



Universidade Federal de Alagoas
Instituto de Computação

Avaliação de Técnicas de Inteligência Artificial para Predição e Classificação de Séries Temporais

Daniel Gomes de Mello Farias

Maceió-AL

Junho, 2020

Daniel Gomes de Mello Farias

Avaliação de Técnicas de Inteligência Artificial para Predição e Classificação de Séries Temporais

Dissertação submetida como requisito para obtenção do título de Mestre no Programa de Pós-Graduação em Modelagem Computacional do Conhecimento da Universidade Federal de Alagoas.

Universidade Federal de Alagoas - UFAL

Instituto de Computação

Programa de Modelagem Computacional do Conhecimento

Orientador: André Luiz Lins de Aquino

Maceió-AL

Junho, 2020

Catálogo na fonte
Universidade Federal de Alagoas
Biblioteca Central
Divisão de Tratamento Técnico

Bibliotecária: Taciana Sousa dos Santos – CRB-4 – 2062

- F224a Farias, Daniel Gomes de Mello.
 Avaliação de técnicas de inteligência artificial para predição e classificação de séries temporais / Daniel Gomes de Mello Farias. – 2020.
 79 f. : il. ; figs. ; grafs. ; tabs. color.
- Orientador: André Luiz Lins de Aquino.
 Dissertação (Mestrado em Modelagem Computacional do Conhecimento) –
 Universidade Federal de Alagoas. Instituto de Computação. Maceió, 2020.
- Bibliografia: f. 73-79.
1. Aprendizagem profunda. 2. Inteligência artificial. 3. Análise de séries temporais.
 4. Sinais cerebrais. 5. Radiação solar. I. Título.

CDU: 004.8

À minha família, para meus pais: Leonides e Frederico; e, meu irmão: Fred. Pelo carinho, compreensão e auxílio nessa jornada.

Agradecimentos

Gostaria de agradecer a todos que me ajudaram na conclusão deste trabalho, com recursos, apoio e motivação.

Primeiramente agradeço a Deus.

À minha mãe Leonides e meu pai Frederico, pelos conselhos, correções e por serem uma força incondicional na minha vida.

Ao meu irmão, Frederico, pelos momentos em que se fez presente para ouvir, elogiar e manter o pensamento positivo.

Ao meu orientador, André Aquino pela confiança, pela orientação e por te me dado a oportunidade de trabalhar junto a família LACCAN.

Ao Prof. Igor Torres, pela enorme contribuição neste trabalho.

Aos meus amigos de mestrado, em especial Mário e Kamilla que sempre estiveram presentes.

Aos amigos do LACCAN, em especial, Eduardo e Hyuri pela contribuição neste trabalho.

“Não pretendemos que as coisas mudem, se sempre fazemos o mesmo. A crise é a melhor benção que pode ocorrer com as pessoas e países, porque a crise traz progressos. A criatividade nasce da angústia, como o dia nasce da noite escura. É na crise que nascem as invenções, os descobrimentos e as grandes estratégias. Quem supera a crise, supera a si mesmo sem ficar ‘superado’. Quem atribui à crise seus fracassos e penúrias, violenta seu próprio talento e respeita mais os problemas do que as soluções. A verdadeira crise é a crise da incompetência... Sem crise não há desafios; sem desafios, a vida é uma rotina, uma lenta agonia. Sem crise não há mérito. É na crise que se aflora o melhor de cada um...”(Albert Einstein)

Resumo

Este trabalho tem por objetivo avaliar o impacto das técnicas de aprendizagem profunda (*Long Short Term Memory* e *Convolutional Neural Network*) para predição e classificação de séries temporais, em duas aplicações específicas. Uma para classificar o sinal de eletroencefalograma, e outro, na predição da radiação solar. Foram utilizadas várias ferramentas nas diversas etapas de pré processamento, extração de características (transformada de Fourier, Wavelet, principais componentes de análise, entropias) e classificação/predição (*convolutional neural network* e *long short term memory*). Os modelos desenvolvidos foram comparados com a literatura utilizando métricas como: acurácia e *root mean square error (RMSE)*, obtendo resultados significativos embora não supere o estado da arte. Na predição da radiação o RMSE foi de $78W/m^2$ enquanto que para a classificação do sinal cerebral, a acurácia do modelo chegou até 86%. **Palavras-chaves:** Aprendizado Profundo, Inteligência Artificial, Radiação Solar, Sinais Cerebrais.

Resumo

This work aims to apply deep learning techniques (Long Short Term Memory and Convolutional Neural Network) in time series. The study was carried out in two databases. One to classify the electroencephalogram signal, and another, to predict solar radiation. Various tools were used in the different stages of pre-processing, feature extraction and classification / prediction. The developed models were compared with the literature using metrics such as: accuracy and root mean square error (RMSE), obtaining significant results. In the radiation prediction the RMSE was $78W/m^2$ while for the classification of the cerebral signal, the accuracy of the model reached 86%, which represents great advances in several areas of health, engineering and meteorology. **Keywords:** Artificial Intelligence, Brain Signal, Deep Learning, Solar Radiation

Lista de ilustrações

Figura 1 – Exemplo de Série Temporal	29
Figura 2 – Divisão do Sistema Nervoso Central	30
Figura 3 – Divisão do Córtex em Regiões (Lobos)	31
Figura 4 – Potencial de Ação em uma Membrana (Neurônio transmite a Informação ao Romper o Limiar)	32
Figura 5 – Posicionamento dos Eletrodos de acordo com o Sistema Internacional 10-20. (a) Vista Lateral; (b) Vista Superior	33
Figura 6 – Equipamentos Comerciais que Permitem a coleta do EEG	34
Figura 7 – Componentes da Radiação Solar	35
Figura 8 – Radiação solar em condições climáticas distintas	36
Figura 9 – Arquitetura da CNN	38
Figura 10 – Exemplo de Operação de Convolução de dois Sinais	38
Figura 11 – Exemplo Gráfico da Operação de Convolução na CNN	39
Figura 12 – Exemplo da Aplicação do Max-Pooling	39
Figura 13 – Modelo de Neurônio Recorrente	40
Figura 14 – Arquitetura da rede LSTM	41
Figura 15 – Etapas da LSTM	42
Figura 16 – Fluxograma para classificar sinal de EGG	47
Figura 17 – Exemplo de Sinal de EEG (Atividade 8). (A) - Anotação T1 que corresponde ao início da imaginação do movimento do punho esquerdo. (B) - Anotação T0 que corresponde ao início do descanso.	49
Figura 18 – Sinal de EEG. Fonte: Autor	50
Figura 19 – Filtros do Sinal de EEG	51
Figura 20 – Transformada de Fourier (FFT)	52
Figura 21 – Gráfico da Morlet Wavelet	53
Figura 22 – Arquiteturas da Rede para classificação do sinal cerebral.	55
Figura 23 – Radiação durante 12/03/2019 a 18/03/2019	58
Figura 24 – Gráfico da Radiação Normalizada / Radiação. Fonte: Autor	59
Figura 25 – Arquiteturas da Rede para Predição da Radiação.	60
Figura 26 – Eletrodo utilizados (destacados).	65
Figura 27 – Resultado do melhor modelo de predição.	68

Lista de tabelas

Tabela 1 – Faixas de Frequência	33
Tabela 2 – Tabela com Técnicas de Radiação Solar (CAPO et al., 2018)	36
Tabela 3 – Algumas Características da base de dados	58
Tabela 4 – Comparação de Modelos para Classificação de Sinais Cerebrais (Movimento Imaginário do punho esquerdo/direito).	63
Tabela 5 – Comparação de Modelos para Classificação de Sinais Cerebrais (Movimento Imaginário do punho esquerdo/direito, ambos os punhos/pés).	66
Tabela 6 – Tabela de Resultados	67

Lista de abreviaturas e siglas

AM	Aprendizado de Máquina
ARIMA	Autoregressive Integrated Moving Average
ARIMAX	Autoregressive Integrated Moving Average with Explanatory Variable
AVC	Acidente Vascular Cerebral
BCI	Brain Computer Interface
BRT	Bagged Regression Trees
CNN	Convolutional Neural Network
ECoG	Eletrocorticografia
EEG	Eletroencefalograma
FFT	Fast Fourier Transform
GBR	Gradient Boosting regression
IA	Inteligência Artificial
IEEG	Eletroencefalograma Intracraniano
KNN	(K-Nearest Neighbors)
LSTM	Long Short Term Memory
MAE	Mean Absolute Error
MAPE	Mean Absolute Percentage Error
MDT	Mineração de Dados Temporais
MLP	Multilayer Perceptron
MLR	Multiple Linear Regression
NN	Neural Network
NOS	Operador Nacional de Sistemas
NRMSE	Normalized Root Mean Square Error
PCA	Principal Componente de Análise

RBM	Restricted Boltzmann Machine
RFR	Random Forest Regression
RMSE	Root Mean Square Error
RNA	Rede Neural Artificial
SEP	Sistema Elétrico de Potência
SNC	Sistema Nervoso Central
SNP	Sistema Nervoso Periférico
ST	Séries Temporais
SVM	Support Vector Regression

Sumário

1	INTRODUÇÃO	23
1.1	Justificativa e Motivação	24
1.2	Problemas associados às aplicações avaliadas	25
1.3	Objetivos	26
1.4	Principais Contribuições	26
1.5	Organização do Trabalho	27
2	FUNDAMENTAÇÃO TEÓRICA	29
2.1	Séries Temporais	29
2.2	Sinal Cerebral	30
2.2.1	Eletroencefalograma (EEG)	32
2.2.2	Brain Computer Interface (BCI)	34
2.3	Radiação Solar	34
2.4	Aprendizado de Máquina	36
2.4.1	<i>Convolutional Neural Network - CNN</i>	37
2.4.2	<i>Long Short Term Memory - LSTM</i>	40
3	TRABALHOS RELACIONADOS	43
3.1	Trabalhos EEG	43
3.2	Trabalhos Radiação	44
4	METODOLOGIA PARA APLICAÇÃO DAS TÉCNICAS	47
4.1	Sinais Cerebrais	47
4.1.1	Base de Dados	48
4.1.2	Pré Processamento	49
4.1.2.1	Normalização	50
4.1.2.2	Filtros	50
4.1.3	Extração de Características	51
4.1.3.1	Transformada de Fourier	51
4.1.3.2	Transformada Wavelet (Morlet)	52
4.1.3.3	Principal Componente de Análise (PCA)	53
4.1.3.4	Entropias	54
4.1.4	Classificação	54
4.1.4.1	Arquitetura das Redes	54
4.1.4.2	Separação Teste e Treino	56
4.1.5	Métricas de Avaliação	57

4.2	Radiação	57
4.2.1	Base de Dados	57
4.2.2	Pré Processamento	59
4.2.3	Predição	59
4.2.3.1	Arquitetura das Redes	59
4.2.3.2	Separação Teste e Treino	60
4.2.3.3	Métricas de Avaliação	60
5	AVALIAÇÃO DAS TÉCNICAS	63
5.1	Resultados - Classificação do Sinal Cerebral	63
5.2	Resultados - Predição da Radiação	66
6	CONCLUSÃO E TRABALHOS FUTUROS	71
	REFERÊNCIAS	73

1 Introdução

Devido aos avanços tecnológicos, houve uma grande produção de dados realizada pela humanidade, a fim de convertê-los em informação e conhecimento úteis. Isso almejou conferir suporte à tomada de decisões, o que só foi possível em virtude dos avanços na área da computação. Esses avanços graduais contribuíram para o desenvolvimento de sistemas computacionais que permitem gerenciar essa quantidade expansível de dados.

Os tipos de dado mais utilizados são os números e letras, que, juntos, podem formar um conjunto de dados mais complexos, como: áudio, vídeo, texto, sinais. Entretanto, vêm ganhando destaque e impulsionando o armazenamento em larga escala os dados sequenciais, que são coletados de forma cronológica para análises posteriores, como: dados de temperatura e radiação de um ambiente, consumo de energia de uma casa ou equipamento, dados cerebrais e musculares ao realizar uma atividade, dentre outros (LAROSE, 2005; LAROSE; LAROSE, 2014).

Embora a análise de alguns desses dados, sequencialmente adquiridos, ainda seja complexa e difícil, vários trabalhos e organizações buscam utilizar o conhecimento nesses dados para compreender melhor os fenômenos observados, como também planejar, aprimorar e aperfeiçoar atividades e processos decisórios baseados nos dados obtidos (MONTGOMERY; JENNINGS; KULAHCI, 2015; CHATFIELD, 2013; METCALFE; COWPERTWAIT, 2009).

Nesse contexto, a Mineração de Dados Temporais (MDT) consiste em um processo que permite, a partir de uma Série Temporal (ST), extrair um conhecimento que pode guiar as tomadas de decisões incumbidas a especialistas do domínio (FRANK; HALL, 2011; MAIMON; ROKACH, 2005, 2005).

Os métodos de predição e classificação de Séries Temporais, ao observar os dados históricos, são baseados na descoberta de padrões de difícil identificação ou interpretação, que podem auxiliar na descrição ou na classificação futura do fenômeno observado. A implementação de um modelo para predição/classificação de séries temporais utiliza algoritmos que realizam suposições acerca dos dados, a fim de modelar as relações entre si, gerando estruturas matemáticas robustas (PARMEZAN, 2014).

A aplicação de métodos estatísticos, baseados em autorregressão e médias móveis, tem sido considerada para a modelagem, e a predição de séries temporais por mais de meio século (GOOIJER; HYNDMAN, 2006). Com o aumento do poder computacional, e na busca de melhores resultados em relação aos já encontrados, com modelos estatísticos, diversos estudos vêm sendo feitos no intuito de criar novas formulações matemáticas para a predição de séries temporais (PARMEZAN, 2014; KANDANANOND, 2012, 2012; CLAVERIA; TORRA, 2014; SAPANKEVYCH; SANKAR, 2009).

Os modelos atualmente utilizados para a predição e classificação de séries temporais são os baseados em Aprendizado de Máquina (AM), que é uma subárea da Inteligência Artificial. Sendo assim, as representações em AM estão relacionadas à pesquisa e à busca constante pelo desenvolvimento de métodos que auxiliem no processamento de grandes bases de dados e, conseqüentemente, na construção de modelos que permitam a representação de novos conhecimentos adquiridos automaticamente, de modo mais eficiente e compreensível (HAN; PEI; KAMBER, 2011; PARMEZAN, 2014).

Neste trabalho, é feita a avaliação de métodos provenientes da área de AM, para o problema da predição e classificação de séries temporais. Para ambos os problemas exploramos dois métodos de aprendizado profundo, a *Convolutional neural Network* e *Long Short Term Memory*), para assim identificar sua aplicabilidade para ambos os problemas. Para a classificação consideramos o problema de classificação de sinais cerebrais; e para predição consideramos o problema de identificar o comportamento futuro da radiação em sistemas fotovoltaico. Sendo este último, apresentando resultados promissores e aplicáveis em cenários reais frente ao estado da arte.

1.1 Justificativa e Motivação

Nos últimos anos, houve um crescente aumento no interesse pela predição e classificação de séries temporais, Mineração de Dados (MD) e Descoberta de Conhecimento. Esse interesse deu origem à proposta de diferentes algoritmos, para tarefas como classificação, recuperação por conteúdo, agrupamento, identificação de padrões morfológicos, detecção de anomalias e predição de valores futuros (FU, 2011).

Pesquisas na área de processamento e análise de séries temporais têm demonstrado que métodos baseados em aprendizado profundo proporcionam resultados muito competitivos, frequentemente superando técnicas mais complexas. Por exemplo, (ROUHI et al., 2015) ao utilizar algoritmos de Inteligência Artificial (IA), conseguiu classificar o câncer de mama em benigno ou maligno com uma acurácia melhor que algoritmos convencionais. Já (MAKKAR et al., 2017) para reconhecimento do dígito, e (HOU et al., 2020) para classificar a imaginação do sinal cerebral, utilizam algoritmos de aprendizagem profunda - *Convolutional Neural Network (CNN)*, e conseguem resultados que são dificilmente superados. Enquanto que (SONG; BROWN, 2019) ao utilizar algoritmos de *Long Short Term Memory (LSTM)*, uma abordagem de aprendizado profundo superou os resultados anteriores que utilizavam métodos menos complexos, como: *Autoregressive Integrated Moving Average with Explanatory Variable (ARIMAX)*, *Support Vector Regression (SVR)* e Médias Móveis para a predição de radiação solar. Presume-se a superioridade dos métodos baseados em aprendizado profundo, em grande parte, devido, então, ao trabalho incessante da comunidade em buscar progresso para antecipar e classificar processos, a fim de obter melhorias nos sistemas.

