



Universidade Federal do ABC  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas  
Programa de Graduação em Engenharia de Informação

**Classificação de pacientes com doença de  
Alzheimer e traumatismo cranioencefálico  
usando Deep Learning em sinais de  
eletroencefalograma**

**Thaís Soares Pereira, William Andrade Colosalle Lima**

**Santo André - SP, Agosto de 2024**

Thaís Soares Pereira, William Andrade Colosalle Lima

**Classificação de pacientes com doença de Alzheimer e  
traumatismo cranioencefálico usando Deep Learning em  
sinais de eletroencefalograma**

**Trabalho de Graduação** apresentado ao curso de Engenharia de Informação da Universidade Federal do ABC, como parte dos requisitos necessários para a obtenção do grau de Bacharel em Engenharia de Informação.

Universidade Federal do ABC – UFABC

Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas

Programa de Graduação em Engenharia da Informação

Orientador: Francisco José Fraga da Silva

Santo André - SP

Agosto de 2024

---

Thaís Soares Pereira, William Andrade Colosalle Lima

Classificação de pacientes com doença de Alzheimer e traumatismo cranioencefálico usando Deep Learning em sinais de eletroencefalograma/ Thaís Soares Pereira, William Andrade Colosalle Lima. – Santo André - SP, Agosto de 2024-  
28 p. : il. (algumas color.) ; 30 cm.

Orientador: Francisco José Fraga da Silva

Trabalho de Graduação – Universidade Federal do ABC – UFABC  
Centro de Engenharia, Modelagem e Ciências Sociais Aplicadas  
Programa de Graduação em Engenharia da Informação, Agosto de 2024.

1. Palavra-chave1. 2. Palavra-chave2. I. Orientador. II. Universidade xxx. III. Faculdade de xxx. IV. Título

CDU 02:141:005.7

---

# Agradecimentos

O desenvolvimento deste Trabalho de Graduação contou com a ajuda, direta ou indiretamente, de diversas pessoas, dentre as quais agradecemos:

Ao professor Francisco José Fraga da Silva, que desde o primeiro momento de contato sobre o Trabalho de Graduação nos prestou todo auxílio necessário para a elaboração do projeto.

Aos professores do curso de Engenharia de Informação e da UFABC, que contribuíram para nosso processo de formação e processo de aprendizagem através de suas aulas e também de atividades extra classe.

Aos nossos pais e familiares, que nos incentivaram a cada momento e deram todo o suporte para concluir os estudos.

Aos nossos colegas, que enriqueceram as horas de estudos individuais através de discussões que foram fundamentais ao processo de aprendizado e também nos trabalhos e estudos em grupo.

# Resumo

O traumatismo cranioencefálico (TCE) é uma lesão causada por uma força externa, geralmente durante uma atividade esportiva, quedas ou acidentes de carro. Já a doença de Alzheimer (DA) é uma doença progressiva que destrói funções mentais importantes, como a memória, e acomete principalmente a população idosa. É possível correlacionar alterações no exame de eletroencefalograma (EEG) com o comprometimento cognitivo na DA e com as lesões cerebrais causadas pelo TCE. O objetivo deste trabalho é utilizar o exame EEG para classificar pacientes com TCE, diferenciando-os de pacientes com DA, utilizando técnicas de Aprendizado Profundo. No geral, os resultados obtidos pelo classificador foram satisfatórios para a tarefa de classificar a DA, mas não para classificar o TCE.

**Palavras-chaves:** doença de Alzheimer, traumatismos encefálicos, eletroencefalografia, análise de EEG, machine learning, redes neurais convolucionais, EEGNet.

# Abstract

Traumatic brain injury (TBI) is an injury caused by an external force, usually during sports activities, falls or car accidents. Alzheimer's disease (AD) is a progressive disease that destroys important mental functions, such as memory, and mainly affects the elderly population. It is possible to correlate changes in the electroencephalogram (EEG) exam with cognitive impairment in AD and with brain injuries caused by TBI. The objective of this study is to use the EEG exam to classify patients with TBI, differentiating them from patients with AD, using Deep Learning techniques. Overall, the results obtained by the classifier were satisfactory for the task of classifying AD, but not for classifying TBI.

**Keywords:** Alzheimer's disease, brain injuries, electroencephalography, EEG analysis, machine learning, convolutional neural network, EEGNet.

# Lista de ilustrações

Figura 1 – Exemplo de uma Escala de Glasgow. . . . .	4
Figura 2 – Touca usada para o exame EEG. . . . .	6
Figura 3 – Diagrama ilustrativo do sistema 10-20. . . . .	7
Figura 4 – Diagrama da arquitetura básica de uma CNN. . . . .	11
Figura 5 – Diagrama da arquitetura EEGNet (LAWHERN et al., 2018) . . . . .	11
Figura 6 – Matriz de confusão obtida pela validação LOSO na classificação DA x TCE. . . . .	21
Figura 7 – Matriz de confusão obtido pela validação 10-fold na classificação DA x TCE. . . . .	22

# Lista de tabelas

Tabela 1 – Parâmetros de cada camada da EEGNet utilizada. . . . .	18
Tabela 2 – Resultados dos sujeitos da base BCI Competition IV, dataset 2a (imagética motora de quatro classes). . . . .	20
Tabela 3 – Resultados da validação 10-Fold para cada fold na classificação DA x TCE. . . . .	22

# Lista de abreviaturas e siglas

EEG	Eletroencefalograma
DA	Doença de Alzheimer
TCE	Traumatismo Cranioencefálico
LEA	Lesão Encefálica Adquirida
CNN	Convolutional Neural Network
LOSO	Leave-One-Subject-Out
BCI	Brain-Computer Interface
CSP	Common Spatial Patterns

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
	Introdução	1
<b>2</b>	<b>LESÕES ENCEFÁLICAS</b>	<b>3</b>
2.1	Traumatismo Cranioencefálico	3
2.2	Doença de Alzheimer	5
<b>3</b>	<b>O EXAME DE ELETROENCEFALOGRAFIA</b>	<b>6</b>
<b>4</b>	<b>APRENDIZADO DE MÁQUINA</b>	<b>8</b>
4.1	Classificadores	9
4.2	Aprendizado Profundo	9
4.2.1	Redes neurais convolucionais	10
4.2.2	EEGNet	11
4.2.3	Outras arquiteturas especializadas para uso em EEG	13
<b>5</b>	<b>INTERFACE CÉREBRO-MÁQUINA</b>	<b>14</b>
<b>6</b>	<b>IMPLEMENTAÇÃO REALIZADA</b>	<b>15</b>
6.1	Validação do classificador do artigo de referência	15
6.1.1	Descrição do BCI Competition IV, Dataset 2a	15
6.2	Obtenção e preparação dos dados	16
6.3	Implementação do classificador	17
6.4	Validação do classificador	17
6.4.1	Validação Leave One Subject Out (LOSO)	18
6.4.2	Validação 10-Fold	18
<b>7</b>	<b>RESULTADOS</b>	<b>20</b>
7.1	Validação do classificador BCI	20
7.2	Validação LOSO	20
7.3	Validação 10-Fold	21
<b>8</b>	<b>CONCLUSÕES</b>	<b>23</b>
	REFERÊNCIAS	24

**APÊNDICES** **27**

**APÊNDICE A –** ..... **28**

**A.1** **Código do trabalho no GitHub** ..... **28**

# 1 Introdução

As Lesões Encefálicas Adquiridas (LEAs) são danos causados ao cérebro após o nascimento. Há diversas possíveis causas para essas lesões, como doenças degenerativas, traumatismo cranioencefálico, acidente vascular cerebral, infecções, tumores e outras. O que há de comum entre elas é o comprometimento de funções fundamentais do cérebro, como a memória e o raciocínio (FMUSP, 2015).

O traumatismo cranioencefálico (TCE) é uma das lesões cerebrais mais comuns. Suas causas podem ser bastante variadas e acometer diferentes partes do encéfalo, mas a causa mais comum pode ser associada a uma força mecânica externa aplicada ao crânio. Ela pode acontecer durante uma atividade esportiva, acidentes no trânsito, quedas e outros motivos diversos.

Já a Doença de Alzheimer (DA) é uma doença progressiva que acomete principalmente a população idosa. Há casos de indivíduos que apresentam DA de maneira precoce, em torno dos 40 anos, e que geralmente é associado a problemas genéticos ou outros contextos específicos (SMITH, 1999). No entanto, o grupo de pessoas com idade acima de 65 anos apresentam a doença com probabilidade que cresce exponencialmente com a idade.

