

Sistema FIEB



CENTRO UNIVERSITÁRIO SENAI CIMATEC
PROGRAMA DE POS-GRADUAÇÃO STRICTO SENSU
MESTRADO ACADÊMICO EM MODELAGEM COMPUTACIONAL E
TECNOLOGIA INDUSTRIAL

FLÁVIO SANTOS CONTERATO

Um estudo comparativo entre redes neurais profundas e o modelo numérico WRF-ARW para previsão de energia solar a curto prazo

Salvador, 2022

FLÁVIO SANTOS CONTERATO

Um estudo comparativo entre redes neurais profundas e o modelo numérico WRF-ARW para previsão de energia solar a curto prazo

Dissertação de mestrado apresentada ao Programa de Pós-Graduação Stricto Sensu do Centro Universitário SENAI CIMATEC como requisito parcial para a obtenção do título de Mestre em Modelagem Computacional e Tecnologia Industrial

Orientador: Prof. Dr. Erick Giovani Sperandio Nascimento

Coorientador: Prof. Dr. Davidson Martins Moreira

Salvador, 2022

Ficha catalográfica elaborada pela Biblioteca do Centro Universitário SENAI CIMATEC

C761e Conterato, Flávio Santos

Um estudo comparativo entre redes neurais profundas e o modelo numérico WRF-ARW para previsão de energia solar a curto prazo / Flávio Santos Conterato – Salvador, 2022.

108 f. : il. color.

Orientador: Prof. Dr. Erick Giovani Sperandio Nascimento.

Coorientador: Prof. Dr. Davidson Martins Moreira.

Dissertação (Mestrado em Modelagem Computacional e Tecnologia Industrial) – Programa de Pós-Graduação, Centro Universitário SENAI CIMATEC, Salvador, 2022.

Inclui referências.

1. Aprendizado profundo. 2. Energia solar. 3. Inteligência artificial. 4. WRF-ARW. 5. Redes Neurais Profundas. 6. Nordeste brasileiro. I. Centro Universitário SENAI CIMATEC. II. Nascimento, Erick Giovani Sperandio. III. Moreira, Davidson Martins. IV. Título.

FLÁVIO SANTOS CONTERATO

Um estudo comparativo entre redes neurais profundas e o modelo numérico WRF-ARW para previsão de energia solar a curto prazo

Aprovada em 31 de março de 2022.

Banca Examinadora

Prof. Dr. Erick Giovani Sperandio Nascimento – Orientador

Doutor em Engenharia Ambiental pela Universidade Federal do Espírito Santo – Centro Universitário SENAI CIMATEC

Prof. Dr. Davidson Martins Moreira

Doutor em Engenharia Mecânica pela Universidade Federal do Rio Grande do Sul – Centro Universitário SENAI CIMATEC

Prof. Dr. Alex Álisson Bandeira Santos

Doutor em Energia e Ambiente pela Universidade Federal da Bahia – Centro Universitário SENAI CIMATEC

Prof. Dr. Gilberto Fernando Fisch

Doutor em Meteorologia pelo Instituto Nacional de Pesquisas Espaciais – Universidade de Taubaté

"Se for possível, está feito! Se for impossível, vamos fazê-lo!" (Marechal Alexandre
Gomes de Argolo Ferrão - Visconde de Itaparica)

AGRADECIMENTOS

Agradeço primeiramente a Deus por ter me mantido no caminho durante todo este projeto de pesquisa com saúde e forças para chegar até o final, principalmente em um período pandêmico e obscuro para a ciência.

Sou grato à minha família pelo apoio que sempre me deram durante toda a minha vida, principalmente nos momentos mais difíceis.

Deixo um agradecimento especial ao meu orientador Prof. Dr. Erick Giovani Sperandio Nascimento pelo incentivo, paciência, comprometimento, sabedoria e dedicação do seu escasso tempo ao meu projeto de pesquisa.

Também agradeço ao meu coorientador Prof. Dr. Davidson Martins Moreira pelos grandes ensinamentos na área meteorológica.

Aos professores Dr. Alex Álisson Bandeira Santos e Dr. Gilberto Fernando Fisch pela contribuição como membros da banca avaliadora e por ter acreditado nessa pesquisa.

Também quero agradecer ao SENAI CIMATEC, a todos os colaboradores e parceiros, principalmente aos professores do meu curso, pela elevada qualidade do ensino oferecido. Agradeço também ao Centro de Supercomputação do SENAI CIMATEC, gestores e os seus respectivos colaboradores pela habitual disponibilidade no suporte ao HPC. E a todos os membros do GPMIC, em especial a Me. Yasmin Kaore e Eng. Rafael Teixeira, por terem me ajudado a entender mais sobre o assunto e por termos caminhados sempre em busca da excelência.

E não menos importante, agradeço a todos os meus amigos que conquistei ao longo da vida por me darem o suporte necessário para encarar mais essa missão.

RESUMO

A utilização de fontes renováveis de energia é um grande passo para o futuro de uma nação, onde no Brasil tem se destacado pela grande disponibilidade de energia solar em todo o seu território. No entanto, a presença de nuvens e aerossóis na atmosfera podem comprometer a utilização deste tipo de energia no sistema elétrico, sendo a previsão das variáveis meteorológicas associadas uma tarefa desafiadora. Neste sentido, tendo em vista um modelo sustentável de geração energia e os recentes avanços na área de Inteligência Artificial (IA) para o desenvolvimento de modelos preditivos, esse trabalho visa desenvolver um modelo computacional baseado em aprendizagem profunda de máquina (*deep learning*) para realizar a previsão de temperatura e radiação solar global, para servirem como base para o cálculo da potência de energia solar, além de também fazer uma comparação com o tradicional modelo atmosférico *Advanced Research Weather Research and Forecasting* (WRF-ARW). Os treinamentos das redes foram realizados com dados de quatro cidades da região do centro-oeste baiano, reconhecida por possuir um alto potencial solarimétrico. Para fins de testes, foram utilizados dados obtidos na região da cidade de Ibotirama na Bahia e na cidade de Petrolina em Pernambuco, sem a inclusão de quaisquer desses dados no treinamento, com o intuito de verificar se as redes conseguiram representar corretamente o comportamento atmosférico do ambiente em estudo. Os resultados apontaram, no geral, que uma configuração composta por duas redes *Multilayer Perceptron* (MLP) apresentou a melhor métrica no cálculo da potência energética para região de Ibotirama, enquanto que uma combinação de *Long Short-Term Memory* (LSTM) e *Convolutional Neural Network* (CNN) foi melhor para Petrolina, no cálculo da potência energética. Todas as redes foram construídas para prever de 1 a 48 horas à frente com o intervalo de 1 hora. Uma análise estatística dos resultados finais para ambas as cidades alvo, sugerem uma boa aceitação da utilização de redes neurais para previsibilidade atmosférica, tendo em vista o baixo custo computacional e o desempenho superior para a previsão da geração de energia solar, em comparação com o WRF-ARW.

Palavras-chave Aprendizado Profundo. Energia Solar. Inteligência Artificial. WRF-ARW. Redes Neurais Profundas. Nordeste Brasileiro.

ABSTRACT

The use of renewable energy sources is a big step for the future of a nation, especially Brazil has been highlighted by the large availability of solar energy throughout its territory. However, the presence of clouds and aerosols in the atmosphere can compromise the use of this type of energy in the electrical system, predicting associated meteorological variables a challenging task. In this sense, in view of a sustainable model of energy generation and recent advances in the area of Artificial Intelligence (AI) for the development of predictive models, this work aims to develop a computational model based on deep machine learning (deep learning) to perform the prediction of temperature and global solar radiation, both used to calculate solar energy power and the respective efficiency, and also to make a comparison with the traditional atmospheric model Advanced Research Weather Research and Forecasting (WRF-ARW). The training of the networks was carried out with data from four cities in the central-west region of Bahia, recognized for having a high solarimetric potential. For testing purposes, data obtained in the region of the city of Ibotirama in Bahia and Petrolina in Pernambuco were used, without the inclusion of any such data in the training, to verify if the networks were able to correctly represent the atmospheric behavior of the environment under study. The results showed, in general, that a configuration composed of two Multilayer Perceptron (MLP) networks presented the best metric in the calculation of energy power for the Ibotirama region. While a combination of Long Short-Term Memory (LSTM) and Convolutional Neural Network (CNN) was better for Petrolina, predicting energy power. All networks were built to predict from 1 to 48 hours ahead with the 1 hour gap. A statistical analysis of the final results for both target cities suggest a good acceptance of the use of neural networks for atmospheric predictability, in view of the low computational cost and superior performance for the prediction of solar energy generation, compared to WRF-ARW.

Keywords: Deep Learning. Solar Energy. Artificial Intelligence. WRF-ARW. Deep Neural Networks. Brazilian Northeast.

LISTA DE TABELAS

- Tabela 1 – Descritores iniciais
- Tabela 2 – Descritores com condicionais da etapa 1
- Tabela 3 – Descritores com condicionais da etapa 2
- Tabela 4 – Descritores com condicionais da etapa 3
- Tabela 5 – Artigos selecionados
- Tabela 6 – Localização e altitude das cidades
- Tabela 7 – Variáveis originais do dataset
- Tabela 8 – Seleção de período para estação de Barra
- Tabela 9 – Seleção dos dados de treinamento para estação de Macaúbas
- Tabela 10 – Seleção dos dados de treinamento para estação de Barreiras
- Tabela 11 – Seleção dos dados de treinamento para estação de Irecê
- Tabela 12 – Seleção dos dados de teste para estação de Ibotirama
- Tabela 13 – Seleção dos dados de teste para estação de Petrolina
- Tabela 14 – Seleção dos dados do teste final para estação de Ibotirama
- Tabela 15 – Seleção dos dados do teste final para estação de Petrolina
- Tabela 16 – Configuração dos domínios do WRF-ARW para o Experimento A
- Tabela 17 – Configuração dos domínios do WRF-ARW para o Experimento B
- Tabela 18 – Parametrização do WRF-ARW
- Tabela 19 – Características de temperatura da placa solar de silício monocristalino
- Tabela 20 – Características da placa solar CS5A-200
- Tabela 21 – Características da placa solar CS3L-360MS
- Tabela 22 – Características da placa solar CS3W-420MB-AG
- Tabela 23 – Características da placa solar CS7N-670MS
- Tabela 24 – Configurações entre modelos de radiação solar global e temperatura
- Tabela 25 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar no teste padrão
- Tabela 26 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura no teste padrão
- Tabela 27 – Resumo das melhores métricas de MAE, RMSE, r e R^2 para potência de saída das placas fotovoltaicas

Tabela 28 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar no teste padrão

Tabela 29 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura no teste padrão

Tabela 30 – Resumo das melhores métricas de MAE, RMSE, r e R^2 para potência de saída das placas fotovoltaicas

Tabela 31 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar, e os tempos de treinamento/simulação e de inferência

Tabela 32 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura, e os tempos de treinamento e de inferência

Tabela 33 – Métricas do Experimento A de potência energética para placa solar de baixa potência (200W)

Tabela 34 – Métricas do Experimento A de potência energética para placa solar de média potência (360W)

Tabela 35 – Métricas do Experimento A de potência energética para placa solar de alta potência (420W)

Tabela 36 – Métricas do Experimento A de potência energética para placa solar industrial (670W)

Tabela 37 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar, e os tempos de treinamento/simulação e de inferência

Tabela 38 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura, e os tempos de treinamento e de inferência

Tabela 39 – Métricas do Experimento B de potência energética para placa solar de baixa potência (200W)

Tabela 40 – Métricas do Experimento B de potência energética para placa solar de média potência (360W)

Tabela 41 – Métricas do Experimento B de potência energética para placa solar de alta potência (420W)

Tabela 42 – Métricas do Experimento B de potência energética para placa solar industrial (670W)

LISTAS DE FIGURAS

- Figura 1 – Radiação solar
- Figura 2 – Comparação entre neurônio biológico e neurônio artificial
- Figura 3 – Rede neural multicamadas
- Figura 4 – Modelo generalizado entre treinamento e validação
- Figura 5 – Modelo com overfitting
- Figura 6 – Modelo com underfitting
- Figura 7 – Funções de ativação TANH e linear
- Figura 8 – Rede neural multicamadas com dropout
- Figura 9 – Aplicação de CNN em uma imagem
- Figura 10 – Execução da Flatten
- Figura 11 – Execução da Max Pooling
- Figura 12 – Recorrência de uma Rede Neural Recorrente
- Figura 13 – Neurônios LSTM e GRU
- Figura 14 – Rede Bidirecional
- Figura 15 – Processo da revisão sistemática
- Figura 16 – Cidades do oeste baiano e Petrolina selecionadas para o estudo
- Figura 17 – Dados faltantes para estação da Barra
- Figura 18 – Dados faltantes para estação de Macaúbas
- Figura 19 – Dados faltantes para estação de Barreiras
- Figura 20 – Dados faltantes para estação de Irecê
- Figura 21 – Dados faltantes para estação de Ibotirama
- Figura 22 – Dados faltantes para estação de Petrolina
- Figura 23 – Climatologia da estação de Ibotirama dos últimos 30 anos
- Figura 24 – Climatologia da estação de Petrolina dos últimos 30 anos
- Figura 25 – Arquitetura geral das redes neurais
- Figura 26 – Arquitetura da Rede MLP
- Figura 27 – Arquitetura da Rede LSTM
- Figura 28 – Arquitetura da Rede CNN
- Figura 29 – Arquitetura da Rede GRU
- Figura 30 – Arquitetura da Rede Bidirecional LSTM
- Figura 31 – Arquitetura da Rede FCN + LSTM

Figura 32 – Localização dos domínios do WRF-ARW. A esquerda Experimento A e a direita o Experimento B.

Figura 33 – Análise dos valores da radiação solar global original x previstas pelos modelos de IA e WRF-ARW para o Experimento A

Figura 34 – Diagrama de Taylor da radiação solar global para o Experimento A

Figura 35 – Análise dos valores da temperatura original x previstas pelos modelos de IA e WRF-ARW para o Experimento A

Figura 36 – Diagrama de Taylor da temperatura para o Experimento A

Figura 37 – Análise dos valores da radiação solar global original x previstas pelos modelos de IA e WRF-ARW para o Experimento B

Figura 38 – Diagrama de Taylor da radiação solar global para o Experimento B

Figura 39 – Análise dos valores da temperatura original x previstas pelos modelos de IA e WRF-ARW para o Experimento B

Figura 40 – Diagrama de Taylor da temperatura para o Experimento B

LISTAS DE SIGLAS E ABREVIATURAS

% - Porcentagem

χ – Coeficiente de temperatura em $^{\circ}\text{C}^{-1}$

ε – Coeficiente de insolação

$\mu_{I_{SC}}$ – Coeficiente de temperatura da corrente de curto-circuito

$\mu_{V_{OC}}$ – Coeficiente de temperatura da voltagem de circuito aberto

\hat{y}_i – Previsão de y_i

F_t – Previsão no período t

\bar{x} – Média dos dados da matriz 1

x_i – Dados da matriz 1.

\bar{y} – Média das observações

\bar{y} – Média dos dados da matriz 2

y_i – Valor observado

y_i – Dados da matriz 2.

y_t – Observação atual no período t

$^{\circ}\text{C}$ – Grau Celsius

1D – 1 Dimensão

ANN – *Artificial Neural Network* (RNA)

COx – Camada Oculta x

CNN – *Convolutional Neural Network*

DL – Deep Learning

FCN – *Fully Convolutional Network*

FF – *Fill Factor* (Fator de Preenchimento)

G – Radiação solar global

G_{NMOT} – Radiação solar global nominal de operação

gr ° - Graus em ângulos, considerando 0 como o Norte.

GRU – *Gated Recurrent Unit*

HPC – *High Performance Computing*

IA – Inteligência Artificial

I_{SC} – Corrente de curto-circuito

$I_{SC,STC}$ – Corrente de curto-circuito em STC

JACIII – *Journal of Advanced Computational Intelligence and Intelligent Informatics*

KJ/m² - Quilojoule por metro quadrado

LSTM – *Long Short-Term Memory*

m/s – Metros por segundo

MAE – *Mean Absolut Error*

mB - Milibar

MLP – *MultiLayer Perceptron*

MSE – *Mean Squared Error*

MW/A – Megawatts por ano

NMOT – Temperatura nominal de operação do módulo

ONS - Operador Nacional do Sistema Elétrico

$P_{max_{NMOT}}$ – Potência máxima nominal de operação da célula

R – Coeficiente de correlação de pearson

R² – Coeficiente de regressão

RNA – Rede Neural Artificial

SGD - *Stochastic Gradient Descent*

SIINTEC – Simpósio Internacional de Inovação e Tecnologia

STC – Condição padrão de teste

T – Temperatura

T_a – Temperatura do ar

T_{a,NMOT} – Temperatura do ar nominal de operação

T_c – Temperatura da Célula

T_{c,NMOT} – Temperatura da célula nominal de operação

T_{stc} – Temperatura da célula em STC

TANH – Tangente Hiperbólica

V_{oc} – Voltagem de circuito aberto

V_{oc,STC} – Voltagem de circuito aberto em STC

W - Watts

W/m² - Watts por metro quadrado

WRF-ARW – *Advanced Research Weather Research and Forecasting Model*

X_{std} – Desvio padrão de X

n – Máximo período de tempo

SUMÁRIO

1.	INTRODUÇÃO	7
1.1.	CONTEXTUALIZAÇÃO	7
1.2.	RELEVÂNCIA	8
1.3.	MOTIVAÇÃO	9
1.4.	OBJETIVOS	9
1.4.1.	<i>OBJETIVO GERAL</i>	9
1.4.2.	<i>OBJETIVOS ESPECÍFICOS</i>	9
2.	FUNDAMENTAÇÃO TEÓRICA.....	11
2.1.	RADIAÇÃO SOLAR	11
2.1.1.	<i>RADIAÇÃO SOLAR DIRETA</i>	11
2.1.2.	<i>RADIAÇÃO SOLAR DIFUSA</i>	12
2.1.3.	<i>RADIAÇÃO SOLAR GLOBAL</i>	12
2.2.	O MODELO WRF-ARW	12
2.3.	INTELIGÊNCIA ARTIFICIAL	13
2.3.1.	<i>REDES NEURAS ARTIFICIAIS</i>	13
2.3.2.	<i>ARQUITETURA MULTICAMADAS</i>	14
2.3.3.	<i>ANÁLISE DO LOSS PARA VERIFICAÇÃO DE OVERFITTING E UNDERFITTING</i>	15
2.3.4.	<i>FUNÇÕES DE ATIVAÇÃO</i>	17
2.3.5.	<i>DROPOUT</i>	17
2.3.6.	<i>REDES CONVOLUCIONAIS (CNN) E FULLY CONVOLUTIONAL NETWORK (FCN)</i>	18
2.3.7.	<i>REDES RECORRENTES (RNN)</i>	20
2.3.8.	<i>REDES BIDIRECIONAIS</i>	21

2.4.	POTÊNCIA ELÉTRICA	21
2.4.1.	TEMPERATURA DA CÉLULA DE UM MÓDULO PV.....	21
2.4.2.	CORRENTE DE CURTO-CIRCUITO	22
2.4.3.	VOLTAGEM DE CIRCUITO ABERTO	22
2.4.4.	POTÊNCIA ENERGÉTICA	23
3.	REVISÃO DA LITERATURA	24
3.1.	DESENVOLVIMENTO DOS DESCRITORES	24
3.2.	REVISÃO SISTEMÁTICA	24
3.3.	METODOLOGIA DAS BUSCAS	25
3.4.	LEVANTAMENTO QUANTITATIVO E QUALITATIVO	26
3.5.	FILTRAGEM DOS ARTIGOS	27
3.6.	ANÁLISE E DISCUSSÃO	29
4.	METODOLOGIA.....	31
4.1.	ÁREA DE ESTUDO.....	31
4.2.	DADOS <i>IN SITU</i>	33
4.3.	CURADORIA DE DADOS	33
4.3.1.	DADOS PARA TREINAMENTO	34
4.3.2.	DADOS DE TESTE PADRÃO.....	36
4.3.2.1.	ESTAÇÃO IBOTIRAMA	36
4.3.2.2.	ESTAÇÃO PETROLINA.....	37
4.3.3.	DADOS DE TESTE FINAL DE PREVISÃO.....	37
4.3.3.1.	EXPERIMENTO A (IBOTIRAMA)	37
4.3.3.2.	EXPERIMENTO B (PETROLINA).....	39
4.3.4.	DADOS TOTAIS.....	40

4.4.	REDES NEURAIS	40
4.4.1.	<i>MULTI LAYER PERCEPTRON (MLP)</i>	42
4.4.2.	<i>LONG SHORT-TERM MEMORY (LSTM)</i>	42
4.4.3.	<i>CONVOLUTION NEURAL NETWORK (CNN)</i>	43
4.4.4.	<i>GATED RECURRENT UNIT (GRU)</i>	44
4.4.5.	<i>LSTM BIDIRECIONAL</i>	44
4.4.6.	<i>FULLY CONVOLUTIONAL NETWORK (FNC) + LSTM</i>	45
4.5.	WRF-ARW	45
4.6.	PLACAS SOLARES	47
4.6.1.	<i>PLACA SOLAR BAIXA POTÊNCIA</i>	48
4.6.2.	<i>PLACA SOLAR MÉDIA POTÊNCIA</i>	48
4.6.3.	<i>PLACA SOLAR ALTA POTÊNCIA</i>	48
4.6.4.	<i>PLACA SOLAR INDUSTRIAL</i>	49
4.7.	AVALIAÇÃO DO DESEMPENHO DOS MODELOS	49
4.7.1.	<i>AVALIAÇÃO QUALITATIVA</i>	49
4.7.2.	<i>AVALIAÇÃO QUANTITATIVA</i>	49
5.	RESULTADOS E DISCUSSÃO	51
5.1.	TESTE PADRÃO	51
5.1.1.	<i>CONFIGURAÇÃO PARA POTÊNCIA ELÉTRICA SOLAR</i>	51
5.1.2.	<i>ESTAÇÃO IBOTIRAMA</i>	52
5.1.2.1.	PARÂMETROS METEOROLÓGICOS.....	52
5.1.2.2.	POTÊNCIA ELÉTRICA	53
5.1.3.	<i>ESTAÇÃO PETROLINA</i>	54
5.1.3.1.	PARÂMETROS METEOROLÓGICOS.....	54

5.1.3.2.	POTÊNCIA ELÉTRICA	55
5.2.	TESTE FINAL COMPARATIVO COM WRF-ARW	55
5.2.1.	<i>EXPERIMENTO A</i>	56
5.2.1.1.	PREVISÕES COM DADOS METEOROLÓGICOS DO EXPERIMENTO A	56
5.2.1.2.	PLACA SOLAR DE BAIXA POTÊNCIA DO EXPERIMENTO A	59
5.2.1.3.	PLACA SOLAR DE MÉDIA POTÊNCIA DO EXPERIMENTO A	60
5.2.1.4.	PLACA SOLAR DE ALTA POTÊNCIA DO EXPERIMENTO A	60
5.2.1.5.	PLACA SOLAR INDUSTRIAL DO EXPERIMENTO A	60
5.2.2.	<i>EXPERIMENTO B</i>	61
5.2.2.1.	PREVISÕES DADOS METEOROLÓGICOS DO EXPERIMENTO B	61
5.2.2.2.	PLACA SOLAR DE BAIXA POTÊNCIA DO EXPERIMENTO B	64
5.2.2.3.	PLACA SOLAR DE MÉDIA POTÊNCIA DO EXPERIMENTO B	65
5.2.2.4.	PLACA SOLAR DE ALTA POTÊNCIA DO EXPERIMENTO B	65
5.2.2.5.	PLACA SOLAR INDUSTRIAL DO EXPERIMENTO B	65
5.3.	DISCUSSÃO	66
6.	CONCLUSÃO	68
	REFERÊNCIAS	69
	PRODUÇÃO TÉCNICA E CIENTÍFICA	77
	APÊNDICE 1 – ANÁLISE DE LOSS DAS REDES	78
	APÊNDICE 2 – MÉTRICAS NO HORIZONTE DE PREVISÃO PARA RADIAÇÃO SOLAR GLOBAL E TEMPERATURA – TESTE PADRÃO	80
	APÊNDICE 3 – TESTE PADRÃO IBOTIRAMA	85
	PLACA DE BAIXA POTÊNCIA – 200W	85
	PLACA DE MÉDIA POTÊNCIA – 360W	86
	PLACA DE ALTA POTÊNCIA – 420W	86

PLACA INDUSTRIAL – 670W	87
APÊNDICE 4 – TESTE PADRÃO PETROLINA	89
PLACA DE BAIXA POTÊNCIA – 200W	89
PLACA DE MÉDIA POTÊNCIA – 360W	90
PLACA DE ALTA POTÊNCIA – 420W	90
PLACA INDUSTRIAL – 670W	91
APÊNDICE 5 – DIAGRAMAS DE TAYLOR – TESTE PADRÃO	93

1. INTRODUÇÃO

1.1. CONTEXTUALIZAÇÃO

A industrialização do mundo globalizado necessita uma alta carga de energia diariamente. O mesmo ocorre no atual cenário brasileiro, onde a demanda por energia continua em expansão, porém com uma oferta de energia que por vezes não tem acompanhado a demanda, principalmente quando se trata de energias renováveis. Com esse objetivo, o país investiu em ampliação da matriz energética, motivado principalmente pela seca histórica nos reservatórios de usinas hidroelétricas (UHE), da qual correspondem a 56,20% da energia produzida no país (AID, 2022). Visando a garantia de outras fontes, e a partir de sua ampliação, as usinas eólicas (EOL) lideraram 2021 em novas construções, passando à frente inclusive das UHE, com 3694,32 MW, ou seja, 39,24% de todas as implantações de novas usinas de energia no Brasil. Mesmo com a grande implantação no ano de 2021, as EOL representam apenas 11,41% de toda a matriz energética brasileira. Na análise ainda do crescimento, como fonte não renovável, as usinas termoelétricas (UTE) cresceram 2449,69 MW e em terceiro lugar, as usinas solares fotovoltaicas (UFV) tiveram o aumento de 1299,46 MW, o que corresponde a 32,39% e 17,18% respectivamente de novas implantações no país (AID, 2022). No que tange à energia solar, o Brasil dispõe de grande potencial, uma vez que recebe elevada radiação solar durante todo o ano. E com essa visão de grande potencial elétrico solar, em 2021 as UFV corresponderam a 63,17% de todas as construções com fontes detentoras de concessão e autorização sem o projeto (AID, 2021; SCG, 2020).

A organização e gestão desta matriz energética brasileira é de responsabilidade do Operador Nacional do Sistema Elétrico (ONS) que controla o estoque e executa a previsão da energia e solicita a produção das usinas para suprimento do abastecimento diário. A análise de geração elétrica de fonte solar é fundamental para determinar o potencial de energia disponível, visando auxiliar na administração de seu despacho. Se eventualmente uma hidroelétrica estiver com baixo volume de água, como ocorreu em boa parte de 2021 (LIN, 2021), o ONS autoriza um uso maior de fontes de geração térmica para suprir a demanda. Assim, a utilização de softwares tem sido uma forma

comum de realizar a previsão e análise de geração de energia solar, com destaque para métodos computacionais e algoritmos de computação inteligentes, como as redes neurais artificiais que buscam obter as previsões de incidência de radiação e analisar a geração de energia necessária (PINHEIRO; LOVATO; RUTHER, 2017).

1.2. RELEVÂNCIA

A Inteligência Artificial (IA), notadamente as redes neurais profundas, têm alcançado grandes e importantes resultados na resolução de problemas em diversas áreas do conhecimento e da indústria, tais como na economia, medicina, militar, ciências atmosféricas, energias renováveis, manufatura inteligente, dentre outras. Na modelagem, identificação, otimização, previsão e domínio de sistemas complexos, tais métodos também são usuais (PINHEIRO *apud* MELLIT, 2008).