Ao utilizar técnicas de aprendizagem profunda, é possível realizar a predição e classificação de alguns eventos. No caso da predição da radiação solar, é possível prever o comportamento da radiação em algumas regiões e, com isso, determinar se é uma região que tem alta/média/baixa incidência de Sol, se é um bom local para a construção de uma usina solar e/ou se a radiação pode ocasionar problemas no sistema elétrico, como super aquecimento e tensões elevadas. Enquanto que, na classificação de sinais cerebrais, é possível o desenvolvimento de sistemas *Brain Computer Interface* (BCI), que são sistemas que permitem a interação do cérebro com a máquina, permitindo, assim, o controle de dispositivos eletroeletrônicos através do pensamento.

Com isso, justifica-se a importância do estudo de técnicas de predição e classificação de séries temporais de forma mais aprofundada, em especial as técnicas de aprendizagem profunda, para as aplicações acima mencionadas.

1.2 Problemas associados às aplicações avaliadas

Para a classificação de sinais cerebrais, observamos que com o envelhecimento da população, associado à melhoria da qualidade de vida e da saúde - o que ocasiona um maior tempo de vida das pessoas -, torna-se imprescindível a utilização das tecnologias assistivas, visando à compensação de determinada deficiência.

Devido ao avanço tecnológico, a utilização de novas tecnologias podem proporcionar uma melhor qualidade de vida para as pessoas que possam apresentar alguma forma de incapacidade. Alguns exemplos são: os robôs, para auxílio na reabilitação do movimento e do gesto; a robótica, com as características de monitoramento remoto e detecção de quedas, permitindo, assim, o acompanhamento de pessoas de idade a todo instante.

Dentre as novas tecnologias, os sensores de EEG (Eletroencefalografia) possibilitam que uma pessoa consiga interagir num ambiente, através do pensamento, controlando dispositivos eletroeletrônicos (televisão, ar condicionado, luzes). Para reconhecer e classificar os padrões de sinais cerebrais, devem ser implementados algoritmos de processamento, baseados nas ideias das interfaces cérebro computador ou *Brain Computer Interfaces (BCI)* (FLÓREZ et al., 2016).

Para a predição da radiação solar, observamos que com o aumento da utilização de energia fotovoltaica pelo Sistema Elétrico de Potência (SEP) no Brasil, cresce a preocupação do Operador Nacional do Sistema (ONS) em utilizar outras fontes em geral, que podem acarretar dificuldades para a programação de fontes complementares, como, a fonte térmica (SOUSA, 2013). Dentre os fatores ambientais que influenciam na potência de saída de uma central fotovoltaica, a radiação solar incidente é o fator preponderante. Sendo assim, é de grande interesse do ONS prevê-la. Desta forma, diversos trabalhos (COELHO, 2016; CAPO et al., 2018; DEB et al., 2017; KIM; JUNG; SIM, 2019; ALZHRANI et al., 2017) foram publicados com respeito à previsão de radiação solar.

Prever a radiação solar é ter controle da quantidade de energia que será produzida em uma determinada região. Vários autores propõem modelos para a predição da radiação a curto/longo prazo, dentre os quais podem ser citados: (SORKUN; İNCEL; PAOLI, 2020; WANG et al., 2018a; QING; NIU, 2018; MISHRA; PALANISAMY, 2019).

1.3 Objetivos

Impulsionado pelos desafios e pelas necessidades da comunidade, de predição e classificação de dados temporais, o escopo deste trabalho concentra-se nos seguintes objetivos:

- Objetivo Geral:
 - Avaliar o uso de técnicas de Inteligência Artificial na predição e classificação de Séries Temporais.
- Objetivos Específicos:
 - Identificar os avanços científicos relacionados ao tema de predição e classificação de Séries Temporais;
 - Aplicar os modelos de aprendizado profundo para predição da radiação solar e classificação de sinais cerebrais;
 - Comparar experimentalmente os algoritmos desenvolvidos com abordagens tradicionais da literatura e o estado da arte.

1.4 Principais Contribuições

As contribuições do presente trabalho são elencadas abaixo:

- Utilização de técnicas de aprendizagem profunda para classificar sinais cerebrais e estimar valores futuros de radiação solar;
- Exploração das propriedades inerentes à predição da radiação solar em vários horizontes temporais (1/2/5 minutos à frente) possibilitando estimar a produção de energia solar em dias chuvosos, nublados e ensolarados, além de, ser capaz de estimar falhas no sistema fotovoltaico e na rede elétrica.
- Investigação de características extraídas dos sinais cerebrais que permitam classificar a imaginação do movimento e, assim, possibilitar o usuário controlar dispositivos eletroeletrônicos e próteses através do pensamento, como também, detectar doenças como epilepsia e AVC.

Desta forma, áreas como meteorologia e engenharia podem se beneficiar com pesquisas de predição de radiação solar. Já na saúde, uma enorme quantidade de pessoas podem se beneficiar com modelos de classificação de sinais cerebrais, na detecção de doenças cerebrais ou, no controle de dispositivos através do pensamento.

1.5 Organização do Trabalho

As seções deste trabalho estão organizadas na seguinte estrutura: o capítulo 2 (Fundamentação Teórica) aborda conhecimentos básicos considerados no estudo da radiação solar, sinal cerebral e algoritmos de aprendizagem de máquina, formando uma base de conhecimentos necessários para alcançar os objetivos deste trabalho. No capítulo 3 (Trabalhos Relacionados) aborda os trabalhos da literatura que utilizaram o aprendizado de máquina, para predição de radiação solar e para a classificação de sinais cerebrais. Já o capítulo 4 (Materiais e Métodos) cita a metodologia utilizada nas análises do trabalho. Apresenta as base de dados utilizadas, o pré-processamento, a extração de características, modelos e arquiteturas de predição/classificação utilizados, bem como a estimativa futura (predição) dos dados de radiação e a classificação dos padrões cerebrais. O capítulo 5 (Análise dos Resultados) apresenta os resultados encontrados, calculando os erros entre valores reais e valores preditos e acurácia. Também compara os modelos propostos com os encontrados na literatura. Por fim, capítulo 6 (Conclusão) descreve o desfecho final desta dissertação e apresenta as considerações finais, apontando as contribuições e limitações desta dissertação, além de propor os trabalhos futuros.

2 Fundamentação Teórica

Neste capítulo, serão apresentados os principais conceitos teóricos utilizados nesta dissertação. A seguir, serão descritos os conceitos sobre Séries Temporais, Sinal Cerebral, Radiação Solar e Aprendizado de Máquina.


2.1 Séries Temporais

Séries Temporais podem ser caracterizadas como um conjunto de observações obtidas sequencialmente, ao longo do tempo. Desse modo, uma série temporal Z de tamanho m pode ser formulada como uma sequência ordenada de observações, ou seja, $Z = (z_1, z_2, \dots, z_m)$ onde $z_t \in \mathbb{R}$ e representa uma observação z no instante de tempo t (CHATFIELD, 2013).

A formulação de dados no domínio do tempo é de grande importância, visto que existe uma relação de dependência entre as observações, o que significa que uma série temporal é uma sequência de dados que teve suas medidas realizadas durante um intervalo de tempo. Devido a sua presença, em quase todos os campos do conhecimento, e sua fácil obtenção, produziu-se um interesse no campo de mineração de dados, previsão e classificação de eventos utilizando séries temporais (BROCKWELL; DAVIS, 2016).

É importante mencionar que, em uma série temporal Z , seu tamanho será dado pelo seu número de pontos em t . Também, uma série temporal apresenta marcações de tempo. Estas marcações geralmente apresentam diferentes números de aspectos, como, um número diferente de estados, o número de transições em (b) na figura 1 onde a transição é feita a cada 12 horas ou 720 amostras e a distribuição da duração de cada evento através de cada estado em (a) na figura 1, onde cada estado (pensamento) tem duração de aproximadamente 4 segundos. Cada um destes aspectos contribui para agregar uma propriedade específica a cada série temporal (FASANG; LIAO, 2014; AGUIAR, 2016).

Figura 1 – Exemplo de Série Temporal



(a) Registro da Atividade Elétrica de um eletrodo, ao usuário imaginar dez de 7 dias vezes um movimento


Fonte: Autor

Como apresentado anteriormente, utilizaremos dois tipos de séries temporais, sinal cerebral e radiação solar, descritos na seção 4.

2.2 Sinal Cerebral

O sistema nervoso humano é composto pelo sistema nervoso central (SNC) e o Sistema Nervoso Periférico (SNP). O SNC engloba o encéfalo e a medula espinhal. O encéfalo encontra-se dentro do crânio e é dividido em cérebro, tronco cerebral e cerebelo, conforme a figura 2 enquanto que o SNP é formado pelos nervos e gânglios nervosos (AMARAL; STRICK, 2013; HALL, 2010; NORTH CUTT; KAAS, 1995).


Figura 2 – Divisão do Sistema Nervoso Central



Fonte: (MACHADO, 1979)

O córtex cerebral é anatomicamente dividido em lobos representados na figura 3. Estes lobos possuem regiões que são especializadas em determinadas funções. O lobo occipital (O) é responsável pela visão; os lobos temporal (T) e parietal (P) são responsáveis pela linguagem, pensamento e audição; enquanto que o córtex motor e o córtex sensorial, região entre o lobo parietal (P) e frontal (F), são responsáveis pelos sentidos e movimentos voluntários (ESSEN; DRURY, 1997).

Figura 3 – Divisão do Córtex em Regiões (Lobos)




Fonte: (SÖRNMO; LAGUNA, 2005; FLÓREZ et al., 2016),

Ao realizar uma atividade, pensamento e/ou ação, os neurônios emitem milhões de impulsos nervosos simultâneos. Esses impulsos se propagam do córtex cerebral até o couro cabeludo na superfície do crânio e, podem ser medidos por meio do EEG, formando uma série temporal (HUTTENLOCHER et al., 1979; FREITAS, 2017). A atividade elétrica neuronal surge a partir da diferença de concentração de íons que se acumulam na membrana celular.

Quando em repouso, as concentrações iônicas se mantêm baixas no interior da célula. A excitação nos neurônios ocorre quando o potencial elétrico ultrapassa o valor limiar, gerando um potencial de ação conforme o gráfico da figura 4 (SANEI; CHAMBERS, 2013).

Figura 4 – Potencial de Ação em uma Membrana (Neurônio transmite a Informação ao Romper o Limiar)



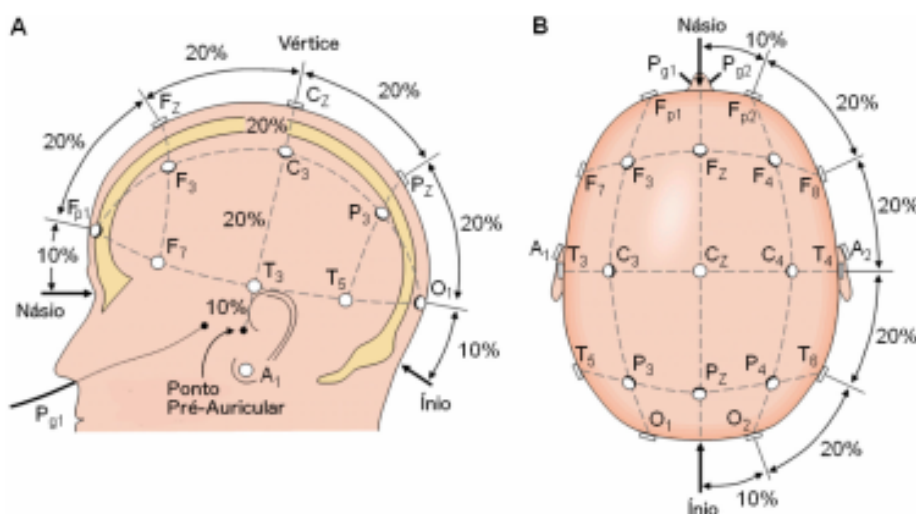
Fonte: (SANEI; CHAMBERS, 2013),

Então, as informações sensoriais são transmitidas através dos impulsos nervosos pelo corpo até o córtex sensorial. Da mesma forma, os movimentos são enviados do córtex motor até os músculos e, os pensamentos e cognição, de outras atividades autônomas, são transmitidas entre os neurônios via impulsos nervosos (AMARAL; STRICK, 2013; NICOLELIS; LEBEDEV, 2009).

2.2.1 Eletroencefalograma (EEG)

Para registrar a atividade elétrica cerebral utiliza-se o EEG, uma técnica não invasiva que consiste em conectar eletrodos sobre o couro cabeludo, e posicionando-os de forma sistemática para captar os sinais cerebrais. O método mais comum de posicionamento dos eletrodos é o Sistema 10-20 (DAVIDSON; JACKSON; LARSON, 2000), ilustrado na figura 5 (MALMIVUO; MALMIVUO; PLONSEY, 1995; BUENO, 2017). Este sistema utiliza dezenove (19) eletrodos para captar os sinais cerebrais em cada parte do cérebro, separado por lobos.

Figura 5 – Posicionamento dos Eletrodos de acordo com o Sistema Internacional 10-20. (a) Vista Lateral; (b) Vista Superior



Fonte: (MALMIVUO; MALMIVUO; PLONSEY, 1995),

Uma das formas de se analisar o sinal de EEG é utilizar o espectro de frequências, pois ele é composto por faixas de frequências específicas chamadas ondas ou ritmos, que variam em amplitude e podem ser classificados em Delta (δ), Teta (θ), Alfa (α) e Beta (β).

As ondas do sinal de EEG representam alguns estados do indivíduo. Por exemplo, é possível perceber a predominância de ondas beta quando o indivíduo está em estado de alerta (vigília). As ondas alfa são observadas em maior intensidade quando o indivíduo está acordado e relaxado. Já as ondas Teta refletem estados cognitivos e de concentração. Enquanto que as ondas Delta ocorrem durante o sono profundo. A tabela 1 mostra a faixa de frequência de cada tipo de onda (BAIJAL; SRINIVASAN, 2010; OREKHOVA et al., 2006; BLINOWSKA; DURKA, 2006).

Tabela 1 – Faixas de Frequência


Tipo de Onda	Faixa de Frequência
Delta (δ)	0.1 Hz - 4 Hz
Teta (θ)	4 Hz - 8 Hz
Alfa (α)	8 Hz - 12 Hz
Beta (β)	12 Hz - 30 Hz

Além da utilização de sistemas BCI, alguns autores citam aplicações do EEG, como na detecção de: epilepsia (WESTBROOK, 2000), distúrbios do sono (TÜSHAUS et al., 2017), profundidade da anestesia durante procedimentos cirúrgicos, fadiga (LIANG et al., 2019), entretenimento (KEROUS; SKOLA; LIAROKAPIS, 2018), memória, estados cognitivos (EDE, 2018) e emoções (SCHAEFER, 2017).

2.2.2 Brain Computer Interface (BCI)

A partir do sinal coletado pelo EEG, é possível construir interfaces BCI - que são técnicas de controle de dispositivos - e equipamentos externos ao corpo humano através do pensamento, permitindo uma interação do cérebro com as máquinas (WOLPAW et al., 2002; VALLABHANENI; WANG; HE, 2005). Pesquisas nesta área vêm sendo feitas desde a década de 60 (VIDAL, 1973; VIDAL, 1977), mas, com as melhorias nas técnicas de processamento de sinal e o desenvolvimento de novas tecnologias, como equipamentos capazes de realizar o EEG de forma simples e rápida (figura 6), permitiram novas descobertas nesta área.

Figura 6 – Equipamentos Comerciais que Permitem a coleta do EEG



(a) Open BCI



(b) Emotiv EPOC

Fonte: Repositório Digital. (a) openbci.com (b) emotiv.com

Existem também outras técnicas capazes de coletar os sinais cerebrais, como o Eletrocorticografia (ECoG) ou EEG Intracraniano (IEEG), que são capazes de obter sinais com menos ruído que o EEG. No entanto, por serem técnicas invasivas, onde se faz necessário realizar uma microcirurgia para implantação dos eletrodos, podem ter diversas complicações como tetraplegia, acidente vascular cerebral (AVC), tumores, epilepsia, dentre outras. Por serem técnicas invasivas, não foram abordadas neste trabalho (KONRAD; SHANKS, 2010).

2.3 Radiação Solar


O Sol é a principal fonte de energia para a Terra. Além de ser responsável pela manutenção da vida no Planeta, a radiação solar constitui-se de uma inesgotável fonte energética, havendo um enorme potencial de sua utilização por meio de sistemas de captação e conversão em outras formas de energia, como, a térmica e a elétrica (PINHO; GALDINO, 2014).