Dentre as LEAs, as duas destacam-se em relevância para a medicina e para o sistema de saúde. O TCE é a lesão mais frequente e que acomete pacientes de todas as idades, visto que qualquer pessoa é suscetível a acidentes. Já a DA é uma doença que acomete metade da população idosa em países desenvolvidos e estudos mostram que os países em desenvolvimento apresentam a mesma tendência, que pode ser agravada com a secular mudança demográfica de envelhecimento populacional (IANOF, 2011). Por isso, o diagnóstico precoce pode ser fundamental para a resposta do paciente ao tratamento, melhorando sua qualidade de vida, mas também para políticas públicas de saúde.

O diagnóstico de lesões encefálicas adquiridas (LEAs) pode ser realizado por meio de exames de imagem e também pelo exame de eletroencefalografia (EEG), sendo que a análise deste último conta com diversas técnicas tradicionais, amplamente exploradas na literatura (NIEDERMEYER; SILVA, 2004b). Um exemplo dessas técnicas é a decomposição das ondas cerebrais em suas componentes de frequência por meio da transformada de Fourier (ACHARYA et al., 2015). Outro exemplo são os chamados potenciais evocados, nos quais é dado um estímulo ao paciente em um instante específico de tempo, como luzes, sons ou toques, e é analisada a resposta das ondas elétricas cerebrais detectadas pelo EEG (LUCK, 2014).

Outro método que tem sido bastante explorado recentemente para a análise de EEG é o uso de redes neurais, especialmente as redes neurais convolucionais. É inegável que

elas tem se mostrado bem sucedidas em variados problemas de classificação e regressão de dados temporais, imagens e outros. No que se refere às aplicações médicas, não é diferente: o emprego dessa classe de algoritmos entrega bons resultados em diagnósticos relacionados à patologias no cérebro, como o TDAH ([PEDROLLO, 2022](#)).

As redes neurais convolucionais possuem diversas arquiteturas, desenhadas para se especializarem em tarefas específicas. No contexto de análise de EEG, a arquitetura EEGNet, ao longo de diversas pesquisas, tem se mostrado muito bem sucedida no que tange os problemas de classificação e projetos de Interfaces Cérebro-Computador ou, do termo em inglês, Brain Computer Interfaces (BCI) ([LAWHERN et al., 2018](#)).

Dessa maneira, esse trabalho busca combinar o sucesso da arquitetura EEGNet com a importância das duas LEAs citadas anteriormente, de forma a construir um classificador baseado em redes neurais convolucionais que sejam capazes de separar pacientes com DA ou com TCE.

## 2 Lesões Encefálicas

Lesão Encefálica Adquirida (LEA) refere-se à lesão que ocorre no encéfalo após o nascimento, não estando relacionada a traumas durante o parto, doenças congênicas (adquiridas durante o desenvolvimento fetal) ou doenças hereditárias (SILVA et al., 2024).

Exemplos de LEAs incluem o Acidente Vascular Cerebral (AVC), neuroinfecções, tumores, Doença de Alzheimer e Traumatismo Cranioencefálico. Assim, nota-se que as LEAs englobam um vasto grupo de lesões que podem ser tanto doenças encefálicas quanto traumas de natureza física (PEIXOTO, 2015).

O paciente portador pode apresentar diversas consequências cognitivas, motoras, sociais, funcionais e em sua personalidade e humor. No âmbito motor e funcional, o paciente pode ter dificuldade no equilíbrio e coordenação, tremores, paralisias, dependência para fazer atividades cotidianas como vestir-se, alimentar-se ou tomar banho. Já nas capacidades cognitivas, pode apresentar dificuldades de concentração, na linguagem, memória e na capacidade de julgar, se planejar e tomar decisões (TABAQUIM; LIMA; CIASCA, 2013).

Por conta dessas consequências citadas, a qualidade de vida do indivíduo é bastante afetada por tal condição. Assim, é importante o rápido e eficiente diagnóstico para reduzir os impactos da lesão, que podem ser permanentes. Geralmente, podem ser detectadas através de exames de imagem, como exames de ressonância magnética ou tomografias, e também através do exame de Eletroencefalograma (EEG).

A Doença de Alzheimer e o Traumatismo Cranioencefálico se destacam entre causas bastante frequentes de LEAs. A primeira está entre as principais doenças encefálicas degenerativas, enquanto que a segunda é a principal lesão adquirida por causas mecânicas (CHEN; XU; LI, 2014).

### 2.1 Traumatismo Cranioencefálico

O traumatismo cranioencefálico (TCE) é um trauma adquirido durante a vida e não degenerativo, cujo causador é, normalmente, uma força externa forte o suficiente para causar uma lesão no crânio e encéfalo. Ele pode ser aberto, quando o dano fica exposto (como por exemplo quando causado por arma de fogo) ou fechado (FMUSP, 2015). Ele não possui um grupo de risco muito bem definido pois pode atingir indivíduos de qualquer idade, porém pessoas que praticam com frequência atividades das quais podem acontecer acidentes, como praticar esportes coletivos, estar diariamente no trânsito intenso ou até mesmo trabalhar com atividades arriscadas, podem ter mais chances de serem acometidos.

O quadro clínico do paciente é bastante variado, pois depende da intensidade

da força, a área do crânio que é atingida, a idade do paciente e muitos outros fatores. Mas, no geral, o paciente apresenta perdas cognitivas que podem ser permanentes ou temporárias, como de linguagem, de memória, capacidade de abstração e raciocínio e perda das capacidades motoras.

O diagnóstico se dá em algumas etapas, conforme a gravidade do caso. De início, o médico responsável pelo paciente deve fazer uma avaliação geral e rápida do trauma a fim de obter informações qualitativas sobre o quadro. Para obter mais detalhes sobre a gravidade, pode ser usada a escala de Glasgow, que sintetiza em uma tabela a severidade do quadro clínico de acordo com respostas que o paciente dá a estímulos oculares, verbais e motores (Brasil. Ministério da Saúde. Secretaria de Atenção à Saúde, 2015). Um exemplo de escala de Glasgow é mostrada na Figura 1.

Parâmetros	Escore
<b>Melhor resposta verbal</b>	
Nenhuma	1
Sons incompreensíveis	2
Palavras inadequadas	3
Confusa	4
Orientada	5
<b>Abertura dos olhos</b>	
Nenhuma	1
Resposta à dor	2
Resposta à fala	3
Espontânea	4
<b>Melhor resposta motora</b>	
Nenhuma	1
Descerebração (extensão anormal dos membros)	2
Decorticação (flexão anormal dos membros superiores)	3
Retirada	4
Localiza o estímulo doloroso	5
Obedece ao comando verbal	6
<b>TOTAL</b>	<b>15</b>

Figura 1 – Exemplo de uma Escala de Glasgow.

Ainda, pode fazer sentido realizar exames de imagem, como o exame de Tomografia Computadorizada (TC), sendo ele muito importante para detectar lesões imperceptíveis, com a observação de que o médico precisa ponderar o uso desse exame devido às consequências da exposição do paciente a radiação.

A reabilitação do paciente depende da severidade do trauma. Em casos mais leves, pode ser ministrado medicamentos para dores e alta hospitalar nas primeiras horas de atendimento, com repouso e observação domiciliar. Em casos mais graves, ele pode ser submetido ao centro cirúrgico para amenizar a pressão na cabeça ou reduzir o sangramento. Já nos casos de danos permanentes, o paciente deve fazer terapia a fim de estimular as capacidades cognitivas e se aproveitar da neuroplasticidade, tentando ao máximo fazer

com que o paciente tenha uma vida relativamente normal (KALMAR; FIGUEROA; MCMAHON, 2010).

## 2.2 Doença de Alzheimer

A Doença de Alzheimer (DA) é uma LEA neurodegenerativa progressiva e irreversível. Pacientes com DA apresentam atrofia cortical, perda neuronal e um grande número de placas senis. Ainda, de acordo com a literatura, acredita-se que o número de placas senis tenha correlação ao grau da DA. Sua evolução pode variar entre 5 e 10 anos e a expectativa de vida se reduz significativamente (SMITH, 1999).

Ela atinge majoritariamente idosos, mas também pode acometer adultos na faixa dos 40 anos devido a causas genéticas. Embora haja fatores hereditários que podem aumentar as chances de desenvolvimento da doença, alguns fatores externos referentes a hábitos e estilo de vida também são relevantes. Por exemplo, indivíduos com baixo nível educacional ou com baixa atividade física e mental durante a vida e a velhice podem ter mais chances de apresentar a DA (NEWTON et al., 2024).

