados. Dessa forma, foi utilizada a função *MinMaxScaler()* do pacote *sklearn.preprocessing*, que transforma todos valores das múltiplas entradas em valores dentro de um intervalo definido, sendo entre 0 e 1 para esse estudo.

3.2.1.5 Mapa de Calor da correlação entre variáveis

Variáveis de entrada que possuem muita correlação entre si, seja essa uma correlação forte positiva ou forte negativa, tendem a ter a mesma influência na saída. Com isso, a remoção de uma dessas entradas pode reduzir o custo computacional durante todo processo de treinamento, validação e teste, sem que impacte negativamente no desempenho

do modelo. A visualização dessa correlação é bastante facilitada com a plotagem de um *heatmap*, gráfico que apresenta, seja através de valores numéricos ou de cores representativas, todas correlações existentes entre os dados informados. O uso da função *heatmap()* da biblioteca *seaborn* torna essa etapa possível.

3.2.1.6 PCA

A aplicação de PCA visa reduzir a dimensionalidade do conjunto de dados. Através do módulo *sklearn.decomposition.PCA*, é possível descobrir os componentes principais de um conjunto de dados e quanto cada um representa das características do *dataset*. Utilizando o valor *Explained Variance Ratio*, que indica o quanto cada componente principal representa da variabilidade total dos dados, é possível definir um novo conjunto de dados de entrada composto por algumas componentes principais, que visam representar a maior variabilidade dos dados com uma menor dimensão.

3.2.2 Escolha dos Métodos de aprendizado de máquina

Foram escolhidos 4 métodos de aprendizado de máquina supervisionados para realizar o treinamento, através do uso da biblioteca *scikit-learn* (PEDREGOSA *et al.*, 2011) e dos seus módulos. Para cada um deles, foram desenvolvidas arquiteturas distintas, variando hiperparâmetros para otimizar o desempenho dos métodos. As técnicas aplicadas foram:

- Árvores de Decisão (*Decision Tree* ou DT): utilizando o módulo chamado *sklearn.tree*, aplicando o *DecisionTreeClassifier*;
- Floresta Aleatória (*Random Forest* ou RF): implementando o *RandomForestClassifier* através do módulo *sklearn.ensemble*;
- Redes Neurais (*Neural Network* ou NN): utilizando o *MLPClassifier* do módulo *sklearn.neural_network*;
- Máquina de Vetores de Suporte (*Support Vector Machine* ou SVM): através do módulo *sklearn.svm*, aplicando o *SVC*.

3.2.3 Otimização de hiperparâmetros

A etapa de pré-processamento é muito necessária para otimização do desempenho de um método de aprendizado de máquina. Para realizar essa otimização, a biblioteca *scikit-learn* fornece diversas possibilidades para cada técnica implementada.

- **Árvore de Decisão (DT):** para que seja obtida uma Árvore de Decisão com alto desempenho, o ideal é que ela tenha o menor tamanho possível. Para isso, existem duas formas principais de reduzir o tamanho de uma árvore:
 - ◊ **Pre-Pruning**, isto é, “podar” a árvore antes mesmo de ela ter sido concebida, através da definição de hiperparâmetros como:
 - *criterion*: função para medir a qualidade de uma divisão de nós;
 - *max_depth*: maior profundidade permitida para a árvore;
 - *min_samples_split*: mínimo de amostras para um nó ser nó-pai;
 - *max_features*: número de *features* a serem consideradas buscando a melhor divisão dos nós;
 - *max_leaf_nodes*: máximo de nós-folha na árvore toda.
 - ◊ **Post-Pruning**, que é realizando a poda após a criação da mesma, momento no qual são identificados ramos que poderiam ser podados para que o desempenho da árvore seja aumentado e para que não haja *overfitting*. O principal algoritmo utilizado nessa etapa é o chamado *Minimal Cost-Complexity Pruning*, que pode ser definido através do hiperparâmetro *ccp_alpha*. A subárvore com maior valor de complexidade-custo que for menor que *ccp_alpha* será escolhida como a DT do algoritmo.
- **Floresta Aleatória (RF):** como essa técnica utiliza diversas DT's para criar o algoritmo, os hiperparâmetros de Árvores de Decisão também podem ser definidos em RF's. Dessa forma, os mesmos hiperparâmetros usados para otimização da DT foram aplicados para RF, além do uso do hiperparâmetro *n_estimators*, que define a quantidade de árvores usadas para gerar a floresta.
- **Redes Neurais Artificiais (ANN):** para definir um otimizado classificador Perceptron multicamadas (MLP), alguns hiperparâmetros são importantes de serem considerados, como:
 - *solver*: solucionador para otimização de peso;
 - *hidden_layer_sizes*: define a quantidade de camadas ocultas e de neurônios por camada;

- *activation*: função de ativação para a camada oculta;
 - *learning_rate*: modo da variação da taxa de aprendizado para atualizações de peso;
 - *learning_rate_init*: valor da taxa de aprendizado inicial da rede;
 - *tol*: tolerância para seguir com o treinamento após *n_iter_no_change*;
 - *n_iter_no_change*: número máximo de épocas sem mudança, baseado em *tol*;
 - *max_iter*: número máximo de iterações. Dependendo do *solver*, esse valor vai representar a quantidade de épocas da rede;
 - *early_stopping*: booleano que define se deve ou não encerrar o treinamento quando a pontuação de validação não estiver melhorando.
- Máquina de Vetores de Suporte (SVM): com o objetivo de otimizar ao máximo o desempenho da topologia, os hiperparâmetro a serem ajustados são:
 - *C*: parâmetro de regularização, deve ser um valor positivo;
 - *kernel*: especifica o tipo de *kernel* a ser usado pelo algoritmo;
 - *degree*: grau da função *kernel* polinomial *poly*, devendo ser um valor positivo. Caso o tipo de *kernel* utilizado seja outro, esse hiperparâmetro é ignorado;
 - *gamma*: o coeficiente *kernel* para as funções *rbf*, *poly* e *sigmoid*.

As Tabelas 7, 4, 5 e 6 apresentam os diferentes hiperparâmetros utilizados nos diversos treinamentos dos 4 modelos. Foram feitas combinações entre todos valores de cada hiperparâmetro presente nas tabelas. Para os modelos aplicando DT, 729 topologias diferentes foram treinadas. Os mesmos hiperparâmetros foram utilizados nos modelos de RF, além de alternar o número de árvores na floresta, totalizando 2187 combinações. Para ANN, 405 topologias distintas foram treinadas. Por fim, 200 combinações de topologias foram aplicadas para SVM.

Tabela 4 – Hiperparâmetros utilizados para Árvores de Decisão.

Hiperparâmetro	Valores
<i>criterion</i>	'gini' / 'entropy' / 'log_loss'
<i>max_depth</i>	5 / 8 / 12
<i>min_samples_split</i>	2 / 4 / 6
<i>max_features</i>	None / 'sqrt' / 'log2'
<i>max_leaf_nodes</i>	5 / 10 / 15
<i>ccp_alpha</i>	0 / 0,01 / 0,05

Fonte: do Autor

Tabela 5 – Hiperparâmetros utilizados para Floresta Aleatória.

Hiperparâmetro	Valores
<i>n_estimators</i>	50 / 100 / 150
<i>criterion</i>	'gini' / 'entropy' / 'log_loss'
<i>max_depth</i>	5 / 8 / 12
<i>min_samples_split</i>	2 / 4 / 6
<i>max_features</i>	None / 'sqrt' / 'log2'
<i>max_leaf_nodes</i>	5 / 10 / 15
<i>ccp_alpha</i>	0 / 0,01 / 0,05

Fonte: do Autor

Tabela 6 – Hiperparâmetros utilizados para Redes Neurais.

Hiperparâmetro	Valores
<i>solver</i>	'lbfgs' / 'sgd' / 'adam'
<i>hidden_layer_sizes</i>	(5,5,5) / (10,10,10) / (15,15,15) / (5,10,10,5) / (10,15,15,15,10)
<i>activation</i>	'logistic' / 'tanh' / 'relu'
<i>learning_rate</i>	'constant' / 'invscaling' / 'adaptive'
<i>learning_rate_init</i>	0,001 / 0,01 / 0,1
<i>tol</i>	0,0001
<i>max_iter</i>	800
<i>early_stopping</i>	<i>True</i>

Fonte: do Autor

Tabela 7 – Hiperparâmetros utilizados para Máquina de Vetores de Suporte.

Hiperparâmetro	Valores
C	0,3 / 0,5 / 1 / 1,5 / 2
$kernel$	'linear' / 'poly' / 'rbf' / 'sigmoid'
$degree$	1 / 2 / 3 / 4 / 5
$gamma$	'scale' / 'auto'

Fonte: do Autor

3.2.4 Estratégia de Treinamento, Validação e Teste

Como forma de corretamente dividir o conjunto total de dados, foram criados 3 subconjuntos com amostragem estratificada, a fim de garantir a proporção das 2 classes em todos subconjuntos, utilizando a função *train_test_split()* presente na biblioteca *sklearn*:

- conjunto treinamento - 60% dos dados totais;
- conjunto validação - 20% dos dados totais;
- conjunto teste - 20% dos dados totais.