A disponibilidade do recurso energético está relacionada à posição relativa entre o Sol e a Terra. Os fatores astronômicos estabelecem a variabilidade da radiação solar incidente

no topo da atmosfera (PEREIRA et al., 2006). No entanto, a incidência de energia solar na superfície também sofre influência de outros processos físicos que podem reduzir a radiação ao longo do percurso, com a presença, principalmente, de nuvens (CAPO et al., 2018).

A radiação solar que chega à superfície e incide sobre uma superfície para a geração de energia é dividida em componentes: direta, que provem diretamente do Sol, e por uma componente difusa, que atinge a superfície após sofrer espalhamento pela atmosfera terrestre (Figura 7). A soma das componentes direta e difusa é denominada radiação global (PINHO; GALDINO, 2014).

Figura 7 – Componentes da Radiação Solar



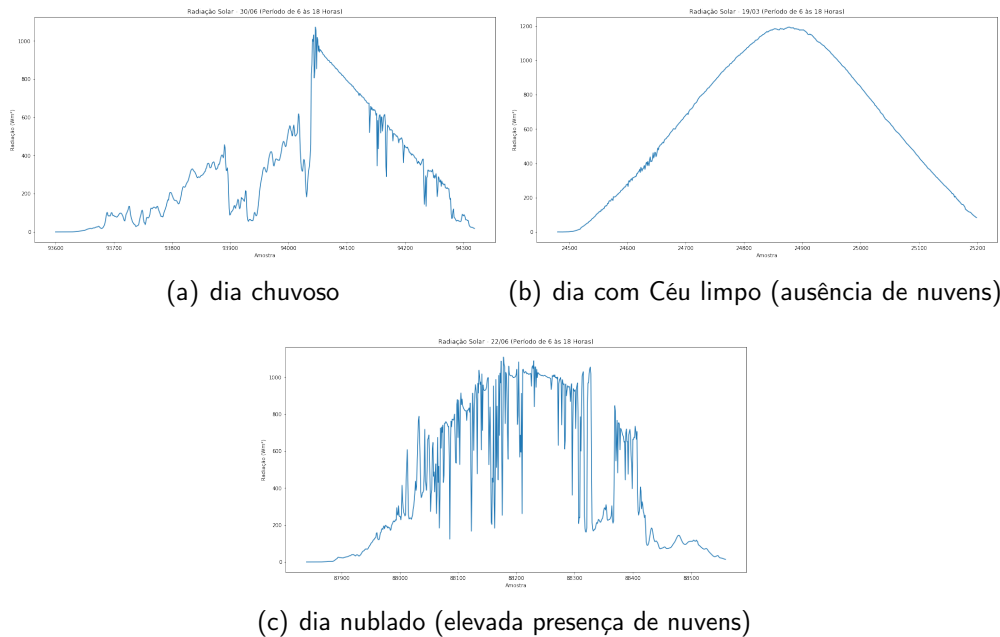
Fonte: (CAPO et al., 2018)

Dada a sazonalidade da radiação solar, as previsões permitem uma adequada alocação dos recursos energéticos. Além disso, espera-se um melhor funcionamento e confiabilidade de usinas e/ou de sistemas menores ou conectados à rede. Assim, a capacidade de prever a radiação solar é uma das características que auxiliam na produção de energia em uma usina solar fotovoltaica (DAVID et al., 2016).

Uma das dificuldades na previsão da radiação está na rápida variação de incidência dos raios solares, devido à presença de nuvens e chuvas, conforme a figura 8. Sendo assim, os modelos de previsão solares existentes podem ser classificados em método de persistência, dados de satélite/métodos de imagens, métodos numérico, método estatístico e método híbrido (HUANG et al., 2012). A tabela 2 separa cada tipo de modelo para o devido horizonte temporal.

Neste trabalho, utilizaram-se os métodos estatísticos, especificamente os de aprendizagem profunda, pois estão sendo amplamente empregados na literatura e superando os métodos estatísticos convencionais como: ARIMA, Média Movel, SVR, regressão, dentre outros.

Figura 8 – Radiação solar em condições climáticas distintas



Fonte: Autor

Tabela 2 – Tabela com Técnicas de Radiação Solar (CAPO et al., 2018)

Técnica	Período do horizonte de Predição
Persistência	Um dia à frente
Imagens de Satélite	Várias horas à frente
Estatístico	Muito Curto (Minutos até duas horas)
Híbrido	Combina os métodos anteriores

2.4 Aprendizado de Máquina

O Aprendizado de máquina é um método de análise de dados que automatiza a construção de modelos analíticos. É uma “habilidade” que faz os computadores aprenderem sem serem explicitamente programados (CHOLLET, 2018). Ao invés dos programadores construírem um conjunto de regras para processamento de dados, um computador aprende através de um treinamento para realizar determinada tarefa ao produzir regras (RODRÍGUEZ, 2020).

A principal característica de um sistema de aprendizado de máquinas é que ele é treinado ao utilizar exemplos relevantes para uma determinada tarefa, seja ela de classificação ou predição, visando encontrar um modelo estatístico que possibilite ao sistema criar regras para automatizar a tarefa (RAMPAZZO et al., 2019). Para isso, os algoritmos precisam de três elementos:

- dados de entrada: são os dados relacionados com a tarefa a ser automatizada, por

exemplo o sinal cerebral/radiação num determinado período;

- saída desejada: em uma tarefa de reconhecimento de padrões, as saídas esperadas podem ser as classificações do sinal cerebral, o que o usuário pensou (moveu a perna ou braço?);
- método de treinamento: uma maneira de medir a eficiência do algoritmo é determinar a diferença entre a saída real e a saída prevista (fornecida pelo modelo de aprendizado de máquina), sendo esta usada como um sinal de retroalimentação para ajustar o algoritmo. Isto é chamado de aprendizado.

Um modelo de aprendizado de máquina tem a capacidade de transformar dados de entrada em saída, mediante um processo aprendido pelo treinamento de exemplos. Portanto, o aprendizado de máquina está focado em procurar por representações dos dados de entrada em um espaço definido de possibilidades (CHOLLET, 2018).

Já o aprendizado profundo (DP) é um subconjunto do aprendizado de máquina que aprende mediante o uso de camadas sucessivas de representações cada vez mais significativas.

O aprendizado profundo tem atraído a atenção da comunidade científica e do público em geral de forma crescente (HATCHER; YU, 2018). Ele tenta responder às mesmas questões fundamentais de regressão e classificação do aprendizado de máquina, propondo modelos mais complexos ao utilizar um maior número de camadas (GOODFELLOW et al., 2016). Essa complexidade das arquiteturas profundas, em conjunto com outras técnicas, como a regularização e a transferência de conhecimento, tem se mostrado promissora para responder a algumas questões (PATTERSON; GIBSON, 2017).

Nos últimos anos, o aprendizado profundo vem ganhado destaque pelos resultados que vem obtendo em diferentes áreas, como: classificação de padrão, predição de eventos, reconhecimento de fala, reconhecimento e tradução de texto (HATCHER; YU, 2018).

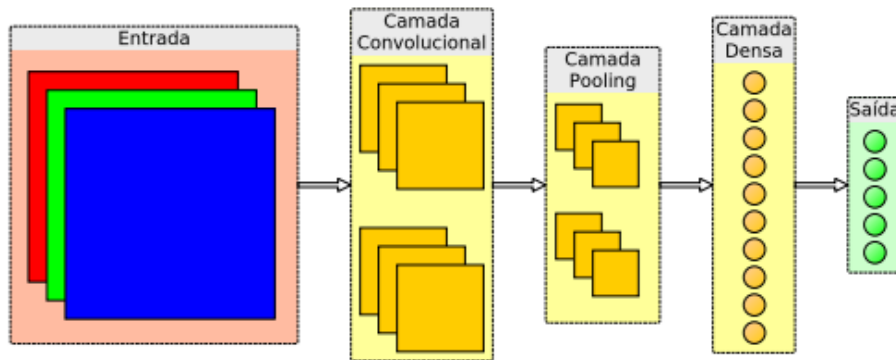
Neste trabalho, foram utilizados dois tipos de aprendizagem profunda, as *Convolutional Neural Network (CNN)* e as *Long Short Term Memory (LSTM)*.

2.4.1 *Convolutional Neural Network - CNN*

A CNN ilustrada na figura 9 é um tipo particular de aprendizagem profunda que possui inspiração neurobiológica na organização do córtex visual dos animais. Os neurônios corticais, organizados de forma hierárquica, respondem individualmente a estímulos em regiões restritas do campo de visão. A região ativada depende diretamente do padrão de estímulo apresentado e a sobreposição parcial dos campos receptivos em diferentes neurônios forma o campo de visão completo (HUBEL; WIESEL, 1977; FARIAS, 2016).

Da mesma forma que o córtex visual é projetado para reconhecer padrões, as CNNs também são, devido a sua organização em forma de grade. Como exemplos deste tipo de

Figura 9 – Arquitetura da CNN

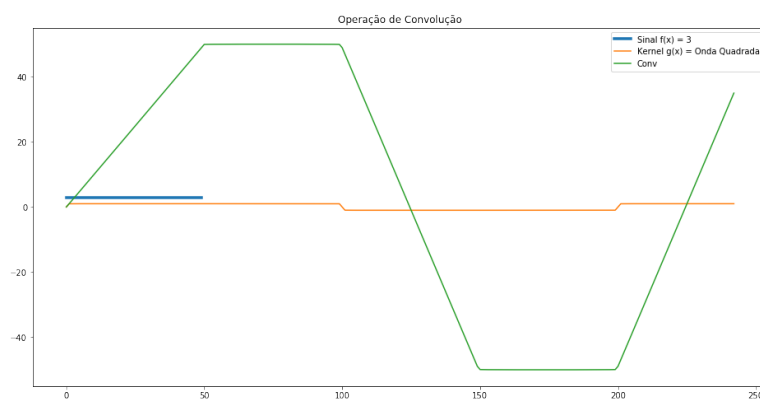


Fonte: (FARIAS, 2016)

organização, temos as séries temporais (em intervalos regulares), imagens (com pixels), vídeos, sons, dentre outros. As CNNs, por serem capazes de solucionar problemas mesmo com alto grau de translação, dimensionamento e inclinação, são atualmente utilizadas em diversas aplicações (HUBEL; WIESEL, 1977; LECUN; BENGIO, 1998).

A operação de convolução ilustrada na figura 10 é responsável por dar nome às CNNs nas quais a operação de multiplicação geral de matrizes é substituída pela operação de convolução, em pelo menos uma de suas camadas (GOODFELLOW et al., 2016). A operação de convolução entre duas funções (f e g) gera uma terceira função h . A operação de convolução pode ser escrita como: $h = f * g$. Onde o argumento f da convolução é referido como o dado de entrada, o argumento g é referido como o kernel ou filtro. A saída da operação de convolução h é referida como o mapa de características.

Figura 10 – Exemplo de Operação de Convolução de dois Sinais



Fonte: Autor


Uma das vantagens do uso da CNN é que os dados de entrada e os filtros podem ser organizados em múltiplas dimensões, com a possibilidade de usar a operação de convolução em mais de um eixo por vez.

Como exemplo, para uma imagem I bidimensional de entrada e filtro K , também bidimensional, a operação de convolução entre eles é representada pela Equação 2.1:

$$S(i, j) = (I * K)(i, j) = \sum_m \sum_n I(m, n)K(i - m, j - n) \quad (2.1)$$

A figura 11 representa a operação de convolução para uma entrada bidimensional de 5 linhas por 5 colunas e filtro de 3 linhas por 3 colunas. A saída é representada pelo mapa de características. Os destaques em azul (operação 1) e vermelho (operação 9) representam exemplos de operações sobre regiões da entrada com suas saídas correspondentes (RAMPAZZO et al., 2019).

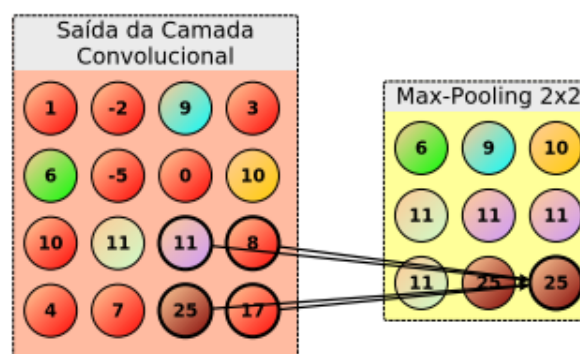
Figura 11 – Exemplo Gráfico da Operação de Convolução na CNN



Fonte: (RAMPAZZO et al., 2019)

Nas arquiteturas de CNN é comum encontrar várias camadas convolucionais seguidas de camadas de Agrupamento (*Pooling*). Esta camada normalmente é utilizada após as camadas convolucionais para reduzir progressivamente o tamanho das representações e reduzir a quantidade de parâmetros no modelo. Também ajuda a controlar a *Overfitting*. Ela utiliza a operação *MAX* para selecionar o valor máximo de um lote de neurônios e representa-o em um único neurônio para ser usado na camada seguinte, conforme a figura 12.

Figura 12 – Exemplo da Aplicação do Max-Pooling




Fonte: (FARIAS, 2016)

Com isto, as redes neurais convolucionais (CNN) estão sendo utilizadas em aplicações de reconhecimento de padrões em imagens ou vídeos, no processamento de linguagem natural, e devido a sua capacidade de processar um sinal bruto e extrair características de forma automática, evitando, assim, uma extração manual são fatores que contribuem para sua utilização, além de produzir resultados superiores às técnicas convencionais (LECUN; BENGIO, 1998; RODRÍGUEZ, 2020; TANG; LI; SUN, 2017).

2.4.2 Long Short Term Memory - LSTM

As camadas do tipo Long-Short Term Memory são camadas utilizadas em nas Redes Neurais Recorrentes (RNN). Os neurônios presentes na RNN podem ter pesos de recorrência (Figura 13). Esta recorrência é responsável por introduzir uma noção de tempo ou sequência nos modelos. Com isso, é possível dizer que as saídas das RNNs sofrem influência não apenas da entrada atual $Z(t)$ mas também das entradas anteriores $Z(t - \tau)$, formando uma espécie de memória.

Figura 13 – Modelo de Neurônio Recorrente




Fonte: (FARIAS, 2016)

A principal ideia da LSTM está na criação de um bloco ou célula de memória que possui portões (gates) controlando o fluxo dos sinais que entram/saem dos blocos LSTM. Os blocos LSTM substituem os neurônios das RNAs. As Equações 2.2 - 2.7 detalham o funcionamento do bloco LSTM. A Figura 14 mostra um bloco da LSTM.

No primeiro momento, é decidido o que será esquecido da rede (*Dropout*) onde; h_{t-1} é a saída da célula anterior, W_f os pesos dos neurônios no *forget gate*, Z_t o valor de entrada atual que passa por uma função sigmoid (σ) em f_t (que retorna valores entre 0 e 1), caso não seja importante, será 0, ilustrado em (a) na figura 15 e pela equação 2.2.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t]) \quad (2.2)$$

Figura 14 – Arquitetura da rede LSTM



Fonte: (OLAH, 2015)

Num segundo momento, é decidido o que será armazenado onde: h_{t-1} é a saída da célula anterior, W é os pesos dos neurônios, Z_t o valor de entrada atual que passam por uma função sigmoide (σ) em i_t representado pela equação 2.3 e pela tangente hiperbólica (\tanh) em \tilde{C}_t representado pela equação 2.4 ilustrados em (b) na figura 15.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t]) \quad (2.3)$$

$$\tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t]) \quad (2.4)$$

Na terceira etapa é feito o cálculo de f_t (*forget date*) para saber se a informação anterior terá relevância e i_t (*input gate*) que informa o que deverá ser armazenado da nova informação e propagado para as próximas células (C_t) conforme a equação 2.5 e ilustrado em (c) na figura 15.

$$C_t = f_c * C_{t-1} + i_t * \tilde{C}_t \quad (2.5)$$

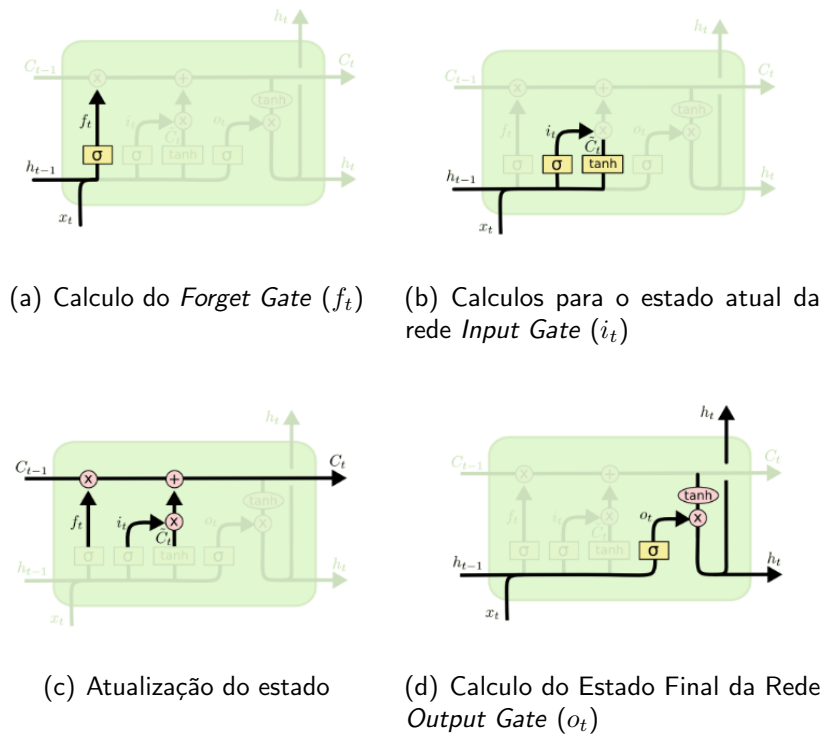
Por fim, a ultima etapa, em o_t (*output gate*) é decidido a saída (equação 2.6) onde, W_o é os pesos dos neurônios no *output gate*, e após aplicar a função sigmoide (σ) e a tangente hiperbólica (\tanh), retorna apenas a informação necessária para ser enviada ao próximo estágio conforme a equação 2.7 (h_t) ilustrados em (d) na figura 15.

$$o_t = \sigma(W_o[h_{t-1}, x_t]) \quad (2.6)$$

$$h_t = o_t * \tanh(C_t) \quad (2.7)$$

Com isso, obtém-se a saída da LSTM que, neste trabalho, será o valor da radiação futura de n (*forecast*) períodos à frente e a classificação dos movimentos cerebrais.