O presente estudo visa incentivar a indústria na implementação futura de usinas de geração de energia solar fotovoltaica para minimizar a emissão de poluentes no meio ambiente, como forma de substituição de geração de energias por fontes não renováveis, conforme acordado pelo governo Brasileiro na Cúpula de Líderes sobre o Clima como meta de 2050 para a neutralização de gases do efeito estufa (GULLINO, 2021). A redução destas emissões afeta diretamente a matriz energética brasileira, da qual 2,0% é dependente de petróleo e derivados, 8,4% de derivados de biomassa, 9,3% de gás natural, 3,3% de lenha e carvão e derivados, totalizando 23,0% da matriz energética dependente da queima de combustíveis que contribuem para o aumento da emissão de poluentes causadores do efeito estufa (EPE, 2021). No entanto, muitos fatores dependem do comportamento futuro do sistema elétrico nacional, onde a previsão da geração de energia solar colabora no desenvolvimento socioeconômico e na qualidade de vida da população em geral. Normalmente, são necessários grandes recursos computacionais para a previsão operacional utilizando abordagens baseadas em modelos numéricos, sendo as redes neurais profundas uma opção moderna e atraente para realizar esse procedimento com menor custo computacional.

1.3. MOTIVAÇÃO

Ainda que o objeto desse estudo seja um sub tópico da seção “Outras Fontes Renováveis” no Plano Nacional de Energia para 2030 (EPE, 2021), este trabalho tem ampla relevância para o cenário atual do mundo. A energia solar se torna potencialmente abrangente devido ao nosso clima e pelo uso exploratório das técnicas de Inteligência Artificial, que têm tido grandes avanços na área científica e acadêmica nos últimos anos, principalmente na área de *deep learning* (aprendizado profundo), de forma que este estudo poderá auxiliar o ONS na tomada de decisão com até 48 horas de antecedência em áreas que tem um histórico de dados reduzido além do baixo custo computacional, comparado com o modelo atmosférico de mesoescala WRF-ARW.

1.4. OBJETIVOS

1.4.1. OBJETIVO GERAL

O objetivo deste trabalho é desenvolver um modelo computacional robusto baseado em redes neurais profundas para previsão da geração de energia solar para as próximas 48 horas, sendo esse um tempo suficiente para que o ONS solicite uso de outras fontes para geração de energia elétrica. Além disso, comparando os resultados dos modelos com previsões realizadas pelo modelo WRF-ARW, treinando-os com dados meteorológicos de diferentes cidades do centro-oeste da Bahia, e validando-os em dois experimentos referentes a duas cidades distintas, não apresentadas durante o treinamento. Sendo uma cidade localizada próxima à região das outras cidades utilizadas no treinamento (oeste baiano), e a outra localizada em região distante das demais cidades, mas dentro de regiões conhecidas por seu alto potencial solarimétrico (extremo sudoeste pernambucano) (MONFORT *et al.*, 2018).

1.4.2. OBJETIVOS ESPECÍFICOS

- a) Realizar o levantamento de dados meteorológicos e análise exploratória de diferentes regiões representativas do oeste da Bahia para o desenvolvimento e testes dos modelos;

- b) Desenvolver, refinar e avaliar diferentes modelos de redes neurais profundas para a previsão dos parâmetros meteorológicos necessários para a realização da previsão de geração de energia solar;
- c) Calcular a potência energética de quatro placas fotovoltaicas distintas com base na radiação solar global e temperatura do ar.
- d) Comparar e selecionar os melhores modelos desenvolvidos para ambas as cidades alvo com base na potência energética em um longo período de teste;
- e) Comparar os valores do cálculo da potência energética dos melhores modelos desenvolvidos com o modelo numérico atmosférico WRF-ARW em um teste de curto período de tempo para as cidades alvo;

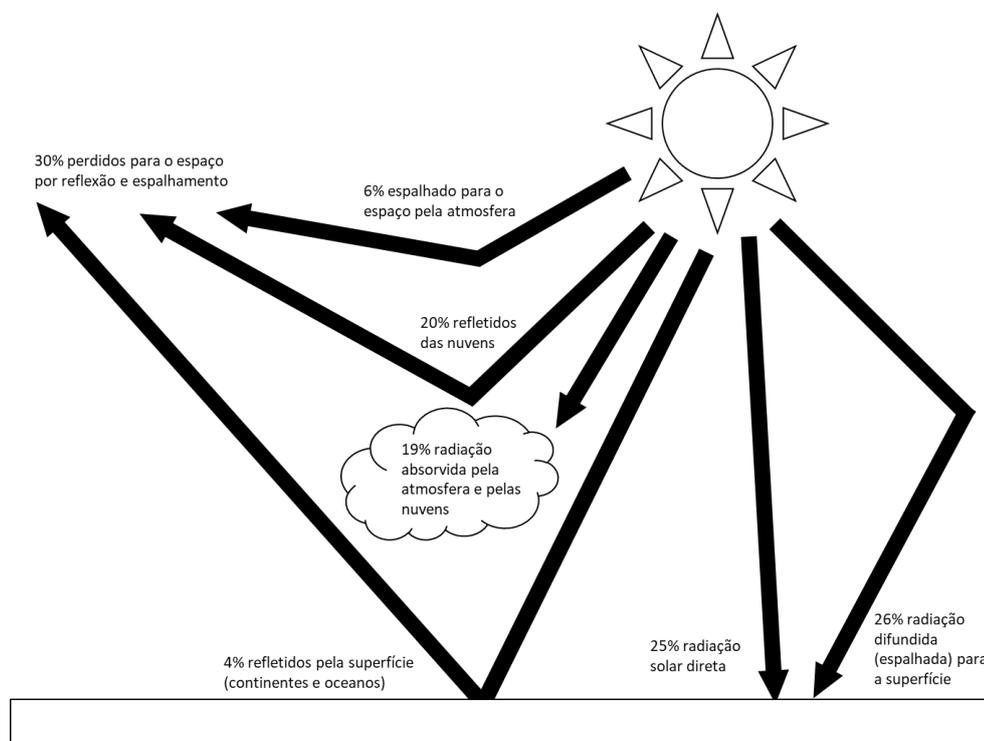
2. FUNDAMENTAÇÃO TEÓRICA

Este capítulo abordará as definições conceituais dos itens importantes para o presente estudo como a radiação solar, WRF-ARW e IA.

2.1. RADIAÇÃO SOLAR

O planeta Terra recebe, constantemente, uma radiação de cerca 1361 W/m^2 no topo da atmosfera terrestre. (WILLIAMS, 2020). Como definição, a radiação global é a soma de todas as radiações que chegam em um determinado corpo, existindo duas componentes: a direta e a difusa (QUERINO *et al.*, 2011), como ilustrado na Figura 1.

Figura 1 – Radiação solar



Fonte: Adaptado de GRIMM (2020).

2.1.1. RADIAÇÃO SOLAR DIRETA

É a radiação que passa sem interferência de outros meios até o objeto irradiado, sofrendo apenas alteração pela ionosfera e camada de ozônio, conforme explicado anteriormente. Essa porcentagem compreende algo em torno de 51 % de toda radiação global (GIL *et al.*, 2017; GRIMM, 2020).

2.1.2. RADIAÇÃO SOLAR DIFUSA

É a radiação que sofre interferência de nuvens, precipitações e aerossóis. De acordo com GRIMM (2020), por conta desta interferência, 19 % de toda radiação solar é absorvida ou refletida pelas nuvens o que reduz a quantidade de radiação solar recebida em solo.

2.1.3. RADIAÇÃO SOLAR GLOBAL

É a soma de todas as radiações (difusa e direta) receptadas em um único objeto. Essa radiação solar global compreende aproximadamente 51 % de toda a radiação solar emitida pelo Sol para a Terra (GRIMM, 2020). A outra parcela é refletida ou absorvida pelas nuvens, pela superfície ou pela atmosfera. Tal radiação solar global será utilizada como objeto de estudo neste trabalho devido somatório de todas as radiações até um determinado objeto.

2.2. O MODELO WRF-ARW

O modelo *Weather Research and Forecasting*, mais comumente conhecido por apenas a sigla WRF (DIAS *et al.*, 2019; POWERS *et al.*, 2020), é um sistema de modelagem numérica de mesoescala para simulação e previsão numérica do tempo, voltados para aplicação operacional e pesquisa (SKAMAROCK *et al.*, 2008). O seu código é aberto e desenvolvido pela parceria entre NCAR (*National Center for Atmospheric Research*), NOAA (*National Oceanic and Atmospheric Administration*), Força Aérea (*U.S. Air Force*), Laboratório de Pesquisa Naval (NRL), Universidade de Oklahoma e a Administração Federal de Aviação (FAA), todos dos Estados Unidos. A ferramenta é dividida em alguns módulos para facilidade de operacionalização, como a química do ar (CHEM), hidrologia (HYDRO), incêndios florestais (FIRE), radiação solar (SOLAR) e previsão do tempo (REAL) (IRIART e FISCH, 2016).

O *Advanced Research WRF* (WRF-ARW) é um núcleo que serve para derivar variáveis meteorológicas de alta resolução espacial e temporal integrando as equações de Euler compreensíveis e não hidrostáticas (SKAMAROCK *et al.*, 2005). Esse núcleo que

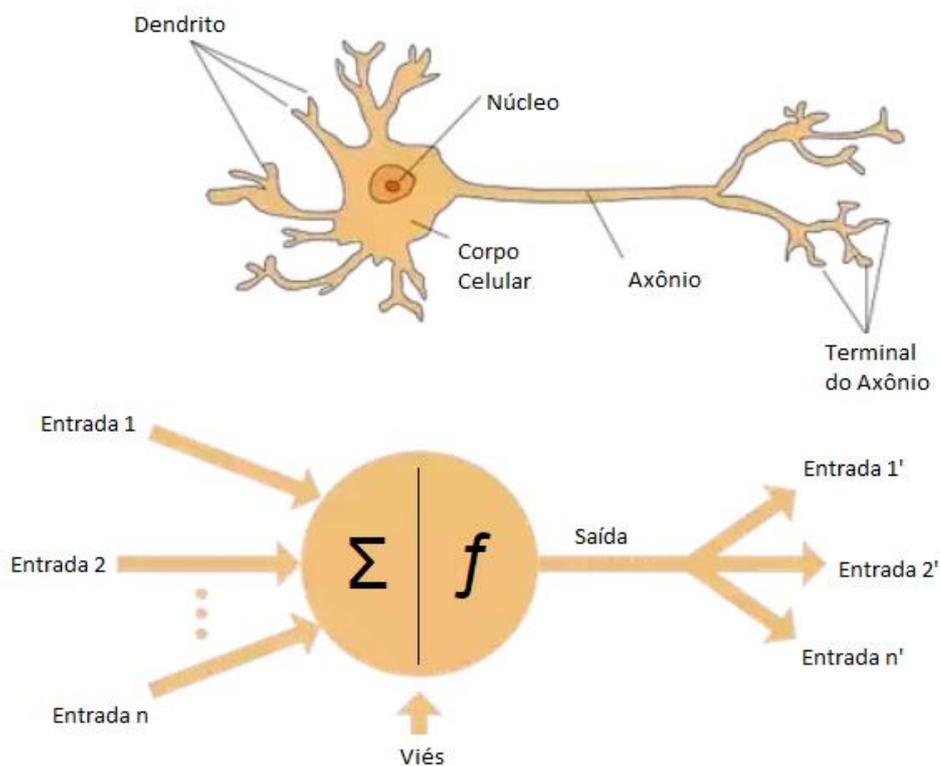
foi utilizado no estudo de DIAS *et al.* (2019) serviu de base para a realização do experimento desta pesquisa.

2.3. INTELIGÊNCIA ARTIFICIAL

2.3.1. REDES NEURAIS ARTIFICIAIS

O neurônio de McCulloch e Pitts é um modelo básico de uma Rede Neural Artificial (RNA) tendo como base o neurônio de um sistema nervoso humano. Graficamente é representado pela Figura 2 em comparação com uma representação de um neurônio humano.

Figura 2 – Comparação entre neurônio biológico e neurônio artificial



Fonte: Adaptado de NAGYFI (2018).

A aparência entre ambos é visualmente semelhante, visando a conexão entre vários neurônios com intuito de formar redes de multicamadas. O cálculo de uma rede neural artificial é o somatório da multiplicação das entradas com seus respectivos pesos. Após este cálculo, é ainda adicionado um viés e posteriormente aplicada uma função de

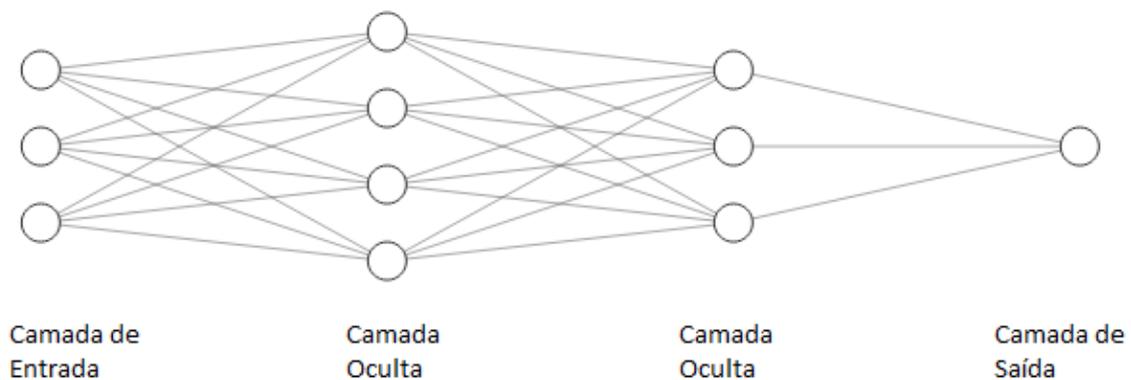
ativação. A partir disso, cria-se uma saída que pode servir de entrada para outros “n” neurônios.

É nessa saída que acontece a verificação do valor esperado pelo valor predito. Quando uma rede apresenta divergência entre ambos, os pesos associados a cada entrada, juntamente com o viés são atualizados de forma que o valor de saída se adapte ao valor real.

2.3.2. ARQUITETURA MULTICAMADAS

Devido à problemática envolvendo os modelos matemáticos, a utilização de um neurônio artificial simples é irrelevante. Com isso tende-se a criação de redes complexas baseadas no cérebro humano, segundo MANTOVANI (2011), com ligações entre múltiplos neurônios em forma de camadas demonstradas na Figura 3. O uso de múltiplas camadas pode resultar em um aprendizado otimizado e consistente, como também subtilizar a rede neural. Tal informação é importante para trabalhos com complexidade baixa ao utilizar múltiplas camadas indiscriminadamente.

Figura 3 – Rede neural multicamadas



Fonte: Elaborada pelo autor.

Em um neurônio biológico, essa passagem de informação é chamada de sinapse que vem através de um terminal de axônio do neurônio anterior (saída) em contato com o dendrito do neurônio corrente (entrada) (HAYKIN, 2008; FILHO, 2000). E é nessa mesma passagem de informação que uma rede artificial atualiza os pesos dos neurônios de cada camada. Após realizar o treinamento dos dados com “n” informações (*batch*

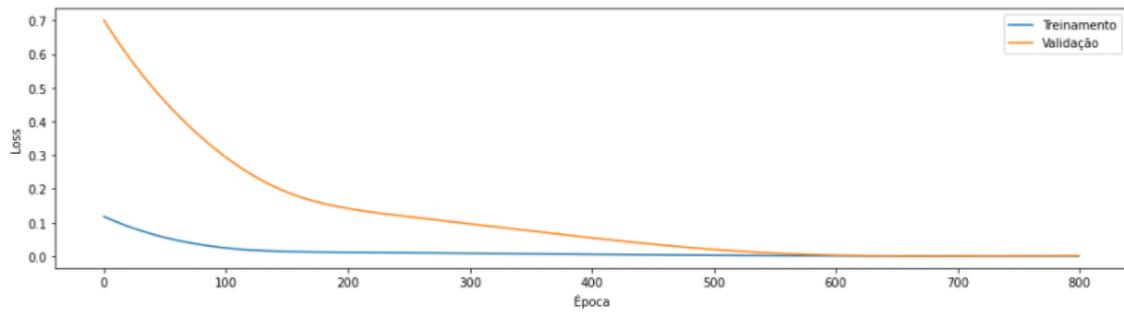
size ou tamanho do lote) a rede retro propaga a diferença do observado pelo predito da última camada e com isso atualiza todos os neurônios, camada a camada, fazendo o processo conhecido como *feedforward backpropagation*.

2.3.3. ANÁLISE DO LOSS PARA VERIFICAÇÃO DE *OVERFITTING* E *UNDERFITTING*

O processo de construção de redes neurais se baseia na utilização de um conjunto de dados de referência que servirá tanto para o seu treinamento, quanto para a realização de testes de inferência sobre uma porção desses dados nunca antes vistos pelo modelo durante o treinamento. Enquanto são treinadas, os pesos das redes são ajustados (*fitting*) através de algoritmos de otimização e de aprendizagem de máquina, época a época, até que o erro associado ao processo de treinamento (*loss*), medido a partir de uma métrica quantitativa que compara o predito pela rede versus o dado real de referência (através de uma função de custo ou perda), se estabilize no menor valor possível e não mais evolua.

No entanto, não há garantias de que esse processo leve as redes a encontrarem os melhores pesos para a melhor solução, ou mínimo global. Por isso, é comum que esse processo leve o modelo a uma solução viável, mas que representa um mínimo local. Para evitar essa situação, e garantir que o modelo consiga ao menos generalizar a solução encontrada para diferentes cenários, algumas técnicas são utilizadas para avaliar se o modelo encontrou uma solução generalizável ou não. Dentre essas técnicas, uma que é muito utilizada é a técnica de “validação”. Através dela, é possível perceber o nível de generalização de um modelo a partir da visualização do progresso, época a época, dos valores de *loss* (erro do modelo) encontrados durante o treinamento, e comparar com a progressão dos valores de *loss* obtidos a partir da aplicação do modelo em outra porção dos dados, diferente da utilizada durante o treinamento, chamada de “validação”. Caso a rede encontre valores e comportamentos semelhantes de *loss* no treinamento e na validação, diz-se que o modelo está conseguindo generalizar (vide Figura 4). Caso contrário, o modelo está com dificuldades de encontrar uma solução mais generalizável, podendo estar ou com *overfitting* ou *underfitting*.

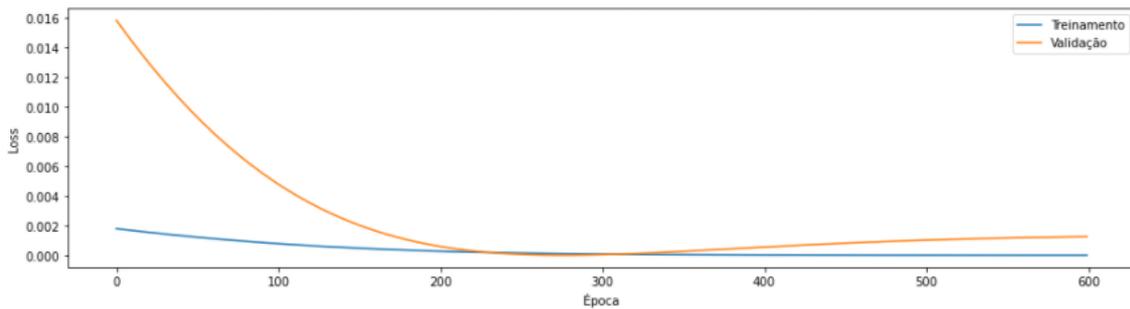
Figura 4 – Modelo generalizado entre treinamento e validação



Fonte: Adaptado de Brownlee (2017).

O *overfitting* ocorre quando os pesos se adaptam muito bem aos dados utilizados durante o treinamento, porém, quando avaliados em outra porção de dados (dados de validação), não conseguem obter o mesmo nível de desempenho, com um erro final medido nos dados de validação maior que o erro medido no de treinamento, conforme a Figura 5.

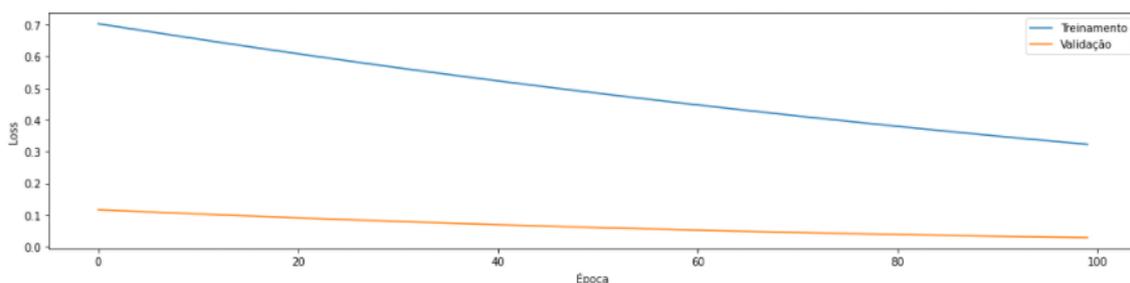
Figura 5 – Modelo com *overfitting*



Fonte: Adaptado de Brownlee (2017).

Já o *underfitting*, por sua vez, ocorre quando o modelo não se adapta bem aos dados de treinamento, tendo um erro final menor nos dados de validação em relação aos de treinamento (Figura 6). Durante o processo de treinamento, o que se busca é que o modelo não seja capaz, apenas, de ter um bom desempenho nos dados de treinamento, mas que também consiga realizar boas previsões sobre os dados presentes na porção separada para validação. Essa análise, portanto, é fundamental para a avaliação da qualidade dos modelos treinados neste trabalho.

Figura 6 – Modelo com *underfitting*

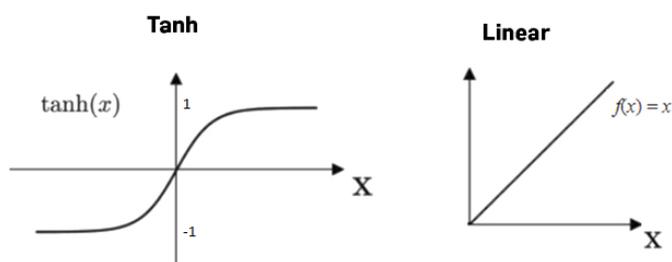


Fonte: Adaptado de Brownlee (2017).

2.3.4. FUNÇÕES DE ATIVAÇÃO

A função de ativação é um passo importante em uma rede neural artificial. Ela vai determinar o intervalo compreendido do valor de saída. Por exemplo, uma rede com a função de ativação Sigmoide, conforme Mantovani (2011), terá o intervalo entre $[0,1]$. Se um valor ultrapassar o limite inferior ou superior, será admitido o piso ou teto deste intervalo. Para este trabalho foram utilizadas as funções de ativação tangente hiperbólica (TANH), que compreende entre $[-1,1]$, e a linear que compreende entre $]-\infty, +\infty[$ conforme mostra a Figura 7.

Figura 7 – Funções de ativação TANH e linear



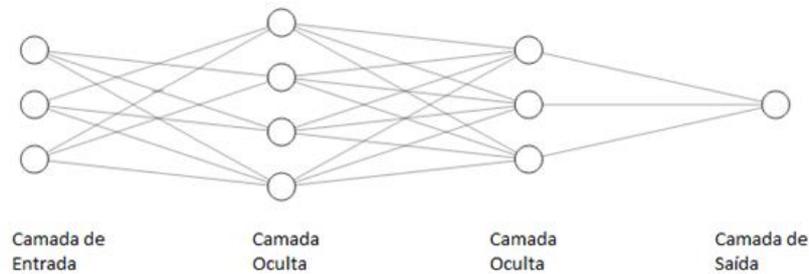
Fonte: Adaptado de KOBRAN e BENYS (2021).

2.3.5. DROPOUT

O *dropout* é uma camada que realiza a remoção de conexões de forma aleatória entre um neurônio de uma camada com o neurônio da camada seguinte. Essa perda de ligação, segundo Keras (2021), serve para evitar que a rede neural aprenda apenas aquele comportamento, conseguindo assim generalizar o problema e realizar previsões

mais precisas. A Figura 8 demonstra um exemplo de rede neural com *droupout* aplicado entre a camada de entrada e a primeira camada oculta.

Figura 8 – Rede neural multicamadas com *droupout*

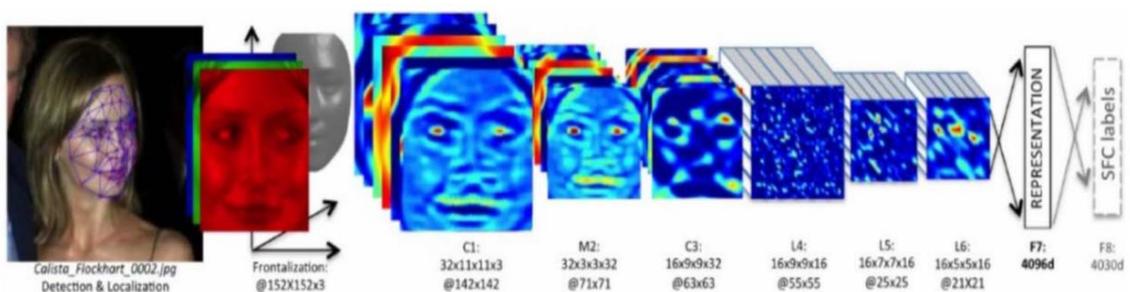


Fonte: Elaborada pelo autor.

2.3.6. REDES CONVOLUCIONAIS (CNN) E *FULLY CONVOLUTIONAL NETWORK (FCN)*

A CNN tem grande aplicação no reconhecimento de padrões, como no processamento de imagens e reconhecimento de voz (ALBAWI *et al.*, 2017). Ela se origina pela aplicação de filtro em um determinado vetor ou matriz (podendo ser unidimensional CNN1D ou multidimensional CNN2D, CNN3D etc.). É dessa aplicação de filtro (*kernel*) que se extraem as principais características dos dados de entrada conforme Figura 9.

Figura 9 – Aplicação de CNN em uma imagem

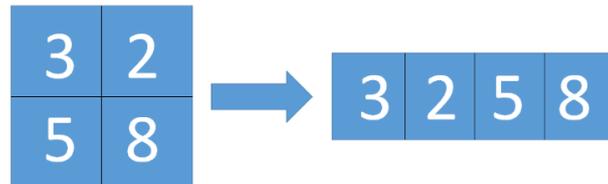


Fonte: ALBAWI *et al.* (2017)

A Figura 9 demonstra várias aplicações de camadas de convolução até chegar ao objetivo de identificação de padrões. Esse exemplo foi utilizado apenas para imagem, porém WANG *et al.* (2019) aplicam múltiplas CNN para série temporal, com intuito de identificar e prever a energia solar com horizonte de previsão intercaladas a cada 3 horas em até 24 horas com base nos padrões meteorológicos apresentados na fase de

treinamento dos modelos. Dois dos componentes bastante utilizados pelas camadas de CNN são a *Flatten* e a *Max Pooling*. A *Flatten* serve para linearizar os dados quando dispostos em uma matriz multidimensional (geralmente dispostos em 2D) para um vetor de uma única dimensão. Por exemplo, o achatamento de uma matriz bidimensional em um vetor unidimensional, conforme ilustrado pela Figura 10.

Figura 10 – Execução da *Flatten*



Fonte: Elaborada pelo autor.

Já a camada *Max Pooling* serve para reduzir a quantidade de dados, porém evidenciando as principais características. Na Figura 11, é executado um *Max Pooling* e como pode-se perceber para cada quadrante, foi selecionado o maior (*max*) valor representado.

Figura 11 – Execução da *Max Pooling*



Fonte: Adaptado de MISHRA (2020).