O conjunto definido para treinamento é usado para treinar cada técnica de aprendizado de máquina a perceber o padrão dos dados, de forma a compreender o que leva um conjunto de entradas a ter determinada saída. Já o conjunto de validação é utilizado em conjunto com os dados de treinamento para validar como o método está se saindo. A sua correta utilização é muito importante para a otimização de hiperparâmetros, porém deve-se evitar o *overfitting*, que ocorre quando um modelo de aprendizado de máquina fornece previsões precisas para os dados de treinamento apenas, e não para novos dados. Com o objetivo de evitar esse comportamento é que se usa o conjunto de teste, conjunto esse que deve ser usado apenas ao fim da otimização de hiperparâmetros para determinar o desempenho final do modelo. Caso esse *feedback* seja utilizado para alterar o algoritmo, o *overfitting* poderia se tornar um problema.

3.2.5 Comparação dos resultados

Após definição dos modelos e obtenção dos desempenhos, comparações são feitas entre os 4 modelos aplicados e entre demais modelos de outros trabalhos presentes na literatura. Os trabalhos utilizados para comparação foram os seguintes:

- KHARE; BAJAJ (2021): Utilizou o classificador F-LSSVM (Flexible Least Square Support Vector Machine), aplicando o método de extração de *features Fisher Score* para selecionar os canais mais discriminantes e o F-TQWT (Flexible Tunable Q Wavelet Transform) para decomposição dos sinais de EEG;
- ZHANG (2019): Aplicou o método Floresta Aleatória com *10-fold cross validation*, técnica utilizada para alternar os conjuntos de treinamento e teste. Foram utilizadas as medições de 9 eletrodos, localizados na parte mais central do córtex, bem como os dados pessoais de cada indivíduo;
- KHARE; BAJAJ; ACHARYA (2021): Com o objetivo de superar limitações de métodos baseados em extração de *features*, foi implementada uma Rede Neural Convolutiva em combinação com análises de tempo-frequência. As 3 condições de ERP são utilizadas;
- AHMAD (2022): Também aplicou CNN como modelo, utilizando os dados medidos dos 64 canais, porém sem juntar com os dados pessoais. Antes de realizar o treinamento, obteve a média dos ensaios para cada uma das 3 condições de ERP.

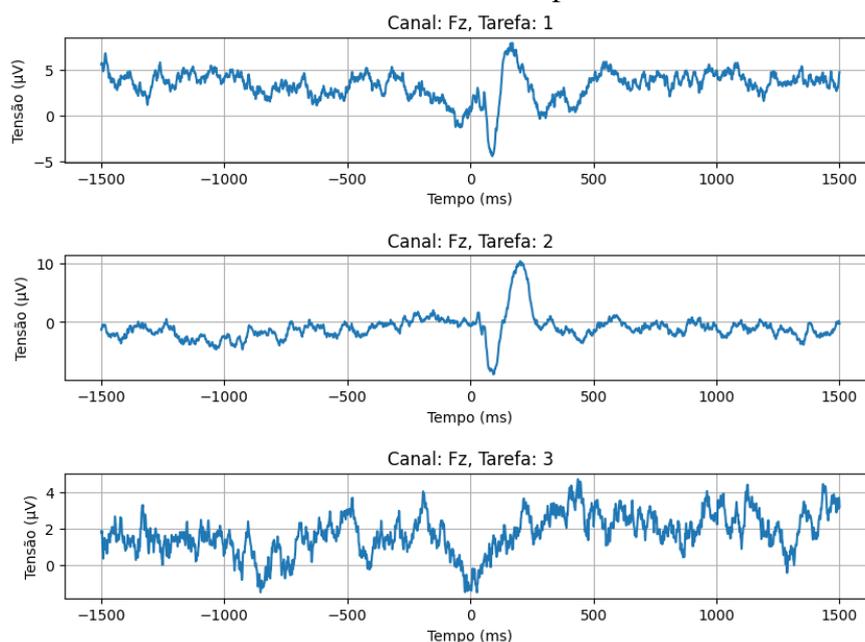
4 RESULTADOS

Nesse capítulo, os resultados obtidos são apresentados e discutidos, baseado nas metodologias apresentadas no Capítulo 3.

4.1 Pré-processamento dos dados

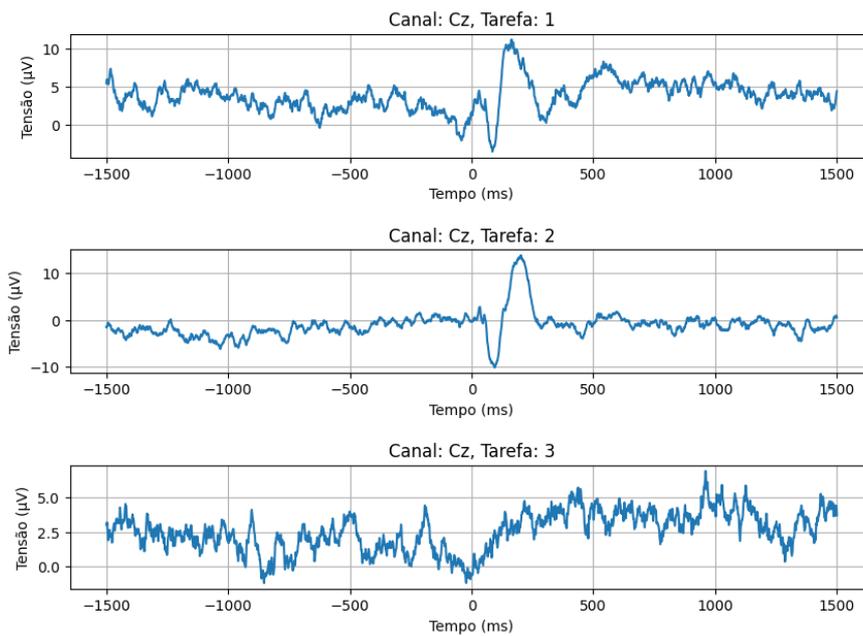
Com o objetivo de reduzir o tamanho do conjunto de dados e extrair as principais características, as técnicas relatadas na subseção 3.2.1 foram implementadas. As Figuras 21 e 22 apresentam as curvas de tensão média para as 100 amostras pelo tempo de cada amostra (3s) para os eletrodos Fz e Cz, localizados no centro do crânio, nas regiões do córtex motor e córtex somatossensorial. Já as Figuras 23 e 24 representam as mesmas curvas para os eletrodos F8 e P10, localizados em regiões mais afastadas do centro.

Figura 21 – Curvas da média de 100 amostras para as 3 tarefas do Canal Fz.



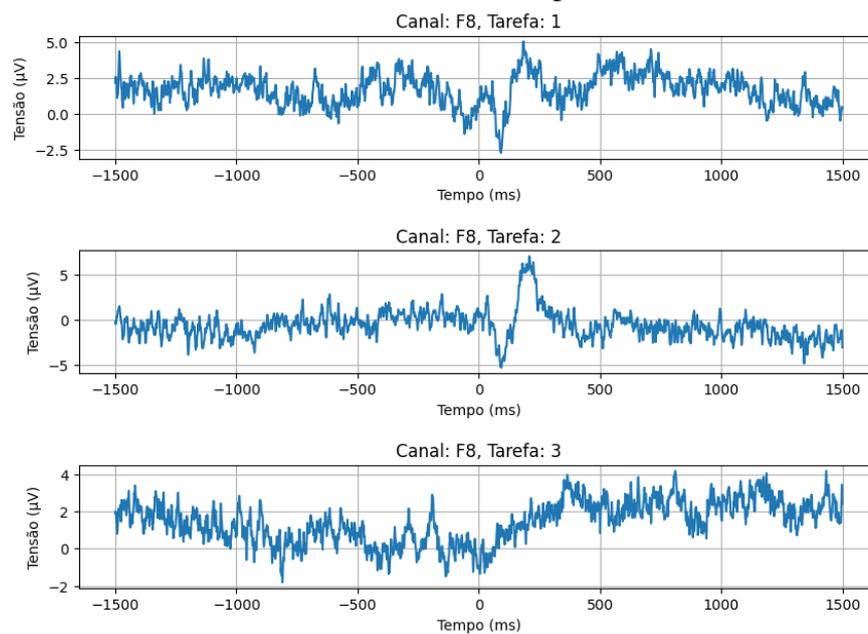
Fonte: do Autor

Figura 22 – Curvas da média de 100 amostras para as 3 tarefas do Canal Cz.