Ainda assim, o fator idade é um dos principais. A mudança demográfica que os países desenvolvidos e em desenvolvimento apresentam, onde a idade média da população aumenta junto com a expectativa de vida e o avanço da medicina, faz com que as demências causadas pela idade tenham uma alta participação dentro da população. A DA, a mais importante das demências, é observada em mais de cinco milhões de pessoas nos Estados Unidos da América, número que deve triplicar nas próximas décadas e se repetir em outros países pelo mundo (SMITH, 1999).

Quanto ao diagnóstico, os médicos também podem se basear pelo histórico familiar, em testes psicológicos ou por exclusão para levantar suspeitas que o indivíduo tenha a doença. Porém, não é possível ter um parecer definitivo sem exames histológicos do cérebro (biópsia ou necrópsia). Também não há uma cura e os tratamentos existentes são feitos com o intuito de reduzir os sintomas ou tentar desacelerar a evolução da doença (HOLLAND; KESSLER, 2013).

### 3 O exame de Eletroencefalografia

O exame de Eletroencefalografia (EEG) consiste na aplicação de eletrodos no couro cabeludo do paciente e o registro das correntes ou potenciais elétricos emitidos espontaneamente pelo cérebro. Com isso, é possível construir um gráfico desses potenciais elétricos em função do tempo, chamado de Eletroencefalograma (EEG), para posterior estudo da atividade cerebral (NIEDERMEYER; SILVA, 2004a).

Apesar de antiga, as aplicações dessa técnica são muitas e incluem desde diagnósticos de doenças cerebrais e fisiológicas, como a Doença de Alzheimer, epilepsia e outras, quanto também o estudo e mapeamento do cérebro na ciência de base (HEEKEREN; MARRETT; UNGERLEIDER, 2008). Além disso, uma outra vantagem é o fato de o resultado do exame ser um sinal eletromagnético no domínio do tempo, o que abre muitas possibilidades de análises matemáticas usando teoria de sinais, bem como análises computacionais (NIEDERMEYER; SILVA, 2004a).

O equipamento completo para o exame conta com diversos componentes, como amplificadores, fios e cabos, softwares para aquisição e tratamento de dados, bem como a touca, que contém os eletrodos que tocam o couro cabeludo. Um exemplo de touca utilizada para o exame de EEG é mostrado na Figura 2.



Figura 2 – Touca usada para o exame EEG.

O número e configuração dos eletrodos, que no contexto de EEG são chamados de canais, podem variar desde 21 canais até 64 ou mais, caso seja necessário capturar atividades mais específicas. O sistema mais utilizado para mapeamento dos eletrodos é o sistema 10-20, onde os canais são nomeados e numerados de acordo com a posição após a divisão da cabeça do paciente em quatro regiões: frontal, central, parietal e occipital. Os

canais também recebem números que indicam se o eletrodo se encontra à direita (números pares), esquerda (números ímpares) ou na linha média do couro cabeludo (letra z). Dessa forma, um eletrodo nomeado como F4 se encontra na porção frontal direita, um eletrodo nomeado como C3 se encontra na porção central esquerda e um eletrodo nomeado de Pz se encontra na porção parietal da linha média do couro cabeludo.

A Figura 3 mostra uma ilustração da disposição dos eletrodos no sistema 10-20.

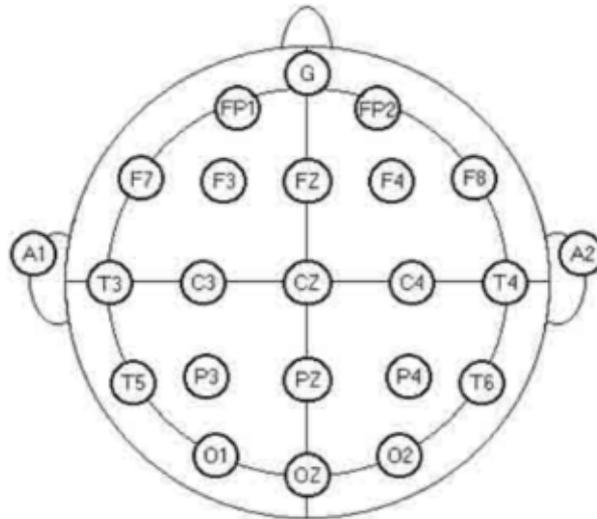


Figura 3 – Diagrama ilustrativo do sistema 10-20.

## 4 Aprendizado de Máquina

O Aprendizado de Máquina é um conjunto de técnicas computacionais, fortemente baseadas em métodos matemáticos e estatísticos, que permitem dar a uma máquina um certo nível de inteligência, no sentido de terem uma capacidade de generalização (GOODFELLOW; BENGIO; COURVILLE, 2016; BISHOP, 2006).

Para ilustrar essa ideia, é possível citar um exemplo de como nós, seres humanos, aprendemos a generalizar através de dados que nos são fornecidos pelo ambiente que estamos inseridos. Quando crianças, alguém nos mostra diversas imagens de cães e gatos e nos mostram que cada uma dessas imagens correspondem a um cão ou um gato. Diante disso, nosso cérebro imediatamente coleta detalhes das características físicas de cada animal, como por exemplo tamanho, formato das patas ou das orelhas e muitos outros, nos permitindo diferenciar um cão de um gato. Assim, sempre que observarmos um outro exemplo de um dos dois animais, vamos saber diferenciar, pois em algum momento nos foi ensinado quem é cada um. Em outras palavras, adquirimos capacidade de generalizar uma regra para um dado desconhecido.

Algoritmos de Aprendizado de Máquina têm sido cada vez mais usados para resolverem problemas ou automatizar tarefas que envolvam Classificação, Regressão, Agrupamento, Ranqueamento e Redução de Dimensionalidade. Alguns exemplos práticos disso são o processamento de linguagem natural, reconhecimento de voz e imagem, previsão de valores futuros em séries temporais e outros (MOHRI, 2021).

Por fim, podemos separar os processos de aprendizado em três: Aprendizado Supervisionado, Aprendizado Não Supervisionado e Aprendizado por Reforço (ALPAYDIN, 2014; SUTTON; BARTO, 2018; MURPHY, 2012). Para esse primeiro, no modelo de aprendizado devem ser apresentados os dados e as corretas saídas (rótulos) dos dados que esperamos que ele seja capaz de prever após ser treinado, como se estivesse aprendendo através de exemplos. Já no Aprendizado Não Supervisionado, os modelos procuram por si só padrões nos dados para tentar prever novas entradas. E o Aprendizado por Reforço se baseia em criar um sistema de recompensa e/ou punição para a máquina, de forma que sempre que ela executa corretamente uma tarefa, nós reforçamos esse comportamento através de uma função de recompensa e, caso contrário, podemos desincentivar as ações que não queremos que ela repita.

## 4.1 Classificadores

A classificação, um dos principais problemas que o Aprendizado de Máquina se propõe a resolver, se trata de tentar dizer a qual classe ou categoria pertence cada objeto. Por exemplo, é possível desenvolver um classificador de texto capaz de dizer se um determinado texto apresentado é do assunto política, esportes, negócios, etc.

Em outras palavras, de maneira mais formal, um classificador é uma função cujo domínio são os objetos a serem classificados e a imagem são as possíveis classes que ele pode classificar cada um dos objetos de entrada. O papel dos modelos preditivos de Aprendizado de Máquina é justamente tentar aproximar essa função, geralmente utilizando dados já pré-classificados como exemplos para aprender a minimizar o erro entre a classe classificada pelo modelo e a classe correta. Importante notar que os classificadores estão no grupo de modelos de Aprendizado Supervisionado, uma vez que se utilizam de dados pré-classificados para serem construídos.

Alguns exemplos de algoritmos famosos utilizados são (em inglês): Naive Bayes, Support Vector Machines, Artificial Neural Networks, K-Nearest Neighbors, Decision Trees e outros. É possível combinar mais de um classificador ou até mesmo utilizar várias instâncias de um deles para tentar melhorar a acurácia do modelo. Por exemplo, o método *Random Forest* utiliza várias Árvores de Decisão, ou *decision trees*, para lidar com classificações mais complexas, especialmente em cenários onde há um espaço não linear entre as classes (BREIMAN, 2001).