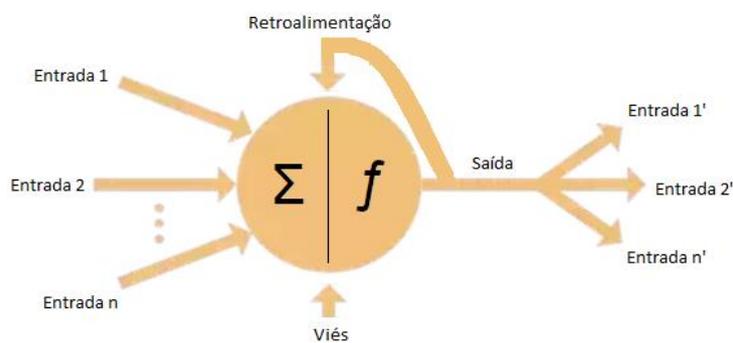
A *Fully Convolutional Network* (FCN) é uma arquitetura de rede, baseada puramente em CNN que serve para evidenciar as características dos dados. Em imagem, i.e., são bastante utilizadas para segmentação semântica, conforme TSANG (2018). Já para série temporal, a respectiva arquitetura serve para extrair o padrão da temporalidade dos dados, sendo bastante utilizadas de forma híbrida com redes

recorrentes (por exemplo a camada LSTM), formando assim as chamadas redes FCN+LSTM (GAO *et al.*, 2020).

2.3.7. REDES RECORRENTES (RNN)

Em uma rede neural recorrente (RNN) existe uma retroalimentação com a saída do neurônio. Essa retroalimentação ajuda o neurônio a “memorizar” o estado anterior com o equacionamento matemático do neurônio (Mantovani, 2011), conforme exemplificado na Figura 12.

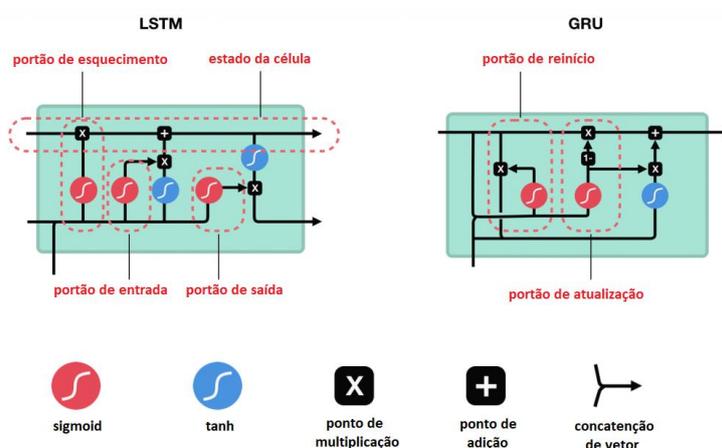
Figura 12 – Recorrência de uma Rede Neural Recorrente



Fonte: Adaptado de NAGYFI (2018).

Duas arquiteturas das mais utilizadas e comumente conhecidas das redes recorrentes são as *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU), conforme representação dos neurônios de ambas pela Figura 13.

Figura 13 – Neurônios LSTM e GRU



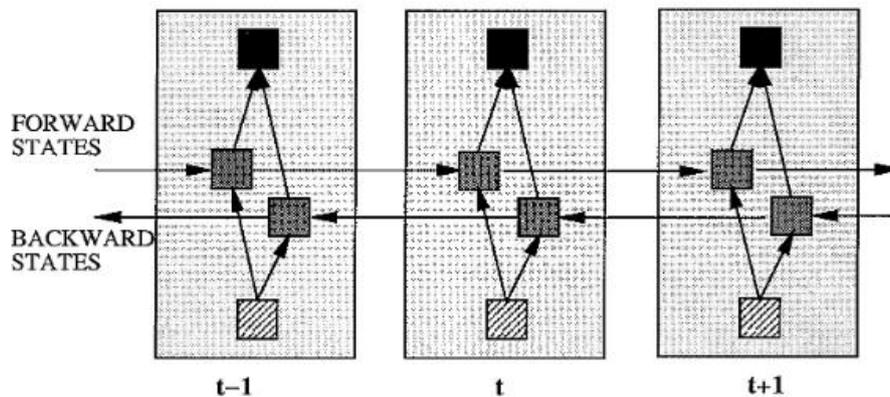
Fonte: Adaptado de Data Science Academy (2021).

A grande diferença entre a GRU e a LSTM é a complexidade da LSTM perante a GRU. O neurônio LSTM, conforme LE *et al.* (2019), contém 4 portas, sendo elas o de esquecimento, entrada atual, novo estado (ou saída) e novo estado oculto (estado da célula). Já a célula GRU contém apenas duas portas que é a porta de reinício (r), que ajusta a incorporação da nova entrada com a memória anterior, e a porta de atualização (z) que controla a preservação do estado da memória anterior, além de não possuir a saída de estado da célula, presente na LSTM (ZHAO *et al.*, 2017).

2.3.8. REDES BIDIRECIONAIS

As redes bidirecionais são amplamente utilizadas na área de Processamento de Linguagem Natural (NLP – *Natural Language Processing*). Porém, em um dos trabalhos, ALTHELAYA *et al.* (2018) utilizaram esta técnica para previsão de ações. Ilustrando na Figura 14, conforme SCHUSTER e PALIWAL (1997), que a rede bidirecional tem o retorno do estado temporal.

Figura 14 – Rede Bidirecional



Fonte: SCHUSTER e PALIWAL (1997).

2.4. POTÊNCIA ELÉTRICA

2.4.1. TEMPERATURA DA CÉLULA DE UM MÓDULO PV

A potência de pico (W_p) de um módulo fotovoltaico é testada sob as condições-padrão de ensaio (*Standard Test Condition - STC*), considerando a radiação solar de 1.000 W/m^2 (G_{STC}) sob temperatura de célula de 25°C (T_{stc}).

Para calcular a W_p , é necessário inicialmente determinar a temperatura da célula (T_c). Na fórmula para calcular a T_c , conforme descrita na Equação 1, de acordo com YANG *et al. apud* Ross e Smokler (2019), depende da temperatura do ar (T_a), da temperatura do ar nominal de operação ($T_{a_{NMOT}}$) que é 20°C, radiação solar global (G), da radiação solar global nominal de operação (G_{NMOT}) que é de 800W/m² e da temperatura nominal de operação das células ($T_{c_{NMOT}}$). Essa última é identificada pela sigla NMOT (*Nominal Module Operating Temperature*), sendo fornecido o valor pelo fabricante nas propriedades da placa solar.

$$T_c = T_a + (T_{c_{NMOT}} - T_{a_{NMOT}}) \left(\frac{G}{G_{NMOT}} \right) \quad (1)$$

2.4.2. CORRENTE DE CURTO-CIRCUITO

A corrente de curto-circuito ($I_{SC}(G,T)$) é expressa em termos de G e da diferença entre T_c e T_{STC} , usando a seguinte relação empírica linear descrita por IBRAHIM e ANANI (2017). O cálculo tem como base na divisão entre da radiação solar global, diferença de temperatura, corrente de curto-circuito em STC ($I_{SC,STC}$) e coeficiente de temperatura ($\mu_{I_{SC}}$), essas duas últimas apresentadas nos dados técnicos dos módulos fotovoltaicos.

$$I_{SC}(G,T) = \left(\frac{G}{G_{STC}} \right) [I_{SC,STC} + \mu_{I_{SC}}(T_c - T_{STC})] \quad (3)$$

2.4.3. VOLTAGEM DE CIRCUITO ABERTO

Ainda segundo IBRAHIM e ANANI (2017) a tensão de circuito aberta ($V_{OC}(T)$) é expressa em termo da T_c .

O cálculo de voltagem de circuito aberto (V_{OC}) em determinada temperatura pode ser calculada com base no uso do coeficiente de temperatura relacionado a tensão de circuito aberto ($\mu_{V_{OC}}$), da diferença de temperatura e da voltagem de circuito aberto em STC ($V_{OC,STC}$), através da Equação 4.

$$V_{OC}(T) = [V_{OC,STC} + \mu_{V_{OC}}(T_c - T_{STC})] \quad (4)$$

2.4.4. POTÊNCIA ENERGÉTICA

O cálculo da potência energética (P) inicia com o cálculo do *Fill Factor* (FF). O mesmo depende da potência máxima (P_{max}) para ser calculado. Como o dado técnico mostra uma potência máxima NMOT ($P_{max_{NMOT}}$), foi utilizada essa potência para calcular o FF , e a partir dessa construção calcular a potência máxima aproximada a partir dos dados meteorológicos (observados e previstos) conforme a Equação 5 apresentada por JAIN e KAPOOR (2004).

$$FF = \frac{P_{max}}{V_{OC} * I_{SC}} \quad (5)$$

$$P = FF * V_{OC} * I_{SC} \quad (6)$$

3. REVISÃO DA LITERATURA

3.1. DESENVOLVIMENTO DOS DESCRITORES

Os descritores têm por finalidade achar palavras-chaves dos artigos que são mais relevantes naquele texto. O uso incorreto de descritores pode-se levar a perda de tempo ou até mesmo prejudicar os andamentos da pesquisa por ser enviesado ao tema original. Tendo em vista que os estudos mais importantes na área de IA estão publicados em revistas predominantes do idioma inglês, todos os descritores apresentados na Tabela 1 foram utilizados nessa língua em específico.

Tabela 1 – Descritores iniciais

Numeração	Descritores
1	<i>Solar Prediction</i>
2	<i>Solar Forecasting</i>
3	<i>ANN</i>
4	<i>Artificial Intelligence</i>
5	<i>Energy</i>
6	<i>Power</i>

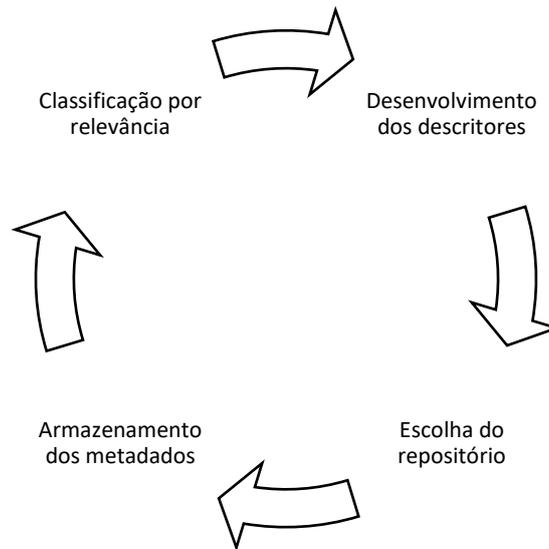
Fonte: Elaborada pelo autor.

3.2. REVISÃO SISTEMÁTICA

As etapas do ciclo apresentado na Figura 15 apontam os melhores descritores que irão se aproximar do objetivo do trabalho proposto. O processo é iterativo até a convergência total dos artigos para um número mínimo viável para análise detalhada.

O primeiro passo consiste em desenvolver os descritores, e irá se repetir toda vez que o processo for iniciado visando minimizar os artigos mais relevantes. Os descritores podem ser utilizados juntamente com operadores booleanos como AND, OR ou NOT para compor um único descritor que engloba várias condicionais.

Figura 15 – Processo da revisão sistemática



Fonte: Elaborada pelo autor.

O segundo passo é a escolha dos repositórios de busca de artigos. Esses repositórios podem ser o ScienceDirect, IEEE Explorer, ACM Library, Scopus e o Google Scholar.

O terceiro passo é o armazenamento dos metadados e a validação de títulos e palavras-chaves que são analisadas sobre os principais artigos, que são selecionados para prosseguir para uma análise futura.

E o último passo é a classificação por ordem de relevância dos artigos conforme as leituras e análises detalhadas para selecionar os principais artigos que possuem relação direta com esta pesquisa.

3.3. METODOLOGIA DAS BUSCAS

As soluções escolhidas para realizar a revisão sistemática deste trabalho foram as ScienceDirect e o Google Scholar. Apesar do Google Scholar não ser uma base e sim um indexador de bases, ele consegue abranger outros repositórios como a IEEE Explorer por exemplo, se tornando relevante para as buscas. A ScienceDirect, por ter as principais revistas voltadas para esse assunto, como a Energy, Renewable Energy e Solar Energy, foi escolhida como base principal de repositório para pesquisas relacionadas. Alguns

critérios foram definidos antes, como, pesquisa exclusiva por artigos publicados, publicações entre 2010 e 2021 e buscas dos descritores no texto.

3.4. LEVANTAMENTO QUANTITATIVO E QUALITATIVO

Para o levantamento quantitativo e qualitativo, foram feitas as pesquisas nas bases conforme alguns critérios de descritores. Os primeiros descritores foram escolhidos como análise combinatória entre a combinação condicional de “Solar Prediction” com “ANN” com as suas respectivas variações, conforme Tabela 2 abaixo com a quantidade retornada por cada base.

Tabela 2 – Descritores com condicionais da etapa 1

N	Descritores	Base	Quantidade
1	<i>“Solar Prediction” AND “ANN”</i>	ScienceDirect	113.097
2	<i>“Solar Prediction” AND “ANN”</i>	Google Scholar	232
3	<i>“Solar Prediction” AND “Artificial Intelligence”</i>	ScienceDirect	19
4	<i>“Solar Prediction” AND “Artificial Intelligence”</i>	Google Scholar	153
5	<i>“Solar Forecasting” AND “ANN”</i>	ScienceDirect	136
6	<i>“Solar Forecasting” AND “ANN”</i>	Google Scholar	1.260
7	<i>“Solar Forecasting” AND “Artificial Intelligence”</i>	ScienceDirect	66
8	<i>“Solar Forecasting” AND “Artificial Intelligence”</i>	Google Scholar	988

Fonte: Elaborada pelo autor.

Com a quantidade de artigos desses descritores, foi realizada uma nova busca conjunta incluindo os descritores “Power” ou “Energy” para elencar os artigos e apresentar trabalhos mais relevantes à pesquisa com a previsão de geração de energia solar (Tabela 3).

Tabela 3 – Descritores com condicionais da etapa 2

N	Descritores	Base	Quantidade
9	<i>(“Solar Forecasting” OR “Solar Prediction”) AND (“Artificial Intelligence” OR “ANN”) AND (“POWER” OR “ENERGY”)</i>	ScienceDirect	176
10	<i>(“Solar Forecasting” OR “Solar Prediction”) AND (“Artificial Intelligence” OR “ANN”) AND (“POWER” OR “ENERGY”)</i>	Google Scholar	1.740

Fonte: Elaborada pelo autor.

Com o intuito de minimizar as buscas, foi executada uma pesquisa na base do ScienceDirect com os descritores de número 11 apenas nos títulos dos artigos, e não se obteve resultado, conforme Tabela 4.

Tabela 4 – Descritores com condicionais da etapa 3

N	Descritores	Base	Quantidade
11	("Solar Forecasting" OR "Solar Prediction") AND ("Artificial Intelligence" OR "ANN") AND ("POWER" OR "ENERGY")	ScienceDirect (apenas no título)	0
12	("Artificial Intelligence" OR "ANN") AND ("WRF") AND ("Solar Forecasting" OR "Solar Prediction") AND ("POWER" OR "ENERGY")	Google Scholar	324

Fonte: Elaborada pelo autor.

O descritor de número 12 retornou centenas de artigos. Após a análise do descritor 12 no repositório, apenas um artigo apresentou estudo envolvendo WRF-ARW e IA, em que se utilizava a saída do WRF-ARW como entrada para treinamento da IA, mas sem de fato comparar seus resultados (BOUCHOUICHA, 2020), enquanto os demais só apresentaram WRF nas referências. Portanto, os descritores dos números 9 e 10, tem-se uma filtragem inicial de artigos, principalmente na base do ScienceDirect.

3.5. FILTRAGEM DOS ARTIGOS

Nesta etapa os artigos foram analisados, porém, como não houve resultado no descritor 11, uma seleção manual por títulos foi realizada no descritor 10 com base na leitura do resumo. Existem inúmeros textos com as palavras “power” ou “energy” apenas na introdução, remetendo a uma breve contextualização, porém no artigo não é apresentado nada sobre as palavras “geração de energia” ou “potência”, sendo automaticamente rejeitados por uma simples busca textual.

Os artigos selecionados foram analisados por inteiro conforme a sua relevância para cada assunto abordado neste trabalho e apresentados na Tabela 5.

Tabela 5 – Artigos selecionados

Título do Artigo	Referência	Ano de Publicação	Revista	Qualis CAPES 2013-2016 - Interdisciplinar	Qtd. de Citações	Fator de Impacto
Short-Mid-Term Solar Power Prediction by Using Artificial Neural Networks	IZGI <i>et al.</i> (2012)	2012	Solar Energy	A1	193	5,742
Neural Network Ensemble-Base Solar Power Generation Short-Term Forecasting	CHAOUAC HI <i>et al.</i> (2010)	2010	JACIII	-	43	-

Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble	CERVONE <i>et al.</i> (2017)	2017	Renewable Energy	A1	127	8,001
Online 24-H Solar Power Forecasting Based on Weather Using Artificial Neural Network	CHEN <i>et al.</i> (2011)	2011	Solar Energy	A1	523	5,742
A 24-H Forecast of Solar Irradiance Using Artificial Neural Network: Application for Performance Prediction of a Grid-Connected PV Plant at Trieste, Italy	MELLIT e PAVAN (2010)	2010	Solar Energy	A1	793	5,742
A short-term solar radiation forecasting system for the Iberian Peninsula. Part 2: Model blending approaches based on machine learning	HUERTAS-TATO <i>et al.</i> (2020)	2020	Solar Energy	A1	14	5,742
Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks	GAO <i>et al.</i> (2020)	2020	Renewable Energy	A1	9	8,001
Aplicabilidade de Redes Neurais Artificiais para Análise de Geração de Energia de um Sistema Fotovoltaico Conectado a Rede Elétrica	PINHEIRO <i>et al.</i> (2017)	2017	Revista Brasileira de Energias Renováveis	B4	3	-

Fonte: Elaborada pelo autor.

3.6. ANÁLISE E DISCUSSÃO

O trabalho desenvolvido por IZGI *et al.* (2012) abordou o uso de IA para previsão de energia solar (W) na região da Universidade Técnica de Istanbul da Turquia. Foi utilizado o Matlab com o otimizador Levenberg-Marquardt e função de ativação de logaritmo-sigmoid para a respectiva rede. A métrica utilizada foi a RMSE.

O trabalho publicado por CHAOUACHI, Aymen *et al.* (2009) comparou tipos de redes distintas, como MLP, redes recorrentes (NARX), *ensemble* e *radial basis*. O horizonte de previsão foi de 24 intervalos de tempo e teve como entrada dados meteorológicos do tipo temperatura (máxima e mínima e média), médias da humidade, pressão de vapor, tempo de intervalo de nascer/pôr do sol, cobertura de nuvens e utilização de dados de 24 horas anteriores (*lookback*) da radiação solar, dados esses anteriores que fazem com que a rede neural entenda o comportamento prévio da série e tente realizar a previsão baseado nesse histórico recente. O trabalho teve como principais métricas o MAPE (Erro de porcentagem média absoluta) e o MAD (Desvio absoluto médio).

A publicação de CERVONE *et al.* (2017) faz o uso de IA com MLP e de *Analog Ensemble* (AnEn) para prever até 72 horas à frente a potência como saída da rede. O texto ainda faz referência ao nordeste brasileiro, devido ao seu respectivo clima e aborda que a junção do AnEn com o MLP melhorou em todos os casos, diminuindo ainda mais um erro que já era pequeno.

O trabalho publicado por CHEN *et al.* (2011) utiliza o horizonte de previsão com 24 horas à frente e demonstra o impressionante uso de *Self-Organizing Map* (SOM) para prever a potência gerada. Como entrada no SOM foram inclusos a radiação solar, total de nuvens e nuvens baixas, além dos dados meteorológicos como velocidade e direção do vento, umidade relativa e temperatura do ar.

Outro trabalho publicado com o horizonte de previsão de 24 horas foi o de MELLIT e PAVAN (2010). Diferente do anterior, este utilizou apenas MLP com o otimizador de Levenberg-Marquardt para realizar a previsão.

O trabalho publicado por HUERTAS-TATO *et al.* (2020) faz a comparação entre métodos matemáticos tradicionais para previsão meteorológica com técnica de inteligência artificial, mais propriamente o *Support Vector Machine* (SVM).

Um trabalho que se destacou foi o de GAO *et al.* (2020) devido ao uso da rede híbrida FCN+LSTM de previsão de radiação solar que serviu de base para uma das arquiteturas implementadas neste trabalho. O mesmo utilizou-se de 4 cidades distintas para realizar o treinamento e validação e comparar 4 modelos distintos de FCN+LSTM.

E um dos trabalhos principais, mesmo sendo publicado em uma revista de estrato inferior, foi o artigo de PINHEIRO *et al.* (2017), que aplicou variáveis meteorológicas para previsão de potência gerada para uma placa fotovoltaica específica em um horizonte de previsão de apenas 1 hora à frente para uma única localidade (Florianópolis, SC).

Portanto, percebe-se que nenhum dos trabalhos abordam a previsão de dados meteorológicos para realizar os cálculos da potência elétrica na geração de energia solar. Os que chegaram mais próximo desse objetivo utilizaram dados meteorológicos como entrada, mas a saída (previsão) da rede é a potência elétrica final. Ademais, nenhum dos trabalhos apresentou um estudo comparativo das previsões realizadas pelas redes neurais profundas com as previsões realizadas pelo WRF-ARW, tampouco a abordagem de previsão para uma localidade não presente nos dados de treinamento, mostrando o potencial inovador deste trabalho e sua contribuição para o avanço no atual estado da arte.

4. METODOLOGIA

Neste capítulo serão abordados os métodos para o desenvolvimento deste trabalho e aplicabilidade dos modelos de IA e do WRF-ARW. Foi utilizada a linguagem de programação Python com alguns módulos bastante difundidos como Pandas, Numpy, Matplotlib, Tensorflow e Keras.

4.1. ÁREA DE ESTUDO

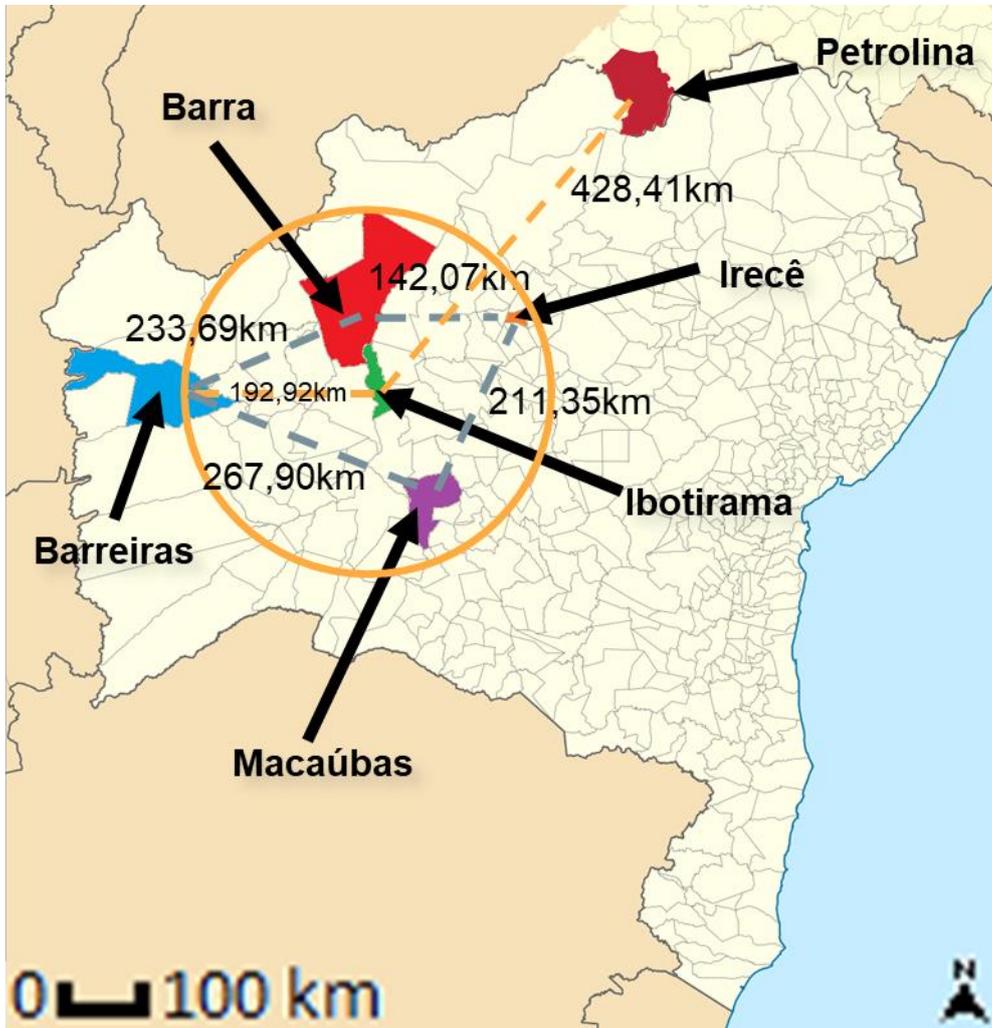
A área em estudo compõe 6 cidades, sendo 5 delas espalhadas pela região do oeste baiano, mais precisamente no bioma da Caatinga, sendo ocupada por aproximadamente 362 mil habitantes e distribuídas em uma área de 42.357,99km² segundo IBGE (2019). A sexta cidade, Petrolina, está localizada no extremo sudoeste pernambucano, fazendo divisa com o norte do estado da BA, uma região que também apresenta alto potencial solarimétrico (TIBA, 2000).

A predominância da incidência de radiação solar no oeste da Bahia e no oeste de Pernambuco, bem como o potencial promissor dessas regiões, foram os fatores determinantes para a escolha desses municípios. Essa região é bastante privilegiada do ponto de vista do potencial solarimétrico, com extensas áreas de planície e irradiação global horizontal (IGH) anual superior a 2.200 kWh/m² e temperatura média anual de 28 °C conforme MONFORT *et al.* (2018). Outro fator importante para a decisão dos municípios foi a disponibilidade de dados solarimétricos provenientes das estações meteorológicas do Instituto Nacional de Meteorologia – INMET (2018). A Rede de estações INMET dispõe de estações automáticas e convencionais. Para este trabalho especificamente, foram considerados os dados das Estações Meteorológicas Automáticas – EMA, que registram dados médios horários de medições de radiação global (KJ/m²) com a coleta sendo realizada pela medida de tensão (CEMTEC, 2011) e a temperatura média horária (°C) sendo calculada através da resistência de corrente de excitação de 1mA, com medições da tensão sobre um elemento Pt100 e um resistor de referência de 100ohms (CEMTEC, 2011).

Esse índice global da região e a localização dos municípios fizeram com que fossem selecionadas as cidades de Barra, Barreiras, Macaúbas e Irecê, todas no estado da Bahia, para compor a fase de treinamento, separando os dados referentes às cidades

de Ibotirama e Petrolina para a realização exclusiva dos testes dos modelos desenvolvidos, configurando-se como dados que nunca serão apresentados às redes neurais durante o treinamento, conforme mostra a Figura 16.

Figura 16 – Cidades do oeste baiano e Petrolina selecionadas para o estudo



Fonte: Elaborada pelo autor.

Como demonstrada na Figura 13, a maior distância entre uma das quatro cidades de treinamento para a cidade alvo (Ibotirama) é de 192,92 km. Na mesma imagem também é apresentado o município de Petrolina, localizado a 428,41 km de distância da cidade de Ibotirama, excedendo a região onde se encontram as demais localidades de treinamento.

A Tabela 6 mostra a localização e altitude das cidades usadas neste estudo, todas representadas graficamente pela Figura 13, incluindo a maior distância entre uma cidade de treino com a cidade alvo, representada pelo círculo laranja.

Tabela 6 – Localização e altitude das cidades

Estação	Latitude (°)	Longitude (°)	Altitude (m)	Distância até Ibotirama (km)
Barra	-11,08	-43,13	403	122,25
Irecê	-11,32	-41,86	755	178,01
Macaúbas	-13,03	-42,61	574	108,81
Barreiras	-12,15	-45,01	470	192,92
Ibotirama	-12,11	-43,13	430	-
Petrolina	-9,38	-40,52	372	428,41

Fonte: IBGE (2019)

4.2. DADOS *IN SITU*

Dentre todas as cidades pesquisadas, a cidade de Ibotirama foi selecionada para ser um dos alvos de teste devido a um grande intervalo com linearidade para todos os parâmetros de entrada e por estar situada geograficamente entre as demais quatro cidades de composição do dataset. O mesmo ainda apresentou bons dados contínuos, o que contribuiu para a representatividade regional dos modelos e para a generalização do problema. Além disso, para compor um outro experimento para validar a generalização meteorológica, foi escolhida a cidade de Petrolina, da qual também apresentou uma grande quantidade de dados em períodos contínuos para a seleção precisa e confiável dos dados.