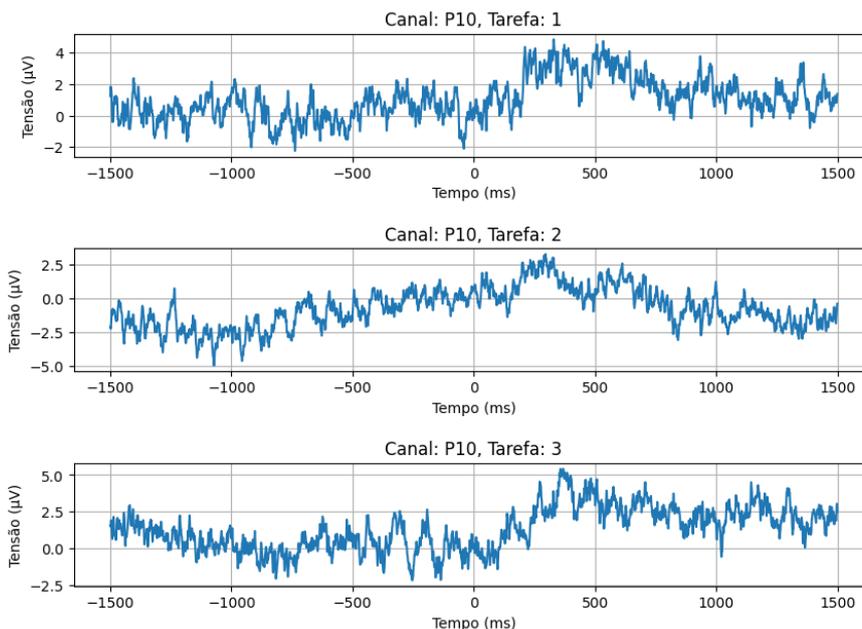
Fonte: do Autor

Figura 23 – Curvas da média de 100 amostras para as 3 tarefas do Canal F8.



Fonte: do Autor

Figura 24 – Curvas da média de 100 amostras para as 3 tarefas do Canal P10.



Fonte: do Autor

Analisando os 4 gráficos, fica evidente que os eletrodos localizados nas regiões mais centrais tiveram uma curva mais clara, com menos ruído, principalmente nas tarefas 1 e 2. Isso se dá ao fato de estarem localizados em regiões que são responsáveis por ações como o controle voluntário do corpo e a interpretação das sensações táteis, ações relacionadas ao ato de pressionar um botão. Além dos canais Fz e Cz, o FCz, FC3, C3, CP3, FC4, C4 e CP4 completam os 9 canais utilizados para extração de características e treinamento dos modelos. As tarefas 1 e 2 apresentaram curvas mais distintas para os eletrodos Fz e Cz que a tarefa 3. Pelo fato de a tarefa 1 se tratar de uma atividade mais completa, pressionar o botão e escutar o som gerado, essa foi a tarefa escolhida para se basear a sequência do estudo e treinamento dos modelos.

Vale ressaltar que o indivíduo utilizado para geração desses gráficos tinha um diagnóstico negativo para o transtorno, porém foram geradas curvas para diversos outros indivíduos, alguns com diagnóstico positivo. Na grande maioria dos casos, as curvas dos canais mais centrais eram bem distinguíveis, assim como as apresentadas nessa seção.

4.1.1 Extração de características dos sinais

A partir da geração das curvas de tensão ao longo do tempo para cada eletrodo selecionado, foram extraídas características desses sinais. A tensão média, a tensão RMS, o desvio padrão da tensão, a potência de banda, a entropia e a curtose foram as características

escolhidas para representar o sinal. A entropia é importante para avaliar a complexidade e incerteza dos dados, e a análise da curtose permite quantificar o achatamento da curva, parâmetro que pode ser muito relevante para compreensão dos dados. Os dados medidos para cada eletrodo podem ser vistos nas Tabelas 8, 9 e 10, medições do mesmo indivíduo.

Tabela 8 – Valores dos Canais Fz, FCz e Cz para indivíduo 1.

	Canal Fz	Canal FCz	Canal Cz
Tensão Média (μV)	3,25765	3,74530	3,84751
Tensão RMS (μV)	3,63208	4,16928	4,35687
Desvio Padrão (μV)	1,60614	1,83182	2,04427
Potência de Banda (W)	1,57535	2,12604	2,33419
Curtose	3,21350	2,35137	1,43731
Entropia	3,16982	3,16774	3,15262

Fonte: do Autor

Tabela 9 – Valores dos Canais FC3, C3 e CP3 para indivíduo 1.

	Canal FC3	Canal C3	Canal CP3
Tensão Média (μV)	3,69316	4,26239	3,81495
Tensão RMS (μV)	4,03164	4,63362	4,20269
Desvio Padrão (μV)	1,61699	1,81727	1,76315
Potência de Banda (W)	1,57482	1,70193	1,59746
Curtose	2,47527	1,62733	1,75868
Entropia	3,32138	3,24358	3,18920

Fonte: do Autor

Tabela 10 – Valores dos Canais FC4, C4 e CP4 para indivíduo 1.

	Canal FC4	Canal C4	Canal CP4
Tensão Média (μV)	2,97647	2,86673	3,29069
Tensão RMS (μV)	3,36883	3,28132	3,74774
Desvio Padrão (μV)	1,57786	1,59653	1,79356
Potência de Banda (W)	1,61327	1,51585	1,49104
Curtose	3,24895	2,39352	1,56141
Entropia	3,16945	3,16569	3,13829

Fonte: do Autor

4.1.2 Normalização

Após realizar a extração das características, os valores foram normalizados, de forma a ficarem entre 0 e 1. Essa técnica é importante principalmente em cenários onde os dados possuem grandezas diferentes, o que não é exatamente o caso.

Apesar desse fator, a normalização é uma técnica muito utilizada em aprendizado de máquina e pode melhorar o desempenho dos modelos mesmo para dados com grandezas semelhantes. Serão apresentados os valores do desempenho utilizando as entradas normalizadas e não normalizadas para efeito de comparação. A Tabela 11 apresenta os dados normalizados do mesmo indivíduo 1, para os canais Fz, FCz e Cz. Todos parâmetros dos demais eletrodos passaram pelo mesmo processo.

Tabela 11 – Valores normalizados dos Canais Fz, FCz e Cz para indivíduo 1.

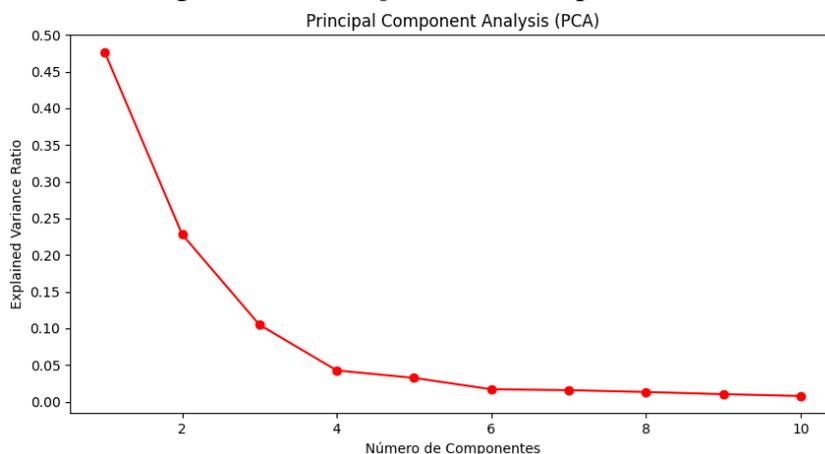
	Canal Fz	Canal FCz	Canal Cz
Tensão Média (μV)	0,77815	0,69746	0,59422
Tensão RMS (μV)	0,28112	0,50892	0,47057
Desvio Padrão (μV)	0,09674	0,28091	0,43069
Potência de Banda (W)	0,18458	0,37523	0,54013
Curtose	0,30684	0,20941	0,14655
Entropia	0,78404	0,72083	0,68872

Fonte: do Autor

4.1.3 PCA

4.1.3.1 Sem normalização

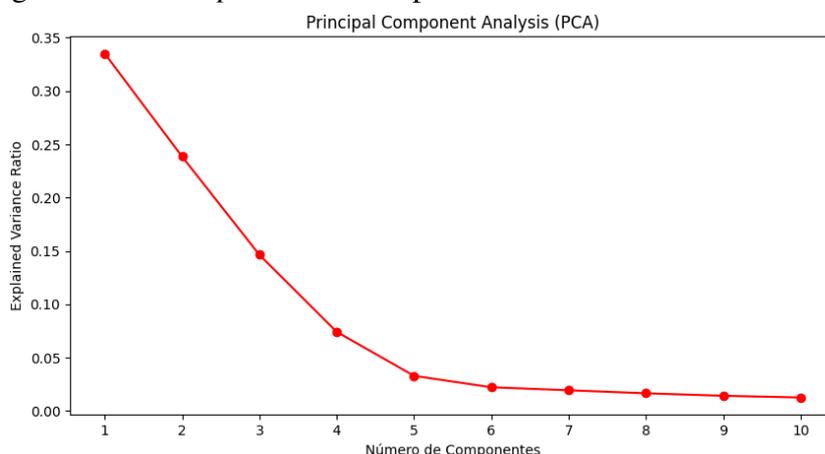
O *scree plot*, gráfico que apresenta a razão de variância explicada para cada componente principal, da análise feita dos componentes principais pode ser visto na Figura 25. Através do gráfico, é possível perceber que a curva perde sua inclinação, até tornar-se praticamente uma reta na horizontal, próximo de 0 no eixo y . Cada ponto representa uma componente principal, e o valor de *Explained Variance Ratio* é o quanto da variabilidade dos dados é explicada por essa componente. O primeiro ponto, situado em 0,476, representa 47,6% da variabilidade total do conjunto. Já o segundo representa 22,81%, e assim por diante. A quantidade de componentes principais escolhida para representar o conjunto total é de 5 componentes que, somadas, representam 88,41% da variabilidade dos dados.