Figura 15 – Etapas da LSTM



Fonte: (OLAH, 2015)

Assim, a LSTM está sendo amplamente utilizada devido a sua capacidade de recordar e descobrir padrões de sinais do passado para estimar o futuro, ou na classificação de padrões de difícil análise (SRIVASTAVA; LESSMANN, 2018; ABDEL-NASSER; MAHMOUD, 2019) na previsão da radiação solar, (GAO et al., 2019; SWAPNA; SOMAN; VINAYAKUMAR, 2018) na detecção de arritmia e em (ALI et al., 2019; TSIOURIS et al., 2018) na previsão de crises de epilepsia. Desta forma, temos a LSTM como uma técnica de grande auxílio nas áreas de engenharia e computação, dentre outras.

3 Trabalhos Relacionados

Neste capítulo são abordados os trabalhos relacionados, bem com uma breve descrição dos métodos e técnicas que tiveram maior relevância classificação de sinais cerebrais e para a predição da radiação.

3.1 Trabalhos EEG

O interesse por empregar técnicas de inteligência artificial, em especial as redes neurais profundas, no problema de classificação de sinais cerebrais, tem aumentado nos últimos anos. Os trabalhos, aqui apresentados, mostram resultados promissores para a questão abordada. Na pesquisa (BILUCAGLIA et al., 2020) ao utilizar 28 usuários avalia os modelos KNN e SVM para classificar o estímulo entre auditivo e visual. Para isso, foram utilizados 128 eletrodos para a coleta do sinal a uma taxa de 250Hz. Como entrada do modelo, é utilizado o sinal no espaço temporal e o sinal no domínio da frequência (ondas teta, alfa e beta) obtendo, no melhor caso, uma acurácia de 63,8% com o SVM.

Já (ZHANG et al., 2019a) utiliza métodos de aprendizagem profunda como LSTM, CNN, híbrido para classificar a imaginação do movimento braços direito/esquerdo, pernas ou língua (*BCI competition IV dataset*). O modelo que obtém melhor resultado é um híbrido (*Convolutional Recurrent Attention Model*) com 59% de acurácia.

(LU et al., 2016) utiliza técnicas de aprendizado de máquina *Restricted Boltzmann machine (RBM)* e compara com os resultados da literatura ao classificar a imaginação dos movimentos do braço (direito ou esquerdo). O melhor resultado encontrado foi de 83% ao utilizar o domínio da frequência (FFT) em conjunto com as técnicas de RBM. Enquanto que o trabalho de (TABAR; HALICI, 2016) obtém resultados inferiores com as técnicas de CNN (77,6 %) e SVM (72,4 %) para a mesma base de dados. Já (WANG et al., 2018b) utiliza LSTM para classificar o sinal obtendo 76% de acurácia.

A proposta de (ZGALLAI et al., 2019) propõe utilizar um sistema *Brain Computer Interface (BCI)* para o controle de uma cadeira de rodas. Ao utilizar o *headset (EmotivEPOC)* para coleta dos sinais, e decompô-los em faixas de frequência para então aplicar as técnicas de CNN, foi capaz de obter um resultado de 96% de acurácia.

Por fim, (ZHANG et al., 2019b) utiliza técnicas de aprendizado de máquina para classificar o movimento imaginário dos punhos. Antes da classificação, foram aplicados filtros de frequência (alfa, beta, theta) e são extraídas algumas características como: densidade espectral, variâncias, média. Ao comparar as técnicas, a que obteve melhor resultado foi a *LSTM + Attention* uma variação da LSTM, como 83,2%. Enquanto o trabalho de (CHIARELLI et al.,

2018) ao utilizar técnicas de CNN na mesma base, encontrou resultados na faixa dos 75% e (HOU et al., 2020) que, além de utilizar técnicas de CNN, fez uso das *boundary element method (BEM)*, foi capaz de obter 94%, superando todos os resultados anteriores.

Com os trabalhos e métodos aqui citados, ficou evidente a evolução de pesquisas por parte da comunidade na classificação da imaginação de atividades utilizando o EEG, além de uma melhor acurácia dos modelos, ao fazer uso das técnicas de aprendizagem profunda, pois estão obtendo resultado superiores aos obtidos com os modelos de classificação convencionais.

Neste trabalho, foi proposto a extração de características dos sinais cerebrais e utilizar os modelos de aprendizado profundo para classificar os sinais cerebrais genérico (vários usuários) e compará-los com a literatura, principalmente, com a pesquisa de (HOU et al., 2020) que obteve 94%.

3.2 Trabalhos Radiação

A energia solar vem ganhando destaque nos últimos anos em razão da crescente demanda energética mundial. Atualmente, também pode ser destacado o avanço tecnológico como fator decisivo para sua inserção na matriz elétrica. Entretanto, a radiação solar que atinge a superfície terrestre varia, principalmente, devido às variações climáticas que ocorrem na atmosfera. Esse fato tem uma grande influência na produção de energia elétrica a partir das tecnologias solares. Portanto, para auxiliar o gerenciamento de operação, principalmente, no caso de usinas fotovoltaicas necessitam-se, entre outros fatores, de estudos que possibilitem conhecer sua disponibilidade regional, variabilidade temporal e previsibilidade.

Quando se trata de previsão da radiação de curto/longo prazo, existem várias propostas de modelos preditivos desenvolvidos a depender da região no globo terrestre (diferentes países, cidades), variáveis coletadas (radiação, velocidade do vento, pressão), do tempo de predição (um minuto à frente, cinco minutos, quinze minutos, algumas horas, dias, meses) e modelos, desde os mais simples, utilizando médias móveis, a modelos mais complexos que utilizam inteligência artificial e aprendizado profundo. Sendo assim, um grande desafio para as áreas da computação, engenharia e meteorologia.

O trabalho de (COELHO, 2016) realiza a predição da radiação de cinco cidades do Brasil e propõe métodos como: regressão polinomial, ajuste de curvas com a linearização de equações não lineares e regressão linear por mínimos quadrados, utilizando dados como: radiação média mensal e índice de claridade, obtendo RMSE abaixo de 5%, utilizando modelo linear para radiação solar global e RMSE abaixo de 8%, utilizando modelo polinomial para radiação solar difusa.

Já (CAPO et al., 2018) propõe utilizar um modelo de Rede Neural Artificial (RNA) para a predição de 3 horas à frente da radiação solar global, onde foi desenvolvida uma rede neural

Perceptron Multicamadas (MLP). Os dados são espaçados em 5 minutos e foram divididos em: 70% treino, 15% validação e 15% teste. Foram utilizadas várias variáveis: radiação, velocidade do vento, umidade e horário. Os resultados encontrados mostram um erro de 2,38% para a predição média anual.

Ao revisar a literatura (DEB et al., 2017) elenca modelos: ARIMA, Redes Neurais, Lógica Fuzzy, Média Móvel, Máquina de Vetor a Suporte (SVM) e Híbridos, para predição da radiação / demanda de uma localidade, de minutos a meses. Os resultados encontrados são avaliados através da métrica *Mean Absolute Percentage Error (MAPE)*, obtendo valores abaixo de 1% ao utilizar o método SVM.

Na pesquisa (KIM; JUNG; SIM, 2019) compara os modelos *Random Forest Regression (RFR)*, *Support Vector Machine SVM*, RNA, *K-Nearest Neighbors (K-NN)* ao utilizar como variáveis independentes: direção do vento, umidade, temperatura, velocidade do vento, tipo do céu (sol, nublado, chuvoso), elevação da cidade, radiação, horário e como variável dependente a radiação solar, obtendo melhores resultados para o RFR com R^2 de 97%.

O trabalho de (ALZHRANI et al., 2017) compara os modelos RNA, SVR e Long Short Term Memory (LSTM) para predição da radiação solar global, obtendo melhor resultado ao utilizar um modelo de LSTM com 2 camadas ocultas e 35 neurônios com RMSE de 0,086 W/m^2 .

Ao comparar técnicas de LSTM, RNA e *Gradient Boosting Regression (GBR)*, (SRIVASTAVA; LESSMANN, 2018) realiza a predição da radiação solar em várias regiões da Austrália, Espanha, EUA, Áustria, Alemanha e França para diversificar os dados ao máximo. Obtendo em quase todas as localidades a LSTM como o melhor modelo e RMSE abaixo de 30 W/m^2 .

Ao comparar quatro modelos: multiple linear regression (MLR), bagged regression trees (BRT), Neural Network (NN) e LSTM para a predição da geração de energia dos painéis solares, (ABDEL-NASSER; MAHMOUD, 2019) obteve melhores resultados com a LSTM, com RMSE de 82 W.

A pesquisa de (MISHRA; PALANISAMY, 2019) compara dois modelos desenvolvidos, um utilizando Redes Neurais Recorrentes (RNN) e outro utilizando LSTM prevendo a radiação: uma, duas, três e quatro horas à frente de algumas regiões dos Estados Unidos. Obtendo resultados similares tanto para LSTM quanto para RNN RMSE médio abaixo dos 30 W/m^2 em todas as regiões, mas, em algumas, com RMSE abaixo dos 10 W/m^2 .

Ao comparar os modelos LSTM e RNA para a predição da radiação solar de cidades dos EUA, Coreia e Alemanha, utilizando dados multivariados (umidade, velocidade do vento, visibilidade) (QING; NIU, 2018) obteve melhores resultados com a LSTM em todas as cidades, com valores de RMSE abaixo dos 100 W/m^2 .

A proposta de (WANG et al., 2018a) foi comparar modelos utilizando CNN, LSTM, Modelo Híbrido, ARIMA, ANN para dias ensolarados, nublados, chuvosos e muita chuva de

duas regiões distintas. Para predição da radiação, foram utilizados os dados brutos de radiação ou os dados após utilizar a transformada Wavelet para extrair características dos sinais de radiação. O modelo híbrido (CNN + LSTM) que utiliza os dados da transformada Wavelet level 2 obteve melhores resultados, com um RSME de $37 W/m^2$ para dias ensolarados e de $140 W/m^2$ para dias chuvosos.

Por fim, (SORKUN; İNCEL; PAOLI, 2020) compara os modelos LSTM, RNA e ARMA para predição da radiação. Dentre os modelos propostos, o que obteve melhor resultado foi o LSTM multivariável que utiliza para predição, além da radiação solar, a temperatura do local, com um *normalized root mean squared error* (NRMSE) de $0,18 W/m^2$.

Assim, observa-se o interesse da comunidade em utilizar modelos matemáticos para a predição da radiação solar em várias regiões, em diferentes tempos à frente (1/5/15 minutos). Apesar da comparação com diversos métodos de predição, os modelos de aprendizado profundo acabaram apresentando uma superioridade na maioria dos trabalhos propostos, superando os modelos utilizados anteriormente, como RNA, ARIMA, SVM.

Neste trabalho, os modelos de aprendizado profundo foram utilizados para predição da radiação de uma base de dados própria. Os dados são de um sistema de geração fotovoltaico com capacidade de produzir 5 Kw/h, localizado no bairro da Jatiúca, na cidade de Maceió, Alagoas. O intuito da predição da radiação é também, estimar a tensão no sistema fotovoltaico e, com isso, detectar possíveis falhas na rede ou nos painéis solares.

4 Metodologia para aplicação das Técnicas

Nesta seção é descrito todo o processo, até a etapa de classificação do sinal cerebral e a previsão da radiação solar. Descrevemos as base de dados, como foi feita e região da coleta, a taxa de amostragem, dentre outras especificações.

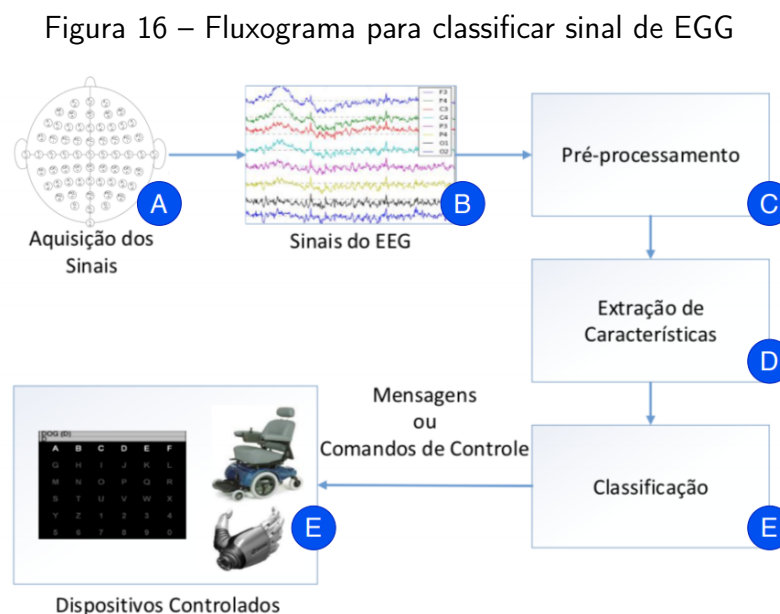
A seção Sinais Cerebrais trata das etapas passo a passo da utilização da base de dados, extrações de características dos sinais como: Fourier, Wavelet, dados estatísticos, os modelos de classificação e a métrica de avaliação.

Da forma similar, a seção Radiação é sobre a previsão de valores futuros, desde a etapa da coleta dos dados até a etapa de previsão com a utilização dos modelos de aprendizado profundo e as métricas de avaliação.

4.1 Sinais Cerebrais

As etapas da classificação dos sinais cerebrais são detalhadas nesta seção. Um fluxograma das etapas é ilustrado na figura 16.

A aquisição do sinal (A) e (B) são detalhados na subseção base de dados. As etapas de pré-processamento (C), extração de características (D) e classificação/dispositivos controlados (E) são detalhados logo em sequência de forma detalhada.