O problema de dizer se determinados pacientes têm TCE ou DA é também um problema de classificação, visto que para isso devemos tomar exemplos de exames de EEG cujos diagnósticos já são conhecidos e tentar desenvolver um modelo para prever entradas futuras não classificadas.

## 4.2 Aprendizado Profundo

O Aprendizado Profundo, também comumente denotado pelo seu nome em inglês, Deep Learning, é uma subcategoria dos algoritmos e técnicas que englobam o Aprendizado de Máquina.

Pode-se dizer que a diferença entre as técnicas convencionais de Aprendizado de Máquina e de Aprendizado Profundo se dá pela abstração dos dados em diferentes níveis ou camadas de especialização (GOODFELLOW; BENGIO; COURVILLE, 2016). Por exemplo, é possível tomar o problema de reconhecimento de imagem, onde são aplicadas técnicas de Aprendizado Profundo, e resolvê-lo através de uma Rede Neural em que uma parte da rede é responsável por reconhecer traços de mais alto nível, como apenas o formato do objeto, enquanto que outras partes se especializam em reconhecer detalhes do objeto.

De fato, as redes neurais são muito utilizadas para resolver tais problemas. É comum criar essa estrutura de especialização através de camadas na rede, onde cada uma funciona como uma unidade de processamento não linear, capaz de se especializar em cada tarefa. Dá para pensar na rede como tendo uma camada com a entrada dos dados, uma camada com a saída dos dados, e várias camadas escondidas. É usado esse termo escondido, ou *hidden layers* em inglês, devido ao fato de que normalmente não é possível ver as saídas de cada uma delas.

Algumas arquiteturas de Redes Neurais comuns de serem usadas nos modelos de Aprendizado Profundo são o Perceptron de Uma Camada, Perceptron de Várias Camadas, as Redes Neurais Convolucionais, as Redes Neurais Recorrentes, entre outras. Ainda, além de algoritmos inspirados no funcionamento de um cérebro biológico, como é o caso das Redes Neurais, no Aprendizado Profundo também há técnicas inspiradas em diversos outros campos do conhecimento, até mesmo na Teoria dos Jogos (BEYSOLOW, 2021).

Com o avanço da capacidade de processamento dos computadores modernos, essa área conseguiu crescer e se desenvolver muito, visto que esses algoritmos são complexos e requerem um grande poder computacional. Isso permitiu novas tecnologias emergentes surgirem pelo mundo, como por exemplo os carros autônomos, redes sociais, aplicativos com capacidades de reconhecimento de imagens ou áudio e até mesmo na área da Medicina.

### 4.2.1 Redes neurais convolucionais

As redes neurais convolucionais são uma classe de redes neurais, que tem sido muito bem sucedida em aplicações relacionadas a processamento de sinais temporais e também de imagens. Elas recebem esse nome pela existência de camadas que aplicam operações de convolução, que no contexto de processamento de sinais refere-se a operações de filtragem do sinal, que permitem a extração de características importantes, como por exemplo as bordas de um objeto em uma imagem (LECUN; BENGIO; HINTON, 2015).

A arquitetura de uma rede neural convolucional conta com camadas convolucionais, onde ocorre o processo de filtragem; com camadas de *pooling*, que fazem reduções de dimensionalidade para preservar características importantes e melhorar a robustez; e as camadas densas, onde existe alta densidade de conexão entre as camadas anteriores e a de saída. Cada uma dessas camadas são conectadas em sequência, isto é, a saída de uma camada é a entrada da próxima (GOODFELLOW; BENGIO; COURVILLE, 2016).

As redes neurais convolucionais possuem diversas variações, cada uma especializada em problemas específicos. São exemplos a LaNet, utilizada para detecção de dígitos manuscritos; AlexNet, para classificação de imagens; GoogleNet ou Inception, para detecção de objetos, dentre outras. A arquitetura utilizada neste projeto foi a EEGNet, que é especializada em análise de exames eletroencefalográficos. A Figura 4 ilustra a arquitetura

básica de uma CNN.

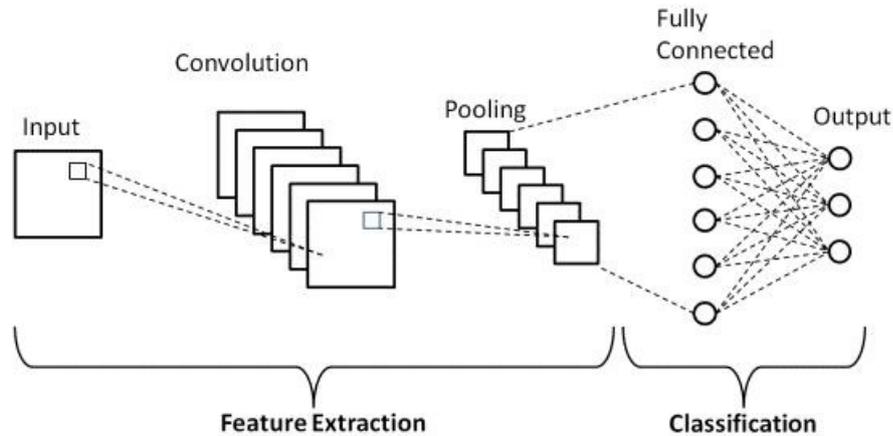


Figura 4 – Diagrama da arquitetura básica de uma CNN.

#### 4.2.2 EEGNet

A arquitetura EEGNet foi desenvolvida em 2018 no U.S. Army Research Laboratory com o intuito de apresentar uma arquitetura única capaz de resolver problemas de classificações de EEGs com um alto poder de generalização e que fosse suficientemente compacta para integrar com dispositivos portáteis com limitação de *hardware* (LAWHERN et al., 2018). Ela tem sido muito bem sucedida em tarefas de análises de sinais EEG, tais como diagnósticos clínicos, BCIs e em pesquisas de base na área de neurociência.

Sua arquitetura é bastante similar à de uma CNN convencional, mas com algumas modificações específicas para melhorar a eficiência em problemas relacionados aos sinais do EEG. A principal inovação da EEGNet reside em suas camadas convolucionais, que são adaptadas para lidar com a natureza dos sinais EEG. Em vez de usar uma única camada convolucional, a EEGNet utiliza duas camadas distintas: a camada de convolução espacial e a camada de convolução temporal. A Figura 5 ilustra a arquitetura de uma EEGNet.

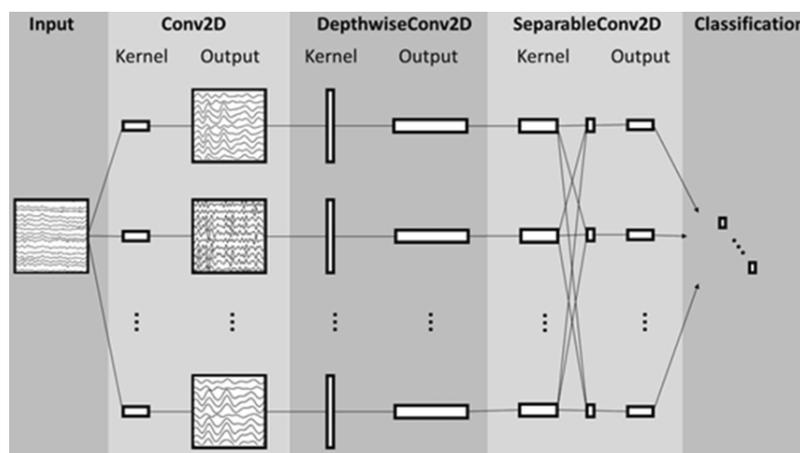


Figura 5 – Diagrama da arquitetura EEGNet (LAWHERN et al., 2018)

- **Camada de Convolução Espacial:** Esta camada é responsável por extrair características espaciais dos sinais EEG. Ela aplica filtros convolucionais para capturar padrões e características que estão relacionadas às regiões do córtex cerebral. No contexto dos EEGs, essa camada ajuda a identificar quais áreas do cérebro estão ativas durante a gravação dos sinais, permitindo a extração de informações espaciais significativas.
- **Camada de Convolução Temporal:** Em paralelo, a camada de convolução temporal é projetada para extrair características temporais dos sinais EEG. Ao aplicar filtros ao longo do tempo, essa camada é capaz de capturar a dinâmica temporal dos sinais, o que é crucial para entender como os padrões de atividade cerebral mudam ao longo do tempo. Isso é especialmente importante para a análise de eventos que ocorrem em diferentes momentos durante a gravação.