Figura 25 – *Scree plot* da análise por PCA.

Fonte: do Autor

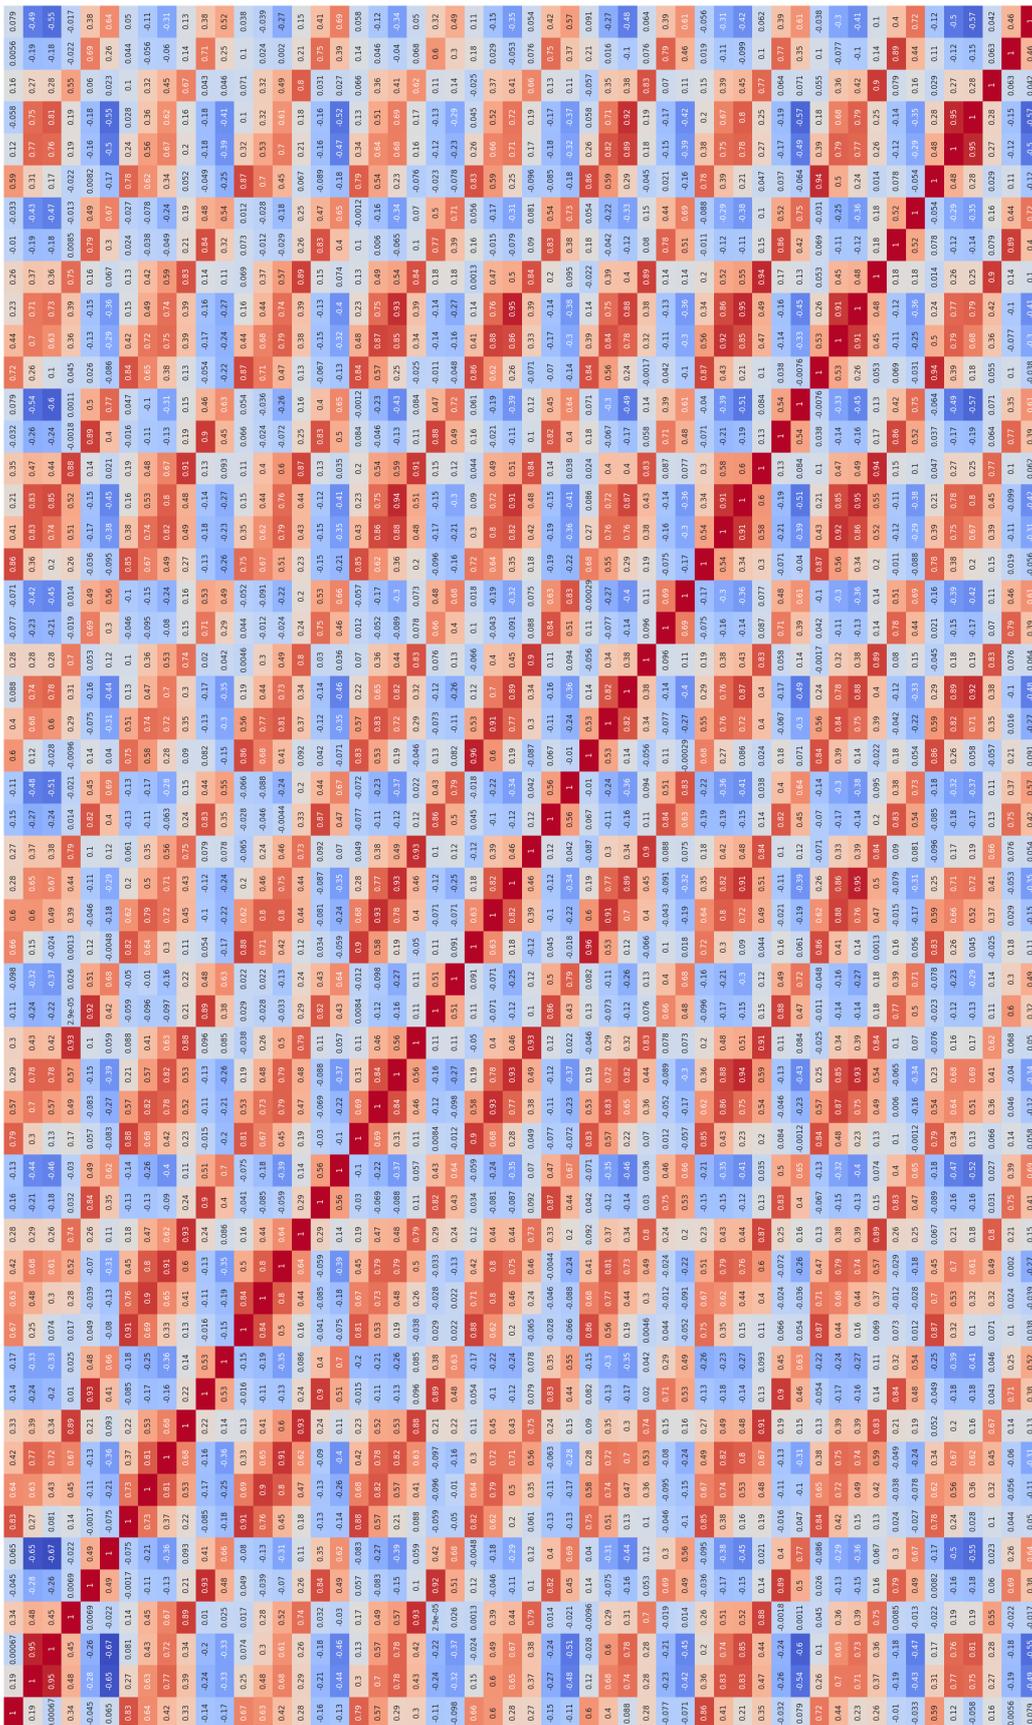
4.1.3.2 Com normalização

A mesma técnica foi aplicada para o conjunto de dados normalizados. A Figura 26 apresenta o *scree plot* para esse conjunto. Comparando à curva sem normalização, é possível perceber que o valor de *Explained Variance Ratio* da primeira componente principal é inferior, representando 33,50% da variabilidade dos dados. Para os mesmos 5 componentes utilizados no caso sem normalização, a soma da variabilidade atinge 82,67% do conjunto total, aproximadamente 6% a menos. Para representar o que as 5 componentes principais representam para o outro conjunto, 8 componentes principais seriam necessárias. Um motivo que explica essa diferença negativa é o fato de os dados não normalizados apresentarem grandezas semelhantes, o que torna a aplicação da normalização um passo não tão necessário.

Figura 26 – *Scree plot* da análise por PCA com dados normalizados.

Fonte: do Autor

Figura 28 – Mapa de Calor da correlação entre variáveis.



Fonte: do Autor

Além de obter os dois mapas de calor descritos acima, que foram feitos a partir do conjunto de dados obtidos após realizar a extração das características dos sinais, foi gerado um novo mapa de calor após aplicar o PCA, como descrito na subseção 4.1.3, utilizando 5 componentes principais. A Figura 29 apresenta esse *heatmap*. Diferentemente dos demais mapas gerados, esse apresenta correlação entre as componentes principais praticamente nula, o que significa que cada componente representa uma parcela diferente da variabilidade do conjunto de dados. Esse fato está de acordo com o que se espera ao aplicar a técnica de PCA, que visa obter componentes, em uma dimensão menor que o conjunto original, mas que representem muito bem esse conjunto. Sendo possível manter um bom desempenho, o custo computacional será altamente reduzido.

Figura 29 – Mapa de Calor da correlação entre as componentes principais após PCA.