4.3. CURADORIA DE DADOS

O *dataset* para treinamento da rede neural foi composto por 17 variáveis, conforme apresentado na Tabela 7, tendo como base os trabalhos de CHEN *et al.* (2011) e MELLIT e PAVAN (2010) para escolha das variáveis.

Tabela 7 – Variáveis originais do dataset

Variáveis				
Ano	Seno Mês	Cosseno Mês	Seno Dia	Cosseno Dia

Seno Hora	Cosseno Hora	Precipitação Total (mm)	Pressão Atmosférica (mB)	Radiação Global (KJ/m ²)
Temperatura do Ar – Bulbo Seco (°C)	Temperatura do Ponto de Orvalho (°C)	Umidade Relativa do Ar (%)	Vento – Velocidade (m/s)	Latitude (°)
Longitude (°)	Altitude (m)			

Fonte: Elaborada pelo autor.

4.3.1. DADOS PARA TREINAMENTO

A Figura 17 mostra os dados faltantes para a estação da Barra. A Tabela 8 mostra os respectivos dados utilizados no treinamento.

Figura 17 – Dados faltantes para estação da Barra



Fonte: Elaborada pelo autor.

Tabela 8 – Seleção de período para estação de Barra

Data Início	Data Fim	Quantidade de Amostras (horas)
04/04/2014 22:00	08/11/2014 22:00	5.232
02/05/2015 11:00	05/10/2015 06:00	3.739
05/10/2015 08:00	26/02/2016 13:00	3.461
26/02/2016 15:00	15/08/2016 16:00	4.105
15/08/2016 18:00	07/02/2017 07:00	4.213
26/04/2017 10:00	10/07/2018 13:00	10.557
Total:		31.307

Fonte: Elaborada pelo autor.

Abaixo, a estação de Macaúbas representada pela Figura 18 dos dados faltantes e na Tabela 9 com dados utilizados na pesquisa.

Figura 18 – Dados faltantes para estação de Macaúbas



Fonte: Elaborada pelo autor.

Tabela 9 – Seleção dos dados de treinamento para estação de Macaúbas

Data Início	Data Fim	Quantidade de Amostras (horas)
03/06/2016 11:00	18/10/2016 17:00	3.294
18/10/2016 19:00	15/01/2017 17:00	2.134
19/02/2017 17:00	22/11/2017 18:00	6.625
01/12/2017 11:00	25/02/2019 02:00	10.815
Total:		22.868

Fonte: Elaborada pelo autor.

A estação de Barreiras mostrada na Figura 19 e Tabela 10 teve um significativo conjunto de dados no treinamento dos modelos.

Figura 19 – Dados faltantes para estação de Barreiras



Fonte: Elaborada pelo autor.

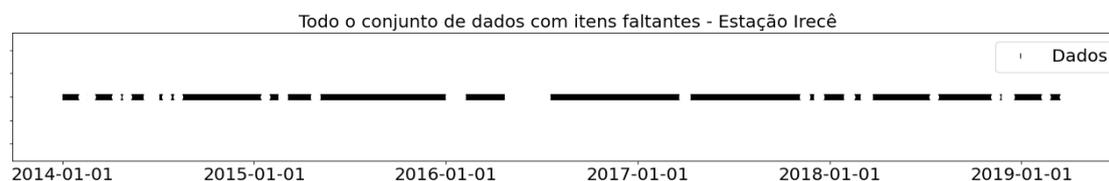
Tabela 10 – Seleção dos dados de treinamento para estação de Barreiras

Data Início	Data Fim	Quantidade de Amostras (horas)
20/06/2014 15:00	22/01/2015 16:00	5.185
22/01/2015 18:00	18/10/2016 17:00	15.239
08/02/2017 14:00	08/04/2019 23:00	18.945
Total:		39.369

Fonte: Elaborada pelo autor.

Já a estação de Irecê foi a que menos contribuiu com dados para o treinamento devido ao seu espaçamento entre os conjuntos de dados. A mesma está representada na Figura 20 com dados faltantes e na Tabela 11 com a seleção do período de treinamento.

Figura 20 – Dados faltantes para estação de Irecê



Fonte: Elaborada pelo autor.

Tabela 11 – Seleção dos dados de treinamento para estação de Irecê

Data Início	Data Fim	Quantidade de Amostras (horas)
27/04/2015 12:00	08/01/2016 23:00	6.155
08/07/2016 11:00	29/03/2017 09:00	6.334
01/04/2017 14:00	14/11/2017 08:00	5.442
Total:		17.931

Fonte: Elaborada pelo autor.

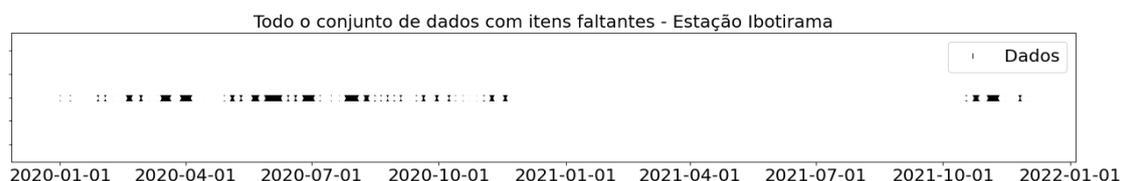
4.3.2. DADOS DE TESTE PADRÃO

O teste padrão é realizado para validar a generalização do problema por um modelo. Nesse caso, foram utilizados dados de aproximadamente dois anos para validação das métricas com intuito de selecionar a melhor rede para servir de comparação com o modelo WRF-ARW (teste final). Essa escala foi definida como um ano completo para cada experimento. Ela serve basicamente para demonstrar o comportamento geral de uma RNA em múltiplas situações em escalas de tempo diferentes, e.g. oscilação diária, semanal, mensal e estações do ano. Geralmente esse teste é realizado com parte dos dados separados dos de treinamento. Esses testes permitem avaliar e validar a rede quanto ao seu aprendizado, testando em dados nunca antes vistos pelo modelo durante seu treinamento. Por isso, evidencia-se a importância da separação dos dados entre treinamento, validação e teste.

4.3.2.1. ESTAÇÃO IBOTIRAMA

Os dados da estação de Ibotirama utilizados para esse teste compreendem o período entre 01/01/2020 à 31/11/2021. Nota, através da Figura 21, a falta de dados entre os períodos de dezembro de 2020 a outubro de 2021, resultando em pouco mais de quatro mil amostras, conforme a Tabela 12.

Figura 21 – Dados faltantes para estação de Ibotirama



Fonte: Elaborada pelo autor.

Tabela 12 – Seleção dos dados de teste para estação de Ibotirama

Data Início	Data Fim	Quantidade de Amostras (horas)
01/01/2020 00:00	31/11/2021 23:00	4.671
Total:		4.671

Fonte: Elaborada pelo autor.

4.3.2.2. ESTAÇÃO PETROLINA

Já os dados da estação de Petrolina utilizados para este outro teste dos modelos, representada pela Figura 22, tem aproximadamente 16 mil amostras, realizadas também no período de janeiro de 2020 a novembro de 2021, representadas pela Tabela 13.

Figura 22 – Dados faltantes para estação de Petrolina



Fonte: Elaborada pelo autor.

Tabela 13 – Seleção dos dados de teste para estação de Petrolina

Data Início	Data Fim	Quantidade de Amostras (horas)
01/01/2020 00:00	31/11/2021 23:00	15.967
Total:		15.967

Fonte: Elaborada pelo autor.

4.3.3. DADOS DE TESTE FINAL DE PREVISÃO

Para o teste final, o objetivo é simular uma aplicação operacional real ao combinar estações cujos dados não foram utilizados na etapa de treinamento, além de selecionar um período futuro aos dados apresentados no treino. A finalidade desse teste é de confrontar as previsões realizadas pelos modelos de IA com a do modelo WRF-ARW, para comparação das previsões a partir de apenas uma única amostra, visando a observação das previsões até 48 horas à frente do objetivo.

4.3.3.1. EXPERIMENTO A (IBOTIRAMA)

A estação de Ibotirama que foi utilizada como teste final dos modelos, representada pela Tabela 14 com exatamente 48 amostras de horizonte de previsão,

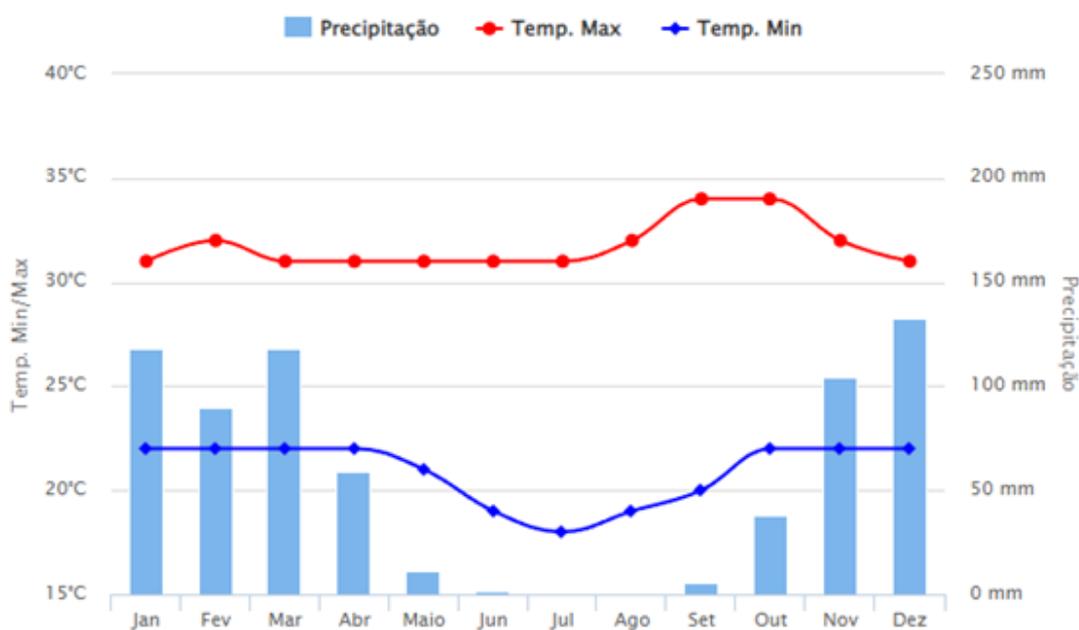
permitindo a comparação com a modelagem realizada pelo WRF-ARW nesse período, baseado em DIAS et al. (2019) e pela análise climatológica da Figura 23.

Tabela 14 – Seleção dos dados do teste final para estação de Ibotirama

Data Início	Data Fim	Quantidade de Amostras (horas)
09/06/2020 00:00	10/06/2020 23:00	48
Total:		48

Fonte: Elaborada pelo autor.

Figura 23 – Climatologia da estação de Ibotirama dos últimos 30 anos



Fonte: Adaptado de Climatempo (2022a).

A Figura 23 demonstra a climatologia para a cidade de Ibotirama. Essa localidade, ao longo dos últimos 30 anos, apresentou temperatura mínima média de 20°C e a temperatura máxima média de 31,7°C. Para o período do experimento, que corresponde ao inverno com uma menor incidência de chuvas, a temperatura mínima do local apresentou 19°C e a máxima 31°C, valores bem próximos da média anual (Climatempo, 2022a). Além da temperatura, a média da radiação solar global diária para a região é de 6,19 kWh, i.e., 22.284 kJ/m² (SPARK, 2022). Esse período foi escolhido por estar no vale da incidência solar, ou seja, no menor valor de média solar anual diária. Em contrapartida, para análise, o maior pico acontece em meados de setembro, com média diária de 24.840 kJ/m².

4.3.3.2. EXPERIMENTO B (PETROLINA)

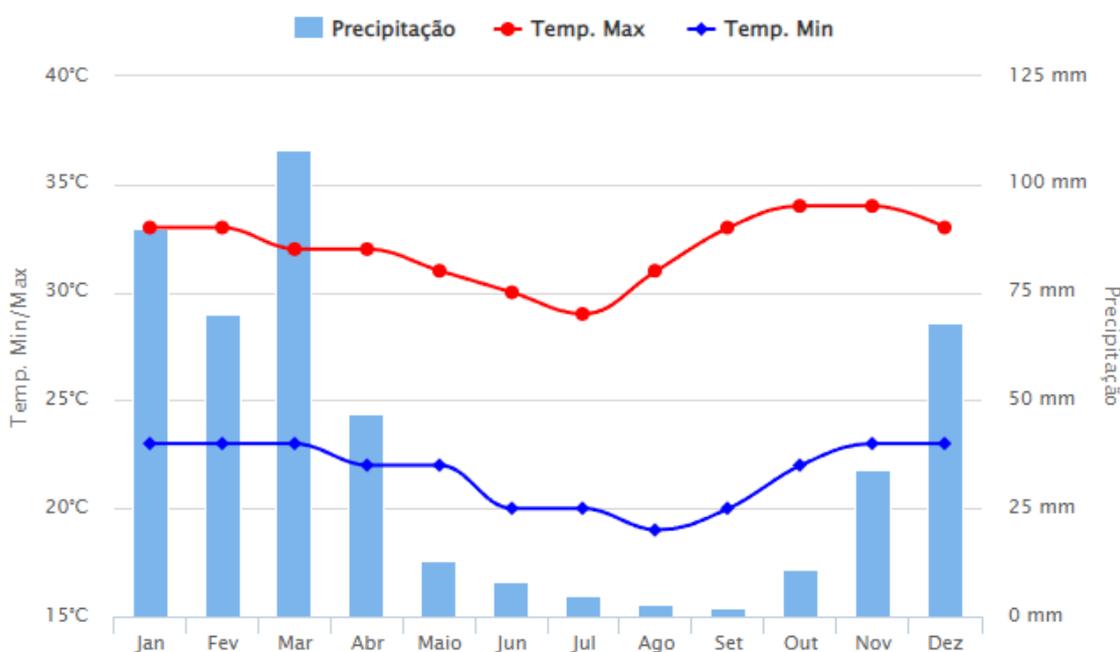
Os dados da estação de Petrolina foram utilizados para este outro experimento (Experimento B), para teste dos modelos, representada pela Tabela 15 com exatamente as 48 amostras de horizonte de previsão (horas à frente), realizadas no período de fevereiro/março e pela análise climatológica da Figura 24.

Tabela 15 – Seleção dos dados do teste final para estação de Petrolina

Data Início	Data Fim	Quantidade de Amostras (horas)
29/02/2020 00:00	01/03/2020 23:00	48
Total:		48

Fonte: Elaborada pelo autor.

Figura 24 – Climatologia da estação de Petrolina dos últimos 30 anos



Fonte: Adaptado de ClimaTempo (2022b).

Com a Figura 24, os dados analisados da região de Petrolina demonstram que a temperatura máxima média no ano tem uma oscilação de 5°C e a temperatura mínima média tem a variação de 4°C. Essa baixa variação de temperatura ajuda a previsibilidade da rede por evitar picos e vales extremos. Para o mês escolhido para o teste, que corresponde ao período do verão e com uma alta incidência média de chuvas, a temperatura mínima se encontra na faixa de 23°C e a máxima em 32°C, ambos os valores

próximos da média anual de 21,6°C de mínima e 32°C de máxima (Climatempo, 2022b). Já a radiação solar global média mensal para a respectiva localidade foi de aproximadamente 22.000 kJ/m², valor bem próximo dos 21.000 kJ/m² de média anual (LEITÃO, 2019).

4.3.4. DADOS TOTAIS

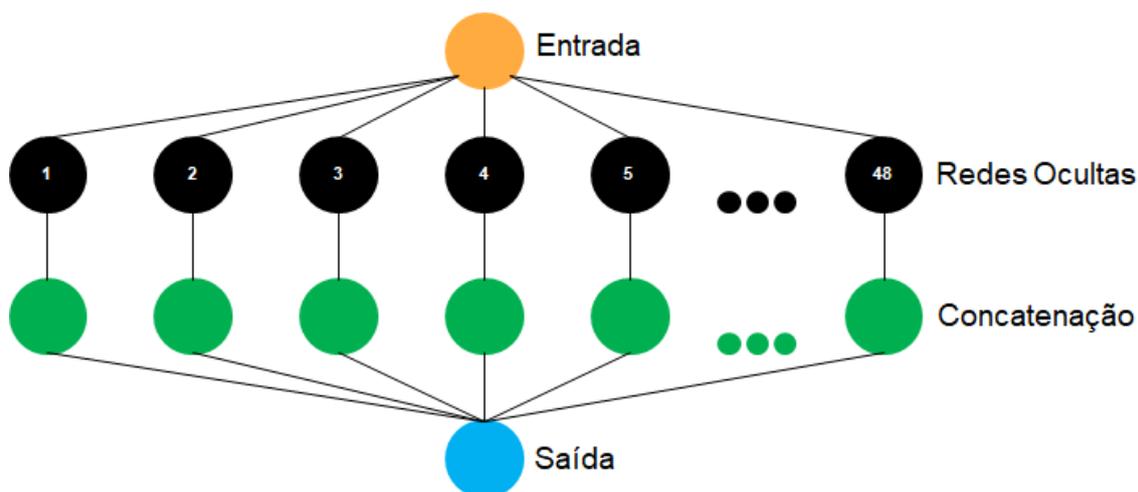
As informações dos dados meteorológicos aplicados neste estudo seguem abaixo:

- Período de referência do estudo: 01/01/2014 às 00 h até 31/11/2021 às 23 h;
- Quantidade total de dados do estudo: 132.209 linhas com 17 entradas (100 %);
- Quantidade total de dados do treinamento e validação: 4 cidades totalizando 111.475 linhas com 17 entradas (84,31 %);
- Quantidade total de dados para teste final:
 - Ibotirama: 4.671 linhas com 17 entradas (3,54 %).
 - Petrolina: 15.967 linhas com 17 entradas (12,07 %)
- Quantidade total de dados para teste final:
 - Experimento A: cidade de Ibotirama com 48 linhas com 17 entradas (0,04 %).
 - Experimento B: cidade de Petrolina com 48 linhas com 17 entradas (0,04 %)

4.4. REDES NEURAIS

As redes neurais desenvolvidas nesse experimento foram compostas por 48 sub redes similares e paralelas, como mostra os círculos pretos presentes na Figura 25, com a saída única de uma lista com 48 horas de horizonte de previsão.

Figura 25 – Arquitetura geral das redes neurais



Fonte: Elaborada pelo autor.

A presente abordagem dedica cada rede paralelizada a se especializar em prever a n ésima hora à frente, conforme o objetivo da rede. Como exemplo, a primeira rede interna é responsável apenas por calcular a 1ª hora à frente, a segunda rede interna pela 2ª hora à frente, e assim sucessivamente com as demais redes internas, tendendo-se a melhorar os resultados através do *feedforward backpropagation*.

Para a criação dessa rede, a camada inicial (*input*) apresenta 17 entradas, correspondentes a cada variável de entrada, para cada *lookback* (totalizando 204 neurônios), e logo em seguida, enviando os dados para cada sub rede e depois agrupando as respectivas saídas para formar um único neurônio responsável por emitir a saída final da rede.

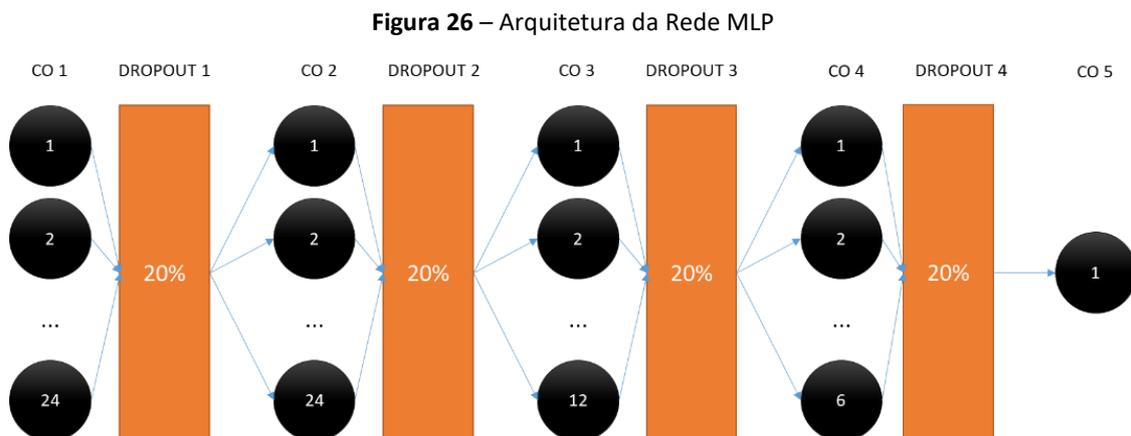
Foram 100 épocas com *lookback* de 12 amostras (exceto para MLP) tendo como base o trabalho publicado por CHAOUACHI *et al.* (2009), tamanho do lote de 100 e divisão entre treinamento e validação em 80% e 20%, respectivamente, com taxa de aprendizagem igual a 0,01. Ainda foi acrescentada a todos os treinamentos uma função do tipo *EarlyStopping*, que serve para parar o treinamento automaticamente caso o mesmo não apresente melhora no erro médio (*loss*) calculado a cada época entre o predito e observado depois de 5 épocas.

Foram realizados testes a fim de se encontrar o melhor conjunto de arquiteturas para cada rede. Esses testes foram realizados na mesma máquina, sendo executado a inferência 3 vezes e extraída a média do tempo para cada modelo, gerando a métrica Tempo Médio de Inferência, sendo calculado em segundos. A seguir a demonstração e configuração das redes e suas respectivas peculiaridades.

4.4.1. MULTI LAYER PERCEPTRON (MLP)

Um dos modelos utilizados e bastante difundidos foi o MLP, que por si traz o conceito de rede neural artificial conforme descrito na metodologia e aplicado em estudos correlacionados como os artigos de IZGI *et al.* (2012) e RODRÍGUEZ *et al.* (2018).

A rede MLP foi composta por 5 camadas, com respectivamente 24 neurônios na primeira (CO1) e segunda camada (CO2), 12 neurônios na terceira camada (CO3), 6 neurônios na quarta camada (CO4) e 1 neurônio na camada de saída (CO5), todas com a função de ativação TANH e *dropout* de 20% entre as camadas, conforme Figura 26.

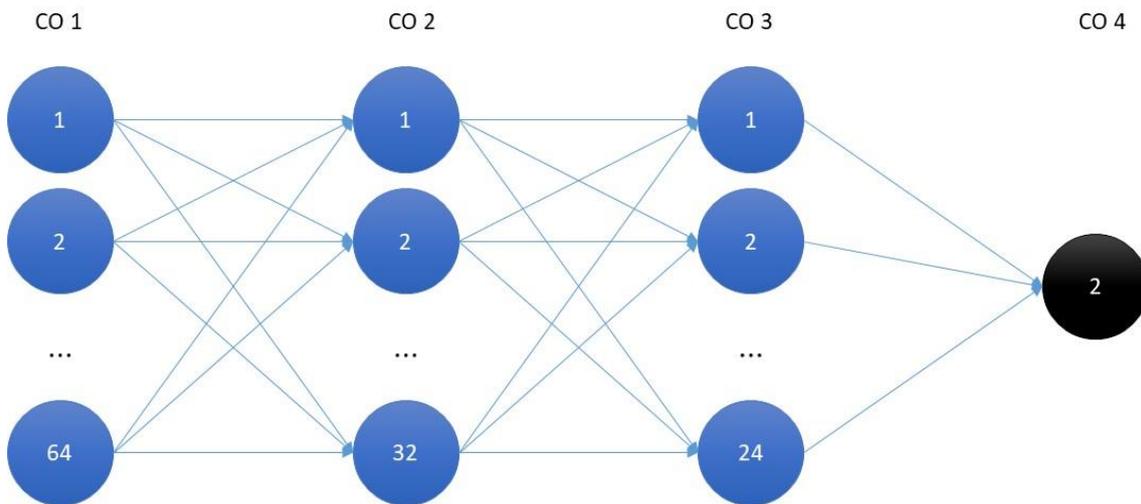


Fonte: Elaborada pelo autor.

4.4.2. LONG SHORT-TERM MEMORY (LSTM)

A rede LSTM foi arquitetada para ter 4 camadas, conforme a Figura 27, sendo a primeira com 64 neurônios, 32 neurônios na segunda camada, sucedido por 24 neurônios na terceira camada e apenas 1 único neurônio na camada de saída. Todas as camadas dessa rede foram ativadas pela função TANH sem *dropout*.

Figura 27 – Arquitetura da Rede LSTM

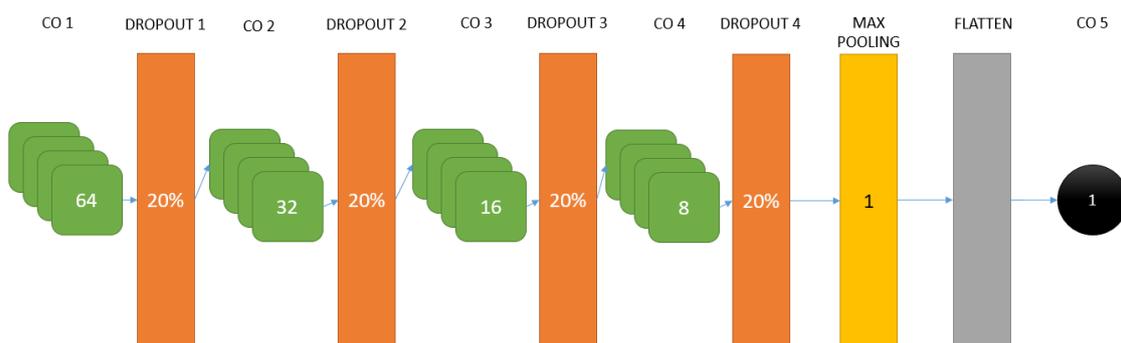


Fonte: Elaborada pelo autor.

4.4.3. CONVOLUTION NEURAL NETWORK (CNN)

A rede CNN1D foi projetada para ter 5 camadas, segundo a Figura 28, sendo a primeira com 64 de filtro, seguida por 32, 16 e 8 filtros para as camadas subsequentes e posteriormente realizado o *Max Pooling* seguido de uma camada *Flatten* para fazer ligação com o único neurônio na camada de saída. Todas as camadas dessa rede foram ativadas pela função *TANH* com *dropout* de 20%.

Figura 28 – Arquitetura da Rede CNN

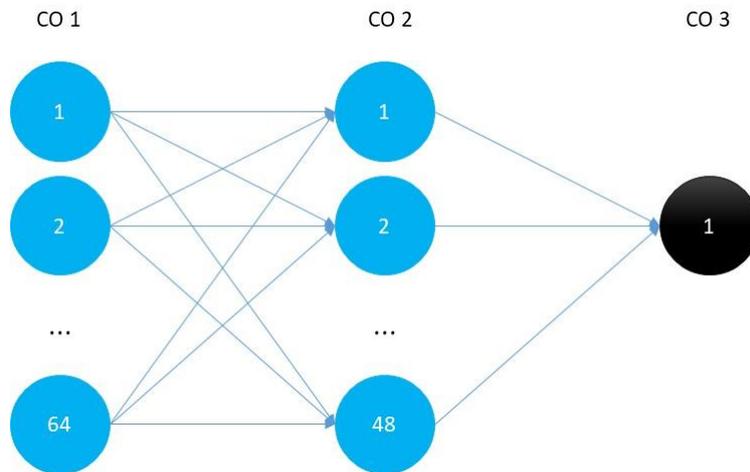


Fonte: Elaborada pelo autor.