Além dessas camadas principais, a arquitetura da EEGNet inclui outras camadas e técnicas que contribuem para sua eficácia e eficiência:

- **Camadas de Pooling:** São utilizadas para reduzir a dimensionalidade dos dados e extrair as características mais relevantes, contribuindo para a redução de sobrecarga computacional e evitando o *overfitting*.
- **Camadas de Normalização:** Aplicadas para estabilizar e acelerar o treinamento da rede, ajudando a manter a aprendizagem mais consistente e eficiente.
- **Camadas de Dropout:** Implementadas para evitar o *overfitting*, essas camadas desativam aleatoriamente alguns neurônios durante o treinamento, forçando a rede a aprender representações mais robustas.

Uma vez que um dos principais focos da arquitetura EEGNet é ser compacta o suficiente para ser embarcada em dispositivos com restrição de *hardware*, ela não é a mais indicada quando é necessário capturar características altamente complexas do exame, sendo que para isso há outras arquiteturas. No entanto, é importante ressaltar que, apesar disso, ela ainda tem um ótimo balanço entre poder de aprendizado e eficiência computacional, o que a torna uma escolha valiosa para muitas aplicações práticas no campo dos EEGs.

### 4.2.3 Outras arquiteturas especializadas para uso em EEG

Além da arquitetura EEGNet, existem outras especializadas em sinais cerebrais, cada uma com suas vantagens e desvantagens.

Alguns exemplos de arquiteturas incluem DeepConvNet, ShallowConvNet, ResNet, Inception Networks, Temporal Convolutional Networks e HybridNet. Caso o problema exija a extração de padrões de alta complexidade, sem a restrição de recursos computacionais e com alta abundância de dados de treino, as mais indicadas são a DeepConvNet e HybridNet (SCHIRRMESTER et al., 2017; LAWHERN et al., 2018). Já em aplicações onde a eficiência computacional é relevante, as mais indicadas são a EEGNet, ShallowConvNet e Inception Networks (LAWHERN et al., 2018; SZEGEDY et al., 2016). Por fim, as Temporal Convolutional Networks são úteis quando a modelagem temporal é mais relevante para o problema (BAI; KOLTER; KOLTUN, 2018).

## 5 Interface Cérebro-Máquina

A interface cérebro-máquina (BCI) é uma tecnologia antiga, mas que começou a avançar e ganhar aplicações comerciais recentemente. Ela permite que o usuário controle diretamente um sistema mecânico ou dispositivos eletrônicos a partir de seus sinais cerebrais e sem necessidade de ativação muscular. Uma de suas mais importantes aplicações é na área médica, como por exemplo o controle de prótese de pacientes com falta de algum membro ou então na compensação de deficiências graves de comunicação ([GUBERT et al., 2019](#)).

Um paradigma particular do BCI é a imagética motora, cuja técnica geralmente consiste na análise do EEG para identificar padrões de sincronização e dessincronização, que estão relacionados a variação de energia em áreas corticais específicas. Assim, o sujeito imagina uma ação, como mover um braço ou fechar os olhos, e o sistema faz a inferência de qual movimento ele imaginou a partir de seu EEG.

Um sistema de imagética motora é composto pelas seguintes etapas: captação de dados e tratamento de ruído, remoção de artefatos (oculares, cardíacos, musculares, etc.), extração de características e um classificador. Para a etapa de extração de características, podem ser usadas as técnicas de *Common Spatial Patterns* (CSP), Transformada de Fourier de Tempo Curto, Algoritmos Genéticos, Bancos de Filtros e Desigualdades Matriciais Lineares ([MACHADO, 2018](#)).

## 6 Implementação Realizada

A fim de simplificar o entendimento dos passos que foram seguidos durante a implementação do processamento e classificação do sinal de EEG, pode-se dividi-la em quatro etapas: validação do classificador utilizado para o BCI Competiton, obtenção e preparação dos dados, implementação do classificador e validação do classificador. O código completo utilizado pode ser encontrado no GitHub, conforme a seção [A.1](#) do Apêndice.

### 6.1 Validação do classificador do artigo de referência

Antes de entrar na implementação da EEGNet para a base de dados de TCE e DA, o classificador do artigo de referência ([LAWHERN et al., 2018](#)) foi replicado a fim de apurar se seria possível chegar aos mesmos resultados descritos, e também oferecer um primeiro contato com a arquitetura criada pelos autores.

O artigo original aborda diversas bases de dados de EEG com as quais o método criado foi validado, mas o foco foi na base de dados BCI Competition IV, dataset 2a.

Os autores do artigo de referência ([LAWHERN et al., 2018](#)) abordaram o problema através de EEGNet e, a partir da documentação fornecida por eles no Github, foi possível instalar as bibliotecas e utilizar os códigos já criados como apoio para replicar o treinamento e teste da rede. Para esta base de dados, foi utilizada a mesma configuração utilizada pelos autores do artigo de referência ([LAWHERN et al., 2018](#)).

#### 6.1.1 Descrição do BCI Competition IV, Dataset 2a

É um conjunto de dados projetado para a competição de interfaces cérebro-computador (BCI) ([ANG et al., 2012](#)), que possui como objetivo a classificação de tarefas de imagética-motora. Esse tipo de tarefa representa um desafio frequente em interfaces cérebro-computador baseadas em EEG.

O conjunto de dados possui registros de EEG de nove participantes. Cada participante foi instruído a imaginar quatro tipos diferentes de movimentos: mão esquerda, mão direita, pés e língua. Esses tipos de tarefas de imagética-motora foram escolhidos como estímulos importantes no estudo, pois ativaram áreas cerebrais distintas, facilitando a classificação dos sinais de EEG ([ANG et al., 2012](#)).

Os sinais de EEG foram coletados utilizando 22 eletrodos posicionados conforme o sistema internacional 10-20. Esses eletrodos foram estrategicamente distribuídos afim de capturar a atividade nas áreas do córtex motor e pré-motor, fundamentais para tarefas de

imagética motora. Além dos sinais de EEG, também foram coletados três canais de EMG (eletromiografia), embora eles não tenham sido utilizados em todos os experimentos (ANG et al., 2012).

Cada ensaio de imagética motora teve uma duração que variou até aproximadamente 7,5 segundos. Durante esse período, os participantes visualizaram um sinal visual que indicava o tipo de movimento que deveriam imaginar, como a movimentação da mão esquerda, mão direita, pés ou língua. Após cada ensaio, houve uma fase de descanso em que os participantes mantinham uma atividade cerebral neutra. O experimento foi composto por 288 ensaios para cada participante, distribuídos igualmente entre as quatro classes de imaginação motora, com 72 ensaios por classe (ANG et al., 2012).

## 6.2 Obtenção e preparação dos dados

A base de dados utilizada neste trabalho foi obtida por meio de uma parceria com a Faculdade de Medicina da Universidade de São Paulo (FMUSP). O estudo foi aprovado pelo Comitê de Ética em Pesquisa (CAPPesq) do Hospital das Clínicas da Faculdade de Medicina da Universidade de São Paulo (FMUSP-HC). Todos os participantes recrutados forneceram consentimento por escrito.

Pacientes idosos diagnosticados com provável DA, conforme determinado pelo Instituto Nacional de Distúrbios Neurológicos e Comunicativos, com pontuações no Mini-Exame do Estado Mental de 13 a 29 – fase leve ou moderada – foram incluídos. Os indivíduos foram recrutados pelo Grupo de Neurologia Cognitiva e Comportamento do Departamento de Neurologia do FMUSP-HC. Os pacientes que participaram deste estudo tinham o diagnóstico de DA há menos de 6 meses.

Adicionalmente, a base de dados inclui indivíduos com 18 anos ou mais diagnosticados com TCE leve ou moderada (pontuações no Mini-Exame do Estado Mental de 13 a 28) na fase crônica e que apresentaram queixas de memória. Eles foram recrutados pelo Grupo de Reabilitação Cognitiva após TCE no Departamento de Neurologia do FMUSP-HC. Os indivíduos TCE que participaram deste estudo foram examinados na fase crônica (mais de 6 meses após TCE). Pacientes com TCE foram diagnosticados com base nos seguintes critérios: 1) Perda de consciência desde o momento da lesão que persistiu além de 6 h; 2) Nenhuma contusão hemorrágica aparente na tomografia computadorizada; 3) Presença de lesão da substância branca cerebral na ressonância magnética.