PC1	1	-1e-16	1e-17	-1.8e-17	4.1e-18
PC2	-1e-16	1	6.6e-18	1e-16	7.3e-18
PC3	1e-17	6.6e-18	1	-2e-16	-4.3e-17
PC4	-1.8e-17	1e-16	-2e-16	1	-6.5e-18
PC5	4.1e-18	7.3e-18	-4.3e-17	-6.5e-18	1
	PC1	PC2	PC3	PC4	PC5

Fonte: do Autor

4.2 Treinamento e Validação

Utilizando o conjunto de treinamento, os modelos foram treinados com a combinação de hiperparâmetros apresentados na subseção 3.2.3. Após cada treinamento, as topologias foram avaliadas utilizando as métricas de *accuracy*, *precision*, *recall* e *f1-score*.

As Tabelas 12 e 13 apresentam os melhores desempenhos e topologias obtidos para os 4 modelos sem nenhuma técnica de pré-processamento (normalização, correlação entre variáveis ou PCA). Já as Tabelas 14 e 15 trazem resultados da técnica de normalização aplicada aos 4 modelos. Com alguns parâmetros removidos pela alta correlação entre variáveis, através da análise do *heatmap*, as Tabelas 16 e 17 exibem os melhores resulta-

dos de desempenho e topologia para os 4 modelos. Por fim, nas Tabelas 18 e 19, podem ser vistos os mesmos resultados, porém para aplicação da técnica de PCA, utilizando 5 componentes principais.

Tabela 12 – Desempenhos para conjunto validação sem técnicas de normalização, PCA e remoção de parâmetros através da correlação entre variáveis.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	75%	80%	80%	80%
RF	62,50%	66,66%	80%	72,72%
ANN	75%	71,43%	100%	83,33%
SVM	68,75%	77,77%	70%	73,68%

Fonte: do Autor

Tabela 13 – Topologias com melhor *accuracy* para conjunto validação sem técnicas de normalização, PCA e remoção de parâmetros através da correlação entre variáveis.

Modelo	Hiperparâmetros
DT	['gini', 5, 2, 'sqrt', 5, 0]
RF	[50, 'entropy', 5, 2, 'sqrt', 5, 0]
ANN	['adam', (15, 15, 15), 'relu', 'constant', 0,01]
SVM	[0,5, 'linear', 1, 'scale']

Fonte: do Autor

Tabela 14 – Desempenhos para conjunto validação com normalização.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	75%	80%	80%	80%
RF	62,50%	66,66%	80%	72,72%
ANN	68,75%	72,72%	80%	76,19%
SVM	68,75%	69,23%	90%	78,26%

Fonte: do Autor

Tabela 15 – Topologias com melhor *accuracy* para conjunto validação com normalização.

Modelo	Hiperparâmetros
DT	['gini', 5, 2, 'sqrt', 5, 0]
RF	[50, 'entropy', 5, 2, 'sqrt', 5, 0]
ANN	['lbfgs', (5, 10, 10, 5), 'relu', 'constant', 0,001]
SVM	[0,3, 'poly', 4, 'scale']

Fonte: do Autor

Tabela 16 – Desempenhos para conjunto validação com parâmetros removidos por correlação entre variáveis.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	68,75%	72,72%	80%	76,19%
RF	68,75%	69,23%	90%	78,26%
ANN	75%	100%	60%	75%
SVM	81,25%	88,88%	80%	84,21%

Fonte: do Autor

Tabela 17 – Topologias com melhor *accuracy* para conjunto validação com parâmetros removidos por correlação entre variáveis.

Modelo	Hiperparâmetros
DT	['gini', 5, 2, 'sqrt', 5, 0,05]
RF	[50, 'entropy', 5, 6, None, 5, 0]
ANN	['sgd', (5, 10, 10, 5), 'tanh', 'constant', 0,01]
SVM	[0,5, 'poly', 3, 'auto']

Fonte: do Autor

Tabela 18 – Desempenhos para conjunto validação com PCA.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	68,75%	72,72%	80%	76,19%
RF	62,50%	66,66%	80%	72,72%
ANN	75%	71,43%	100%	83,33%
SVM	68,75%	77,77%	70%	73,68%

Fonte: do Autor

Tabela 19 – Topologias com melhor *accuracy* para conjunto validação com PCA.

Modelo	Hiperparâmetros
DT	['gini', 5, 2, 'sqrt', 5, 0]
RF	[50, 'entropy', 5, 2, 'sqrt', 5, 0]
ANN	['adam', (15, 15, 15), 'relu', 'constant', 0,01]
SVM	[0,5, 'linear', 1, 'scale']

Fonte: do Autor

4.3 Desempenho final de cada modelo

Após realizada a otimização de hiperparâmetros para cada técnica aplicada e definido o modelo com melhor desempenho (nesse caso, a métrica utilizada foi a *accuracy*, principal métrica utilizada em trabalhos da literatura, porém as demais métricas são apresentadas para uma análise mais completa do desempenho de cada modelo), é feita uma previsão dos resultados utilizando o conjunto teste.

Esse conjunto não foi utilizado para realizar nenhuma alteração no modelo, diferentemente do conjunto validação, que tem como objetivo justamente alterar a topologia em busca de melhores resultados. Dessa forma, é possível que o conjunto teste apresente resultados inferiores, apesar de não ser o cenário ideal. No entanto, caso um modelo esteja conseguindo generalizar com eficiência, é de se esperar que os resultados para um novo conjunto sejam semelhantes aos resultados do conjunto validação.

As Tabelas 20, 21, 22 e 23 apresentam os resultados de desempenho aplicando o conjunto teste para a melhor topologia de cada um dos 4 modelos, conforme descrito na seção 4.2.

Tabela 20 – Desempenhos para conjunto teste sem técnicas de normalização, PCA e remoção de parâmetros através da correlação entre variáveis.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	70,58%	77,77%	70%	73,68%
RF	35,29%	46,15%	60%	52,17%
ANN	64,70%	64,28%	90%	75%
SVM	64,70%	70%	70%	70%

Fonte: do Autor

Tabela 21 – Desempenhos para conjunto teste com normalização.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	70,58%	77,77%	70%	73,68%
RF	35,29%	46,15%	60%	52,17%
ANN	52,94%	62,50%	50%	55,55%
SVM	52,29%	57,14%	80%	66,66%

Fonte: do Autor

Tabela 22 – Desempenhos para conjunto teste com parâmetros removidos por correlação entre variáveis.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	35,29%	45,45%	50%	47,62%
RF	41,17%	50%	60%	54,54%
ANN	52,91%	62,50%	50%	55,55%
SVM	64,70%	70%	70%	70%

Fonte: do Autor

Tabela 23 – Desempenhos para conjunto teste com PCA.

Modelo	<i>Accuracy</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
DT	70,58%	72,72%	80%	76,19%
RF	47,06%	53,84%	70%	60,87%
ANN	64,70%	66,66%	80%	72,72%
SVM	64,70%	64,28%	90%	75%

Fonte: do Autor

Analisando os resultados, é possível afirmar que uma parte das topologias e técnicas não conseguiram generalizar com eficiência para esse novo conjunto, como é o caso do modelo RF nas 4 técnicas diferentes. Para esses cenários, o modelo atingiu resultados maiores quando previstos com o conjunto validação, mesmo não sendo os melhores resultados entre os modelos. Dessa forma, não é possível afirmar que ocorreu um *overfitting*, visto que o modelo não se ajustou muito bem para o conjunto anterior.

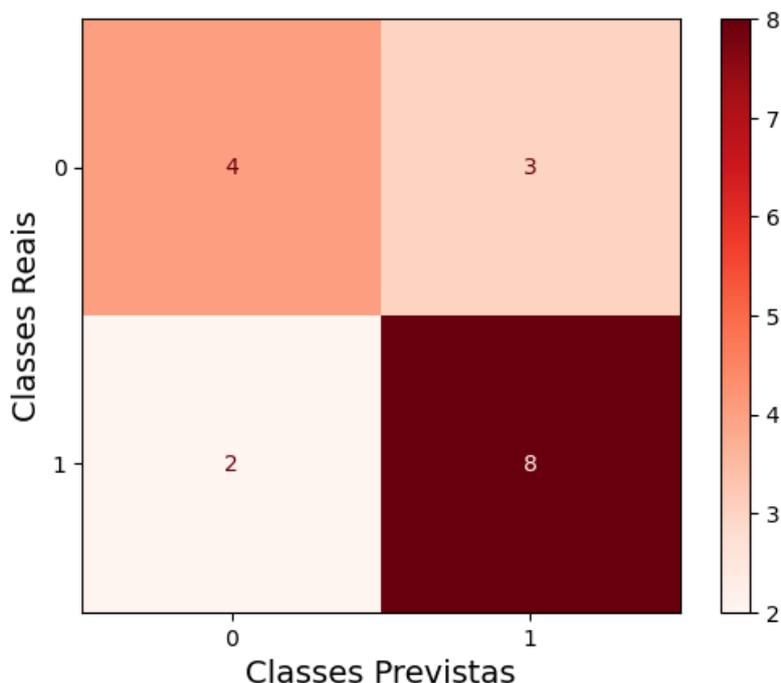
A técnica de PCA se mostrou mais poderosa quando comparada às demais, com exceção do modelo RF. Além de atingir alguns resultados superiores de desempenho, a utilização de PCA em um modelo reduz bastante a dimensionalidade, reduzindo o custo

computacional. Com apenas 5 componentes principais, o modelo conseguiu ter resultados semelhantes e até melhores que os demais modelos, que contam com mais parâmetros. O modelo sem nenhuma técnica de pré-processamento, por exemplo, conta com 54 parâmetros de entrada, aproximadamente 11x mais.