4.4.4. GATED RECURRENT UNIT (GRU)

A rede GRU (Figura 29) foi construída com 3 camadas com respectivamente 64, 24 e 1 neurônios para suas camadas ocultas (CO1, CO2 e CO3), todas elas com a função de ativação de TANH, sem o *dropout* presente entre camadas.

Figura 29 – Arquitetura da Rede GRU

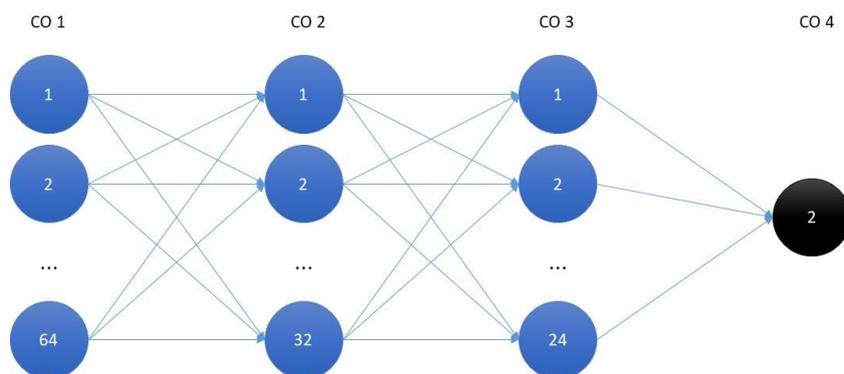


Fonte: Elaborada pelo autor.

4.4.5. LSTM BIDIRECIONAL

Como a rede Bidirecional foi projetada nesse experimento com o modelo da rede LSTM, mantendo a mesma quantidade de neurônios e camadas, porém com o formato bidirecional para todas as camadas conforme Figura 30.

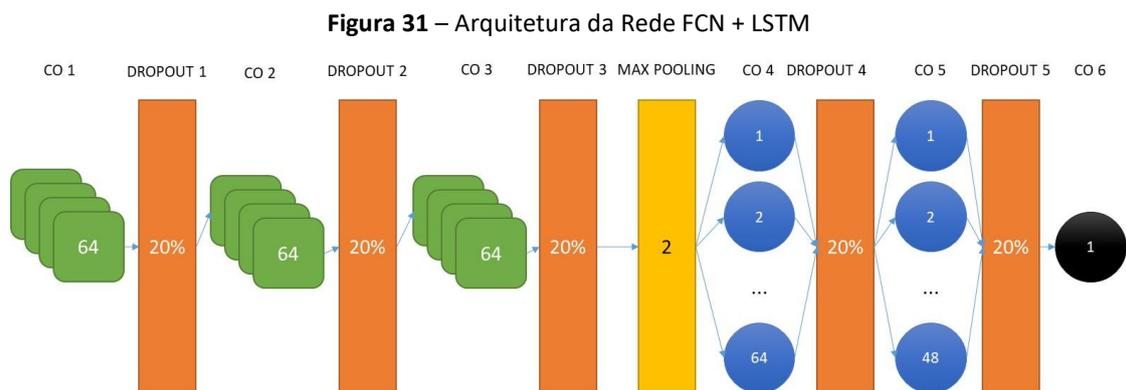
Figura 30 – Arquitetura da Rede Bidirecional LSTM



Fonte: Elaborada pelo autor.

4.4.6. FULLY CONVOLUTIONAL NETWORK (FNC) + LSTM

O modelo FCN + LSTM foi a junção dos modelos CNN1D e do LSTM com algumas ressalvas propostas por GAO *et al.* (2020). O modelo CNN foi criado com 3 camadas ocultas com 64 filtros e tamanho do *kernel* de 2, sendo seguido por um *Max Pooling 1D* de tamanho 2 para seguir para a rede LSTM com 64, 48 e 1 neurônios nas camadas subsequentes. Todas as camadas tiveram a função de ativação *TANH* e *dropout* entre camadas, apresentado na Figura 31.



Fonte: Elaborada pelo autor.

4.5. WRF-ARW

O modelo WRF-ARW teve como base as parametrizações do trabalho de DIAS *et al.* (2019), tendo sido executado no modo de simulação, pois utilizou como base os dados do GDAS FNL (*Global Data Assimilation System – Final Analysis*). Conforme NCEI (2021), esse dataset é interpolado e contém mais dados observados e integralizados, porém são dados que demoram até 4 dias a partir do presente momento para serem disponibilizados. Ou seja, o dado referente ao dia 1 de janeiro de 2022 só será disponibilizado no dia 5 do respectivo mês e ano e assim sucessivamente. Como o presente trabalho se refere à previsão da geração de energia e sua aplicabilidade à indústria de energias renováveis, para que os modelos possam ser úteis, é necessário estabelecer uma base temporal de previsão que sirva para fins operacionais, partindo de um momento no tempo mais próximo possível ao presente.

Deste modo, o experimento para essa pesquisa foi realizado com os dados de inicialização do modelo operacional de previsão global (GFS F00 – *Global Forecast*

System), que contém menos informação do que o GDAS FNL, porém é operacional com diferença útil de até 6 horas a partir do presente momento. A resolução espacial de cada domínio D1, D2, D3 (Ibotirama) e D4 (Petrolina), seguiu o padrão de 9km, 3km e 1km para os dois últimos domínios respectivamente, conforme demonstrado na Figura 32 (escolhida para os experimentos) e nas Tabelas 16 e 17.

Tabela 16 – Configuração dos domínios do WRF-ARW para o Experimento A

Domínio	Resolução	Índice IxJ	Início Domínio Pai	WE/SN Fim	Latitude	Longitude
D01	9 km	1x1		216x216	-12.11	-43.13
D02	3 km	47x47		382x382	-12.11	-43.13
D03	1 km	135x223		55x55	-12.11	-43.13

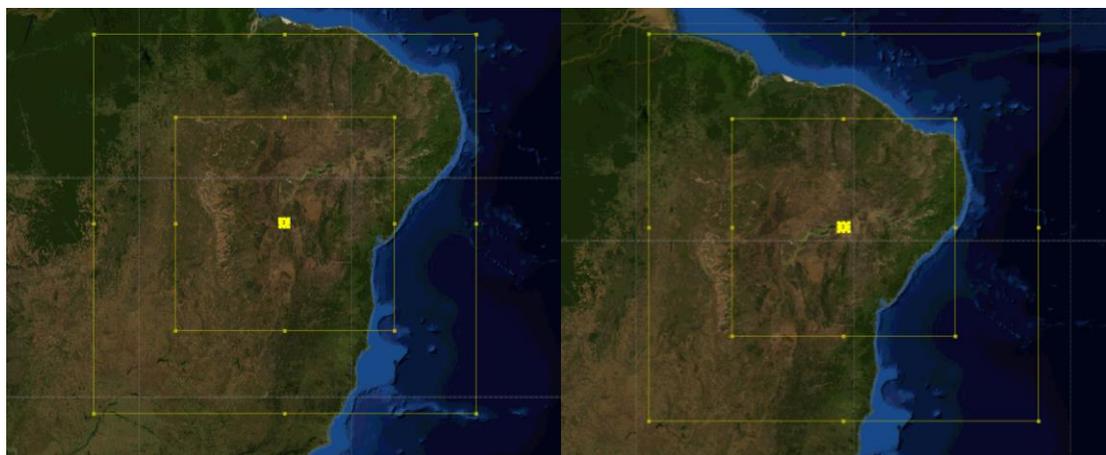
Fonte: Elaborada pelo autor.

Tabela 17 – Configuração dos domínios do WRF-ARW para o Experimento B

Domínio	Resolução	Índice IxJ	Início Domínio Pai	WE/SN Fim	Latitude	Longitude
D01	9 km	1x1		216x216	-9.399	-40.502
D02	3 km	47x47		382x382	-9.399	-40.502
D03	1 km	135x223		55x55	-9.399	-40.502

Fonte: Elaborada pelo autor.

Figura 32 – Localização dos domínios do WRF-ARW. A esquerda Experimento A e a direita o Experimento B.



Fonte: Elaborada pelo autor.

Além das configurações, as parametrizações utilizadas em ambos os experimentos, A (D3) e B (D3), se baseiam em DIAS *et al.* (2019) e são apresentadas na Tabela 18.

Tabela 18 – Parametrização do WRF-ARW

Parametrizações modelo WRF-ARW	Tipo
Camada Limite Superficial	Unified Noah Land Surface Model
Camada Limite Atmosférica	Bougeault-Lacarrere Scheme (BouLac)
Superfície do Solo	Eta Similarity Scheme
Microfísica	Purdue LinScheme
Radiação de Onda Longa	RRTMG Shortwave and Longwave Schemes
Radiação de Onda Curta	RRTMG Shortwave and Longwave Schemes
Cúmulos	Betts-Miller-Janjic Scheme
Projeção	Mercator

Fonte: DIAS *et al.* (2019)

O período selecionado seguiu o padrão dos dados para RNA. Para o Experimento A, a previsão ocorreu a partir do dia 09/06/2020 às 01h até 11/06/2020 às 00h, com *spin-up* de 08/06/2020 às 00h até 09/06/2020 às 00h para a cidade de Ibotirama. Já para o Experimento B, a previsão foi do dia 29/02/2020 às 00:00h até 01/03/2020 às 23:00h para a cidade de Petrolina com um *spin-up* de 27/02/2020 às 23h até 28/02/2020 às 23h.

4.6. PLACAS SOLARES

As placas solares têm uma grande variação perante a eficiência, potência e material composto, o que os tornam cada vez mais caras e confiáveis. Essa pesquisa foi realizada com placas solares de silício monocristalino (amplamente utilizadas no mercado), devido ao coeficiente do material encontrado na literatura. Para ampliar os testes, foram realizados os experimentos com 4 placas com diferentes potências da mesma fabricante Canadian Solar. Sendo que todas, como são de silício monocristalino, apresentam as mesmas características de temperatura, conforme a Tabela 19 (Canadian Solar, 2020a).

Tabela 19 – Características de temperatura da placa solar de silício monocristalino

Coeficiente Temperatura (P_{max})	Coeficiente Temperatura (V_{oc})	Coeficiente Temperatura (I_{sc})	NMOT
-0,34 % / °C	-0,26 % / °C	0,05 % / °C	41 ± 3°C

Fonte: CanadianSolar (2021a)

4.6.1. PLACA SOLAR BAIXA POTÊNCIA

A placa solar de baixa potência foi a CS5A-200 com os seguintes dados fornecidos pelo fabricante representado respectivamente pela Tabela 20 (Canadian Solar, 2020a).

Tabela 20 – Características da placa solar CS5A-200

	P_{max}	V_{mp}	I_{mp}	V_{oc}	I_{sc}
STC	200 W	37,9 V	5,28 A	45,7 V	5,66 A
NMOT	150 W	35,5 V	4,22 A	43,2 V	4,56 A

Fonte: CanadianSolar (2021a)

4.6.2. PLACA SOLAR MÉDIA POTÊNCIA

A placa solar de média potência foi a CS3L-360MS com os seguintes dados fornecidos pelo fabricante representado respectivamente pela Tabela 21 (Canadian Solar, 2020b).

Tabela 21 – Características da placa solar CS3L-360MS

	P_{max}	V_{mp}	I_{mp}	V_{oc}	I_{sc}
STC	360 W	33,7 V	10,69 A	40,4 V	11,40 A
NMOT	270 W	31,6 V	8,55 A	38,2 V	9,19 A

Fonte: CanadianSolar (2021b)

4.6.3. PLACA SOLAR ALTA POTÊNCIA

A placa solar de baixa potência foi a CS3W-420MB-AG com os seguintes dados fornecidos pelo fabricante representado respectivamente pela Tabela 22 (Canadian Solar, 2020c).

Tabela 22 – Características da placa solar CS3W-420MB-AG

	P_{max}	V_{mp}	I_{mp}	V_{oc}	I_{sc}
STC	460 W	41,5 V	11,09 A	49,5 V	11,72 A
NMOT	345 W	38,0 V	8,59 A	45,8V	9,21 A

Fonte: CanadianSolar (2021c)

4.6.4. PLACA SOLAR INDUSTRIAL

A placa solar de baixa potência foi a CS7N-670MS com os seguintes dados fornecidos pelo fabricante representado respectivamente pela Tabela 23 (Canadian Solar, 2020d).

Tabela 23 – Características da placa solar CS7N-670MS

	P_{max}	V_{mp}	I_{mp}	V_{oc}	I_{sc}
STC	670 W	38,7 V	17,32 A	45,8 V	18,55 A
NMOT	502 W	36,3 V	13,85 A	43,3 V	14,96 A

Fonte: CanadianSolar (2021d)

4.7. AVALIAÇÃO DO DESEMPENHO DOS MODELOS

4.7.1. AVALIAÇÃO QUALITATIVA

A avaliação qualitativa foi feita através de gráficos, principalmente na análise de do *loss* de treinamento e de validação para verificação de *overfitting* e *underfitting*, e da comparação entre as imagens das séries temporais das previsões para a melhor compreensão e complemento da avaliação quantitativa.

4.7.2. AVALIAÇÃO QUANTITATIVA

Os cálculos para validação quantitativa da saída das RNA e WRF-ARW foram baseados no diagrama de Taylor, que mostra a correlação e o desvio padrão de forma integrada, e nos índices estatísticos MAE (equação 7) e RMSE (equação 8), ambas com valores tendendo a 0,0 (zero) para modelos que melhor explicam o fenômeno. Além dessas métricas, outras métricas foram empregadas para validar o desempenho das redes: o coeficiente de regressão R^2 (equação 9) e o coeficiente de correlação de Pearson r (equação 10), de modo que valores mais próximos a 1,0 (um) são referentes a um modelo que melhor explica o fenômeno.

$$MAE = \frac{\sum_{t=1}^n |y_t - F_t|}{n} \quad (7)$$

$$RMSE = \sqrt{\frac{\sum_{t=1}^n (y_t - F_t)^2}{n}} \quad (8)$$

$$R^2 = \frac{\sum_{i=1}^n (\hat{y}_i - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})} \quad (9)$$

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}} \quad (10)$$

Onde:

- y_t = Observação atual no período t
- F_t = Previsão no período t
- n = Quantidade de dados
- y_i = Valor observado
- y = Média das observações
- \hat{y}_i = Previsão de y_i
- x_i = Dados da matriz 1.
- y_i = Dados da matriz 2.
- \bar{x} = Média dos dados da matriz 1
- \bar{y} = Média dos dados da matriz 2

5. RESULTADOS E DISCUSSÃO

Utilizando o supercomputador Cimatic Ògún, localizado no SENAI CIMATEC, em Salvador, Bahia, foram treinadas, validadas e testadas as redes específicas para previsão de temperatura e radiação solar global, e a modelagem numérica com o WRF-ARW. Os gráficos de *loss* do treinamento e da validação de todas as redes estão dispostas no Apêndice 1.

5.1. TESTE PADRÃO

O teste padrão, conforme descrito na seção de Metodologia, ocorreu em um grande período de dados (aproximadamente dois anos de amostras horárias) para cada estação meteorológica respectivamente. Foram calculadas as métricas para os valores meteorológicos e posteriormente as métricas da potência energética para cada uma das quatro placas fotovoltaicas para ambas as estações alvo. Os gráficos de métrica dos horizontes de previsão de cada modelo meteorológico é apresentado no Apêndice 2.

5.1.1. CONFIGURAÇÃO PARA POTÊNCIA ELÉTRICA SOLAR

Para realizar os experimentos, foram criadas combinações entre um modelo de previsão da radiação solar global com outro modelo de previsão da temperatura do ar de bulbo seco chamada de Configurações. O objetivo dessa criação é para realizar a previsão da potência elétrica (W) perante cada placa solar. As redes neurais foram nomeadas conforme o objetivo de previsão (radiação ou temperatura) como prefixo e logo em seguida o modelo utilizado, i.e., o modelo T-BiLSTM que visa a previsão da temperatura utilizando o modelo BiLSTM. E com isso, foram montadas as seguintes configurações conforme a Tabela 24, seguindo o padrão anterior de nomenclatura referentes aos modelos apresentados de Radiação Solar e Temperatura, *e.g.*, a configuração R-MLP/T-LSTM sendo composta das redes MLP para radiação (R-MLP) e LSTM para temperatura (T-LSTM), respectivamente.

Tabela 24 – Configurações entre modelos de radiação solar global e temperatura

Nome do Modelo	Rede para Radiação Solar	Rede para Temperatura
R-MLP/T-MLP	R-MLP	T-MLP

R-MLP/T-LSTM	R-MLP	T-LSTM
R-MLP/T-BiLSTM	R-MLP	T-BiLSTM
R-MLP/T-FCN+LSTM	R-MLP	T-FCN+LSTM
R-MLP/T-GRU	R-MLP	T-GRU
R-MLP/T-CNN	R-MLP	T-CNN
R-LSTM/T-MLP	R-LSTM	T-MLP
R-LSTM/T-LSTM	R-LSTM	T-LSTM
R-LSTM/T-BiLSTM	R-LSTM	T-BiLSTM
R-LSTM/T-FCN+LSTM	R-LSTM	T-FCN+LSTM
R-LSTM/T-GRU	R-LSTM	T-GRU
R-LSTM/T-CNN	R-LSTM	T-CNN
R-FCN+LSTM/T-MLP	R-FCN+LSTM	T-MLP
R-FCN+LSTM/T-LSTM	R-FCN+LSTM	T-LSTM
R-FCN+LSTM/T-BiLSTM	R-FCN+LSTM	T-BiLSTM
R-FCN+LSTM/T-FCN+LSTM	R-FCN+LSTM	T-FCN+LSTM
R-FCN+LSTM/T-GRU	R-FCN+LSTM	T-GRU
R-FCN+LSTM/T-CNN	R-FCN+LSTM	T-CNN
R-GRU/T-MLP	R-GRU	T-MLP
R-GRU/T-LSTM	R-GRU	T-LSTM
R-GRU/T-BiLSTM	R-GRU	T-BiLSTM
R-GRU/T-FCN+LSTM	R-GRU	T-FCN+LSTM
R-GRU/T-GRU	R-GRU	T-GRU
R-GRU/T-CNN	R-GRU	T-CNN
R-CNN/T-MLP	R-CNN	T-MLP
R-CNN/T-LSTM	R-CNN	T-LSTM
R-CNN/T-BiLSTM	R-CNN	T-BiLSTM
R-CNN/T-FCN+LSTM	R-CNN	T-FCN+LSTM
R-CNN/T-GRU	R-CNN	T-GRU
R-CNN/T-CNN	R-CNN	T-CNN

Fonte: Elaborada pelo autor.

Como o modelo BiLSTM de radiação solar global apresentou um valor constante na previsão (valor zero), o mesmo também foi descartado destas combinações de redes pois o cálculo das métricas tendia ao infinito em algumas análises.

5.1.2. ESTAÇÃO IBOTIRAMA

5.1.2.1. PARÂMETROS METEOROLÓGICOS

Com a previsão meteorológica realizada, foram calculadas as médias, para todos os horizontes de previsão, entre as métricas obtidas de temperatura e radiação solar na estação de Ibotirama para compor as Tabelas 25 e 26 respectivamente. As melhores métricas foram destacadas em negrito para facilitar a visualização.

Tabela 25 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar no teste padrão

Modelo	Média MAE	Média RMSE	Média r	Média R^2
R-MLP	70,5408	121,3234	0,9258	0,8543
R-LSTM	118,8552	227,2329	0,7289	0,4860
R-GRU	116,9879	226,5050	0,7368	0,4894
R-BiLSTM	233,6803	389,4785	0,5158	-0,5091
R-FCN+LSTM	169,6157	279,7517	0,6932	0,2208
R-CNN	145,5479	246,6197	0,6913	0,3946

Fonte: Elaborada pelo autor.

Tabela 26 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura no teste padrão

Modelo	Média MAE	Média RMSE	Média r	Média R^2
T-MLP	0,5385	0,6878	0,8615	0,7310
T-LSTM	0,6948	0,9503	0,7182	0,5009
T-GRU	0,6730	0,9397	0,7335	0,5120
T-BiLSTM	0,6895	0,9478	0,7218	0,5036
T-FCN+LSTM	0,7076	0,9716	0,7173	0,4784
T-CNN	0,6968	0,9688	0,7357	0,4814

Fonte: Elaborada pelo autor.

Com base nas tabelas acima, pode-se perceber que a rede MLP obteve os melhores resultados para todas as métricas para a previsão da temperatura e da radiação solar simultaneamente.

5.1.2.2. POTÊNCIA ELÉTRICA

Com a previsão dos parâmetros meteorológicos realizadas, foram calculadas as métricas da potência energética para os quatro tipos de placas solares. Na Tabela 27, estão representadas as melhores configurações com base análises multivariadas das métricas obtidas para cada uma placa solar distinta para sua respectiva potência elétrica.

Tabela 27 – Resumo das melhores métricas de MAE, RMSE, r e R^2 para potência de saída das placas fotovoltaicas

Placa	Configuração	MAE	RMSE	r	R^2
CS5A-200	R-MLP/T-MLP	10,149	17,5921	0,9267	0,8563
CS3L-360MS	R-MLP/T-MLP	19,4592	33,7305	0,9268	0,8565
CS3W-420MB-AG	R-MLP/T-MLP	21,3345	36,9798	0,9266	0,8563
CS7N-670MS	R-MLP/T-MLP	33,8702	58,7177	0,9267	0,8564

Fonte: Elaborada pelo autor.

Com base na tabela acima, pode-se perceber que a configuração R-MLP/T-MLP foi a melhor para todos os tipos de placas solares para a região de Ibotirama, para a previsão da potência elétrica para todo o período do teste padrão para 48h à frente. A tabela completa com todas as métricas de cada uma das placas fotovoltaicas é apresentada no Apêndice 3, acompanhada pelos diagramas de Taylor no Apêndice 5.

5.1.3. ESTAÇÃO PETROLINA

5.1.3.1. PARÂMETROS METEOROLÓGICOS

Além do teste com a estação Ibotirama, também foi realizada a experimentação na estação de Petrolina. Após realizar a inferência para todos os horizontes de previsão, foram calculadas as médias para compor as Tabelas 28 e 29 respectivamente. As melhores métricas foram destacadas em negrito para facilitar a visualização.

Tabela 28 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar no teste padrão

Modelo	Média MAE	Média RMSE	Média r	Média R^2
R-MLP	103,1837	173,5386	0,9298	0,4701
R-LSTM	80,15310	132,7192	0,9307	0,7002
R-GRU	82,18840	141,5770	0,9025	0,6629
R-BiLSTM	180,5578	298,8109	0,6646	-0,5005
R-FCN+LSTM	140,7171	217,4075	0,8436	0,1858
R-CNN	135,6773	220,7196	0,8420	0,1729

Fonte: Elaborada pelo autor.

Tabela 29 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura no teste padrão

Modelo	Média MAE	Média RMSE	Média r	Média R^2
T-MLP	0,4067	0,5316	0,8970	0,7359
T-LSTM	0,4940	0,6289	0,8571	0,6356
T-GRU	0,5397	0,6785	0,8546	0,5739
T-BiLSTM	0,4813	0,6146	0,8568	0,6553
T-FCN+LSTM	0,5220	0,6638	0,8501	0,5960
T-CNN	0,5787	0,7353	0,7990	0,5089

Fonte: Elaborada pelo autor.

Tendo em vista com base nas métricas apresentadas nas tabelas acima, percebe-se que a rede LSTM foi a melhor para a previsão da radiação, enquanto que a MLP ficou com a melhor métrica para a temperatura.

5.1.3.2. POTÊNCIA ELÉTRICA

Logo após a previsão dos parâmetros meteorológicos, foram realizados os cálculos para obtenção da potência elétrica para cada uma das quatro placas solares estudadas. Após a obtenção dos cálculos, foram processadas as métricas e apresentadas a potência na Tabela 30, sendo selecionada apenas as melhores para cada placa solar. No Apêndice 4 estão todas as tabelas completas referentes a comparação de cada uma das 30 configurações perante cada placa fotovoltaica com seu respectivo diagrama de Taylor apresentado no Apêndice 5.

Tabela 30 – Resumo das melhores métricas de MAE, RMSE, r e R^2 para potência de saída das placas fotovoltaicas

Placa	Configuração	MAE	RMSE	r	R^2
CS5A-200	R-LSTM/T-CNN	11,3827	19,4087	0,9272	0,6991
CS3L-360MS	R-LSTM/T-CNN	21,7932	37,1572	0,9274	0,7009
CS3W-420MB-AG	R-LSTM/T-CNN	23,9425	40,822	0,9271	0,6986
CS7N-670MS	R-LSTM/T-CNN	37,8945	64,6371	0,9273	0,7008

Fonte: Elaborada pelo autor.

Com base na tabela acima, pode-se perceber que a configuração R-LSTM/T-CNN fixou-se como a melhor combinação de redes neurais profundas para a previsão da potência energética para 48h à frente, em todo o período do teste padrão.

5.2. TESTE FINAL COMPARATIVO COM WRF-ARW

O teste final foi composto, conforme descrito na metodologia, na previsão de uma amostra, simulando uma situação real, com dados operacionais. Os modelos foram selecionados com base na escolha das melhores métricas do teste padrão para as estações de Ibotirama e Petrolina, para a previsão da potência elétrica 48h à frente. Para a análise meteorológica, foram selecionadas as redes que obtiveram os melhores para cada estação em seus respectivos testes padrão. Na análise da potência, para a estação de Ibotirama foi selecionada a rede R-MLP/T-MLP e para a estação de Petrolina a configuração R-LSTM/T-CNN, ambas apresentadas com as melhores métricas.

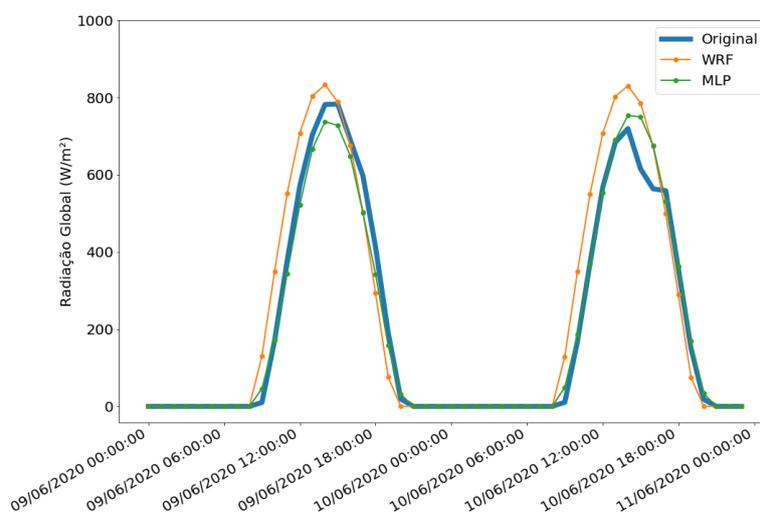
5.2.1. EXPERIMENTO A

O Experimento A foi feito visando a previsão na cidade de Ibotirama conforme comentado na seção de Curadoria de Dados para um período uma única amostra visando a previsão de 48 horas. Para todo o experimento, os resultados dos dados meteorológicos continuaram servindo como entrada para serem calculadas as respectivas potências elétricas dos quatro tipos de placas fotovoltaicas.

5.2.1.1. PREVISÕES COM DADOS METEOROLÓGICOS DO EXPERIMENTO A

Para iniciar o Experimento A foram previstos os parâmetros meteorológicos de temperatura e radiação solar para posteriormente ser calculada a potência elétrica gerada para cada uma das quatro placas fotovoltaicas. A Figura 33 mostra uma análise dos valores da previsão da radiação solar global, convertida de KJ/m^2 para W/m^2 , para as próximas 48 horas, utilizando a melhor rede R-MLP vista no teste padrão da estação de Ibotirama, a partir da data de início do período de teste final para previsão na cidade de Ibotirama. É possível perceber que, em geral, as previsões possuem uma capacidade preditiva que não se degrada muito na medida em que se avançam no tempo, sendo validadas na Tabela 31, com a média das métricas, juntamente com a Figura 34 que demonstra a correlação e o desvio padrão via diagrama de Taylor.