Os dados utilizados no processo de treinamento da rede foram obtidos já pré-processados com o software EEGLAB, que roda no ambiente Matlab, conforme descrito em (IANOF, 2011). A taxa de amostragem foi reduzida de 10.000 Hz para 1.000 Hz e, após uma filtragem passa-baixa com filtro Chebyshev de 5<sup>a</sup> ordem e frequência de corte em 115 Hz, foi novamente reamostrado para 400 Hz. Depois, foram aplicados dois filtros

Butterworth de 4ª ordem para eliminar interferências da rede elétrica (frequência de 60 Hz) e outro para remover flutuações muito lentas (passa-alta de 0.4 Hz). Eventos de abertura e fechamento dos olhos foram identificados e removidos com Independent Component Analysis do EEGLAB, assim como artefatos musculares e cardíacos. Por fim, os dados de EEG livres de artefatos foram separados em setenta épocas de 4s e foram armazenados em dois arquivos com extensão Matlab (.mat v7.3): um arquivo (cell array do Matlab) contendo o exame de 20 pacientes com DA e outro com 19 pacientes com TCE.

Cada unidade de cell array contém a série de dados temporais dos exames EEG de cada paciente, que se encontra em uma matriz tridimensional no formato (1600,64,70), sendo a primeira dimensão o número de observações de cada época de tamanho 4s a uma taxa de amostragem de 400Hz, a segunda dimensão o número de canais, que foi fixado em 64 para todos os sujeitos, e a terceira dimensão o número de épocas, que foi fixado em 70. Com auxílio da biblioteca h5py, foi definida uma função que carrega os arquivos e armazena os dados em uma matriz mais simples, indexada por paciente.

Dado que a arquitetura EEGNet aceita apenas matrizes de quatro dimensões como entrada, foi feita uma reformatação para atender a essa condição. Assim, a matriz final utilizada no treinamento apresenta um formato (1400,64,1600,1) para pacientes com DA e (1330,64,1600,1) para pacientes com TCE. Nesse formato, a primeira dimensão é a soma do número de épocas de todos os pacientes de cada classe juntos, a segunda dimensão é o número de canais, a terceira dimensão é o total de amostras em cada época e a quarta dimensão é unitária para representar apenas duas classes. Por fim, foi criado ainda um vetor preenchido apenas por zeros para representar a classe de DA e outro preenchido por uns para representar a classe TCE.

### 6.3 Implementação do classificador

A implementação foi feita em Python, utilizando as bibliotecas TensorFlow e Keras (TensorFlow Team, 2024). A função implementa a arquitetura EEGNet, contando com a camada de entrada e uma convolução 2D inicial, uma camada de convolução Depthwise, uma de Pooling e Dropout, uma de convolução separável, outra de Pooling, Dropout e Flatten e, finalmente, a saída. A função retorna o modelo compilado, que é usado no decorrer do código.

A tabela 1, a seguir, mostra os parâmetros da rede utilizados.

### 6.4 Validação do classificador

O classificador foi avaliado através de dois métodos distintos: validação Leave One Subject Out (LOSO) e validação 10-Fold. Ambas serão detalhadas adiante.

Tabela 1 – Parâmetros de cada camada da EEGNet utilizada.

Camada	Tipo	Parâmetros
<b>Conv2D</b>	Convolução 2D	Filtros:64, Kernel:(1,64)
<b>BatchNorm</b>	Normalização	-
<b>DepthwiseConv2D</b>	Convolução Profunda	Kernel:(1400,1), Depth Mult:2
<b>BatchNorm</b>	Normalização	-
<b>Activation</b>	ELU	-
<b>AvgPooling2D</b>	Pooling	Pool Size:(1,4)
<b>Dropout</b>	Regularização	Taxa:0.5
<b>SeparableConv2D</b>	Convolução Separável	Filtros:16,Kernel(1,16)
<b>BatchNorm</b>	Normalização	-
<b>Activation</b>	ELU	-
<b>AvgPooling2D</b>	Pooling	Pool Size:(1,8)
<b>Dropout</b>	Regularização	Taxa:0.5
<b>Dense</b>	Densa	Unidades:1, Ativação:Sigmoid

### 6.4.1 Validação Leave One Subject Out (LOSO)

A validação Leave One Subject Out (LOSO) foi escolhida por ser bastante utilizada no contexto de análise de dados biomédicos. Nela, os dados de treino e teste são separados por sujeito, ou seja, o classificador é treinado com todos os pacientes exceto um, que será utilizado para a validação, repetindo-se esse processo para cada um deles. Isso garante que o modelo seja testado com dados completamente independentes, simulando o funcionamento real do sistema. Ou seja, um paciente desconhecido será classificado com base em outros diagnósticos que já são conhecidos.

Para implementar esse método de validação, foi criada uma função que recebe a matriz de treinamento como parâmetro e, dentro de um laço de repetição, seleciona um sujeito para deixar de fora, treina o modelo com os demais sujeitos e imprime a matriz de confusão, fazendo a validação época a época. Caso o paciente deixado de fora tenha mais da metade de suas épocas classificadas corretamente, então o classificador aponta que o paciente foi corretamente classificado. O processo é repetido para todos os 39 pacientes do experimento. Para desenvolver essa validação, foram utilizadas ferramentas da biblioteca Scikit Learn ([SCIKIT-LEARN, 2007–2024](#)).

### 6.4.2 Validação 10-Fold

A validação 10-Fold é uma técnica de validação cruzada amplamente utilizada em problemas de classificação. Ela se baseia na divisão do conjunto de dados em dez partes de tamanhos aproximadamente iguais, e são feitas dez iterações, onde em cada uma delas uma parte é usada como conjunto de validação e as outras nove como conjunto de treinamento. De forma análoga à validação LOSO, uma nova função foi definida para esse método. Nela, a matriz de quatro dimensões é dividida em dez partes iguais e, também

---

através de um laço de repetição, cada uma dessas partes entra na base de dados de validação, enquanto as restantes são usadas para o treinamento. Da mesma forma, a matriz de confusão é impressa e o total de épocas corretamente classificadas é contada. Para desenvolver essa validação, também foram utilizadas ferramentas da biblioteca Scikit Learn ([SCIKIT-LEARN, 2007–2024](#)).

# 7 Resultados

Nesta seção será descrito o desempenho do modelo, de acordo com as metodologias de avaliação descritas anteriormente.

## 7.1 Validação do classificador BCI

Os resultados obtidos para cada um dos nove sujeitos da base utilizada são mostrados pela Tabela 2.

Tabela 2 – Resultados dos sujeitos da base BCI Competition IV, dataset 2a (imagética motora de quatro classes).

Sujeito	Acurácia
<b>Sujeito 1</b>	0.80
<b>Sujeito 2</b>	0.57
<b>Sujeito 3</b>	0.82
<b>Sujeito 4</b>	0.68
<b>Sujeito 5</b>	0.72
<b>Sujeito 6</b>	0.57
<b>Sujeito 7</b>	0.76
<b>Sujeito 8</b>	0.79
<b>Sujeito 9</b>	0.83

Com isso, é possível verificar que os resultados obtidos condizem com o que foi descrito pelo artigo de referência (LAWHERN et al., 2018). Nele, os autores obtiveram uma acurácia perto de 0.70 com o EEGNet. De fato, ao tomar a média de acurácia dos nove sujeitos, o resultado obtido é de 0.73, ligeiramente superior ao do artigo (LAWHERN et al., 2018). Ainda, nota-se que, dos nove sujeitos, apenas três ficam abaixo dos 0.70 de acurácia e dois deles passam dos 0.80.

## 7.2 Validação LOSO

Após o processo de treinamento, verificou-se que o modelo classificou corretamente 22 dos 39 pacientes, o que corresponde a uma taxa de acerto de 0.56. Em termos de épocas, ele classificou corretamente 1479 de 2730 épocas, o que resulta em uma taxa de acerto de 0.54. A Figura 6 mostra a matriz de confusão obtida.