Foram geradas matrizes de confusão para os cenários de melhor *accuracy* de cada modelo, de forma a evidenciar quais foram as previsões para o conjunto de teste. A Figura 30 apresenta a matriz de confusão para o modelo DT utilizando PCA. Na Figura 31, pode-se ver o resultado para o modelo RF, que teve o pior desempenho entre os 4 modelos. A matriz de confusão para a ANN é exibida na Figura 32. Por fim, a Figura 33 apresenta a matriz para o modelo SVM.

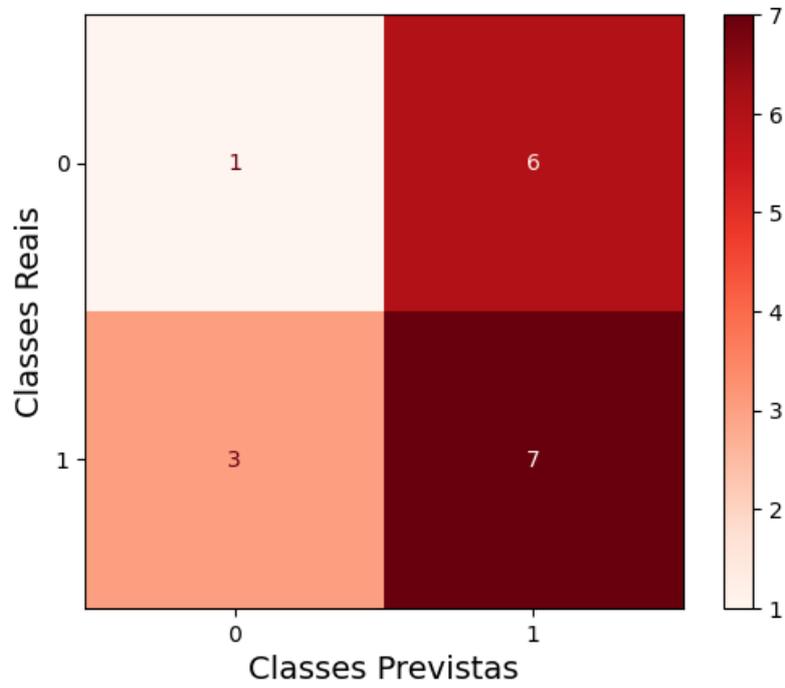
As 4 métricas utilizadas (*accuracy*, *precision*, *recall* e *f1-score*) podem ser calculadas a partir dessas matrizes, conforme relatado na seção 2.7. Foi possível obter uma maior taxa de acerto para os casos de Verdadeiro Positivo (VP) do que Verdadeiro Negativo (VN), resultado esse que era esperado. O conjunto de dados é desbalanceado, contendo mais casos com saída positiva, que representa a presença de esquizofrenia. Sendo assim, existem mais casos VP que VN, resultando em mais casos treinados para essa classe e mais amostras para validação e teste.

Figura 30 – Matriz de Confusão para DT.



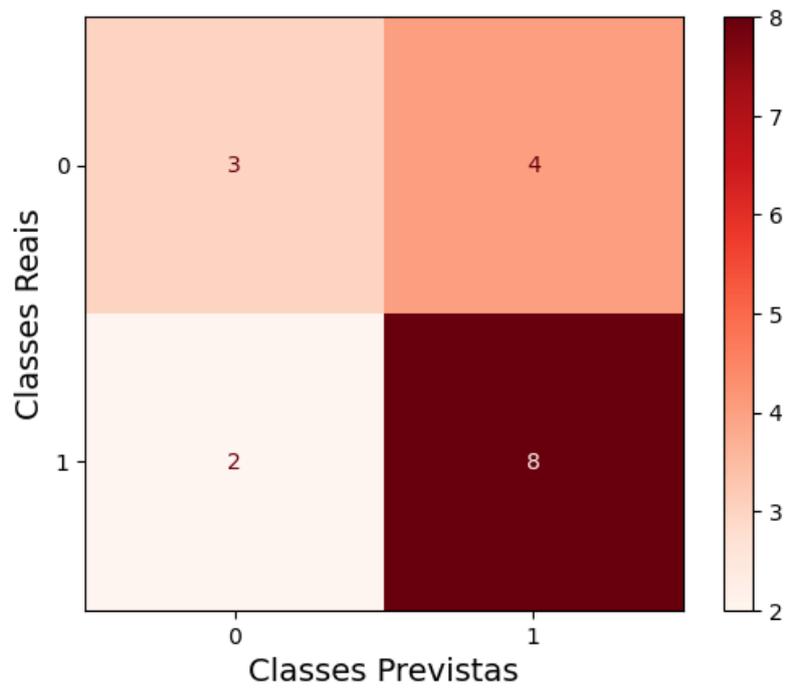
Fonte: do Autor

Figura 31 – Matriz de Confusão para RF.



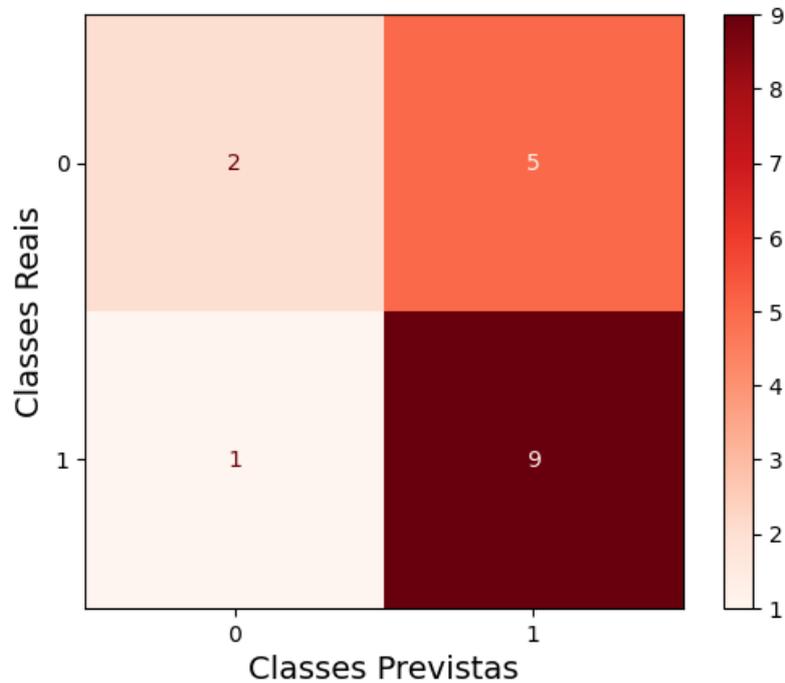
Fonte: do Autor

Figura 32 – Matriz de Confusão para ANN.



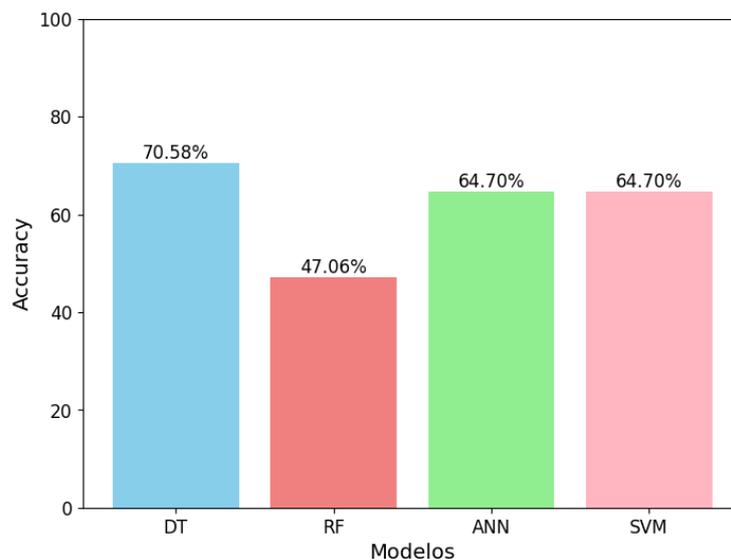
Fonte: do Autor

Figura 33 – Matriz de Confusão para SVM.



Fonte: do Autor

A Figura 34 apresenta os valores obtidos para a técnica de PCA da melhor topologia para cada um dos 4 modelos após a otimização de hiperparâmetros utilizando o conjunto de validação. Os valores iguais dos modelos de ANN e SVM se dão pelo fato de o conjunto de teste ter poucas amostras, aumentando bastante a chance de resultados semelhantes. A *accuracy* atingida pela DT representa apenas 1 previsão correta a mais.