Fonte: Modificado de (FARIAS; RATIVA; FILHO, 2014)

4.1.1 Base de Dados

Como apresentado, neste trabalho foi utilizada uma base de dados disponível na *Internet* contendo o sinal de EEG durante a imaginação do movimento. A base foi desenvolvida e disponibilizada em (SCHALK et al., 2004), onde se buscou classificar o pensamento do movimento

A aquisição dos sinais de EEG foi em conformidade com o protocolo *BCI2000 System* e foram coletados os sinais de 109 voluntários. Cada sujeito realizou 14 execuções experimentais, sendo duas execuções da linha de base de um minuto (uma com os olhos abertos, outra com os olhos fechados) e três execuções de dois minutos de cada uma das quatro tarefas a seguir:


- Um alvo aparece no lado esquerdo ou direito da tela. O sujeito abre e fecha o punho correspondente até o alvo desaparecer. Então, o usuário descansa (Atividades: 3, 7, 11).
- **Um alvo aparece no lado esquerdo ou direito da tela. O sujeito imagina abrir e fechar o punho correspondente até o alvo desaparecer. Então, o usuário descansa (Atividades: 4, 8, 12).**
- Um alvo aparece na parte superior ou inferior da tela. O sujeito abre e fecha os dois punhos (se o alvo estiver em cima) ou os dois pés (se o alvo estiver em baixo) até que o alvo desapareça. Então, o usuário descansa (Atividades: 5, 9, 13).
- **Um alvo aparece na parte superior ou inferior da tela. O sujeito imagina abrir e fechar os dois punhos (se o alvo estiver em cima) ou os dois pés (se o alvo estiver em baixo) até que o alvo desapareça. Então, o usuário descansa (Atividades: 6, 10, 14).**

Os dados contêm 64 sinais de EEG (um para cada eletrodo), a uma taxa de 160 amostras por segundo (160 Hz) e um canal de anotação. Cada anotação inclui um dos três códigos (T0, T1 ou T2) ilustrados na figura 17:

- T0 corresponde ao descanso;
- T1 corresponde ao início do movimento (real ou imaginado) do:
 - punho esquerdo (nas atividades 3, 4, 7, 8, 11 e 12);
 - ambos os punhos (nas atividades 5, 6, 9, 10, 13 e 14);
- T2 corresponde ao início do movimento (real ou imaginado) do:
 - punho direito (nas corridas 3, 4, 7, 8, 11 e 12);
 - ambos os pés (nas corridas 5, 6, 9, 10, 13 e 14).

Neste trabalho, foram utilizados apenas os dados de imaginação dos punhos esquerdo ou direito, atividades 4, 8, 12 e imaginação de ambos os punhos ou ambos os pés, atividades 6, 10, 14.

Figura 17 – Exemplo de Sinal de EEG (Atividade 8). (A) - Anotação T1 que corresponde ao início da imaginação do movimento do punho esquerdo. (B) - Anotação T0 que corresponde ao início do descanso.



Fonte: Autor

4.1.2 Pré Processamento

A etapa de pré processamento dos dados tem como objetivo evitar grandes discrepâncias nos valores das base de dados, evitar que haja dados faltando, entre outros ajustes necessários às bases.

4.1.2.1 Normalização

A normalização é um pré processamento de dados bastante utilizado e tem como finalidade evitar que haja predominância de alguma característica e que ela possa ser responsável pela maior parcela do modelo. Para isso, faz-se necessário normalizar os dados. Neste caso a normalização foi de 0 a 1 e se encontra ilustrada na figura 18, no eixo x, o tempo em minutos, e no eixo y, a tensão em μV conforme a equação 4.9.




Figura 18 – Sinal de EEG. Fonte: Autor

Temos que Z_i é o valor do sinal no momento i , k é o eletrodo, Z_{max}^k e Z_{min}^k são respectivamente os valores máximos e mínimos da amostra do sinal e $(Z_i^k)_N$ é o valor do sinal normalizado variando de 0 a 1.


$$(Z_i^k)_N = \frac{Z_i^k - Z_{min}^k}{Z_{max}^k - Z_{min}^k}, \quad (4.1)$$

A normalização dos dados fez-se necessária para que as técnicas de aprendizado de máquina funcionem melhor, pois é uma forma de assegurar que variáveis em intervalos diferentes tenham a mesma significância durante o treinamento.

4.1.2.2 Filtros

Os filtros podem ser utilizados para reduzir o ruído de um sinal ou para visualizá-los em uma faixa em que ele possui maior significância. Um exemplo seria utilizar o filtro passa faixa de 8 Hz à 12 Hz, a fim de obter apenas o sinal da onda alfa, que aparece em maior intensidade durante atividades motoras. Neste trabalho, foi utilizado o filtro passa faixa nas ondas: Theta (4Hz - 8Hz), Alfa (8Hz - 12Hz) e Beta (12Hz - 30Hz), ilustradas na figura 19.

Figura 19 – Filtros do Sinal de EEG



Fonte: Autor

Percebe-se, que ao aplicar filtros aos sinais de EEG, é possível analisar o sinal de uma forma diferente, pois ele sofre alterações de amplitude. Sendo assim uma característica que pode ser avaliada para a identificação de padrões.

4.1.3 Extração de Características

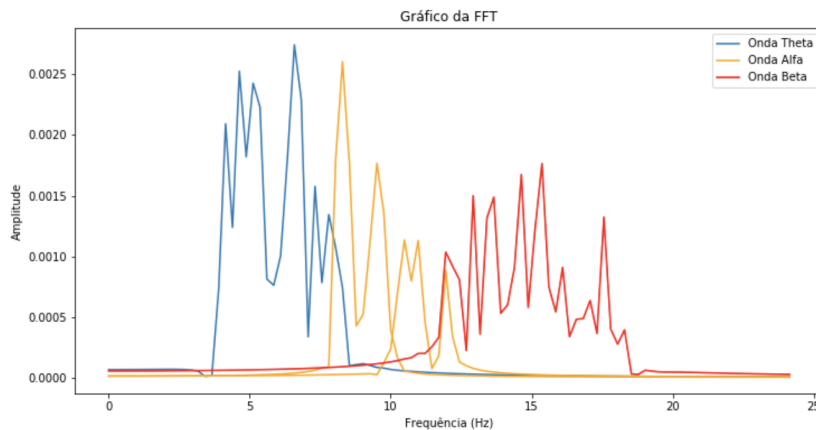
Para estabelecer uma relação entre a classificação das séries temporais, fez-se necessário buscar variáveis que possam representar/descrever o sinal através de métricas.

4.1.3.1 Transformada de Fourier

A transformada de Fourier é um método matemático que permite transformar um sinal no domínio do tempo (série temporal) em domínio da frequência, possibilitando uma análise diferente do sinal cerebral. Pois as atividades realizadas pelos pacientes / usuários podem ser predominantes em determinadas faixas de frequência.

A transformada de Fourier foi utilizada para auxiliar a análise dos EEG, visto que, algumas faixas de onda são predominantes durante alguns eventos específicos. Por exemplo, durante o movimento/pensamento as ondas alfa aparecem com maior intensidade, enquanto que durante períodos de relaxamento, as ondas theta são predominantes. Desta forma, a FFT fornece uma visão no domínio da frequência podendo auxiliar na classificação do sinal de acordo com a intensidade da faixa de onda. A figura 20 ilustra a presença das ondas utilizadas e suas respectivas intensidades onde, em azul temos a onda Theta (4 Hz - 8 Hz), já em amarelo a onda Alfa (8 Hz - 12 Hz) e em vermelho a onda Beta (12 - 30 Hz).

Figura 20 – Transformada de Fourier (FFT)



Fonte: Autor

O cálculo da *Fast Fourier Transform* (FFT) é dado pela equação 4.2.

$$F(u) = \frac{1}{N} \sum_{x=0}^{N-1} Z(x)W_N^{ux}, \quad (4.2)$$

Onde $Z(x)$ é o sinal no domínio do tempo, $F(u)$ é o sinal no domínio da frequência e N o número de amostras do sinal.

Com isso, uma das características utilizadas para classificar o sinal de EEG foi a frequência e sua amplitude.

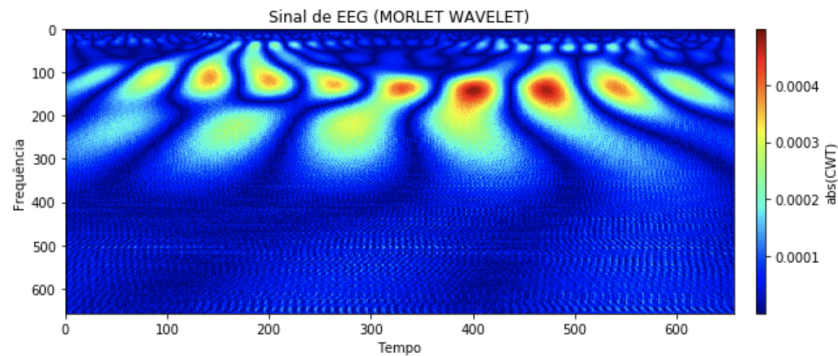
4.1.3.2 Transformada Wavelet (Morlet)

Uma outra característica extraída do sinal de EEG foi a *Morlet Wavelet*, que complementa a transformada de Fourier através da operação de convolução, ao utilizar uma função núcleo, neste caso a *Morlet*, $e^{-1/2t^2}$. Além de fornecer a informação no domínio da frequência, permite sua visualização temporal com diferentes intensidades (amplitudes). A utilização da transformada wavelet foi devido a sua capacidade de decompor o sinal em pequenas faixas para a análise em conjunto no tempo e frequência, possibilitando uma nova interpretação do sinal, conforme a figura 21.

$$\Psi(t) = \pi^{-\frac{1}{4}} e^{iW_0 t} e^{-1/2t^2} \quad (4.3)$$

Onde $\Psi(t)$ é o valor da Transformada *Morlet Wavelet*, que pode ser entendida como função periódica, cuja amplitude é modulada por uma gaussiana de núcleo $e^{-1/2t^2}$, t o tamanho do sinal.

Figura 21 – Gráfico da Morlet Wavelet



Fonte: Autor

4.1.3.3 Principal Componente de Análise (PCA)

A técnicas de PCA é um método estatístico de múltiplas variáveis que realiza a análise dos dados visando sua redução de dimensões, eliminando sobreposições e representando os dados a partir de combinações lineares das variáveis. A análise das componentes principais é uma maneira de identificar a relação entre características extraídas dos dados, e é bastante útil quando existem muitas dimensões, quando a representação gráfica não é possível.

O objetivo do PCA é que, dado um conjunto de variáveis $Z = (Z_1, Z_2, \dots, Z_n)$, é possível encontrar combinações lineares que resultem em $Y = (C_1X_1, C_2X_2, \dots, C_nX_n)$, não correlacionados, ordenados de forma que C_1X_1 seja mais relevante que C_2X_2 , e assim sucessivamente, que descrevam as variações dos dados com a maior variância possível, mas preservando ao máximo as informações dos dados originais.

De acordo com (BINGHAM; MANNILA, 2001), as componentes principais podem ser obtidas calculando os autovalores da matriz de covariância C , como apresentada na equação 4.4.

$$CV_i = \gamma V_i \quad (4.4)$$

Onde C é a matriz covariância dos dados, γ os autovalores da matriz C e V_i os autovetores correspondentes. Considerando $E_k = [V_{i_1}, V_{i_2}, \dots, V_{i_n}]$ e $\gamma = [\gamma_1, \gamma_2, \dots, \gamma_n]$, temos que $CE_k = E_k\gamma$, então:

$$X^{PCA} = E_k^T X \quad (4.5)$$

A técnica de PCA foi utilizada nos sinais cerebrais para reduzir a quantidade de eletrodos (64) para apenas 10, que foram capaz de representar 85 % da variância total dos dados, facilitando o processo de treinamento.

A escolha dos 10 eletrodos foi devido ao fato deles representarem 85% dos dados, com isso, foi possível reduzir a dimensão de 64 para apenas 10, e ao excluir o restante dos eletrodos, perdeu-se apenas 15% de representatividade dos dados. No entanto, comprimiu consideravelmente a quantidade de dados, reduzindo assim o tempo de treinamento.

4.1.3.4 Entropias

Uma outra característica extraída foi a entropia que, de acordo com (SHANNON, 1948), é utilizada para medir o grau de incerteza das informações relativas a um conjunto de dados analisados. A entropia permite uma comparação entre propriedades de sistemas em termos numéricos, por meio da sua distribuição de probabilidades (DAN, 2011).

Onde dado uma amostra de dados $Z = z_1, z_2, z_3, \dots, z_m$, a entropia de Shannon pode ser definida pela equação 4.6:

$$H(X) = -c \sum p(Z_i) * \log_2 p(Z_i), \quad (4.6)$$

onde c é uma constante positiva e $p(z_i)$ é a probabilidade de $Z_i \in X$ satisfazer: $\sum p(Z_i) = 1$.

Utilizou-se também, como característica a entropia de permutação ou *permutation entropy* (BANDT; POMPE, 2002), descrita pela equação 4.7:

$$PE_D = - \sum_{i=1}^{D!} p_i * \log_2 p_i, \quad (4.7)$$

onde D é comprimento de blocos que captura as relações de ordem (classificações de permutação) entre os valores e p_i é a frequência associada ao i th padrão de permutação, $i = 1, 2, 3, \dots, D!$. (HENRY; JUDGE, 2019).

4.1.4 Classificação

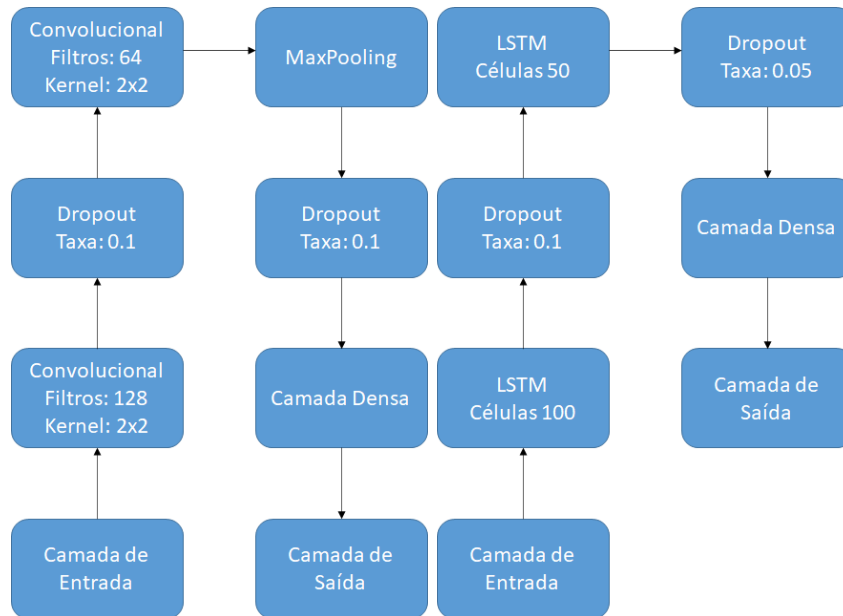
A seção de classificação dos dados trata do detalhamento dos modelos de *deep learning* desenvolvidos para classificar os sinais cerebrais. Desde a quantidade de dados separados para o treinamento e teste, como também, as métricas utilizadas para comparar os resultados obtidos com a literatura.

4.1.4.1 Arquitetura das Redes

As arquiteturas das redes utilizadas neste trabalho são descritas com as informações de modelo de treinamento, quantidade de neurônios em cada camada, quantidade de camadas e valores de saída (camada de saída).

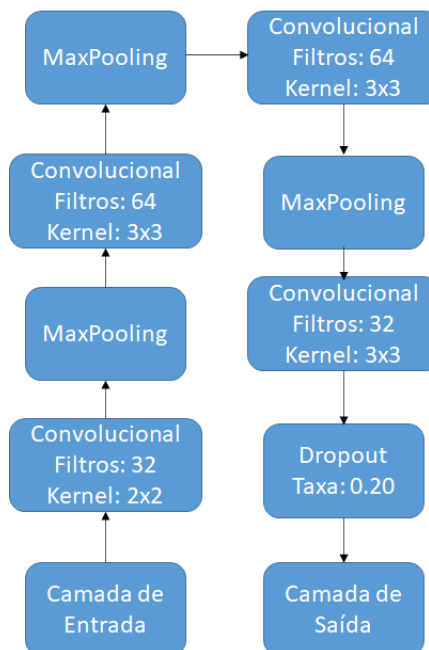
As arquiteturas utilizadas para a classificação do sinal cerebral foram de acordo com a figura 22.

Figura 22 – Arquiteturas da Rede para classificação do sinal cerebral.



(a) Arquitetura CNN (Método 1)

(b) Arquitetura LSTM (Método 1)



(c) Arquitetura CNN (Método 2)

Fonte: Autor

O método 1 foi utilizado para classificar os sinais cerebrais em apenas duas categorias, imaginação do movimento do punho direito ou esquerdo. A camada de entrada foram os dados dos sinais bruto (sem extração de características) ou alguma característica extraída (PCA, Entropia). Na arquitetura CNN, após os filtros convolucionais, utilizou-se uma taxa de perda de

10% por fim, na camada de saída foi o resultado da classificação da imaginação do movimento. Já na LSTM, após a camada de entrada, também tem duas camadas ocultas mas na primeira, o dropout é de 10% enquanto que a segunda, é de 5%, reduzindo ainda mais o esquecimento, finalmente na camada de saída, é classificado a imaginação do movimento.