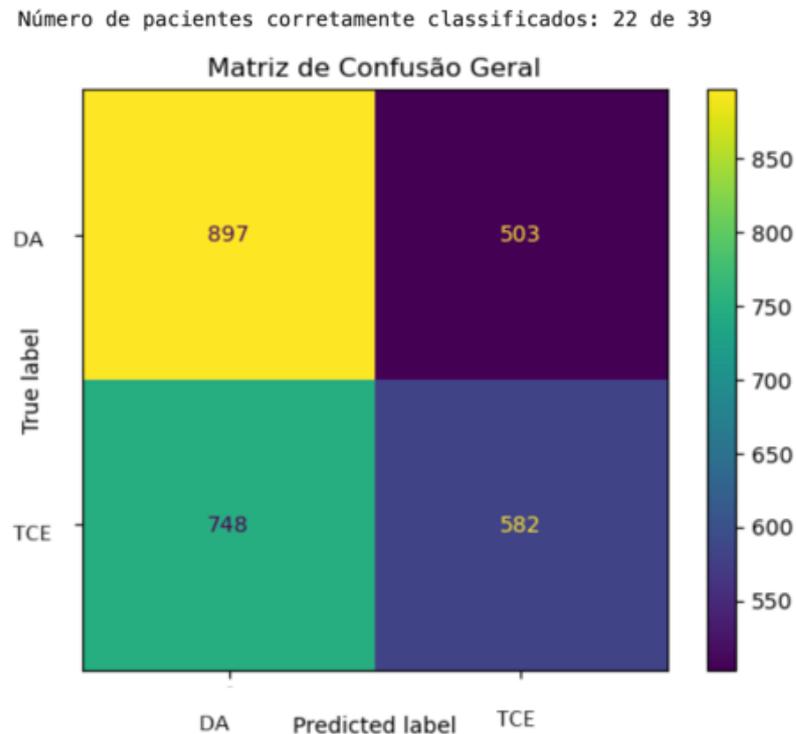


Figura 6 – Matriz de confusão obtida pela validação LOSO na classificação DA x TCE.

A partir da matriz de confusão, fica claro que o modelo tem um viés para classificar as épocas como DA. Isso pode ser percebido pelo fato de que 748 épocas em que a classe correta era TCE foram classificadas como DA, e que o número de classificações de TCE tende a ser menor que DA.

### 7.3 Validação 10-Fold

Para a metodologia de validação 10-fold, serão mostrados somente os resultados por épocas. Isso se deve ao fato de que os folds são separados por épocas, e não por sujeitos, como na validação LOSO.

Uma observação inicial que foi possível notar para a validação 10-fold é que o processo de treinamento e validação é bem menos custoso computacionalmente em relação a validação LOSO, visto que há apenas 10 folds para serem treinados e validados. De fato, o tempo de execução do algoritmo foi menos da metade do necessário para a validação LOSO.

Da mesma forma que na validação LOSO, pacientes com DA foram melhores classificados, e o classificador tende a apontar para a classe de DA com mais frequência. A taxa de acerto obtida para a classe de DA foi de 0.62; já para a classe TCE foi de 0.50. A Figura 7 mostra a matriz de confusão obtida.

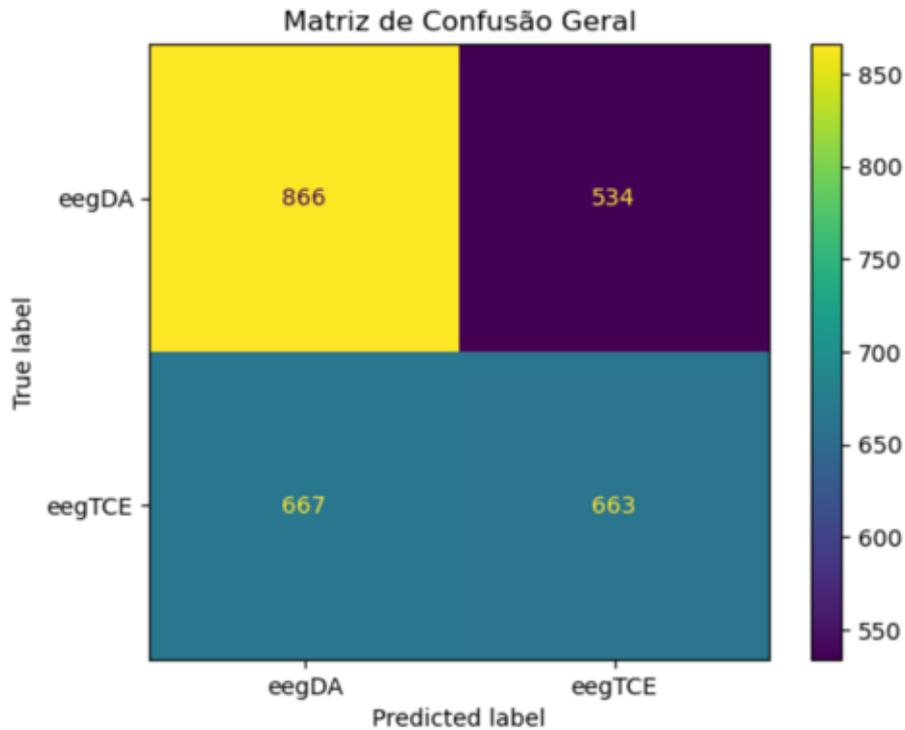


Figura 7 – Matriz de confusão obtido pela validação 10-fold na classificação DA x TCE.

Quando a análise é feita por fold, o resultado obtido é que 7 dos 10 folds apresentam taxa de acerto maiores ou iguais a 0.5. A Tabela 2 mostra o resultado para cada fold.

Tabela 3 – Resultados da validação 10-Fold para cada fold na classificação DA x TCE.

Fold	Taxa de acerto
<b>Fold 1</b>	0.59
<b>Fold 2</b>	1.00
<b>Fold 3</b>	0.62
<b>Fold 4</b>	0.58
<b>Fold 5</b>	0.26
<b>Fold 6</b>	0.18
<b>Fold 7</b>	0.41
<b>Fold 8</b>	0.76
<b>Fold 9</b>	0.57
<b>Fold 10</b>	0.51

## 8 Conclusões

Os resultados atingidos com o projeto cumprem parcialmente a proposta inicial, visto que o classificador consegue atribuir corretamente a classe DA para a maioria dos pacientes, porém não apresenta o mesmo desempenho para pacientes com TCE. Uma das possíveis explicações para isso é que as duas patologias estudadas possuem efeitos similares no exame de EEG dos pacientes, tornando difícil a separação das duas classes. Para reforçar essa afirmação, as pontuações de Mini-Exame do Estado Mental são praticamente idênticas para as duas classes: de 13 a 28 para TCE e de 13 a 29 para DA. Um outro motivo poderia ser também o fato de que o TCE trata-se de uma patologia bastante variada, como já dito anteriormente. Os motivos para adquirir essa patologia são variados e podem afetar áreas diferentes do cérebro, o que pode tornar os dados dos sujeitos dessa classe bastante variados e o modelo não conseguiu encontrar características fortes o suficientes para classificar os pacientes com TCE.

Como trabalhos futuros, pode-se pensar em treinar o classificador com pacientes com DA e sujeitos saudáveis e, posteriormente, pacientes com TCE e sujeitos saudáveis. O classificador poderia assim melhorar seu desempenho ao ser exposto a uma patologia por vez, justamente pelo fato de que isso poderia aumentar a separabilidade dos dados. Além disso, é possível pensar em fazer pré-processamentos nos dados de treino, como filtros e reamostragem, para trazer dados mais normalizados no processo de treinamento. Outras arquiteturas de maior complexidade e profundidade podem ser bem-vindas para o problema também, como por exemplo a *HybridNet*.

O custo computacional durante o processo de treinamento também é um ponto que pode ser melhorado, caso o classificador tivesse que ser treinado com um número maior de pacientes. Por fim, um estudo posterior do dataset para identificar novas características que possam separar as duas classes é um ótimo ponto de partida para um próximo passo.

# Referências

ACHARYA, U. R. et al. Eeg signal classification using wavelet transform and support vector machine. *International Journal of Wavelets, Multiresolution and Information Processing*, World Scientific, v. 13, n. 01, p. 1550001, 2015. Citado na página 1.

ALPAYDIN, E. *Introduction to Machine Learning*. Cambridge, MA: MIT Press, 2014. Provides a broad overview of machine learning techniques, including supervised, unsupervised, and reinforcement learning. Citado na página 8.

ANG, K. K. et al. Filter bank common spatial pattern algorithm on bci competition iv datasets 2a and 2b. *Frontiers in Neuroscience*, Frontiers Media SA, v. 6, 2012. Disponível em: <<https://doi.org/10.3389/fnins.2012.00039>>. Citado 2 vezes nas páginas 15 e 16.

BAI, S.; KOLTER, J.; KOLTUN, V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *Proceedings of the International Conference on Learning Representations (ICLR)*, p. 1–14, 2018. Citado na página 13.