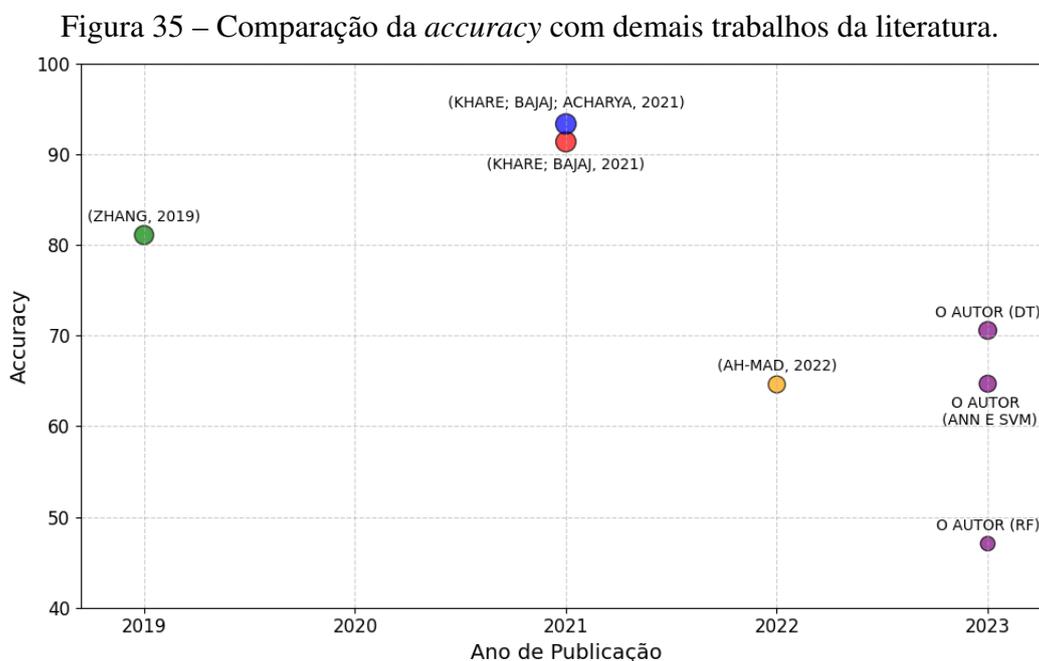
Figura 34 – Comparação da *accuracy* para os 4 modelos utilizando PCA.

Fonte: do Autor

Um ponto essencial que influenciou negativamente nos resultados é o tamanho do conjunto de entrada. Apesar de o conjunto de dados inicialmente contar com milhões de linhas de medições, apenas 81 indivíduos participaram do estudo. A classe de saída é a presença ou não do transtorno, tendo apenas uma classificação possível para cada indivíduo. Sendo assim, o conjunto, após passar pelas etapas de tratamento e pré-processamento de dados, foi composto por 81 dados de entrada apenas. Desses 81, 60% foi utilizado para treinamento, restando 20% para validação e 20% para teste. Isso significou um tamanho de 16 e 17 amostras para validação e teste, respectivamente. Com isso, o peso de cada amostra no resultado final se torna muito relevante, além de ter poucas amostras para realizar um treinamento mais efetivo de cada modelo.

4.4 Comparação com trabalhos da literatura

O conjunto de dados original foi utilizado em alguns trabalhos presentes na comunidade. A Figura 35 apresenta um comparativo da *accuracy* obtida nesses trabalhos com os resultados dos 4 modelos trabalhos na monografia, todos com a aplicação de PCA, sem normalização e sem remoção de variáveis a partir do *heatmap*.



Fonte: do Autor

O desempenho da DT para o conjunto de teste atingiu um resultado melhor que a rede desenvolvida no estudo AHMAD (2022), que aplicou uma CNN. A Rede Neural desen-

volvida no presente trabalho obteve um resultado semelhante à Rede Neural Convolucional no estudo citado. Os demais trabalhos, porém, conseguiram resultados mais satisfatórios, alcançando 93,36% no estudo realizado no artigo KHARE; BAJAJ; ACHARYA (2021), no qual foi desenvolvida uma Rede Neural Convolucional em combinação com análises de tempo-frequência.

Um fator que influenciou nesses resultados melhores é a forma que o conjunto de dados foi utilizado. Pelas informações que foram disponibilizadas nos artigos, os demais trabalhos aplicaram o treinamento para as 3 atividades, utilizando diversas entradas para cada indivíduo. Dessa forma, havia mais dados para treinar cada modelo, resultando em desempenhos melhores.

Outro ponto a ser considerado é a quantidade de parâmetros de cada modelo. Nos modelos apresentados nessa monografia, a maior quantidade de parâmetros foi de 54, nos casos em que não foi aplicada a extração de características ou remoção de parâmetros através da correlação entre variáveis, reduzindo para apenas 5 na topologia utilizando PCA. Modelos apresentados no estudo KHARE; BAJAJ; ACHARYA (2021) ultrapassaram 60 milhões de parâmetros treináveis utilizando CNN. Uma quantidade menor de parâmetros torna o modelo mais rápido, podendo ser vantajoso em alguns cenários.

5 CONCLUSÕES

O presente trabalho traz formas diversas de tratar os dados de EEG baseado no tipo de tarefa aplicada na análise de ERP. A correta escolha dos eletrodos se faz muito necessária, visto que a atividade cerebral em decorrência dos estímulos utilizados no exame é mais presente nas regiões centrais, próximo ao córtex motor e córtex somatossensorial.

A forma de tratar as medições, no entanto, não é tão evidente. A abordagem escolhida foi a extração de algumas características do sinal elétrico, após a separação dos dados em segmentos de 3s, sendo 1,5s antes da tarefa e 1,5s depois. Os instantes antes da tarefa são importantes para o entendimento do sistema de previsão que ocorre em nosso sistema cerebral, através da cópia eferente do ato motor e da descarga corolária. As diferenças, porém, não são perceptíveis apenas pela análise das curvas dos sinais elétricos, motivo que favorece o uso da inteligência artificial e do aprendizado de máquina para o correto diagnóstico de esquizofrenia.

A técnica de PCA para extração de características do conjunto de dados se mostrou de certa forma eficiente, reduzindo em mais de 90% a quantidade de parâmetros, com uma pequena redução no desempenho dos modelos. Com mais amostras, é possível reduzir essa diferença de desempenho, mantendo a grande redução de parâmetros. O mapa de calor, utilizado para remoção de variáveis com alta correlação, foi eficiente na redução dos parâmetros, reduzindo para 28 de um total inicial de 54. Ele também foi importante para comprovar a variabilidade das componentes principais utilizadas na análise de PCA. A normalização dos dados, porém, não apresentou resultado relevante positivamente. Isso se deve ao fato de os valores extraídos dos sinais possuírem mesmas grandezas, o que torna a normalização uma etapa não tão necessária.

Quanto aos métodos, o que apresentou resultados mais satisfatórios foi a Árvore de Decisão, atingindo uma *accuracy* de 70,58%. O método de Floresta Aleatória, que é com-

posto por múltiplas árvores de decisão, apresentou o pior desempenho. Uma explicação para esse fato está na quantidade de amostras utilizadas para treinamento, não sendo o suficiente para permitir uma boa generalização do modelo com tantas árvores envolvidas, visto que a menor quantidade utilizada foi de 50 árvores. Os modelos ANN e SVM apresentaram resultados semelhantes, chegando a 64,7% de *accuracy*.

5.1 Contribuições

Entendendo o que foi executado e traçando vínculos com as regiões do cérebro, os canais utilizados em exames de EEG especificamente para o diagnóstico da esquizofrenia podem ser otimizados, de forma a captar a atividade cerebral mais relativa às atividades executadas. A extração de características dos sinais em resposta a esses estímulos pode ser uma abordagem importante para atingir o objetivo de auxiliar no diagnóstico médico do transtorno.

As técnicas de extração de características e pré-processamento discutidas nessa monografia podem contribuir com trabalhos futuros sobre o tema, utilizando novas combinações, com diferentes conjuntos de dados e outros modelos de ML. Os resultados obtidos na utilização de PCA contribuem para a redução do custo computacional, podendo ser uma alternativa estudada futuramente para aplicações em *hardwares* limitados, caso necessário, com o objetivo de ampliar o acesso ao diagnóstico e reduzir seus custos.

5.2 Trabalhos Futuros

O desempenho obtido no estudo demonstra que há margem para melhorias nas topologias, tanto na escolha dos modelos e hiperparâmetros, como nas técnicas utilizadas para extração de *features* e pré-processamento. A aplicação de Redes Neurais Artificiais mais complexas, como as Convolucionais, pode ser uma alternativa promissora caso seja aplicada a um conjunto de dados com mais amostras.