Já o fluxograma da figura (c), o método 2, foi utilizado para classificar além da imaginação dos movimentos imaginários dos punhos direito/esquerdo, os movimentos de ambos os punhos/pés, ou seja, 4 categorias. Para esta classificação, procurou-se utilizar uma arquitetura similar ao trabalho de (HOU et al., 2020) com algumas modificações. Desta forma, a camada de entrada foi a transformada Morlet Wavelet após o sinal passar por um filtro passa banda entre 8 Hz e 32Hz, com intuito de predominar apenas as ondas, alfa e beta. Logo em sequência, o treinamento da rede se deu com a escolha dos parâmetros para os filtros convolucionais e o kernel na sequência de uma camada MaxPooling para reduzir o tamanho das amostras. Antes da saída, há a função dropout com 20% e, por fim, a saída que é capaz de classificar um dos 4 pensamentos.

As camadas de entrada foram bem diversificadas, desde dados brutos (sinal do EEG apenas normalizado) a entradas resultantes da extração de características, envolvendo frequência, PCA e entropia. Já na camada de saída, conforme mencionado na seção 4.1.1, foram utilizados dois métodos, um para classificar duas categorias de movimentos imaginários dos punhos direito/esquerdo, método 1 (atividades 4,8 e 12) e outro para classificar, além dos movimentos dos punhos, os movimentos de ambos os pés/punhos (atividades 6,10,14) totalizando quatro categorias, método 2.

4.1.4.2 Separação Teste e Treino

Devido ao fato da base de dados cerebrais possuir 109 usuários, foram selecionados apenas 10: do 100 ao 109, que foram treinados em conjunto, onde não houve distinção dos sinais individuais.

Quando um usuário realiza uma atividade (separada em apenas duas categorias), são gravados dois minutos de sinal. Neste caso, o usuário repete a atividade 30 vezes, sendo que apenas 15 referem-se ao pensamento de um movimento. Quanto ao restante, não houve pensamento de nenhuma ação, pois houve descanso, que não foi utilizado no treinamento. Desta forma, uma atividade possui 15 registros, como foram realizadas 3 atividades para imaginação do movimento do punho direito/esquerdo (atividades 4,8,12), tem-se 45 registros de forma individual.

Da mesma maneira, quando foram utilizadas duas atividades distintas, imaginação do movimento do punho direito/esquerdo, ou ambos os pés/punhos (classificação de 4 categorias), houve 15 registros por atividade. Como neste caso foram duas atividades realizadas, cada uma duas vezes, o total foi de 90 registros. No entanto, estes testes foram realizados de forma conjunta com os 10 usuários, perfazendo então 900 amostras.

Para os treinamentos dos sinais cerebrais, utilizou-se uma validação cruzada com $k = 3$, onde os dados foram divididos em 3 subconjuntos. A validação cruzada é uma técnica para avaliar a capacidade de generalização de um modelo, a partir de um conjunto de dados. Onde são feitas K interações, sempre variando os dados de treinamento e teste, de forma que, ao fim, todos os dados tenham sido testados.

4.1.5 Métricas de Avaliação

Os dados cerebrais foram avaliados de acordo com a acurácia (ACC) do modelo, quanto mais próximo de 100%, melhor. Isso indica uma performance geral do modelo.

$$ACC = \frac{VP + VN}{VP + VN + FP + FN}, \quad (4.8)$$

onde, VP - verdadeiro positivo; VN - verdadeiro negativo; FP - falso positivo e FN - falso negativo.

Desta forma, é possível avaliar os modelos, de classificação e compará-los com a literatura.

4.2 Radiação

4.2.1 Base de Dados

A medição da radiação solar foi conduzida num horizonte anual do ano de 2019. Os dados experimentais foram adquiridos numa estação experimental localizada na cidade de Maceió, Alagoas, situado mais especificamente, no bairro da Jatiúca, próximo ao litoral. A medição das variáveis climatológicas, temperatura ambiente e radiação solar foram provenientes dos sensores de temperatura de ar e um solarímetro fotovoltaico, ambos com saídas analógicas.

O armazenamento das informações de temperatura ambiente ($^{\circ}C$) e radiação solar (W/m^2) é efetivada a partir de um datalogger da empresa CAMPBELL, referência CR1000. O datalogger é programado via software (LOGGER NET), assim tem-se uma gama de possibilidades de ajustar as configurações das portas analógicas de leitura dos sensores em uso, como selecionar o range de tensão, aplicar filtros contra ruídos, offset entre outras funções.

Além disso, a taxa de aquisição de dados foi programada numa frequência de 1 registro por minuto, isso reflete em 1440 dados de informações por variável em um dia, no ano tem-se um total de 525600 de dados por variável. Por vez, o usuário pode realizar a análise das variáveis, acessando o arquivo em formato de texto da memória de massa do datalogger.

Paralelamente, o dispositivo de aquisição de dados também recebe informações operacionais de um sistema fotovoltaico de geração de energia elétrica conectado à rede elétrica local da distribuidora. Assim como as variáveis climatológicas, todas as grandezas elétricas inerentes ao sistema fotovoltaico também são coletadas e armazenadas na memória do CR1000.

O gerador fotovoltaico é composto por 19 painéis de 270 Watt Pico (Wp) cada, totalizando uma capacidade instalada de 5130 Wp fornecendo potência em corrente contínua (CC) para um inversor de tensão de potência nominal de 5000 W, responsável por fazer a interface e o sincronismo entre o arranjo fotovoltaico e a rede elétrica da concessionária de eletricidade (CA).

Algumas características da base de dados estão descritas na Tabela 3. A coluna horário refere-se ao horário da medição, contendo a data, hora e minuto da medição. A coluna radiação descreve a média da radiação no período de um minuto, da mesma forma a temperatura no painel, que descreve a média da temperatura nos 19 painéis solares. Por fim, a coluna demanda, informa a quantidade de energia consumida na residência.

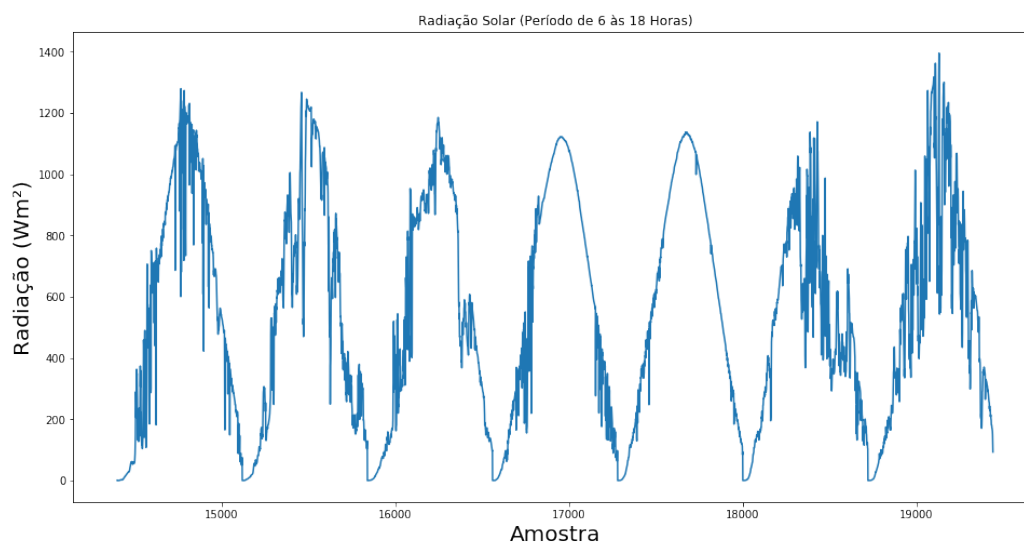
Tabela 3 – Algumas Características da base de dados

Horário	Radiação	Temperatura no Painel	Demanda
11-01-2019 06:00:00	0.864	27.47	241.8
17-03-2019 14:34:00	885	49.06	228.1
22-04-2019 11:08:00	1063	54.16	39.64
30-06-2019 16:16:00	392.3	34.44	63.37

Devido ao fato de não haver sol durante o período noturno (18h às 6h), apenas foram considerados os dados de 6h da manhã às 18h da noite, período em que há a presença do sol, pois é durante o dia que existe a dificuldade de prever a radiação, devido as condições climáticas, como nuvens e chuva.

Uma amostra da radiação no período de uma semana é ilustrado na figura 23.

Figura 23 – Radiação durante 12/03/2019 a 18/03/2019



Fonte: Autor

4.2.2 Pré Processamento

De forma similar ao sinal de EEG, os dados de radiação também foram normalizados de 0 a 1, de acordo com a equação

$$(R_i)_N = \frac{R_i - R_{min}}{R_{max} - R_{min}}, \quad (4.9)$$

e é ilustrada o período de um dia na figura 24.

Onde R_i é o valor da radiação no momento i , R_{max} e R_{min} são respectivamente os valores máximos e mínimos da amostra do sinal, e $(R_i)_N$ é o valor da radiação normalizada, variando de 0 a 1.




Figura 24 – Gráfico da Radiação Normalizada / Radiação. Fonte: Autor

Como não houve extração de características dos sinais de radiação solar, a etapa seguinte foi a de predição dos dados.

4.2.3 Predição

Aqui, são abordados os modelos desenvolvidos para a predição dos dados de radiação solar, a separação dos dados de treino e teste, e as métricas de avaliação dos resultados.

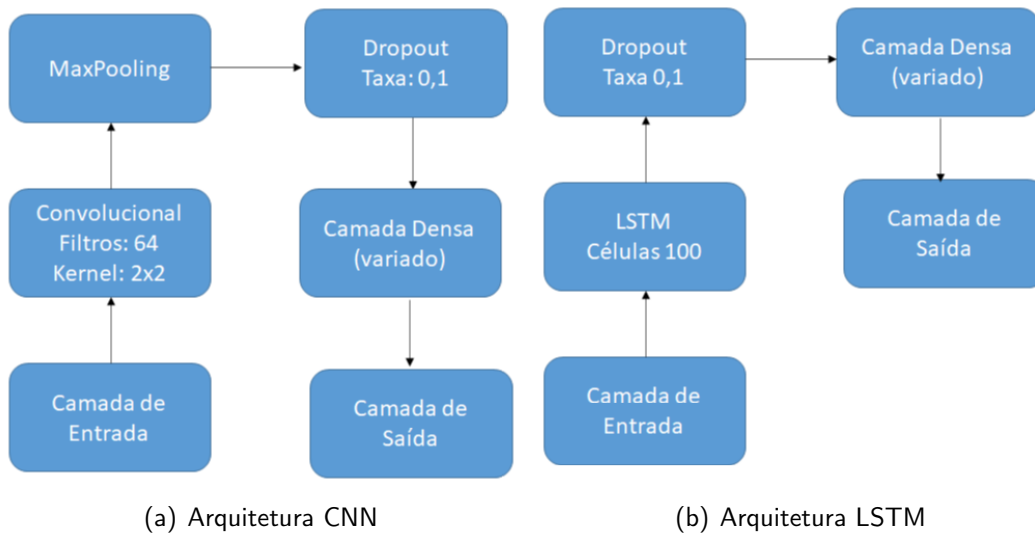
4.2.3.1 Arquitetura das Redes

As arquiteturas das redes utilizadas neste trabalho são descritas com as informações de modelo de treinamento, quantidade de neurônios em cada camada, quantidade de camadas e valores de saída (camada de saída).

Para os dados de radiação, foram utilizados dois modelos apenas, um de LSTM e um de CNN, que são ilustrados na figura 25.

As duas arquiteturas foram utilizadas para predição da radiação n minutos à frente. A camada de entrada, onde os dados anteriores de radiação são inseridos, variou entre 10, 20, 60 e 100 minutos, ou seja, eram visto os 10/20/60/100 últimos dados de radiação para estimar os próximos valores *forecast*, de 1, 2 e 5 minutos à frente. Devido a pouca quantidade de dados

Figura 25 – Arquiteturas da Rede para Predição da Radiação.



Fonte: Autor

na camada de entrada, não se viu a necessidade de utilizar 2 camadas ocultas ou tornar o modelo mais complexo, com mais camadas.

4.2.3.2 Separação Teste e Treino

Conforme mencionado na seção 4.1.1, os dados de radiação foram obtidos durante o ano de 2019 de 1 em 1 minuto, totalizando 1440 dados diários. Devido à utilização, apenas, dos dados do período diurno, entre 6h e 18h, eles foram reduzidos pela metade, totalizando então 720 dados/dia. No entanto, devido à presença de dados que estavam faltando, incoerência e outros erros, dos 365 dias, restaram 286. Sendo assim, a base de dados de radiação utilizada possuía 205.920 amostras. Então, separou-se para treino 80% (164.736) e para teste 20% (41.184) dados.

Para o treinamento dos dados de radiação foram utilizados 30 épocas, otimizadores "adam" e função de perda "mse", tanto na arquitetura LSTM quanto na CNN.

4.2.3.3 Métricas de Avaliação

Os resultados da predição dos dados de radiação são analisados de acordo com o *root mean square error*,

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}}, \quad (4.10)$$

que é um erro que atribui pesos às diferenças entre o valor real (y_i) e o valor predito (\hat{y}_i). Quanto menos, melhor; o *mean absolute error* (MAE)

$$MAE = \frac{\sum_{i=1}^N |y_i - \hat{y}_i|}{N}, \quad (4.11)$$

que é o somatório dos erros, dividido pelo número de erros calculado, mais uma vez, quanto menor, melhor; e o Coeficiente de Determinação (R^2)

$$R^2 = 1 - \frac{\sum(y_i - \hat{y})^2}{\sum(y_i - \bar{y})^2}, \quad (4.12)$$

que mede quanto do erro de previsão é eliminado quando usamos a regressão de mínimos quadrados, onde \bar{y} a média dos valores reais.

5 Avaliação das técnicas

Os resultados foram separados de acordo com o tipo da base de dados. Para os sinais de EEG, utilizou-se a acurácia dos modelos para avaliar o desempenho, enquanto que, nos dados de radiação, os resultados foram analisados de acordo com os erros na predição (RSME, MAE e R^2).

Para o treinamento foi utilizado um Macbook Pro I5 8ª Geração com 8GB de RAM. A linguagem de programação foi Python e a biblioteca *TensorFlow 2.0.0*.

5.1 Resultados - Classificação do Sinal Cerebral

Os dados cerebrais foram treinados com 30 execuções para cada usuário. No primeiro método, o resultado encontrado foi a média das apurações referente aos dados dos 10 usuários, tendo como objetivo classificar a imaginação do movimento do punho direito/esquerdo e são elencados na tabela 4. A coluna Dados/Características Extraídas descreve o tipo de dado utilizado e se foi empregada alguma extração de características na base. Já a coluna Pré Processamento, descreve as etapas o processamento dos elementos. A coluna Modelo, elenca os modelos utilizados. Por fim, a ultima coluna, acurácia, é representada pelo resultado final da média dos 10 usuário e do desvio padrão.

Tabela 4 – Comparação de Modelos para Classificação de Sinais Cerebrais (Movimento Imaginário do punho esquerdo/direito).

Dados/Característica Extraída	Pré Processamento	Modelo	Acurácia
Dados Bruto	Normalização	LSTM	67% (7%)
Dados Bruto	Normalização	CNN	64% (5%)
Dados Bruto	Normalização	CNN + LSTM	65% (11%)
Densidade Espectral	Normalização + Filtros (8 Hz - 32Hz)	LSTM	48% (12%)
Entropia (Shannon + Permutation)	Normalização + Filtros (8 Hz - 32Hz)	LSTM	53% (14%)
PCA	Normalização + Filtros (8 Hz - 32Hz)	LSTM	55% (11%)

Os dados de densidade espectral foram utilizados após a aplicação da FFT nos sinais. Já os dados de PCA, conforme descritos na seção 4.1.3, foram reduzidos de 64 eletrodos para apenas 10 com uma representatividade de 85%.

Os resultados mostram que a utilização dos dados brutos, sem nenhuma extração de características, apenas a utilização de pré processamento, tiveram resultados superiores às técnicas em que houve, ao menos, uma extração de características e podem ser comparados

com (FARIAS; RATIVA; FILHO, 2014) que obteve resultados similares para a mesma base de dados.

Desta forma, simplesmente extrair características dos dados não obteve um resultado interessante, principalmente ao utilizar a densidade espectral que resultou num resultado abaixo dos 50%, mostrando que, ao aplicar apenas a FFT em conjunto com a LSTM não é interessante.

Dentre os modelos utilizados, a LSTM obteve melhor resultado, confirmando que pode ser uma boa técnica para séries temporais, conforme descrito na seção 3. Por ser capaz de recordar o que foi aprendido e encontrar padrões, a LSTM foi superior a CNN na análise dos dados brutos que está no domínio do tempo.