Figura 33 – Análise dos valores da radiação solar global original x previstas pelo modelo de IA e WRF-ARW para o Experimento A



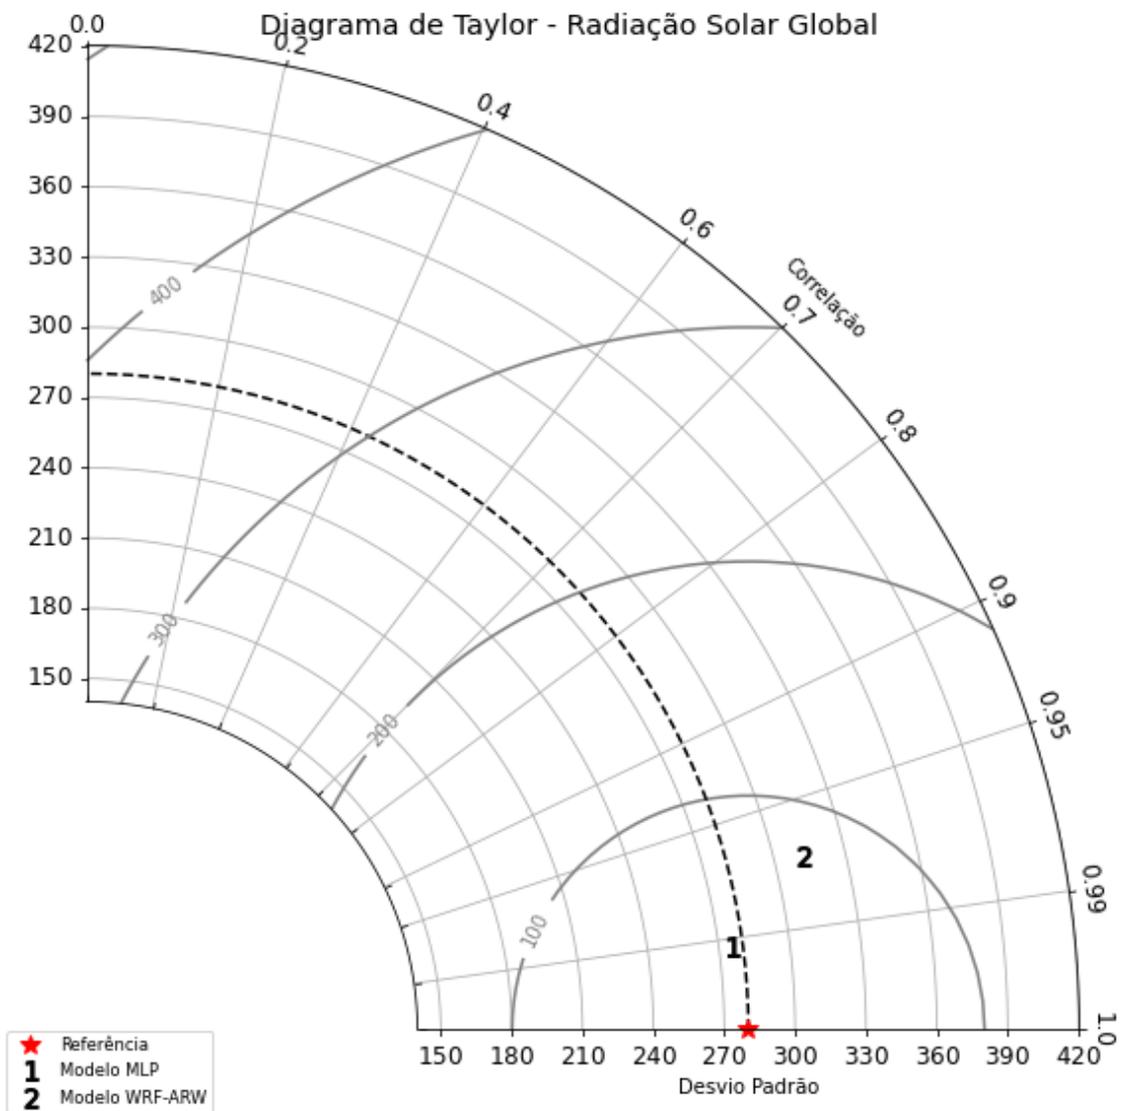
Fonte: Elaborada pelo autor.

Tabela 31 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar, e os tempos de treinamento/simulação e de inferência

Modelo	Média MAE	Média RMSE	Média r	Média R^2	Tempo de Treinamento (min)	Tempo Médio de Inferência / Previsão (s)
MLP	19,5780	36,3965	0,9916	0,9831	291	1,45
WRF-ARW	51,6299	82,3626	0,9715	0,9136	-	30.360

Fonte: Elaborada pelo autor.

Figura 34 – Diagrama de Taylor da radiação solar global para o Experimento A

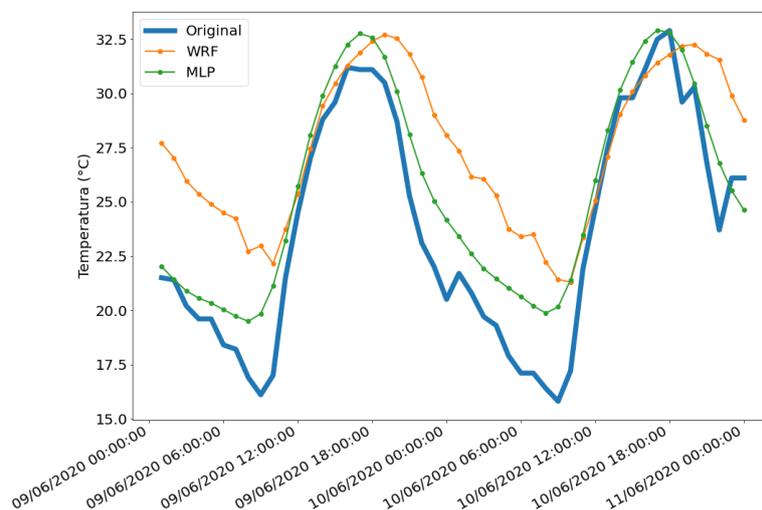


Fonte: Elaborada pelo autor.

Já a Figura 35 mostra uma análise dos valores das métricas para cada horizonte de previsão da temperatura, apresentando qualitativamente a rede T-MLP com a

melhor métrica na respectiva imagem e também quantitativamente presente na Tabela 32. Para complementar a análise, o diagrama de Taylor é evidenciado na Figura 36.

Figura 35 – Análise dos valores da temperatura original x previstas pelo modelo de IA e WRF-ARW para o Experimento A



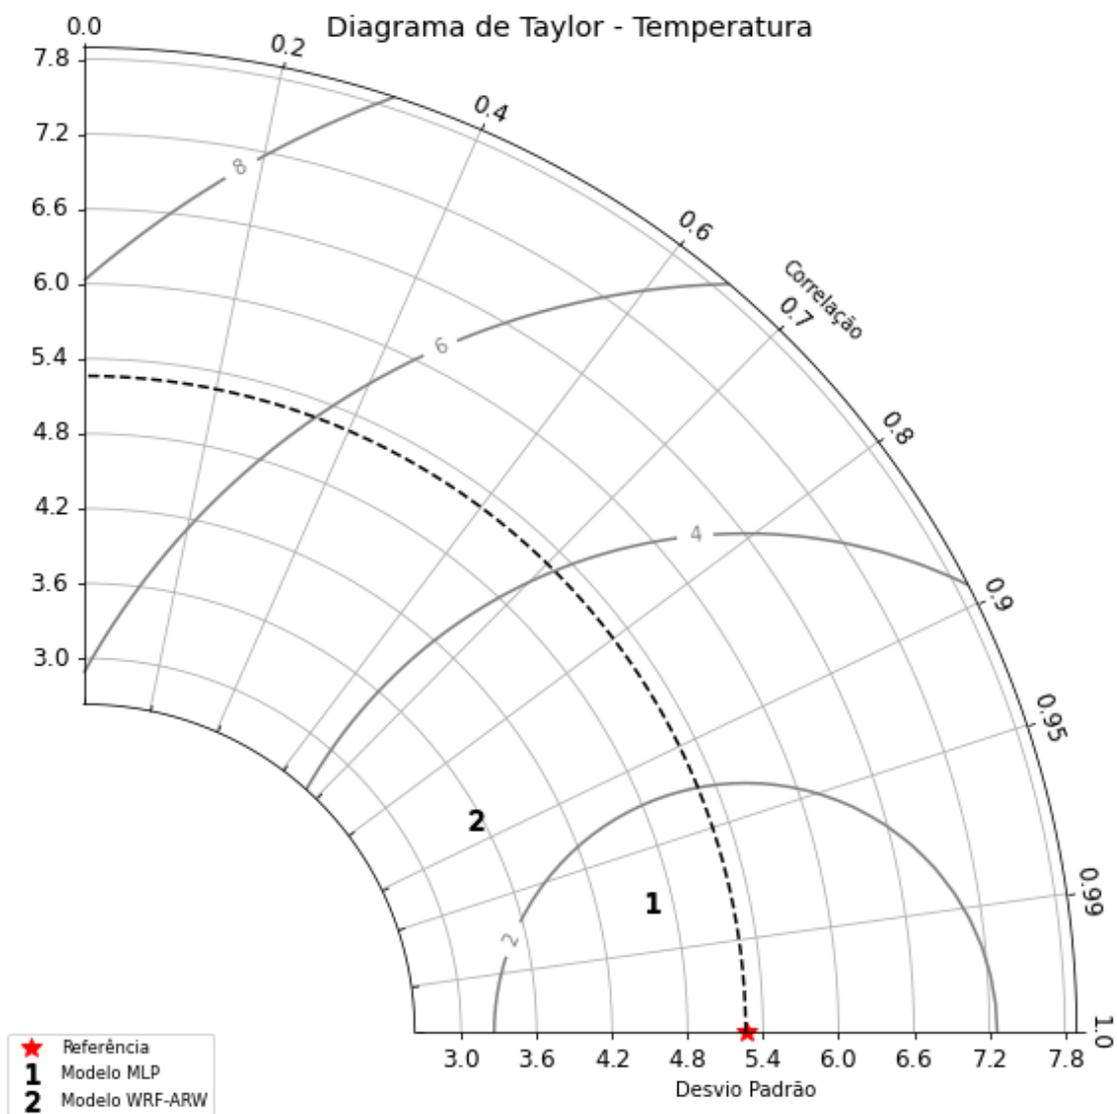
Fonte: Elaborada pelo autor.

Tabela 32 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura, e os tempos de treinamento e de inferência

Modelo	Média MAE	Média RMSE	Média r	Média R^2	Tempo de Treinamento (min)	Tempo Médio de Inferência / Previsão (s)
MLP	1,8628	2,1956	0,9738	0,8259	285	1,61
WRF-ARW	3,9098	4,6565	0,8768	0,2171	-	30.360

Fonte: Elaborada pelo autor.

Figura 36 – Diagrama de Taylor da temperatura para o Experimento A



Fonte: Elaborada pelo autor.

5.2.1.2. PLACA SOLAR DE BAIXA POTÊNCIA DO EXPERIMENTO A

A respectiva placa solar de baixa potência CS5A-200 de 200W obteve o melhor resultado para a configuração do modelo R-MLP/T-MLP. Esta combinação de redes apresentou os melhores valores para todas as métricas desta respectiva placa fotovoltaica para potência, conforme a Tabela 33.

Tabela 33 – Métricas do Experimento A de potência energética para placa solar de baixa potência (200W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-MLP/T-MLP	2,8677	5,2986	0,9917	0,9834
WRF-ARW	7,5779	12,0947	0,9712	0,9135

Fonte: Elaborada pelo autor.

5.2.1.3. PLACA SOLAR DE MÉDIA POTÊNCIA DO EXPERIMENTO A

A outra placa solar, agora representada como de média potência com 360W, obteve o melhor resultado para potência com a configuração R-MLP/T-MLP, conforme demonstrado na Tabela 34.

Tabela 34 – Métricas do Experimento A de potência energética para placa solar de média potência (360W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-MLP/T-MLP	5,5202	10,1869	0,9917	0,9834
WRF-ARW	14,5839	23,2804	0,9711	0,9131

Fonte: Elaborada pelo autor.

5.2.1.4. PLACA SOLAR DE ALTA POTÊNCIA DO EXPERIMENTO A

Tendo em vista o teste de uma placa solar de alta potência, foi apresentada a CS3W-420MB-AG com 420W. A previsão da mesma teve o melhor resultado com a configuração do modelo R-MLP/T-MLP, conforme demonstrado na Tabela 35.

Tabela 35 – Métricas do Experimento A de potência energética para placa solar de alta potência (420W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-MLP/T-MLP	6,0189	11,1249	0,9917	0,9834
WRF-ARW	15,9076	25,3880	0,9713	0,9137

Fonte: Elaborada pelo autor.

5.2.1.5. PLACA SOLAR INDUSTRIAL DO EXPERIMENTO A

E por fim do experimento A, foi realizado o teste com a placa solar industrial com 670W de potência. A previsão da mesma teve o melhor resultado com a configuração R-MLP/T-MLP para potência elétrica, conforme demonstrado na Tabela 36.

Tabela 36 – Métricas do Experimento A de potência energética para placa solar industrial (670W)

Configuração	MAE	RMSE	r	R^2
R-MLP/T-MLP	9,6283	17,7691	0,9917	0,9833
WRF-ARW	25,4211	40,5818	0,9711	0,9128

Fonte: Elaborada pelo autor.

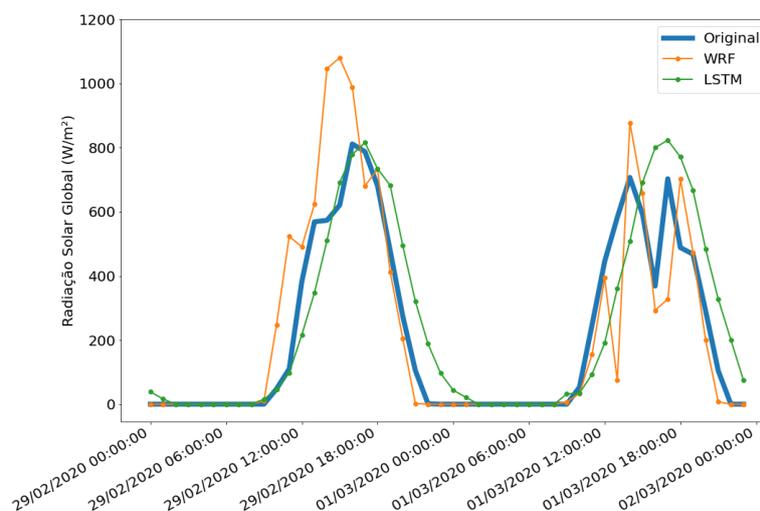
5.2.2. EXPERIMENTO B

O Experimento B serviu como base para validar se a configuração da rede neural artificial estava conseguindo generalizar os dados meteorológicos, mesmo distante das cidades cujos dados foram utilizados para o treinamento, e da cidade alvo do Experimento A.

5.2.2.1. PREVISÕES DADOS METEOROLÓGICOS DO EXPERIMENTO B

Esta análise seguiu o fluxo de experimentação, conforme o Experimento A, iniciando através da previsão dos parâmetros meteorológicos de temperatura e radiação solar. Na Figura 37 mostra uma análise dos valores absolutos para cada horizonte de previsão da radiação solar global do modelo R-LSTM e WRF, ambos convertidos de KJ/m^2 para W/m^2 . Além desta figura, a Tabela 37 e o diagrama de Taylor, apresentado na Figura 38, complementam a análise dos dados para radiação solar global.

Figura 37 – Análise dos valores da radiação solar global original x previstas pelos modelos de IA e WRF-ARW para o Experimento B



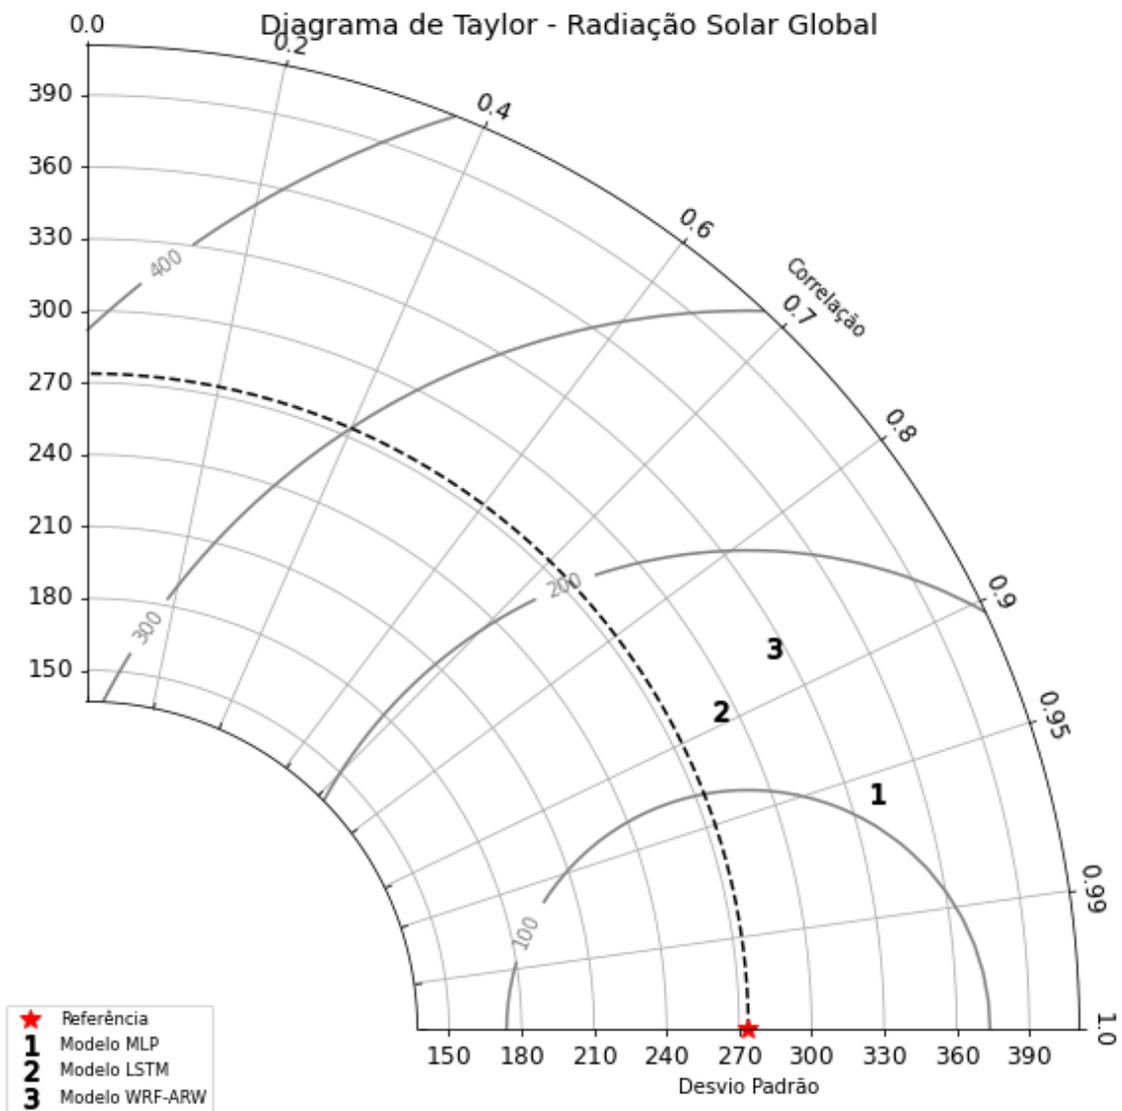
Fonte: Elaborada pelo autor.

Tabela 37 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de radiação solar, e os tempos de treinamento/simulação e de inferência

Modelo	Média MAE	Média RMSE	Média r	Média R^2	Tempo de Treinamento (min)	Tempo Médio de Inferência / Previsão (s)
LSTM	91,8880	138,2084	0,8917	0,7452	416	12,28
WRF-ARW	85,3606	161,0020	0,8728	0,6543	-	30.360

Fonte: Elaborada pelo autor.

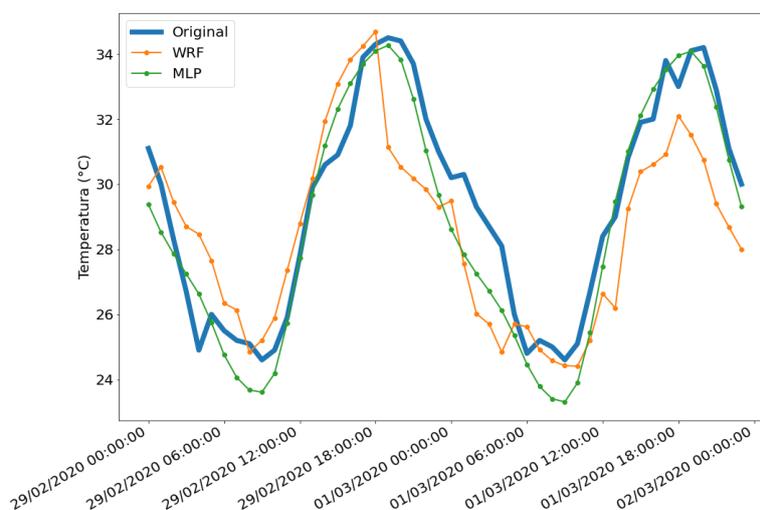
Figura 38 – Diagrama de Taylor da radiação solar global para o Experimento B



Fonte: Elaborada pelo autor.

Além disso, a Figura 39 mostra uma análise dos valores da temperatura para as próximas 48 horas a partir da data de previsão na cidade de Petrolina. É interessante a análise ao validar, que as redes possuem uma capacidade preditiva que não se degradam significativamente na medida em que se avança no tempo, mesmo quando se considera a distância entre as cidades envolvidas no treinamento e o alvo. A Tabela 38 e a Figura 40 complementam essa análise quantitativa e qualitativamente.

Figura 39 – Análise dos valores da temperatura original x previstas pelos modelos de IA e WRF-ARW para o Experimento B



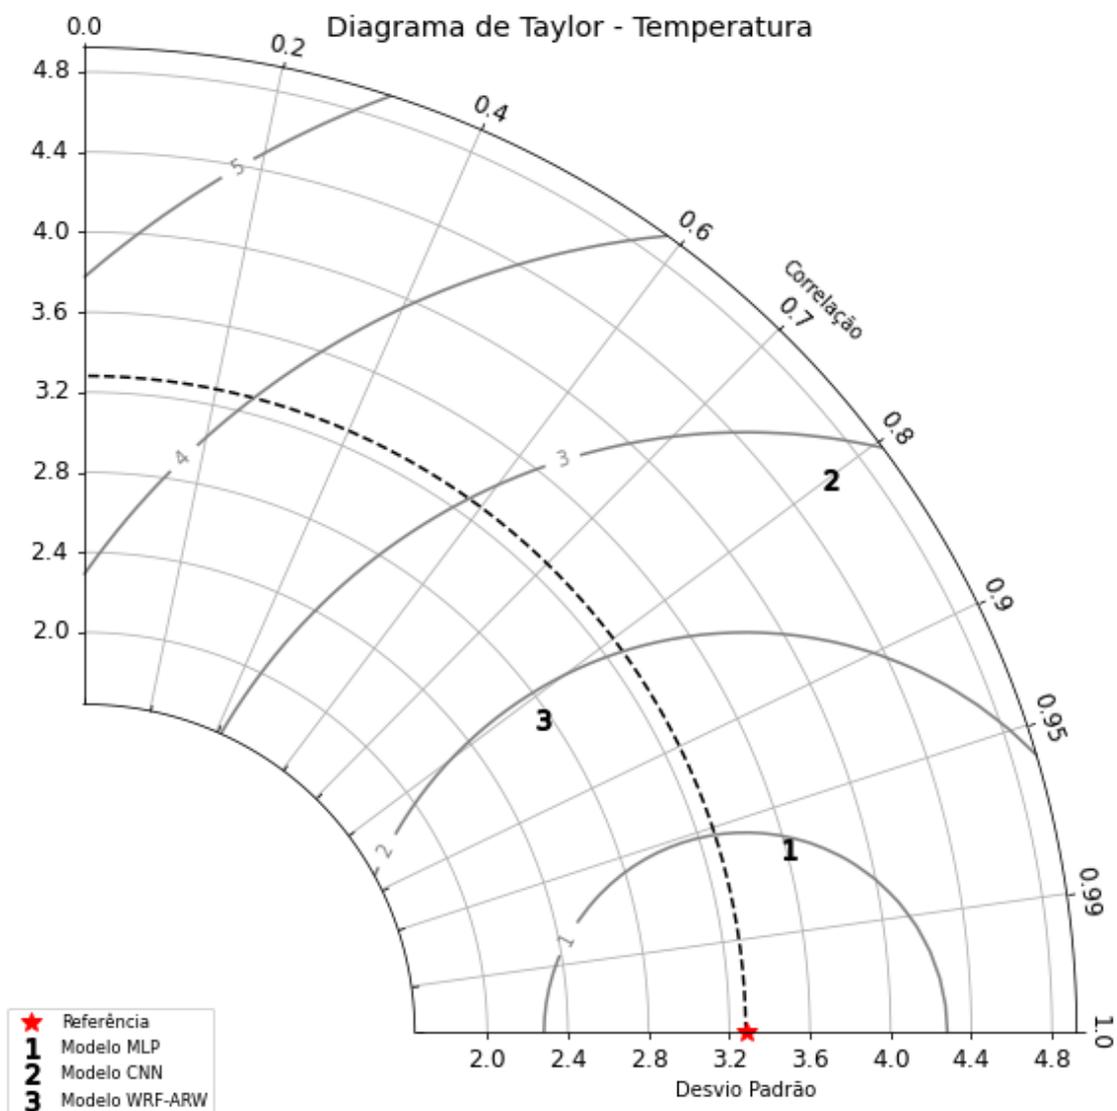
Fonte: Elaborada pelo autor.

Tabela 38 – Resumo das métricas de MAE, RMSE, r e R^2 para modelos de temperatura, e os tempos de treinamento e de inferência

Modelo	Média MAE	Média RMSE	Média r	Média R^2	Tempo de Treinamento (min)	Tempo Médio de Inferência / Previsão (s)
MLP	0,9053	1,0899	0,9673	0,8897	285	1,61
WRF-ARW	1,6939	2,0184	0,8232	0,6216	-	30.360

Fonte: Elaborada pelo autor.

Figura 40 – Diagrama de Taylor da temperatura para o Experimento B



Fonte: Elaborada pelo autor.

5.2.2.2. PLACA SOLAR DE BAIXA POTÊNCIA DO EXPERIMENTO B

Para início da experimentação B, foi realizado o teste com a placa solar de baixa potência CS5A-200 de 200W. A mesma obteve o melhor resultado com a configuração R-LSTM/T-CNN para potência conforme a Tabela 39, baseado na análise multivariada.

Tabela 39 – Métricas do Experimento B de potência energética para placa solar de baixa potência (200W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-LSTM/T-CNN	13,4064	20,1262	0,8922	0,7475
WRF-ARW	12,2984	23,2781	0,8741	0,6622

Fonte: Elaborada pelo autor.

5.2.2.3. PLACA SOLAR DE MÉDIA POTÊNCIA DO EXPERIMENTO B

Também foi realizado um teste com uma placa solar de média potência de 360W. O resultado com maior confiabilidade foi a configuração R-LSTM/T-CNN para a análise da potência elétrica, conforme apresentado na Tabela 40.

Tabela 40 – Métricas do Experimento B de potência energética para placa solar de média potência (360W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-LSTM/T-CNN	25,7210	38,6045	0,8922	0,7475
WRF-ARW	23,5836	44,6469	0,8742	0,6623

Fonte: Elaborada pelo autor.