Apesar da base de dados ser bem completa, contando com mais de 70 medições de canais distintos, e também possuir alguns dados pessoais, ela é bem reduzida na quantidade de indivíduos, o que prejudicou bastante os resultados obtidos. A ampliação desse conjunto de dados, de forma a obter mais amostras de novos indivíduos, permitiria um treinamento mais eficiente e, por consequência, resultados de previsão melhores. Esse é

um dos aspectos responsáveis pelo desempenho dos modelos não ter sido maior.

Outra abordagem interessante de ser estudada e aprofundada é a análise de ERP dos mesmos canais para intervalos de frequência de acordo com as ondas Delta (δ), Theta (θ), Alfa (α), Beta (β) e Gama (γ), podendo ser feito utilizando filtros *Butterworth*. Dessa forma, seria possível estudar a influência de cada tipo de onda nos eventos aplicados através da análise de ERP em sinais de EEG. A faixa de frequência de 13 até 30 Hz, correspondente às ondas Beta, está associada a estados de atenção, concentração e atividade mental, possivelmente tendo um resultado mais claro durante a execução da tarefa proposta no estudo original.

Por fim, uma direção promissora para trabalhos futuros envolve a validação dos resultados por meio da aplicação dos modelos a conjuntos de dados provenientes de clínicas médicas ou hospitais, em colaboração com profissionais de saúde. Essa abordagem poderia contribuir significativamente para o aprimoramento do diagnóstico do transtorno.

REFERÊNCIAS

AHMAD, O. **Training of EEG Schizophrenia Disorder using CNN**. Disponível em: <<https://www.kaggle.com/code/owaiskhan9654/training-of-eeg-schizophrenia-disorder-using-cnn>>. Acesso em: 19/08/2023.

ANALISAR, L. G. V. **Regressão linear**: um dos tipos mais importantes de análise de dados. Disponível em: <<https://vamosanalisar.wordpress.com/2019/07/17/regressao-linear-um-dos-tipos-mais-importantes-de-analise-de-dados/>>. Acesso em: 25/07/2023.

BAŞAR, E. *et al.* Gamma, alpha, delta, and theta oscillations govern cognitive processes. **International journal of psychophysiology**, v. 39, n. 2-3, p. 241–248, 2001.

BIOSEMI. **Active electrodes**. Disponível em: <https://biosemi.com/pin_electrode.htm>. Acesso em: 18/08/2023.

BREIMAN, L. Random forests. **Machine learning**, v. 45, p. 5–32, 2001.

CLEVERT, D.-A.; UNTERTHINER, T.; HOCHREITER, S. Fast and accurate deep network learning by exponential linear units (elus). **arXiv preprint arXiv:1511.07289**, 2015.

DE FILIPPIS, R. *et al.* Machine learning techniques in a structural and functional MRI diagnostic approach in schizophrenia: a systematic review. **Neuropsychiatric disease and treatment**, p. 1605–1627, 2019.

FOR DEVELOPERS, G. **Conceitos de ML**: classificação. Disponível em: <<https://developers.google.com/machine-learning/crash-course/classification/video-lecture>>. Acesso em: 29/07/2023.

FORD, J. M. *et al.* Did I do that? Abnormal predictive processes in schizophrenia when button pressing to deliver a tone. **Schizophrenia bulletin**, v. 40, n. 4, p. 804–812, 2014.

GAO, X. *et al.* Recurrent neural networks for real-time prediction of TBM operating parameters. **Automation in Construction**, v. 15, p. 130–140, 01 2019.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. MIT press, 2016.

HAAS, L. F. Hans berger (1873–1941), richard caton (1842–1926), and electroencephalography. **Journal of Neurology, Neurosurgery & Psychiatry**, v. 74, n. 1, p. 9–9, 2003.

IBM. **What is random forest?** Disponível em: <<https://www.ibm.com/topics/random-forest>>. Acesso em: 21/07/2023.

IBM. **What is deep learning?** Disponível em:

<<https://www.ibm.com/topics/deep-learning>>. Acesso em: 14/04/2023.

IHME. **Global Burden of Disease (GBD) Results.** Disponível em:

<<https://vizhub.healthdata.org/gbd-results/?params=gbd-api-2019-permalink/4fbcffce62eb73acf7d41ff995b81909>>. Acesso em: 05/04/2023.

KEBOOLA. **A Guide to Principal Component Analysis (PCA) for Machine Learning.** Disponível em: <<https://www.keboola.com/blog/pca-machine-learning>>. Acesso em: 25/07/2023.

KHARE, S. K.; BAJAJ, V. A self-learned decomposition and classification model for schizophrenia diagnosis. **Computer Methods and Programs in Biomedicine**, v. 211, p. 106450, 2021.

KHARE, S. K.; BAJAJ, V.; ACHARYA, U. R. SPWVD-CNN for automated detection of schizophrenia patients using EEG signals. **IEEE Transactions on Instrumentation and Measurement**, v. 70, p. 1–9, 2021.

LIU, L. T. *et al.* Delayed impact of fair machine learning. *In*: INTERNATIONAL CONFERENCE ON MACHINE LEARNING, 2018. **Proceedings [...]** 2018. p. 3150–3158.

LIU, X. *et al.* A comparison of deep learning performance against health-care professionals in detecting diseases from medical imaging: a systematic review and meta-analysis. **The lancet digital health**, v. 1, n. 6, p. e271–e297, 2019.

LUFT, C.; ANDRADE, A. A pesquisa com EEG aplicada à área de aprendizagem motora. **Rev Port Cien Desp**, v. 6, n. 1, p. 106–15, 2006.

MCCARTHY, J. *et al.* A proposal for the dartmouth summer research project on artificial intelligence, august 31, 1955. **AI magazine**, v. 27, n. 4, p. 12–12, 2006.

MILLETT, D. Hans Berger: from psychic energy to the eeg. **Perspectives in biology and medicine**, v. 44, n. 4, p. 522–542, 2001.

MINSKY, M.; PAPERT, S. An introduction to computational geometry. **Cambridge tiass., HIT**, v. 479, n. 480, p. 104, 1969.

NIH. **Brain Basics: know your brain.** Disponível em:

<<https://www.ninds.nih.gov/health-information/public-education/brain-basics/brain-basics-know-your-brain>>. Acesso em: 18/08/2023.

PEDREGOSA, F. *et al.* Scikit-learn: machine learning in Python. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.

RIEG, T. *et al.* High-performance detection of alcoholism by unfolding the amalgamated EEG spectra using the Random Forests method. **abc**, 2019.

ROACH, B. **EEG data from basic sensory task in Schizophrenia.** Disponível em: <<https://www.kaggle.com/datasets/broach/button-tone-sz>>. Acesso em: 22/04/2023.

ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. **Psychological review**, v. 65, n. 6, p. 386, 1958.

RUMELHART, D. E. *et al.* **Learning internal representations by error propagation**. Institute for Cognitive Science, University of California, San Diego La . . . , 1985.

RUSSELL, S. J.; NORVIG, P. **Artificial Intelligence: a modern approach**, 4th ed. Pearson Education, Inc., 2021.

SCHIRRMESTER, R. T. *et al.* Deep learning with convolutional neural networks for EEG decoding and visualization. **Human brain mapping**, v. 38, n. 11, p. 5391–5420, 2017.

SCHLOSSER, K. *et al.* High-performance exclusion of schizophrenia using a novel machine learning method on EEG data. *In: IEEE INTERNATIONAL CONFERENCE ON E-HEALTH NETWORKING, APPLICATION & SERVICES (HEALTHCOM)*, 2019., 2019. **Proceedings [...]** 2019. p. 1–6.

SHEHAB, M. *et al.* Machine learning in medical applications: a review of state-of-the-art methods. **Computers in Biology and Medicine**, v. 145, p. 105458, 2022.

SILVA, A. M. *et al.* Esquizofrenia: uma revisão bibliográfica. **UNILUS Ensino e Pesquisa**, v. 13, n. 30, p. 18–25, 2016.

STEINER, D. F. *et al.* Impact of deep learning assistance on the histopathologic review of lymph nodes for metastatic breast cancer. **The American journal of surgical pathology**, v. 42, n. 12, p. 1636, 2018.

TOPOL, E. **Deep medicine: how artificial intelligence can make healthcare human again**. Hachette UK, 2019.

ULAS, A. *et al.* Biomarker evaluation by multiple Kernel learning for schizophrenia detection. *In: SECOND INTERNATIONAL WORKSHOP ON PATTERN RECOGNITION IN NEUROIMAGING*, 2012., 2012. **Proceedings [...]** 2012. p. 89–92.

ZHANG, G. **What is the kernel trick? Why is it important?** Disponível em: <<https://medium.com/@zxr.nju/what-is-the-kernel-trick-why-is-it-important-98a98db0961d>>. Acesso em: 22/07/2023.

ZHANG, L. EEG signals classification using machine learning for the identification and diagnosis of schizophrenia. *In: EMBC*, 2019., 2019. **Proceedings [...]** 2019. p. 4521–4524.