Um segundo método de avaliação consistiu na ordenação da classificação de 4 categorias, onde, além de classificar a imaginação do movimento do punho, incluiu a imaginação do movimento dos dois punhos e dos dois pés. Para este modelo, foram avaliados eletrodos distintos de acordo com a região de interesse (HOU et al., 2020). Para isso, utilizou-se a transformada Morlet Wavelet como entrada da rede neural e como saída uma das 4 classificações. Antes de aplicar a transformada Morlet Wavelet, os dados foram normalizados e filtrados com um filtro passa faixa entre 8 Hz e 32 Hz.

A utilização da Morlet Wavelet se deu devido a sua capacidade de não apenas analisar o sinal no domínio do tempo ou da frequência separadamente, mas, de analisar o sinal em ambos os domínios simultaneamente, permitindo assim, a visualização do momento em que há a predominância de uma faixa de frequência específica.

Como a Morlet Wavelet transforma o sinal temporal em um espectrograma, ou seja, uma imagem, foram utilizadas, apenas, redes de aprendizado profundo do tipo CNN que tendem a obter melhores resultados para classificar imagens e vídeos.

Desta forma, no método 2, em cada sinal de eletrodo foi aplicado a Morlet Wavelet, mas, dos 64 eletrodos, apenas 21 foram utilizados separadamente, ou seja, a classificação do movimento foi utilizando apenas um eletrodo de cada vez. Os eletrodos utilizados estão destacados na figura 26, eles foram selecionados de acordo com a região de interesse e o trabalho de (HOU et al., 2020).

Figura 26 – Eletrodo utilizados (destacados).



Fonte: Modificada de (GOLDBERGER et al., 2000).

Os resultados encontrados representam a classificação de cada eletrodo individualmente na tabela 5.

Para a classificação de 4 categorias e utilizando como extração de característica, a transformada Morlet Wavelet, o eletrodo 16 (CP3) obteve melhor resultado, com uma acurácia de 83%, superando os demais. Por ser localizado no lobo parietal, região responsáveis pelos pensamentos, é possível que tenha contribuído para seu resultado superior aos demais e, podem ser comparados com alguns trabalhos da literatura obtendo resultados superiores. Como (FARIAS; RATIVA; FILHO, 2014) que obteve resultado de 71% para a mesma base de dados. No entanto, não foi capaz de superar (HOU et al., 2020) que, ao utilizar CNN na classificação, obteve uma acurácia de 94%.

Já alguns eletrodos obtiveram resultados péssimos (abaixo de 50%), principalmente os localizados na região central, entre frontal e parietal. Outra região que não obteve resultados interessantes (acima de 60%) foram os localizados na região temporal. Por fim, temos que os eletrodos localizados na região centro parietal do hemisfério esquerdo (eletrodos 15 e 16), são os que obtém melhores resultados.

Como o hemisfério esquerdo é responsável pela parte lógica e pensamento e o lado direito pelas emoções, é possível que o resultado superior no lado esquerdo do cérebro seja

Tabela 5 – Comparação de Modelos para Classificação de Sinais Cerebrais (Movimento Imaginário do punho esquerdo/direito, ambos os punhos/pés).

Hemisfério	Eletrodo	Acurácia (desvio)
Hemisférios Esquerdo	43 - T_9	58% (1,4%)
	41 - T_7	50% (4,3%)
	8 - C_5	50% (8%)
	9 - C_3	33% (1,5%)
	10 - C_1	50% (8%)
	15 - CP_5	71,4% (4,6%)
	16 - CP_3	86% (8%)
	17 - CP_1	57% (0,6%)
	47 - P_7	66,6% (1,4%)
	48 - P_5	41,6% (1,7%)
Hemisférios Direito	49 - P_3	58,3% (2,2%)
	7 - FC_6	58,3% (2%)
	40 - FT_8	50% (4,1%)
	12 - C_2	50% (8%)
	13 - C_4	50% (8%)
	14 - C_6	25% (7%)
	42 - T_8	50% (0,69%)
	20 - CP_4	41,6% (2,5%)
	19 - CP_2	41,6% (1,8%)
	52 - P_2	50% (8%)
53 - P_4	50% (1,8%)	

devido a essas características.

Resultados similares foram encontrados em (HOU et al., 2020) que, também, obteve melhores resultados no hemisfério esquerdo e na região centro parietal.

De acordo com os resultados obtidos nas tabelas 4 observa-se que a LSTM obteve resultados superiores a CNN ao classificar as séries temporais sem extração de características. Já na tabela 5, em que a classificação foi de acordo com a região (eletrodo), percebe-se que o hemisférios esquerdo do cérebro, na região centro parietal, obteve os melhores resultados.

Assim, percebe-se que as técnicas de aprendizagem profunda são capazes de classificar sinais cerebrais, dando uma maior motivação para novas investigações.

5.2 Resultados - Predição da Radiação

Os treinamentos da predição da radiação solar foram realizados com 30 épocas. Os resultados encontrados são representados em relação aos modelos de treinamento (LSTM / CNN) e o erro encontrado.

A tabela 6 elenca os resultados obtidos na predição da radiação. Os dados lidos representam a quantidade de dados que foram utilizados para realizar a predição, *forecast* é a quantidade de dados que foram preditos à frente. Observa-se que os melhores resultados são aqueles em que ocorre a predição apenas de um único valor à frente, ou seja, *forecast* igual a 1. Outra observação é que, quanto mais dados estimados à frente, *forecast* maior, resultando um aumento do erro, ou seja, as estimativas tendem a se afastar mais do valor real.

Os melhores resultados (predição de 1 minuto à frente) são superiores pois, prever um maior horizonte temporal torna-se mais difícil em razão das mudanças abruptas do clima, seja a passagem de uma nuvem ou a presença de chuva.

Tabela 6 – Tabela de Resultados

Dados Lidos	Forecast	Arquitetura	RMSE	MAE	R ²
20	1	LSTM	78,52	34,83	0.955
		CNN	79,36	35,53	0.954
	2	LSTM	92,38	44,74	0.937
		CNN	97,52	54,78	0.93
60	1	LSTM	78,84	34,14	0.954
		CNN	80,03	37,86	0.953
	2	LSTM	93,22	45,6	0.936
		CNN	93,92	45,92	0.935
	5	LSTM	113,22	58,1	0.906
		CNN	115,98	58,52	0.901
100	1	LSTM	80,96	36,02	0,952
		CNN	79,97	37,10	0.953
	2	LSTM	100,95	53,32	0.925
		CNN	92,82	42,77	0.937
	5	LSTM	114,05	60,58	0.904
		CNN	115,93	58,92	0.901

Utilizamos uma variação de 20/60/100 dados lidos (dados observados no passado para estimar as previsões futuras) e uma predição (*forecast*) de poucos dados à frente (1/2/5 minutos), pois o intuito foi utilizar a predição da radiação para prever as variações da tensão nos painéis, num curto espaço de tempo, pois podem ocasionar problemas na rede de distribuição e na operação do sistema fotovoltaico. Neste caso, com a predição da tensão, é possível desenvolver estratégias para mitigar as falhas nos painéis.

Durante o treinamento foram utilizados vários valores de leitura e de predição, conforme apresentados na tabela 6, buscando encontrar um modelo que obtivesse o melhor resultado possível.

O menor erro encontrado foi com RMSE de $78,52 \text{ W/m}^2$ e MAE de $34,83 \text{ W/m}^2$ ao


utilizar a arquitetura de LSTM, superando as que utilizaram a CNN. Os valores encontrados são interessantes pois, a máxima radiação solar é de 1600 W/m^2 , dessa forma, o erro médio absoluto encontrado é $34,83 \text{ W/m}^2$, ou seja, o valor estimado fica entre, mais ou menos, $34,83 \text{ W/m}^2$ do valor real, na média.

Outro fato observado foi que a predição de mais dados à frente obteve resultados inferiores e que, na maioria das situações, a LSTM foi superior à CNN.

O gráfico 27 ilustra o melhor resultado encontrado, onde é possível perceber que os resultados de predição (vermelho) estão muito próximos dos valores reais (azul).

No entanto, alguns valores de predição estão distantes dos valores reais, isso ocorre, principalmente, em dias com uma grande oscilação da radiação solar, onde a predição é de extrema dificuldade. Dias com oscilações bruscas, tendem a ser dias com fortes chuvas ou, com grande presença de nuvens, o que dificulta a predição da radiação solar, aumento assim, o erro.

Figura 27 – Resultado do melhor modelo de predição.



Fonte: Autor

Ainda no gráfico 27, onde é ilustrada a predição de 5 dias, ao analisar os 3 últimos dias, nota-se, uma maior variação da radiação, desta forma, a predição tem mais erros. Apesar de todas as adversidades, na média, a radiação obteve o RMSE de $34,83 \text{ W/m}^2$.

Assim, entende-se que, ao utilizar técnicas de aprendizado profundo, é possível obter a predição da radiação com um erro baixo.

As técnicas de aprendizagem profunda obtiveram respostas que, podem ser comparados, de forma qualitativa, aos da literatura. Para o cenário que consideramos, nosso melhor resultado foi o de RMSE de 78 W/m^2 ao utilizar a LSTM, que supera os apresentados para os trabalhos de (ABDEL-NASSER; MAHMOUD, 2019) com RMSE de $82,15 \text{ W/m}^2$ e (CAPO et al., 2018) com um RMSE anual médio de $122,73 \text{ W/m}^2$; além de obter resultados similares ao trabalho

de (WANG et al., 2018a) com R^2 de 95,5%. Apesar de não considerarmos os mesmos dados e cenários, nossos resultados são promissores e indicados para outras aplicações.

6 Conclusão e Trabalhos Futuros

Este estudo investigou a aplicação das redes neurais de aprendizado profundo para a previsão da classificação de sinais cerebrais ao extrair diversas características destes sinais, e da radiação solar em diferentes horizontes temporais.

Apesar dos resultados obtidos, classificar um sinal cerebral e prever a radiação é algo complexo e difícil, pois depende de variáveis que nem sempre podemos mensurar com a qualidade necessária. Todavia, são áreas que vêm ganhando força, a do desenvolvimento de modelos para a classificação de EEG, para o controle de próteses e comunicação através dos pensamentos, e a predição de eventos futuros para estimar produção de energia e falhas no sistema fotovoltaico. Os avanços na meteorologia, engenharia, e saúde, têm sido de uma grandeza imensurável, ou seja, a ciência como um todo tem aproveitado e sido grande parceira dos avanços tecnológicos.

De acordo com os resultado obtidos, apesar da dificuldade em classificar a imaginação de um movimento, foi possível obter uma acurácia de 86%, ao utilizar técnicas de aprendizado profundo. Mostrando que, apesar do sinal cerebral conter uma enorme quantidade de ruído, com a utilização de técnicas cada vez mais robusta, torna-se viável sua classificação.

De forma similar, com a utilização de técnicas complexas, como a CNN e LSTM, foi possível estimar a predição da radiação solar em diferentes horizontes temporais com um RMSE de $78,52 \text{ W/m}^2$. Desta forma, é possível estimar a produção de energia solar, bem como, detectar possível falhas nos sistemas fotovoltaicos.

Com isso, vários estudos ainda devem ser realizados em diversas áreas para a classificação e predição de eventos, e as redes neurais de aprendizado profundo podem ser uma excelente ferramenta para auxiliar esses estudos devido a sua capacidade de recordar o que foi aprendido e de extrair características dos dados que podem descrevê-los com mais precisão. Cabe salientar que todos esses métodos, técnicas e ferramentas, aqui apresentados, são de fundamental importância para embasar as tomadas de decisões nas mais diversas áreas de estudo - objetivo primordial de todos os pesquisadores.

Como trabalhos futuros, para os sinais cerebrais, pretendemos utilizar outras base de dados, além de buscar outras características que possam ser utilizadas para classificação do sinal e, assim, superar a literatura. Já para a radiação solar, pretendemos realizar a predição de um maior horizonte temporal, como dez ou quinze minutos à frente, a aplicação de técnicas de extração de características como *Wavelet*, além de desenvolver diferentes modelos para dias chuvosos e ensolarados. Por fim, seria também interessante utilizar um maior número de variáveis na predição da radiação como: temperatura dos painéis solares, temperatura ambiente, velocidade do vento, dentre outras.

Referências

- ABDEL-NASSER, M.; MAHMOUD, K. Accurate photovoltaic power forecasting models using deep lstm-rnn. *Neural Computing and Applications*, Springer, v. 31, n. 7, p. 2727–2740, 2019. Citado 3 vez(s) na página(s) 42, 45 e 68.
- AGUIAR, J. L. D. N. *Medidas de Similaridade entre Séries Temporais*. Tese (Doutorado) — Universidade Católica do Rio de Janeiro, 2016. Citado na página 29.
- ALI, H. et al. Seizure prediction using bidirectional lstm. In: *Cyberspace Data and Intelligence, and Cyber-Living, Syndrome, and Health*. [S.l.]: Springer, 2019. p. 349–356. Citado na página 42.
- ALZHRANI, A. et al. Solar irradiance forecasting using deep neural networks. *Procedia Computer Science*, Elsevier, v. 114, p. 304–313, 2017. Citado 2 vez(s) na página(s) 25 e 45.
- AMARAL, D. G.; STRICK, P. The organization of the central nervous system. *Principles of neural science*, McGraw-Hill New York, p. 337–355, 2013. Citado 2 vez(s) na página(s) 30 e 32.
- BAIJAL, S.; SRINIVASAN, N. Theta activity and meditative states: spectral changes during concentrative meditation. *Cognitive processing*, Springer, v. 11, n. 1, p. 31–38, 2010. Citado na página 33.
- BANDT, C.; POMPE, B. Permutation entropy: a natural complexity measure for time series. *Physical review letters*, APS, v. 88, n. 17, p. 174102, 2002. Citado na página 54.
- BILUCAGLIA, M. et al. Applying machine learning eeg signal classification to emotion-related brain anticipatory activity. *F1000Research*, F1000 Research Limited, v. 9, n. 173, p. 173, 2020. Citado na página 43.
- BINGHAM, E.; MANNILA, H. Random projection in dimensionality reduction: applications to image and text data. In: *Proceedings of the seventh ACM SIGKDD international conference on Knowledge discovery and data mining*. [S.l.: s.n.], 2001. p. 245–250. Citado na página 53.
- BLINOWSKA, K.; DURKA, P. Electroencephalography (eeg). *Wiley encyclopedia of biomedical engineering*, Wiley Online Library, 2006. Citado na página 33.
- BROCKWELL, P. J.; DAVIS, R. A. *Introduction to time series and forecasting*. [S.l.]: springer, 2016. Citado na página 29.
- BUENO, L. *Interface Cérebro-Computador Baseada em EEG Utilizando Redes Neurais Auto-Organizadas*. Tese (Doutorado) — Universidade Federal do Espírito Santo, Brazil, 2017. Citado na página 32.
- CAPO, P. Í. M. et al. *Desenvolvimento de uma ferramenta para previsão de curto prazo da radiação solar utilizando redes neurais artificiais*. Tese (Doutorado) — Universidade Federal de Santa Catarina, 2018. Citado 6 vez(s) na página(s) 17, 25, 35, 36, 44 e 68.
- CHATFIELD, C. *The Analysis of Time Series: An Introduction Sixth*. [S.l.]: CRC press, 2013. Citado 2 vez(s) na página(s) 23 e 29.