5.2.2.4. PLACA SOLAR DE ALTA POTÊNCIA DO EXPERIMENTO B

Ainda foi realizada a previsão da geração de energia solar para uma placa solar de alta potência (CS3W-420MB-AG) com 420W. A Tabela 41 demonstra que a previsão da respectiva placa teve o melhor resultado com configuração R-LSTM/T-CNN no cálculo da potência elétrica.

Tabela 41 – Métricas do Experimento B de potência energética para placa solar de alta potência (420W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-LSTM/T-CNN	28,1781	42,3037	0,8923	0,7476
WRF-ARW	25,8483	48,9189	0,8741	0,6625

Fonte: Elaborada pelo autor.

5.2.2.5. PLACA SOLAR INDUSTRIAL DO EXPERIMENTO B

E para a conclusão do Experimento B, foi realizado o teste com a placa solar industrial com 670W de potência. A configuração R-LSTM/T-CNN demonstrou através da Tabela 42 como a melhor configuração para o cálculo da potência elétrica.

Tabela 42 – Métricas do Experimento B de potência energética para placa solar industrial (670W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-LSTM/T-CNN	44,7561	67,1860	0,8920	0,7471
WRF-ARW	41,0748	77,7890	0,8739	0,6610

Fonte: Elaborada pelo autor.

5.3. DISCUSSÃO

Para os dados meteorológicos isolados, e.g., analisados apenas a temperatura com o dado original, a rede T-MLP obteve as melhores métricas para as estações de Ibotirama e Petrolina respectivamente, conforme apresentado no teste padrão. Para a análise da radiação solar global, a rede R-MLP se destacou perante os demais modelos para a estação de Ibotirama, situação diferente para a estação de Petrolina, que apresentou a melhor métrica com a rede R-LSTM.

Na previsão da potência da estação de Ibotirama, a melhor configuração apresentada foi a R-MLP/T-MLP, pela análise quantitativa e qualitativa das métricas, reforçando a uso destas redes para a previsão dos dados meteorológicos isolados no teste padrão. O resultado da análise da previsão da potência para a estação de Petrolina foi um pouco diferente, pois na análise em conjunto, a rede R-LSTM/T-CNN superou a combinação das duas melhores redes dos parâmetros meteorológicos (R-LSTM/T-MLP), vide Apêndice 4, sendo assim, definida a R-LSTM/T-CNN para o cálculo da potência na estação de Petrolina para o Experimento B.

A grande diferença apresentada entre o teste padrão e os experimentos A e B é devida a quantidade de amostras utilizadas no teste padrão para cada uma das estações, em comparação com a amostra única dos experimentos. A mesma serviu como base robusta e refinada para selecionar a melhor rede para ambos os testes finais (experimentos) com o WRF-ARW, que por questões de viabilidade computacional e tempo de execução, o mesmo só foi utilizado no teste final.

Além disso, um dos pontos principais dessa pesquisa, é em relação ao tempo para previsão. Uma vez que os modelos estejam treinados, o maior tempo para realizar a inferência foi de 12,28 segundos com a R-LSTM (Experimento B) e o menor tempo com a R-MLP em 1,45 segundo (Experimento A). Em contrapartida, o tempo requerido pelo

WRF-ARW para realizar a previsão, depende do tempo de execução do *spin-up* e do tempo da execução da modelagem em si para a previsão (conforme descrito na Metodologia), o que levou cerca de 506 minutos para se concluir para apenas 48 horas de previsão.

A vantagem do WRF-ARW em comparação com as RNAs é que o mesmo é generalista ao simular todos os aspectos e propriedades físicas do fluido atmosférico de forma integrada para uma grade computacional. Com isso, se calcula vários parâmetros meteorológicos de uma só vez, obtendo assim a temperatura, radiação solar, velocidade e direção do vento, dentre outros, em uma única simulação. A desvantagem, por outro lado, é que se for necessário extrair parâmetros meteorológicos específicos para regiões de interesse específicas, como no caso dos Experimentos A e B, as RNAs se sobressaem por terem um tempo de previsão bem menor e com resultados mais aderentes ao observado, se tornando mais relevantes para esse tipo de situação.

E sobre a operacionalização de redes neurais visando a previsão e geração dos dados meteorológicos para lugares relativamente distantes, o Experimento B demonstrou que, mesmo afastado a 428,41 km do foco do Experimento A, e, por conseguinte, da região contendo os dados utilizados durante o treinamento, as RNAs conseguiram se mostrar aptas para realizar as previsões com baixa perda e alta confiabilidade.

6. CONCLUSÃO

Como apresentado, o objetivo principal deste trabalho que visa desenvolver um modelo computacional robusto baseado em redes neurais profundas para previsão da potência elétrica solar para as próximas 48 horas se demonstrou totalmente viável, principalmente nos quesitos de confiabilidade da previsão, poder computacional e tempo de inferência. Com os testes padrões e os Experimentos A e B, as técnicas de *Deep Learning* demonstraram ser capazes de realizar previsões meteorológicas com boa qualidade, de forma confiável e em um tempo menor em comparação à previsão executada pelo modelo numérico WRF-ARW. Ainda assim, os modelos apresentados podem ter o treinamento e a inferência melhorados ainda mais com o uso de uma ou mais Unidades de Processamento Gráfico (*GPU*).

Em geral, os resultados são otimistas por demonstrarem que as técnicas de aprendizado de máquina, principalmente o modelo MLP, podem superar as técnicas tradicionais de previsão do tempo. Com isso, poderão servir de base para uma futura mudança de paradigma ao utilizar essas técnicas para prever dados meteorológicos específicos a curto e médio prazo, em conjunto com as técnicas de modelagem numérica atmosférica.

Como sugestões de trabalhos futuros, ficam as utilizações de transformadas *wavelets* e uso de *Transformers* para previsão de dados meteorológicos visando à previsão da geração de energia solar fotovoltaica, ainda existindo a possibilidade de expandir um pouco mais além para novas técnicas, i.e., Redes Neurais em Grafos (*Graph Neural Networks* - GNN). Também, outras possibilidades residem no uso e desenvolvimento de técnicas baseadas em aprendizagem de máquina informada pela física (*Physics Informed Machine Learning*).

REFERÊNCIAS

- AID. Brasil termina 2021 com maior acréscimo em potência instalada desde 2016. **Agência Nacional de Energia Elétrica**, 2022. Disponível em: https://www.aneel.gov.br/sala-de-imprensa-exibicao-2/-/asset_publisher/zXQREz8EVIZ6/content/brasil-termina-2021-com-maior-acrescimo-em-potencia-instalada-desde-2016/656877_ Acesso em: 06 jan. 2022.
- ALBAWI, Saad; MOHAMMED, Tareq Abed; AL-ZAWI, Saad. Understanding of a convolutional neural network. **2017 International Conference on Engineering and Technology (ICET)**. Ieee, 2017. p. 1-6.
- ALTHELAYA, Khaled A.; EL-ALFY, El-Sayed M.; MOHAMMED, Salahadin. Evaluation of bidirectional LSTM for short-and long-term stock market prediction. **2018 9th international conference on information and communication systems (ICICS)**. IEEE, 2018. p. 151-156.
- BARRY, Roger G.; CHORLEY, Richard J. **Atmosfera, tempo e clima**. Bookman Editora, 2009. P 1 parágrafo 1.
- BOUCHOUICHA, K. *et al.* ANN-Based Correction Model of Radiation and Temperature for Solar Energy Application in South of Algeria. Em: **International Conference in Artificial Intelligence in Renewable Energetic Systems**. Springer, Cham, 2020. p. 584-591.
- BROWNLEE, JASON. How to Diagnose Overfitting and Underfitting of LSTM Models. **Machine Learning Mastery**, 2017. Disponível em: <https://machinelearningmastery.com/diagnose-overfitting-underfitting-lstm-models/>. Acesso em: 03 fev. 2022.
- CANADIAN SOLAR. CS5A-M-PLUS. **Canadian Solar**, 2021a. Disponível em: https://static.csisolar.com/wp-content/uploads/2020/12/31153518/CS-Datasheet-CS5A-M-PLUS_v1.0_EN-F16.pdf. Acesso em: 20 out. 2021

CANADIAN SOLAR. HiKu CS3L-MS. **Canadian Solar**, 2021b. Disponível em: https://static.csisolar.com/wp-content/uploads/2019/12/07163018/CS-Datasheet-HiKu_CS3L-MS_EN.pdf. Acesso em: 24 out. 2021.

CANADIAN SOLAR. BiHiKu CS3W-MB-AG. **Canadian Solar**, 2021c. Disponível em: https://www.canadiansolar.com/wp-content/uploads/2019/12/Canadian_Solar-Datasheet-BiHiKu_CS3W-MB-AG_EN.pdf. Acesso em: 24 out. 2021.

CANADIAN SOLAR. HiKu7 CS7N-MS. **Canadian Solar**, 2021d. Disponível em: https://static.csisolar.com/wp-content/uploads/2020/10/03101352/CS-Datasheet-HiKu7_CS7N-MS_v2.0_EN.pdf. Acesso em: 26 out. 2021.

CEMTEC - CENTRO DE MONITORAMENTO DO TEMPO E DO CLIMA DE MS. NOTA TÉCNICA No. 001/2011/SEGER/LAIME/CSC/INMET, **Instituto Nacional de Meteorologia**, 2011. Disponível em: http://www.cemtec.ms.gov.br/wp-content/uploads/2019/02/Nota_Tecnica-Rede_estacoes_INMET.pdf. Acesso em: 31 jul. 2021.

CERVONE, Guido *et al.* Short-term photovoltaic power forecasting using Artificial Neural Networks and an Analog Ensemble. **Renewable Energy**, v. 108, p. 274-286, 2017.

CHAOUACHI, Aymen *et al.* Neural network ensemble-based solar power generation short-term forecasting. **World Academy of Science, Engineering and Technology**, v. 54, p. 54-59, 2009.

CHEN, Changsong *et al.* Online 24-h solar power forecasting based on weather type classification using artificial neural network. **Solar energy**, v. 85, n. 11, p. 2856-2870, 2011.

CIULLA, Giuseppina; LO BRANO, Valerio; MORECI, Edoardo. Forecasting the cell temperature of PV modules with an adaptive system. **International Journal of Photoenergy**, v. 2013, 2013.

CLIMATEMPO. Climatologia Ibotirama – BR. **Climatepo**, 2022a. Disponível em: <https://www.climatepo.com.br/climatologia/3518/ibotirama-ba>. Acesso em: 24 jan. 2022.

CLIMATEMPO. Climatologia Petrolina – BR. **Climatempo**, 2022b. Disponível em: <https://www.climatempo.com.br/climatologia/258/petrolina-pe>. Acesso em: 24 jan. 2022.

DA SILVA, Elias F. A geopolítica brasileira para a Antártica: A reconstrução da Estação Antártica Comandante Ferraz como elemento afirmador da importância geopolítica da Antártica para o Brasil. **Escola Naval de Guerra**, 2018. Disponível em: <https://www.marinha.mil.br/egn/sites/www.marinha.mil.br.egn/files/CC%20%28T%29%20Elias%20Ferreira%20da%20Silva%20-%20A%20GEOPOLITICA%20BRASILEIRA%20PARA%20A%20ANTARTICA.pdf> Acesso em: 07 fev. 2021

DATA SCIENCE ACADEMY. **Deep Learning Book**, 2021. Disponível em: <https://www.deeplearningbook.com.br/arquitetura-de-redes-neurais-gated-recurrent-unit-gru/>. Acesso em: 10 jun. 2021.

DIAS, Palmira Maria Acioli; Aylas, Georgynio Yossimar Rosales; Conterato, Flávio Santos; Santos, José Vicente Cardoso; Vieira, Carolina Sacramento; Nascimento, Erick Giovanni Sperandio; Moreira, Davidson Martins ; "ANÁLISE DO POTENCIAL DE ENERGIA SOLAR NO ESTADO DA BAHIA USANDO UMA MODELAGEM COMPUTACIONAL", p. 556-563 . **Anais do V Simpósio Internacional de Inovação e Tecnologia**. São Paulo: Blucher, 2019. ISSN 2357-7592, DOI 10.5151/siintec2019-70

EPE. Matriz Energética e Elétrica. **Empresa de Pesquisa Energética**, 2021. Disponível em: <https://www.epe.gov.br/pt/abcdenergia/matriz-energetica-e-eletrica>. Acesso em: 22 abr. 2021.

ESTIMATIVA POPULACIONAL 2019. **Instituto Brasileiro de Geografia e Estatística (IBGE)**, 2019. Disponível em: <https://cidades.ibge.gov.br/brasil/ba/barra/panorama>. Acesso em: 30 ago. 2019

EVANS, D. L. Simplified method for predicting photovoltaic array output. **Solar energy**, v. 27, n. 6, p. 555-560, 1981.

FILHO, João Inácio da Silva; ABE, Jair Minoro. Fundamentos das Redes Neurais Paraconsistentes. **São Paulo: Arte & Ciência**, 2000. 188 p.

FERRARI, Francesco. **Exploiting the WRF-ARW model for the prediction of flash-floods events over Liguria: a validation strategy and an investigation of the role of the sea surface temperature**. Orientador: Andrea Mazzino. 2016. 120f. Dissertação (Doutorado) - Curso de Engenharia Civil, Química e Ambiental. Escola Politécnica, Universidade de Genova, Itália, 2016. Disponível em: <http://www3.dicca.unige.it/mazzino/Tutoring/pdf/phd-Ferrari.pdf> Acesso em: 06 jan. 2022.

GAO, Bixuan *et al.* Hourly forecasting of solar irradiance based on CEEMDAN and multi-strategy CNN-LSTM neural networks. **Renewable Energy**, v. 162, p. 1665-1683, 2020.

GIL, L. *et al.* Situação do solar térmico em Portugal. **Renov Mag-Rev Técnico-Profissional Energias Renov**, v. 30, p. 48-52, 2017.

GONZÁLEZ, Jaime. Um passeio pelo Vale da Morte, o lugar mais quente do mundo. **BBC NEWS**, 2013. Disponível em: https://www.bbc.com/portuguese/noticias/2013/07/130702_vale_da_morte_bg. Acesso em: 08 jan. 2021

GRIMM, Alice M. **Meteorologia Básica**, 2020. Disponível em: <https://fisica.ufpr.br/grimm/aposmeteo/cap2/cap2-7.html>. Acesso em: 18 out. 2020.

GULLINO, Daniel. Pressionado por ações ambientais, Bolsonaro antecipa para 2050 meta de neutralizar gases poluentes. **O Globo**, 2021. Disponível em: <https://oglobo.globo.com/mundo/pressionado-por-acoes-ambientais-bolsonaro-antecipa-para-2050-meta-de-neutralizar-gases-poluentes-24982244>. Acesso em: 22 abr. 2021.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. Tradução Paulo Martins Engel. 2. ed. **Bookman**, 2008. 898 p.

HUERTAS-TATO, Javier *et al.* A short-term solar radiation forecasting system for the Iberian Peninsula. Part 2: Model blending approaches based on machine learning. **Solar Energy**, v. 195, p. 685-696, 2020.

IBRAHIM, Haider; ANANI, Nader. Variations of PV module parameters with irradiance and temperature. **Energy Procedia**, v. 134, p. 276-285, 2017.

INSTITUTO NACIONAL DE METEOROLOGIA – INMET. **Rede de Estações Meteorológicas Automáticas do INMET**. Brasília: INMET, 2018. 11 p. Nota Técnica no 001/2018/SEGER/LAIME/ CSC/INMET.

IRIART, Paulo Geovani; FISCH, Gilberto. Uso do Modelo WRF-CHEM para a Simulação da Dispersão de Gases no Centro de Lançamento de Alcântara. **Revista Brasileira de Meteorologia**, v. 31, n. 4, p. 610-625, 2016.

IZGI, Ercan *et al.* Short–mid-term solar power prediction by using artificial neural networks. **Solar Energy**, v. 86, n. 2, p. 725-733, 2012.

JAIN, Amit; KAPOOR, Avinashi. Exact analytical solutions of the parameters of real solar cells using Lambert W-function. **Solar Energy Materials and Solar Cells**, v. 81, n. 2, p. 269-277, 2004.

KERAS, Team. Dropout layer. **Keras**, 2021. Disponível em: https://keras.io/api/layers/regularization_layers/dropout. Acesso em: 16 jan 2022.

KOBRAN, Daniel; BENYS, David. Activation Function. **Paperspace.com**, 2021. Disponível em: <https://docs.paperspace.com/machine-learning/wiki/activation-function>. Acesso em: 05 jan 2021.

LEITÃO, Mário de Miranda Vilas Boas Ramos *et al.* Radiação Solar Média Mensal – Estação Petrolina – PE. **Universidade Federal do Vale do São Francisco**, 2019. Disponível em: <http://labmet.univasf.edu.br/joomla/index.php/dados-climaticos/graficos/estacao-petrolina-pe/radiacao-solar>. Acesso em: 21 jan 2021.

Layers of Earth's Atmosphere. **University Corporation of Atmospheric Research**, 2020. Disponível em: <https://scied.ucar.edu/atmosphere-layers>. Acesso em: 12 out. 2020.

LE, Xuan-Hien *et al.* Application of long short-term memory (LSTM) neural network for flood forecasting. **Water**, v. 11, n. 7, p. 1387, 2019.

LIN, Nelson. Sistema Cantareira atinge nível mais baixo dos últimos seis anos, 2021. **Empresa Brasil de Comunicação**.

MANTOVANI, William Amaro. Utilização de Redes Neurais Recorrentes na Caracterização de Cargas Não Lineares em Sistemas Elétricos. Ilha Solteira-SP, 2011. 73 p. Dissertação (Engenharia Elétrica) - **Universidade Estadual Paulista Júlio de Mesquita Filho**.

MELLIT, Adel; PAVAN, Alessandro Massi. A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy. **Solar Energy**, v. 84, n. 5, p. 807-821, 2010.

Mercado de energia elétrica: tudo o que você precisa saber. **CPFL Soluções**, 2020. Disponível em: <https://cpflsolucoes.com.br/mercado-de-energia-eletrica-tudo-o-que-voce-precisa-saber/>. Acesso em: 20 out. 2020.

MinMaxScaler. **Scikit Learn**, 2020. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.MinMaxScaler.html>. Acesso em: 17 ago. 2020.

MISHRA, Mayank. Convolutional Neural Networks, Explained. Towards Data Science, 2020. Disponível em: <https://towardsdatascience.com/convolutional-neural-networks-explained-9cc5188c4939>. Acesso em: 17 jan. 2022.

MONFORT, Eulàlia *et al.* “Bahia Atlas Solar Energy 2018. Atlas Solar Bahia 2018,” Curitiba: Camargo Schubert; Salvador: SECTI, SEINFRA, CIMATEC/SENAI, Brazil, 2018. 76p.

NAGYFI, Richard. The differences between Artificial and Biological Neural Networks. **Towards Data Science**, 2018. Disponível em: <https://towardsdatascience.com/the-differences-between-artificial-and-biological-neural-networks-a8b46db828b7> Acesso em: 18 ago. 2020.

NOTTON, Gilles *et al.* Modelling of a double-glass photovoltaic module using finite differences. **Applied thermal engineering**, v. 25, n. 17-18, p. 2854-2877, 2005.

PINHEIRO, Elisangela; LOVATO, Adalberto; RUTHER, Ricardo. Aplicabilidade de Redes Neurais Artificiais para Análise de Geração de Energia de um Sistema Fotovoltaico Conectado a Rede Elétrica. **Revista Brasileira de Energias Renováveis**, v. 6, n. 5, 2017.

Plano Nacional de Energia – 2030. **Empresa de Pesquisa Energética**, 2021. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-165/topico-175/PNE%202030%20-%20Gera%C3%A7%C3%A3o%20Hidrel%C3%A9trica.pdf> Acesso em: 20 fev. 2021.

POWERS, Jordan *et al.* Weather Research and Forecasting Model. **National Center of Atmospheric Research**, 2020. Disponível em: <https://www.mmm.ucar.edu/weather-research-and-forecasting-model> Acesso em: 18 out. 2020.

QUERINO, Carlos Alexandre Santos *et al.* Estudo da radiação solar global e do índice de transmissividade (kt), externo e interno, em uma floresta de mangue em Alagoas-Brasil. **Revista Brasileira de Meteorologia**, v. 26, p. 204-214, 2011.

RODRÍGUEZ, Fermín *et al.* Predicting solar energy generation through artificial neural networks using weather forecasts for microgrid control. **Renewable Energy**, v. 126, p. 855-864, 2018.

SCHUSTER, Mike; PALIWAL, Kuldip K. Bidirectional recurrent neural networks. **IEEE transactions on Signal Processing**, v. 45, n. 11, p. 2673-2681, 1997.

SCG. Sistema de Informações de Geração da ANEEL – SIGA. **Agência Nacional de Energia Elétrica**, 2020. Disponível em: https://www.aneel.gov.br/siga_ Acesso em: 17 jan. 2022.

SHARP, Tim. What Is Earth's Average Temperature? **Space.com**, 2018. Disponível em: <https://www.space.com/17816-earth-temperature.html>. Acesso em: 17 ago. 2020.

SKAMAROCK, William C. *et al.* A description of the advanced research WRF version 2. **National Center For Atmospheric Research Boulder Co Mesoscale and Microscale Meteorology Div**, 2005.

SPARK, Weather. Clima e condições meteorológicas médias em Ibotirama no ano todo Brasil. **Weather Spark**, 2022. Disponível em: <https://pt.weatherspark.com/y/30628/Clima-caracter%C3%ADstico-em-Ibotirama-Brasil-durante-o-ano>. Acesso em: 24 jan. 2022.

STEHLY, Tyler; HEIMILLER, Donna; SCOTT, George. 2016 Cost of Wind Energy Review. **National Renewable Energy Laboratory**, 2016. Disponível em: <https://www.nrel.gov/docs/fy18osti/70363.pdf>. Acesso em: 09 mar 2021.

STULL, Roland B. **An introduction to boundary layer meteorology**. Springer Science & Business Media, 1988.

TIBA, Chigueru *et al.* Atlas Solarimétrico do Brasil. Ed. **Universitária da UFPE**, 2000. Disponível em: http://www.cresesb.cepel.br/publicacoes/download/atlas_solarimetrico_do_brasil_2000.pdf. Acesso em: 17 jan. 2022.

VAREJÃO-SILVA, Mario Adelmo. **Meteorologia e climatologia**. Brasília: INMET, 2000.

WANG, Kang *et al.* Multiple convolutional neural networks for multivariate time series prediction. **Neurocomputing**, v. 360, p. 107-119, 2019.

WILLIAMS, David R. Earth Fact Sheet. **National Aeronautics and Space Administration**, 2020. Disponível em: <https://nssdc.gsfc.nasa.gov/planetary/factsheet/earthfact.html>. Acesso em: 17 out. 2020.

YANG, Renata Lautert *et al.* Photovoltaic Cell Temperature Estimation for a Grid-Connect Photovoltaic Systems in Curitiba. **Brazilian Archives of Biology and Technology**, v. 62, n. SPE, 2019.

ZHAO, Rui *et al.* Machine health monitoring using local feature-based gated recurrent unit networks. **IEEE Transactions on Industrial Electronics**, v. 65, n. 2, p. 1539-1548, 2017.

PRODUÇÃO TÉCNICA E CIENTÍFICA

Dias, Palmira Maria Acioli; Aylas, Georgynio Yossimar Rosales; Conterato, Flávio Santos; Santos, José Vicente Cardoso; Vieira, Carolina Sacramento; Nascimento, Erick Giovani Sperandio; Moreira, Davidson Martins. "ANÁLISE DO POTENCIAL DE ENERGIA SOLAR NO ESTADO DA BAHIA USANDO UMA MODELAGEM COMPUTACIONAL", p. 556-563 . **Anais do V Simpósio Internacional de Inovação e Tecnologia**. São Paulo: Blucher, 2019. ISSN 2357-7592, DOI 10.5151/siintec2019-70

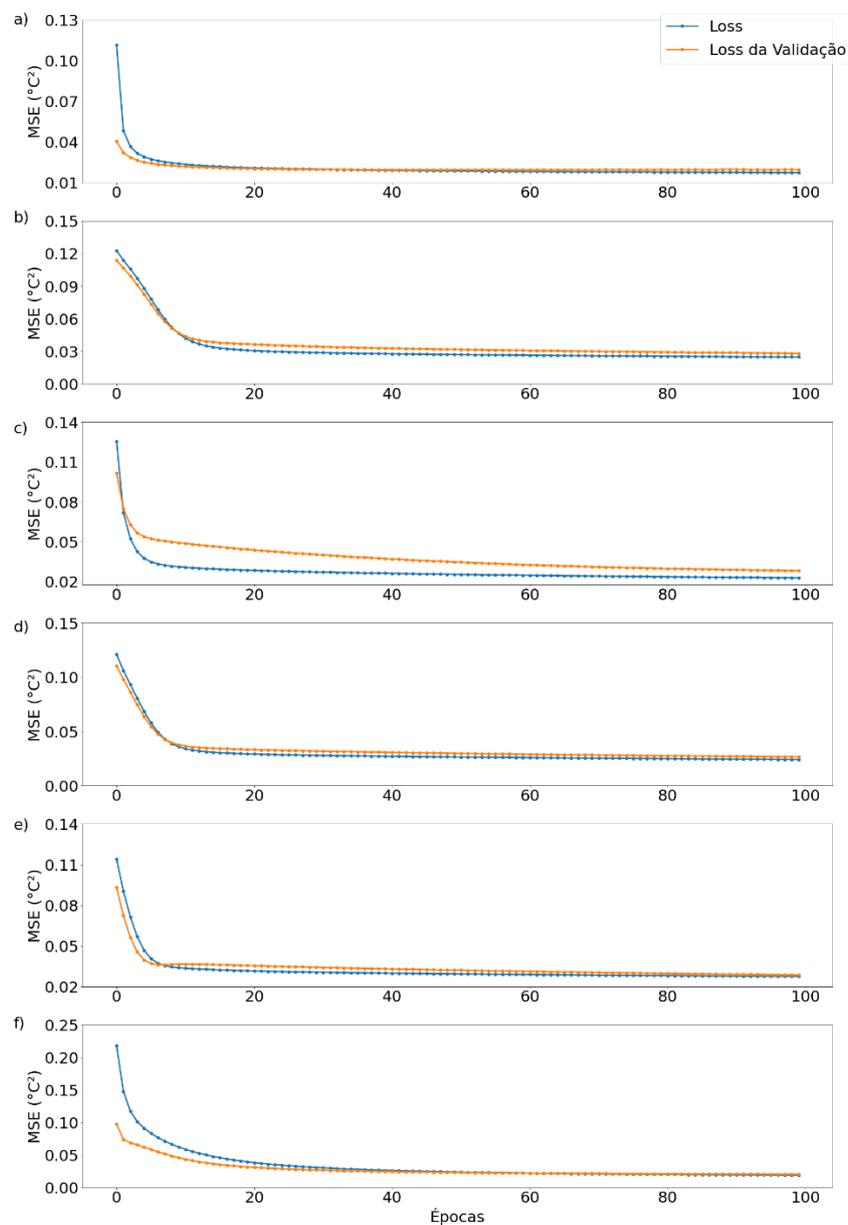
Conterato, Flavio Santos; Moraes, Caique Augusto Cardoso de; Pabst, Grhamm; Caldas, João Felipe de Araújo; Souza, Matheus Carvalho Nascimento de; Moreira, Davidson Martins; Nascimento, Erick Giovani Sperandio. "COMPARISON OF SHORT-TERM TEMPERATURE FORECASTING BETWEEN ARTIFICIAL NEURAL NETWORK AND MACHINE LEARNING.", p. 535-542 . **Anais do VI Simpósio Internacional de Inovação e Tecnologia**. São Paulo: Blucher, 2020. ISSN 2357-7592, ISBN: 2357-7592 DOI 10.5151/siintec2020-COMPARISONOFSHORT-TERM

Teixeira, Rafael Silva; Conterato, Flávio Santos; Dias, Palmira Maria Acioli; Kitagawa, Yasmin Kaore Lago; Moreira, Davidson Martins; Nascimento, Erick Giovani Sperandio. "HYBRID MODEL OF WIND SPEED PREDICTION IN SHORT TIME RANGE USING WRF AND ARTIFICIAL NEURAL NETWORKS", p. 617-625 . **Anais do VI Simpósio Internacional de Inovação e Tecnologia**. São Paulo: Blucher, 2020. ISSN 2357-7592, ISBN: 2357-7592 DOI 10.5151/siintec2020-HYBRIDMODEL

APÊNDICE 1 – ANÁLISE DE LOSS DAS REDES

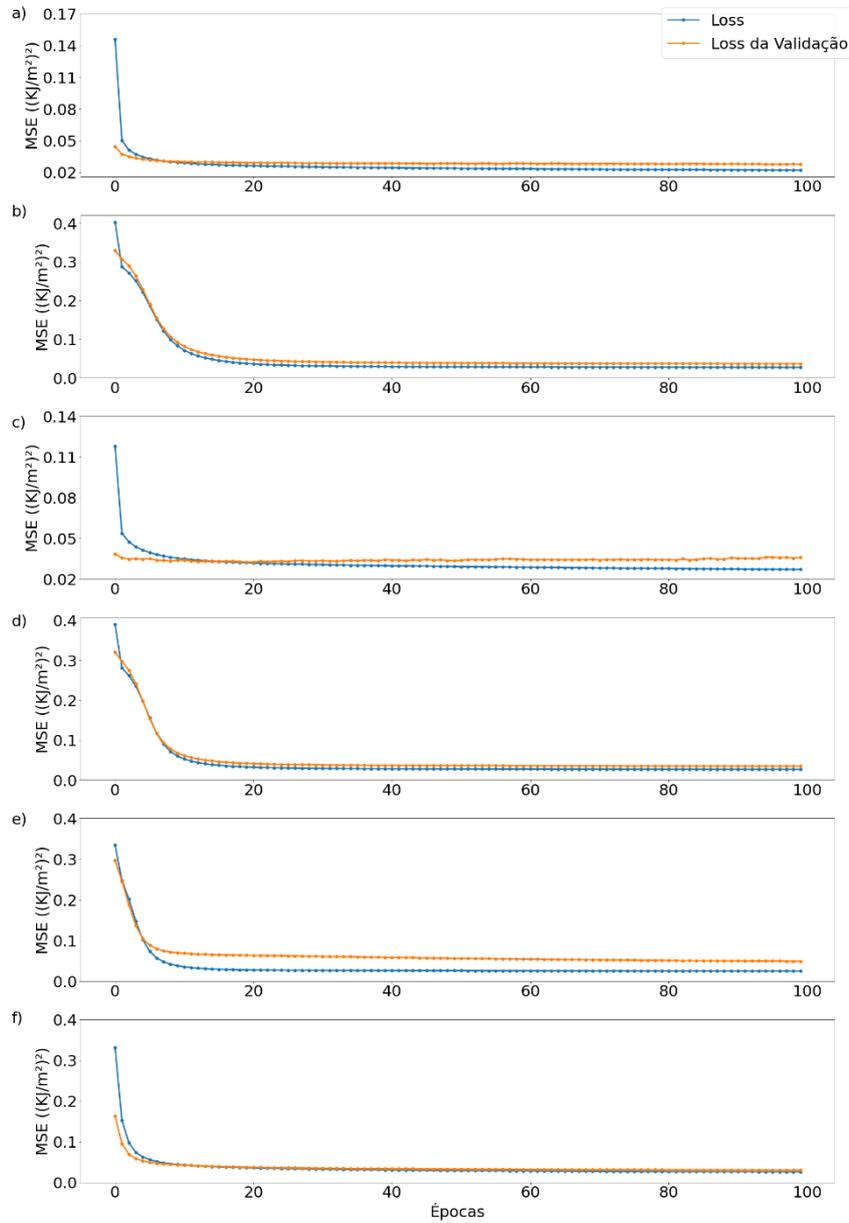
As Figuras 1 e 2 deste apêndice servem como análise qualitativa para verificar se houve *overfitting* ou *underfitting* de cada modelo. É possível verificar que todas as redes não apresentaram nenhum dos dois comportamentos, sendo, portanto, validadas para prosseguir com a inferência de teste.