BEYSOLOW, T. *Introduction to Deep Learning Using R: A Step-by-Step Guide to Learning and Implementing Deep Learning Models Using R*. New York: Apress, 2021. ISBN 978-1484265775. Citado na página 10.

BISHOP, C. M. *Pattern Recognition and Machine Learning*. New York: Springer, 2006. An essential textbook covering a broad range of machine learning techniques, with emphasis on statistical methods and theory. Citado na página 8.

Brasil. Ministério da Saúde. Secretaria de Atenção à Saúde. Diretrizes. *Diretrizes de atenção à reabilitação da pessoa com traumatismo cranioencefálico*. Brasília: Ministério da Saúde, 2015. 132 p. ISBN 978-85-334-2088-5. Citado na página 4.

BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001. Citado na página 9.

CHEN, Z.; XU, L.; LI, S. Traumatic brain injury and alzheimer's disease: Evidence from clinical and experimental studies. *Neuropsychiatric Disease and Treatment*, Dove Medical Press, v. 10, p. 723–734, 2014. Available at: <<https://doi.org/10.2147/NDT.S56309>>. Citado na página 3.

FMUSP, I. de Medicina Física e R. *Cuidado Nutricional na Lesão Encefálica Adquirida*. São Paulo, 2015. Edição não disponível, URL não aplicável. Citado 2 vezes nas páginas 1 e 3.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep Learning*. Cambridge, MA: MIT Press, 2016. A comprehensive introduction to deep learning techniques and methods, including mathematical foundations and applications. Citado 3 vezes nas páginas 8, 9 e 10.

GUBERT, P. H. et al. Uma contribuição à matriz de informações em sistemas bci baseados em imagética motora. In: *Anais do XXXVII Simpósio Brasileiro de Telecomunicações e Processamento de Sinais (SBrT2019)*. Petrópolis, RJ, Brasil: SBrT, 2019. Citado na página 14.

- HEEKEREN, H. R.; MARRETT, K.; UNGERLEIDER, J. M. The neural systems that mediate visual working memory and their role in cognitive tasks. *The Journal of Neuroscience*, Society for Neuroscience, v. 28, n. 23, p. 6122–6135, 2008. Discusses the role of EEG in visual working memory and other cognitive tasks. Citado na página 6.
- HOLLAND, A. J.; KESSLER, D. Diagnosis and management of neurodegenerative disorders. *The Lancet Neurology*, Elsevier, v. 12, n. 7, p. 620–630, 2013. Explores diagnostic criteria and management strategies for neurodegenerative disorders, including the use of histological exams and symptomatic treatment. Citado na página 5.
- IANO, J. N. *Análise Comparativa do Eletroencefalograma em Pacientes com Doença de Alzheimer e Lesão Axonal Difusa*. Dissertação (Tese de mestrado) — Universidade de São Paulo, 2011. Citado 2 vezes nas páginas 1 e 16.
- KALMAR, J.; FIGUEROA, L.; MCMAHON, R. Rehabilitation and recovery after traumatic brain injury: A review. *Brain Injury*, Taylor Francis, v. 24, n. 5, p. 562–573, 2010. Discusses various rehabilitation strategies and outcomes for traumatic brain injury patients. Citado na página 5.
- LAWHERN, V. J. et al. Eegnet: a compact convolutional neural network for eeg-based brain–computer interfaces. *Journal of Neural Engineering*, v. 15, n. 5, p. 056013, 2018. Disponível em: <<http://stacks.iop.org/1741-2552/15/i=5/a=056013>>. Citado 5 vezes nas páginas 11, 2, 13, 15 e 20.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. *Nature*, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015. A comprehensive review of deep learning techniques, including convolutional neural networks, their architectures, and applications in signal and image processing. Citado na página 10.
- LUCK, S. J. *An introduction to the event-related potential technique*. [S.l.]: MIT Press, 2014. Citado na página 1.
- MACHADO, G. S. *Análise do desempenho de técnicas de processamento de sinais para uma interface cérebro-computador baseada em imagética motora*. Dissertação (Mestrado) — Universidade Federal de Ouro Preto, Instituto de Ciências Exatas e Aplicadas, Departamento de Computação e Sistemas, João Monlevade, MG, 2018. Citado na página 14.
- MOHRI, M. *Foundations of Machine Learning*. 2nd. ed. Cambridge, MA: The MIT Press, 2021. ISBN 978-0262043797. Citado na página 8.
- MURPHY, K. P. *Machine Learning: A Probabilistic Perspective*. Cambridge, MA: MIT Press, 2012. Covers a wide range of machine learning methods, including supervised and unsupervised learning approaches. Citado na página 8.
- NEWTON, C. et al. Entorhinal-based path integration selectively predicts midlife risk of alzheimer’s disease. *Alzheimer’s Dementia*, Wiley, v. 20, n. 2, p. 123–134, 2024. First published: 29 February 2024. Disponível em: <<https://doi.org/10.1002/alz.13733>>. Citado na página 5.
- NIEDERMEYER, E.; SILVA, F. H. da. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Philadelphia: Lippincott Williams Wilkins, 2004. A

comprehensive reference on EEG principles, clinical applications, and the use of EEG in brain research. Citado na página 6.

NIEDERMEYER, E.; SILVA, F. L. da. *Electroencephalography: Basic principles, clinical applications, and related fields*. [S.l.]: Lippincott Williams & Wilkins, 2004. Citado na página 1.

PEDROLLO, G. R. *Diagnóstico Automatizado de Transtorno de Atenção Hiperatividade Utilizando Eletroencefalografia e Ressonância Magnética com Inteligência Computacional*. Dissertação (Tese de doutorado) — Universidade Federal do Rio Grande do Sul, 2022. Citado na página 2.

PEIXOTO, R. M. *Lesões Encefálicas: Definições, Perspectivas e Repercussão Social*. Dissertação (Trabalho de Conclusão de Curso) — Universidade Federal de Minas Gerais, Belo Horizonte, 2015. Citado na página 3.

SCHIRRMESTER, R. et al. Deepconvnet: A deep convolutional neural network for eeg-based brain-computer interfaces. *Journal of Neural Engineering*, v. 14, n. 1, p. 016003, 2017. Citado na página 13.

SCIKIT-LEARN. '*sklearn.model\_selection*'. [S.l.], 2007 – 2024. Accessed : 2024 – 08 – 20. Disponível em : <>. Citado 2 vezes nas páginas 18 e 19.

SILVA, K. M. d. et al. Perfil epidemiológico e funcional de indivíduos com lesão encefálica adquirida na infância e tratados na fisioterapia aquática. *Revista Brasileira de Fisioterapia*, Associação Brasileira de Fisioterapia, São Paulo–SP, Brasil, v. 28, n. 3, p. 123–135, 2024. Citado na página 3.

SMITH, M. de A. C. Doença de alzheimer. *Genética - vol.21*, 1999. Citado 2 vezes nas páginas 1 e 5.

SUTTON, R. S.; BARTO, A. G. *Reinforcement Learning: An Introduction*. Cambridge, MA: MIT Press, 2018. A comprehensive resource on reinforcement learning, detailing both theoretical and practical aspects. Citado na página 8.

SZEGEDY, C. et al. Going deeper with convolutions. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, p. 1–9, 2016. Citado na página 13.

TABAQUIM, M. d. L. M.; LIMA, M. P. d.; CIASCA, S. M. Avaliação neuropsicológica de sujeitos com lesão cerebral: uma revisão bibliográfica. *Revista Psicopedagogia*, São Paulo, v. 30, n. 92, p. 105–115, 2013. ISSN 0103-8486. Citado na página 3.

TensorFlow Team. *TensorFlow Documentation*. 2024. Accessed: 2024-08-20. Disponível em: <<https://www.tensorflow.org/>>. Citado na página 17.

# Apêndices

# APÊNDICE A –

## A.1 Código do trabalho no GitHub

O repositório no GitHub tg-ufabc contém o código e os recursos utilizados durante a elaboração do Trabalho de Graduação em Engenharia de Informação na Universidade Federal do ABC. Este código foi desenvolvido por Thais Soares Pereira e William Andrade Colosalle Lima.

No repositório se encontra a implementação das arquiteturas de rede neurais utilizadas, o código para pré-processamento dos dados, scripts para treinamento e validação dos modelos, bem como documentação detalhada para replicação dos experimentos e análise dos resultados.

Link do repositório: <https://github.com/thataaz/tg-ufabc>