- CHIARELLI, A. M. et al. Deep learning for hybrid eeg-fnirs brain–computer interface: application to motor imagery classification. *Journal of neural engineering*, IOP Publishing, v. 15, n. 3, p. 036028, 2018. Citado na página 44.
- CHOLLET, F. *Deep Learning mit Python und Keras: Das Praxis-Handbuch vom Entwickler der Keras-Bibliothek*. [S.l.]: MITP-Verlags GmbH & Co. KG, 2018. Citado 2 vez(s) na página(s) 36 e 37.
- CLAVERIA, O.; TORRA, S. Forecasting tourism demand to catalonia: Neural networks vs. time series models. *Economic Modelling*, Elsevier, v. 36, p. 220–228, 2014. Citado na página 23.
- COELHO, L. D. N. *Modelos de estimativa das componentes de radiação solar a partir de dados meteorológicos*. Tese (Doutorado) — Universidade de Brasília, 2016. Citado 2 vez(s) na página(s) 25 e 44.
- DAN, X. Energy entropy used in identification based on motor imagery eeg. In: TRANS TECH PUBL. *Advanced Materials Research*. [S.l.], 2011. v. 304, p. 274–278. Citado na página 54.
- DAVID, M. et al. Probabilistic forecasting of the solar irradiance with recursive arma and garch models. *Solar Energy*, Elsevier, v. 133, p. 55–72, 2016. Citado na página 35.
- DAVIDSON, R. J.; JACKSON, D. C.; LARSON, C. L. *Human electroencephalography*. Cambridge University Press, 2000. Citado na página 32.
- DEB, C. et al. A review on time series forecasting techniques for building energy consumption. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 74, p. 902–924, 2017. Citado 2 vez(s) na página(s) 25 e 45.
- EDE, F. van. Mnemonic and attentional roles for states of attenuated alpha oscillations in perceptual working memory: a review. *European Journal of Neuroscience*, Wiley Online Library, v. 48, n. 7, p. 2509–2515, 2018. Citado na página 33.
- ESSEN, D. V.; DRURY, H. Structural and functional analyses of human cerebral cortex using a surface-based atlas. *Journal of Neuroscience*, Soc Neuroscience, v. 17, n. 18, p. 7079–7102, 1997. Citado na página 30.
- FARIAS, F.; RATIVA, D.; FILHO, C. B. Comparando técnicas de aprendizado de máquina para classificação de sinais de eletroencefalograma. 2014. Citado 3 vez(s) na página(s) 47, 64 e 65.
- FARIAS, F. C. *Deep Learning para a Classificação de Sinais Cerebrais*. Tese (Doutorado) — Escola Politécnica de Pernambuco, 2016. Citado 4 vez(s) na página(s) 37, 38, 39 e 40.
- FASANG, A. E.; LIAO, T. F. Visualizing sequences in the social sciences: Relative frequency sequence plots. *Sociological Methods & Research*, Sage Publications Sage CA: Los Angeles, CA, v. 43, n. 4, p. 643–676, 2014. Citado na página 29.
- FLÓREZ, C. A. C. et al. *Domótica assistiva baseada na utilização de um sensor de EEG: estudo de caso*. Tese (Doutorado) — Universidade Estadual de Campinas (UNICAMP), 2016. Citado 2 vez(s) na página(s) 25 e 31.
- FRANK, E.; HALL, M. A. *Data mining: practical machine learning tools and techniques*. [S.l.]: Morgan Kaufmann, 2011. Citado na página 23.

- FREITAS, D. R. R. d. *Plataforma para análise do sinal de EEG aplicado ao ERD/ERS no reconhecimento em tempo real da imaginação do movimento*. Tese (Doutorado) — Universidade Federal de Pernambuco, 2017. Citado na página 31.
- FU, T.-c. A review on time series data mining. *Engineering Applications of Artificial Intelligence*, Elsevier, v. 24, n. 1, p. 164–181, 2011. Citado na página 24.
- GAO, J. et al. An effective lstm recurrent network to detect arrhythmia on imbalanced ecg dataset. *Journal of healthcare engineering*, Hindawi, v. 2019, 2019. Citado na página 42.
- GOLDBERGER, A. L. et al. Physiobank, physiokit, and physionet. *Circulation*, Am Heart Assoc, v. 101, n. 23, p. e215–e220, 2000. Citado na página 65.
- GOODFELLOW, I. et al. *Deep learning. vol. 1*. [S.l.]: MIT press Cambridge, 2016. Citado 2 vez(s) na página(s) 37 e 38.
- GOOIJER, J. G. D.; HYNDMAN, R. J. 25 years of time series forecasting. *International journal of forecasting*, Elsevier, v. 22, n. 3, p. 443–473, 2006. Citado na página 23.
- HALL, J. E. *Guyton and Hall textbook of medical physiology e-Book*. [S.l.]: Elsevier Health Sciences, 2010. Citado na página 30.
- HAN, J.; PEI, J.; KAMBER, M. *Data mining: concepts and techniques*. [S.l.]: Elsevier, 2011. Citado na página 24.
- HATCHER, W. G.; YU, W. A survey of deep learning: platforms, applications and emerging research trends. *IEEE Access*, IEEE, v. 6, p. 24411–24432, 2018. Citado na página 37.
- HENRY, M.; JUDGE, G. Permutation entropy and information recovery in nonlinear dynamic economic time series. *Econometrics*, Multidisciplinary Digital Publishing Institute, v. 7, n. 1, p. 10, 2019. Citado na página 54.
- HOU, Y. et al. A novel approach of decoding EEG four-class motor imagery tasks via scout ESI and CNN. *Journal of Neural Engineering*, IOP Publishing, v. 17, n. 1, p. 016048, feb 2020. Citado 6 vez(s) na página(s) 24, 44, 56, 64, 65 e 66.
- HUANG, R. et al. Solar generation prediction using the arma model in a laboratory-level micro-grid. In: IEEE. *2012 IEEE third international conference on smart grid communications (SmartGridComm)*. [S.l.], 2012. p. 528–533. Citado na página 35.
- HUBEL, D. H.; WIESEL, T. N. Ferrier lecture-functional architecture of macaque monkey visual cortex. *Proceedings of the Royal Society of London. Series B. Biological Sciences*, The Royal Society London, v. 198, n. 1130, p. 1–59, 1977. Citado 2 vez(s) na página(s) 37 e 38.
- HUTTENLOCHER, P. R. et al. Synaptic density in human frontal cortex-developmental changes and effects of aging. *Brain Res*, Elsevier, v. 163, n. 2, p. 195–205, 1979. Citado na página 31.
- KANDANANOND, K. A comparison of various forecasting methods for autocorrelated time series. *International Journal of Engineering Business Management*, SAGE Publications Sage UK: London, England, v. 4, p. 4, 2012. Citado na página 23.
- KEROUS, B.; SKOLA, F.; LIAROKAPIS, F. Eeg-based bci and video games: a progress report. *Virtual Reality*, Springer, v. 22, n. 2, p. 119–135, 2018. Citado na página 33.

- KIM, S.-G.; JUNG, J.-Y.; SIM, M. K. A two-step approach to solar power generation prediction based on weather data using machine learning. *Sustainability*, Multidisciplinary Digital Publishing Institute, v. 11, n. 5, p. 1501, 2019. Citado 2 vez(s) na página(s) 25 e 45.
- KONRAD, P.; SHANKS, T. Implantable brain computer interface: Challenges to neurotechnology translation. *Neurobiology of disease*, Elsevier, v. 38, n. 3, p. 369–375, 2010. Citado na página 34.
- LAROSE, D. T. An introduction to data mining. *Traduction et adaptation de Thierry Vallaud*, 2005. Citado na página 23.
- LAROSE, D. T.; LAROSE, C. D. *Discovering knowledge in data: an introduction to data mining*. [S.l.]: John Wiley & Sons, 2014. v. 4. Citado na página 23.
- LECUN, Y.; BENGIO, Y. The handbook of brain theory and neural networks. *chapter Convolutional networks for images, speech, and time series*, MIT Press, p. 255–258, 1998. Citado 2 vez(s) na página(s) 38 e 40.
- LIANG, Y. et al. Prediction of drowsiness events in night shift workers during morning driving. *Accident Analysis & Prevention*, Elsevier, v. 126, p. 105–114, 2019. Citado na página 33.
- LU, N. et al. A deep learning scheme for motor imagery classification based on restricted boltzmann machines. *IEEE transactions on neural systems and rehabilitation engineering*, IEEE, v. 25, n. 6, p. 566–576, 2016. Citado na página 43.
- MACHADO, A. B. Neuroanatomia funcional. In: *Neuroanatomia funcional*. [S.l.: s.n.], 1979. p. 292–292. Citado na página 30.
- MAIMON, O.; ROKACH, L. *Data mining and knowledge discovery handbook*. Springer, 2005. Citado na página 23.
- MAKKAR, T. et al. Analogizing time complexity of knn and cnn in recognizing handwritten digits. In: IEEE. *2017 Fourth International Conference on Image Information Processing (ICIIP)*. [S.l.], 2017. p. 1–6. Citado na página 24.
- MALMIVUO, P.; MALMIVUO, J.; PLONSEY, R. *Bioelectromagnetism: principles and applications of bioelectric and biomagnetic fields*. [S.l.]: Oxford University Press, USA, 1995. Citado 2 vez(s) na página(s) 32 e 33.
- METCALFE, A. V.; COWPERTWAIT, P. S. *Introductory time series with R*. [S.l.]: Springer, 2009. Citado na página 23.
- MISHRA, S.; PALANISAMY, P. An integrated multi-time-scale modeling for solar irradiance forecasting using deep learning. *arXiv preprint arXiv:1905.02616*, 2019. Citado 2 vez(s) na página(s) 26 e 45.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. *Introduction to time series analysis and forecasting*. [S.l.]: John Wiley & Sons, 2015. Citado na página 23.
- NICOLELIS, M. A.; LEBEDEV, M. A. Principles of neural ensemble physiology underlying the operation of brain–machine interfaces. *Nature reviews neuroscience*, Nature Publishing Group, v. 10, n. 7, p. 530–540, 2009. Citado na página 32.

- NORTHCUTT, R. G.; KAAS, J. H. The emergence and evolution of mammalian neocortex. *Trends in neurosciences*, Elsevier, v. 18, n. 9, p. 373–379, 1995. Citado na página 30.
- OLAH, C. Understanding lstm networks. 2015. Citado 2 vez(s) na página(s) 41 e 42.
- OREKHOVA, E. et al. Eeg theta rhythm in infants and preschool children. *Clinical neurophysiology*, Elsevier, v. 117, n. 5, p. 1047–1062, 2006. Citado na página 33.
- PARMEZAN, A. R. S. *Predição de séries temporais por similaridade*. Tese (Doutorado) — Universidade de São Paulo, 2014. Citado 2 vez(s) na página(s) 23 e 24.
- PATTERSON, J.; GIBSON, A. *Deep learning: A practitioner's approach*. [S.l.]: "O'Reilly Media, Inc.", 2017. Citado na página 37.
- PEREIRA, E. B. et al. *Atlas brasileiro de energia solar*. [S.l.]: Inpe São José dos Campos, 2006. v. 1. Citado na página 35.
- PINHO, J. T.; GALDINO, M. A. Manual de engenharia para sistemas fotovoltaicos. *Rio de Janeiro*, v. 1, p. 47–499, 2014. Citado 2 vez(s) na página(s) 34 e 35.
- QING, X.; NIU, Y. Hourly day-ahead solar irradiance prediction using weather forecasts by lstm. *Energy*, Elsevier, v. 148, p. 461–468, 2018. Citado 2 vez(s) na página(s) 26 e 45.
- RAMPAZZO, W. et al. *Aprendizado profundo e interfaces cérebro-computador*. Tese (Doutorado) — Universidade Estadual de Campinas, 2019. Citado 2 vez(s) na página(s) 36 e 39.
- RODRÍGUEZ, J. E. B. *Classificação de sinais de EEG para potenciais visuais evocados utilizando Deep Learning*. Tese (Doutorado) — Universidade Estadual Paulista (UNESP), 2020. Citado 2 vez(s) na página(s) 36 e 40.
- ROUHI, R. et al. Benign and malignant breast tumors classification based on region growing and cnn segmentation. *Expert Systems with Applications*, Elsevier, v. 42, n. 3, p. 990–1002, 2015. Citado na página 24.
- SANEI, S.; CHAMBERS, J. A. *EEG signal processing*. [S.l.]: John Wiley & Sons, 2013. Citado 2 vez(s) na página(s) 31 e 32.
- SAPANKEVYCH, N. I.; SANKAR, R. Time series prediction using support vector machines: a survey. *IEEE Computational Intelligence Magazine*, IEEE, v. 4, n. 2, p. 24–38, 2009. Citado na página 23.
- SCHAEFER, H.-E. Music-evoked emotions—current studies. *Frontiers in neuroscience*, Frontiers, v. 11, p. 600, 2017. Citado na página 33.
- SCHALK, G. et al. Bci2000: a general-purpose brain-computer interface (bci) system. *IEEE Transactions on biomedical engineering*, IEEE, v. 51, n. 6, p. 1034–1043, 2004. Citado na página 48.
- SHANNON, C. E. A mathematical theory of communication. *Bell system technical journal*, Wiley Online Library, v. 27, n. 3, p. 379–423, 1948. Citado na página 54.
- SONG, Z.; BROWN, L. E. Multi-dimensional evaluation of temporal neural networks on solar irradiance forecasting. In: IEEE. *2019 IEEE Innovative Smart Grid Technologies-Asia (ISGT Asia)*. [S.l.], 2019. p. 4192–4197. Citado na página 24.

- SORKUN, M. C.; İNCEL, Ö. D.; PAOLI, C. Time series forecasting on multivariate solar radiation data using deep learning (lstm). *Turkish Journal of Electrical Engineering & Computer Sciences*, The Scientific and Technological Research Council of Turkey, v. 28, n. 1, p. 211–223, 2020. Citado 2 vez(s) na página(s) 26 e 46.
- SÖRNMO, L.; LAGUNA, P. The electroencephalogram—a brief background. *Bioelectrical Signal Processing in Cardiac and Neurological Applications*, Elsevier Inc, v. 1, p. 25–53, 2005. Citado na página 31.
- SOUSA, J. A importância da previsão da geração elétrica de base eólica. *Brazil Windpower*, 2013. Citado na página 25.
- SRIVASTAVA, S.; LESSMANN, S. A comparative study of lstm neural networks in forecasting day-ahead global horizontal irradiance with satellite data. *Solar Energy*, Elsevier, v. 162, p. 232–247, 2018. Citado 2 vez(s) na página(s) 42 e 45.
- SWAPNA, G.; SOMAN, K.; VINAYAKUMAR, R. Automated detection of cardiac arrhythmia using deep learning techniques. *Procedia computer science*, Elsevier, v. 132, p. 1192–1201, 2018. Citado na página 42.
- TABAR, Y. R.; HALICI, U. A novel deep learning approach for classification of eeg motor imagery signals. *Journal of neural engineering*, IOP Publishing, v. 14, n. 1, p. 016003, 2016. Citado na página 43.
- TANG, Z.; LI, C.; SUN, S. Single-trial eeg classification of motor imagery using deep convolutional neural networks. *Optik*, Elsevier, v. 130, p. 11–18, 2017. Citado na página 40.
- TSIOURIS, K. M. et al. A long short-term memory deep learning network for the prediction of epileptic seizures using eeg signals. *Computers in biology and medicine*, Elsevier, v. 99, p. 24–37, 2018. Citado na página 42.
- TÜSHAUS, L. et al. In human non-rem sleep, more slow-wave activity leads to less blood flow in the prefrontal cortex. *Scientific reports*, Nature Publishing Group, v. 7, n. 1, p. 1–13, 2017. Citado na página 33.
- VALLABHANENI, A.; WANG, T.; HE, B. Brain—computer interface. In: *Neural engineering*. [S.l.]: Springer, 2005. p. 85–121. Citado na página 34.
- VIDAL, J. J. Toward direct brain-computer communication. *Annual review of Biophysics and Bioengineering*, Annual Reviews 4139 El Camino Way, PO Box 10139, Palo Alto, CA 94303-0139, USA, v. 2, n. 1, p. 157–180, 1973. Citado na página 34.
- VIDAL, J. J. Real-time detection of brain events in eeg. *Proceedings of the IEEE*, IEEE, v. 65, n. 5, p. 633–641, 1977. Citado na página 34.
- WANG, F. et al. Wavelet decomposition and convolutional lstm networks based improved deep learning model for solar irradiance forecasting. *Applied Sciences*, Multidisciplinary Digital Publishing Institute, v. 8, n. 8, p. 1286, 2018. Citado 3 vez(s) na página(s) 26, 45 e 69.
- WANG, P. et al. Lstm-based eeg classification in motor imagery tasks. *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, IEEE, v. 26, n. 11, p. 2086–2095, 2018. Citado na página 43.

WESTBROOK, G. Seizures and epilepsy. *Principles of neural science*, McGraw-Hill, v. 910, 2000. Citado na página 33.

WOLPAW, J. R. et al. Brain–computer interfaces for communication and control. *Clinical neurophysiology*, Elsevier, v. 113, n. 6, p. 767–791, 2002. Citado na página 34.

ZGALLAI, W. et al. Deep learning ai application to an eeg driven bci smart wheelchair. In: IEEE. *2019 Advances in Science and Engineering Technology International Conferences (ASET)*. [S.l.], 2019. p. 1–5. Citado na página 43.

ZHANG, D. et al. A convolutional recurrent attention model for subject-independent eeg signal analysis. *IEEE Signal Processing Letters*, IEEE, v. 26, n. 5, p. 715–719, 2019. Citado na página 43.

ZHANG, G. et al. Classification of hand movements from eeg using a deep attention-based lstm network. *IEEE Sensors Journal*, IEEE, 2019. Citado na página 43.