Figura 1 do Apêndice 1 – Análise qualitativa das perdas (*loss*) do treinamento e validação para previsão da temperatura a) MLP perda em MSE ($^{\circ}\text{C}^2$) b) LSTM perda em MSE ($^{\circ}\text{C}^2$) c) GRU perda em MSE ($^{\circ}\text{C}^2$) d) BiLSTM perda em MSE ($^{\circ}\text{C}^2$) e) FCN+LSTM perda em MSE ($^{\circ}\text{C}^2$) f) CNN perda em MSE ($^{\circ}\text{C}^2$)



Fonte: Elaborada pelo autor.

Figura 2 do Apêndice 1 – Análise qualitativa das perdas (*loss*) do treinamento e validação para previsão da radiação solar a) MLP perda em MSE ((KJ/m²)²) b) LSTM perda em MSE ((KJ/m²)²) c) GRU perda em MSE ((KJ/m²)²) d) BiLSTM perda em MSE ((KJ/m²)²) e) FCN+LSTM perda em MSE ((KJ/m²)²) f) CNN perda em MSE ((KJ/m²)²)

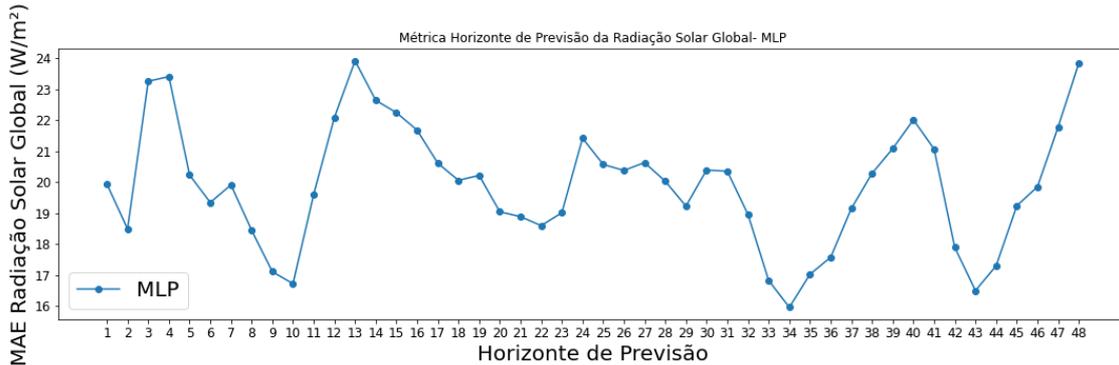


Fonte: Elaborada pelo autor.

APÊNDICE 2 – MÉTRICAS NO HORIZONTE DE PREVISÃO PARA RADIAÇÃO SOLAR GLOBAL E TEMPERATURA – TESTE PADRÃO

As figuras apresentadas nesse Apêndice visam mostrar as métricas no horizonte de previsão dos modelos. Essa métricas foram baseadas com 48 amostras distintas e realizadas as suas respectivas médias, evitando assim um enviesamento do horizonte de previsão, i.e., com um horário noturno e sem radiação solar global. Os valores da radiação solar global foram convertidos de KJ/m^2 para W/m^2 .

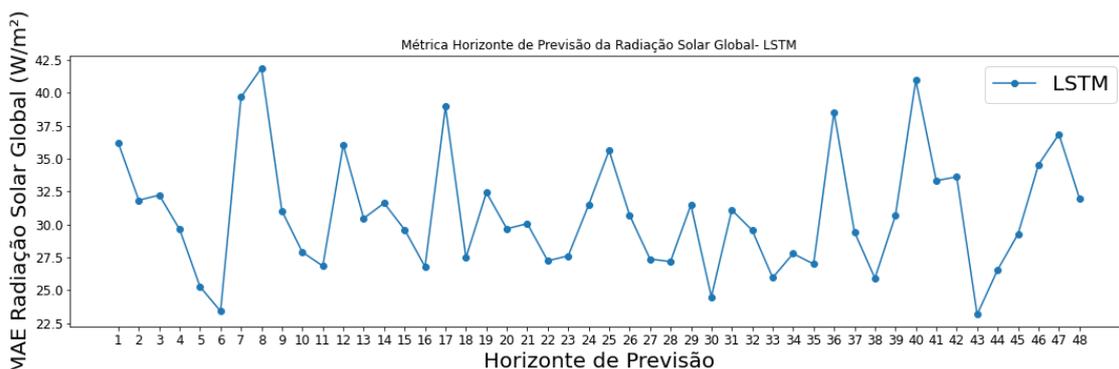
Figura 1 do Apêndice 2 – Métrica no Horizonte de previsão da radiação solar global (W/m^2) da rede MLP



Fonte: Elaborada pelo autor.

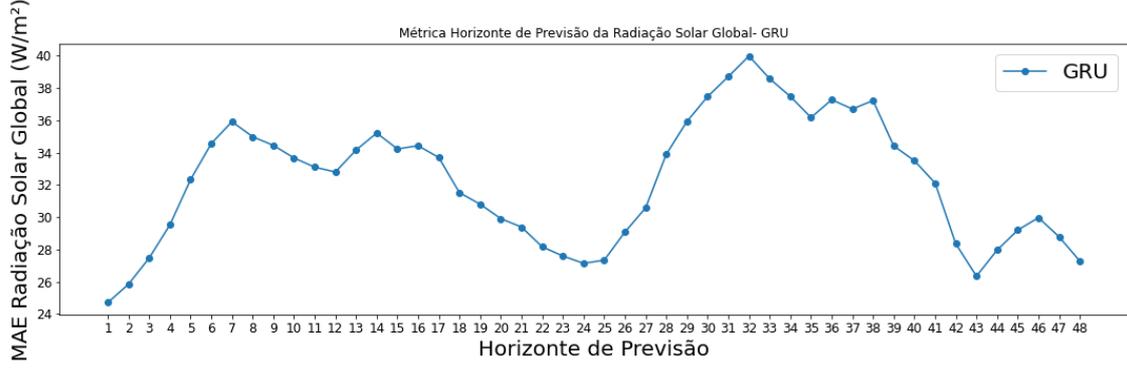
Figura 2 do Apêndice 2 – Métrica no Horizonte de previsão da radiação solar global (W/m^2) da rede

LSTM



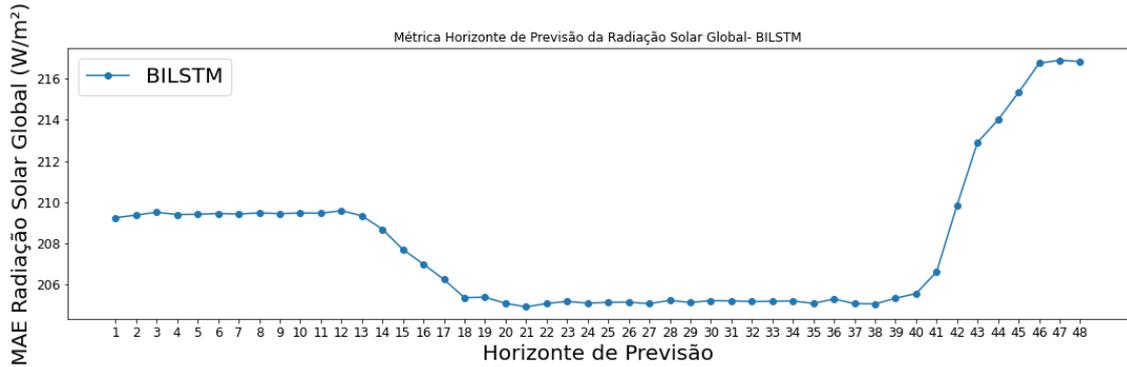
Fonte: Elaborada pelo autor.

Figura 3 do Apêndice 2 – Métrica no Horizonte de previsão da radiação solar global (W/m^2) da rede GRU



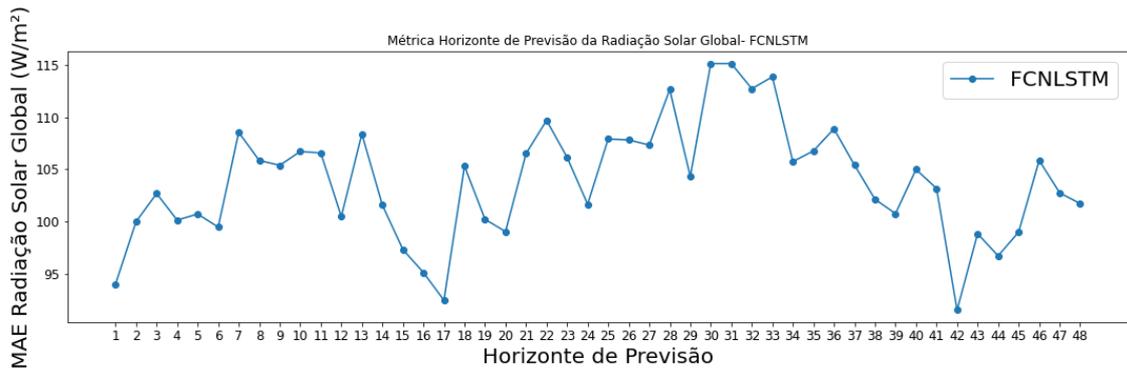
Fonte: Elaborada pelo autor.

Figura 4 do Apêndice 2 – Métrica no Horizonte de previsão da radiação solar global (W/m^2) da rede BiLSTM



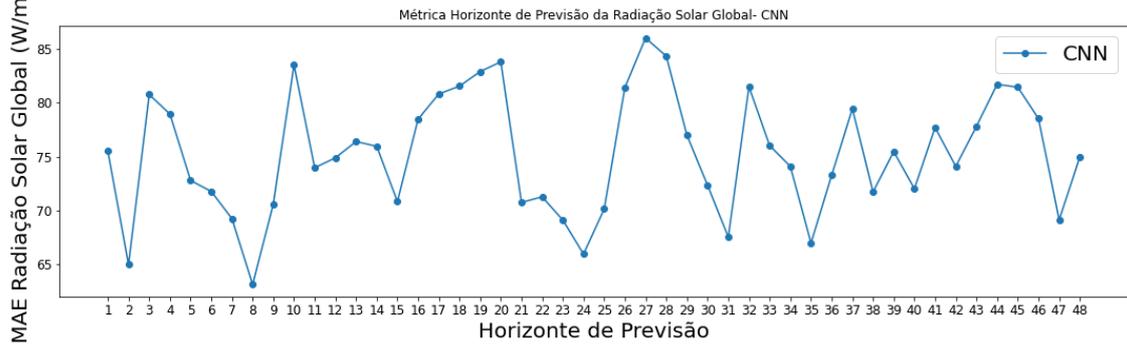
Fonte: Elaborada pelo autor.

Figura 5 do Apêndice 2 – Métrica no Horizonte de previsão da radiação solar global (W/m^2) da rede FCN + LSTM



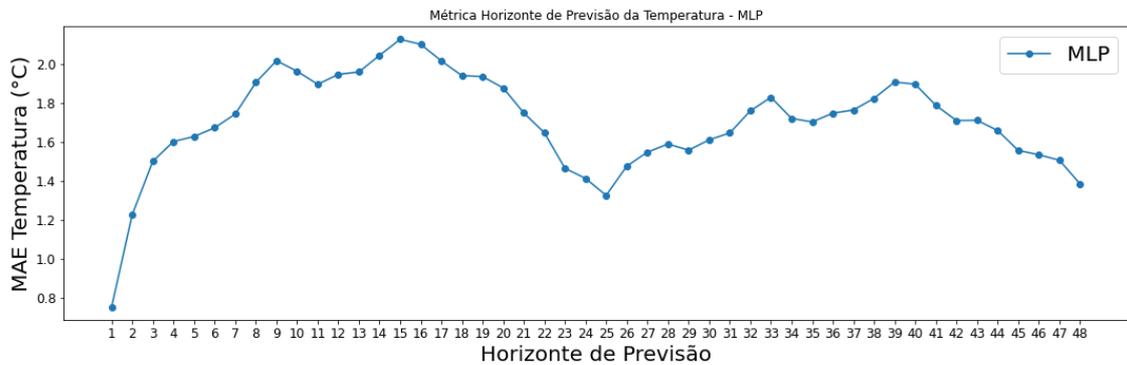
Fonte: Elaborada pelo autor.

Figura 6 do Apêndice 2 – Métrica no Horizonte de previsão da radiação solar global (W/m^2) da rede CNN



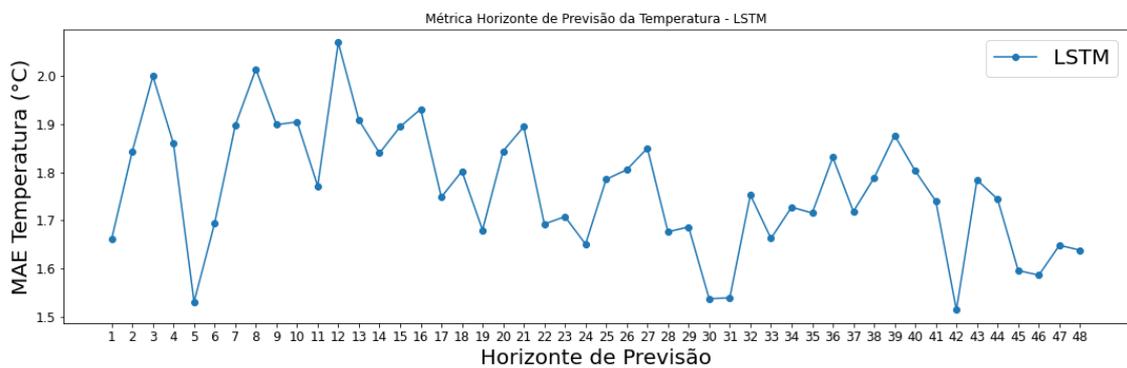
Fonte: Elaborada pelo autor.

Figura 7 do Apêndice 2 – Métrica no Horizonte de previsão da temperatura bulbo seco ($^{\circ}C$) da rede MLP



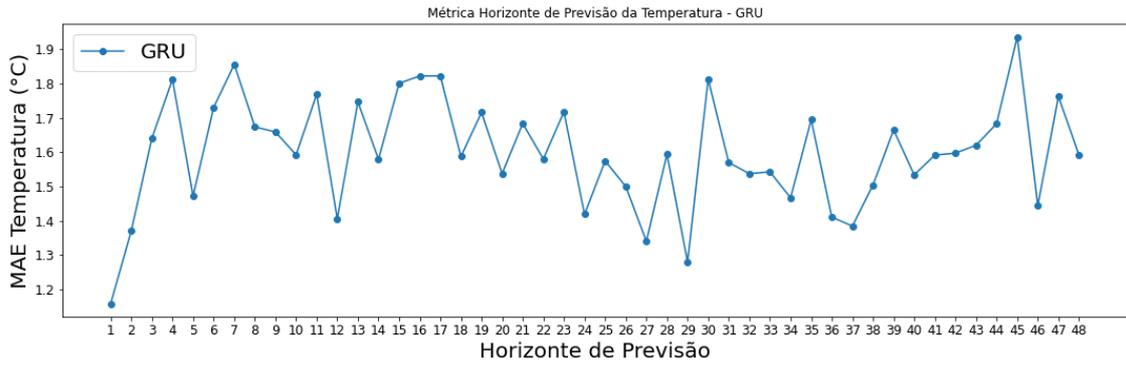
Fonte: Elaborada pelo autor.

Figura 8 do Apêndice 2 – Métrica no Horizonte de previsão da temperatura bulbo seco ($^{\circ}C$) da rede LSTM



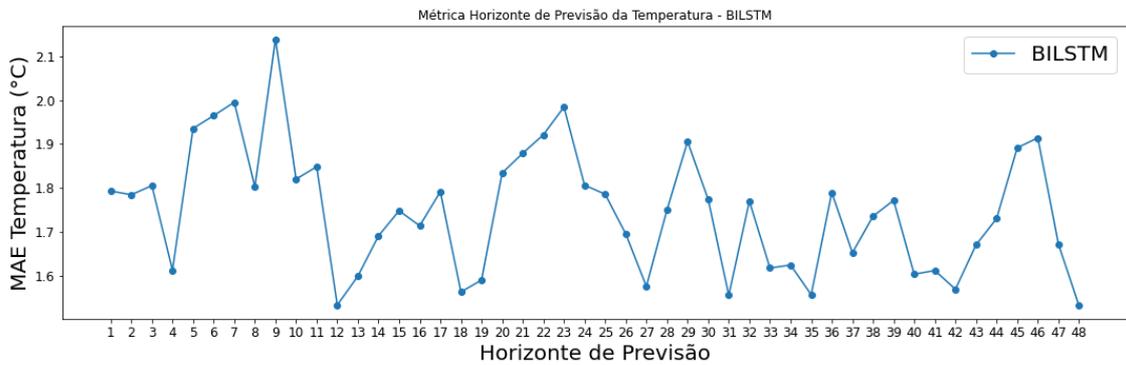
Fonte: Elaborada pelo autor.

Figura 9 do Apêndice 2 – Métrica no Horizonte de previsão da temperatura bulbo seco (°C) da rede GRU



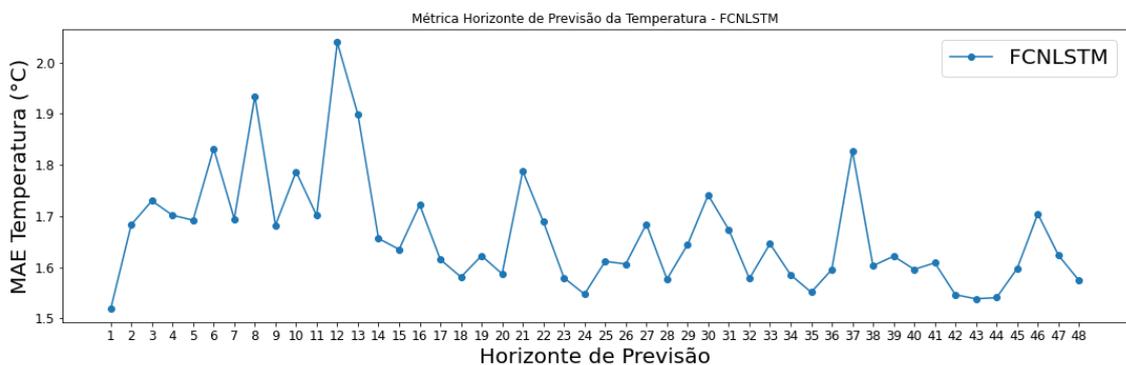
Fonte: Elaborada pelo autor.

Figura 10 do Apêndice 2 – Métrica no Horizonte de previsão da temperatura bulbo seco (°C) da rede BiLSTM



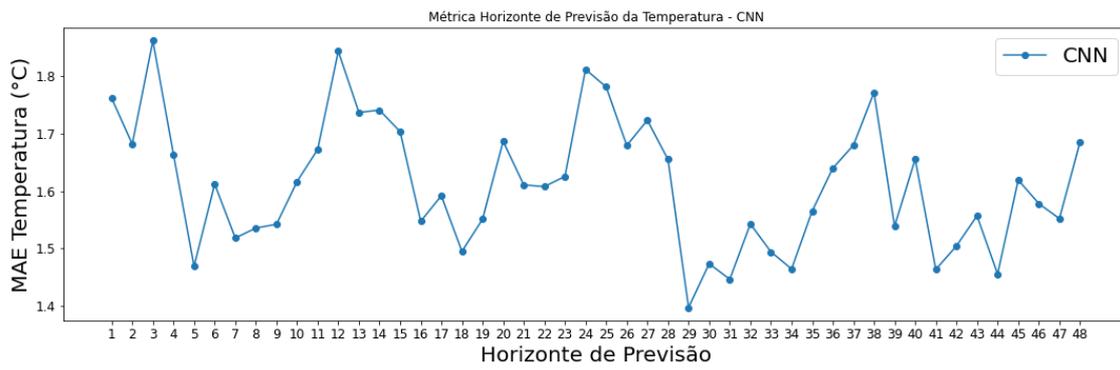
Fonte: Elaborada pelo autor.

Figura 11 do Apêndice 2 – Métrica no Horizonte de previsão da temperatura bulbo seco (°C) da rede MLP



Fonte: Elaborada pelo autor.

Figura 12 do Apêndice 2 – Métrica no Horizonte de previsão da temperatura bulbo seco (°C) da rede MLP



Fonte: Elaborada pelo autor.

APÊNDICE 3 – TESTE PADRÃO IBOTIRAMA

As tabelas apresentadas nesse apêndice mostram a comparação entre todas as configurações de redes neurais para cada uma das placas solares para a estação de Ibotirama, conforme o teste padrão realizado nos “Resultados e Discussão”. Em destaque, a melhor rede pela análise multivariada das métricas para todas as tabelas abaixo.

PLACA DE BAIXA POTÊNCIA – 200W

Tabela 1 do Apêndice 3 – Métricas da potência da placa de baixa potência (200W)

Configuração	MAE	RMSE	r	R^2
R-MLP/T-MLP	10,149	17,5921	0,9267	0,8563
R-MLP/T-LSTM	10,2722	17,8039	0,926	0,8551
R-MLP/T-BiLSTM	10,2712	17,8013	0,926	0,8551
R-MLP/T-FCN+LSTM	10,2702	17,7984	0,926	0,8552
R-MLP/T-GRU	10,2712	17,8014	0,926	0,8551
R-MLP/T-CNN	10,2723	17,8012	0,9259	0,8551
R-LSTM/T-MLP	22,9725	37,6998	0,6594	0,3027
R-LSTM/T-LSTM	22,699	37,2724	0,6601	0,3031
R-LSTM/T-BiLSTM	22,6928	37,2621	0,66	0,3035
R-LSTM/T-FCN+LSTM	22,6838	37,2498	0,6601	0,3039
R-LSTM/T-GRU	17,1645	33,2239	0,7285	0,4843
R-LSTM/T-CNN	17,1601	33,1812	0,7285	0,4856
R-FCN+LSTM/T-MLP	24,7187	41,085	0,6931	0,2224
R-FCN+LSTM/T-LSTM	24,6678	40,9559	0,6932	0,2163
R-FCN+LSTM/T-BiLSTM	24,653	40,935	0,6932	0,2171
R-FCN+LSTM/T-FCNLSTM	24,653	40,9325	0,6931	0,2172
R-FCN+LSTM/T-GRU	24,6563	40,9417	0,693	0,2168
R-FCN+LSTM/T-CNN	24,5584	40,8082	0,6931	0,2219
R-GRU/T-MLP	17,0059	33,3275	0,737	0,4883
R-GRU/T-LSTM	16,9091	33,1307	0,7371	0,4871
R-GRU/T-BiLSTM	16,9042	33,1212	0,737	0,4874
R-GRU/T-FCN+LSTM	16,9025	33,1164	0,7371	0,4876
R-GRU/T-GRU	16,9037	33,1144	0,737	0,4877
R-GRU/T-CNN	16,878	33,0689	0,737	0,4891
R-CNN/T-MLP	21,2181	36,289	0,6916	0,3934
R-CNN/T-LSTM	21,1197	36,1041	0,6918	0,391
R-CNN/T-BiLSTM	21,1145	36,0944	0,6918	0,3913
R-CNN/T-FCN+LSTM+LSTM	21,1156	36,0936	0,6917	0,3913
R-CNN/T-GRU	21,1224	36,0989	0,6916	0,3911
R-CNN/T-CNN	21,0737	36,0217	0,6919	0,3937

Fonte: Elaborada pelo autor.

PLACA DE MÉDIA POTÊNCIA – 360W

Tabela 2 do Apêndice 3 – Métricas da potência da placa de média potência (360W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-MLP/T-MLP	19,4592	33,7305	0,9268	0,8565
R-MLP/T-LSTM	19,7876	34,2865	0,9259	0,8549
R-MLP/T-BiLSTM	19,785	34,2796	0,9259	0,855
R-MLP/T-FCN+LSTMLSTM	19,7824	34,2717	0,9259	0,8551
R-MLP/T-GRU	19,7853	34,2803	0,9259	0,855
R-MLP/T-CNN	19,7891	34,2809	0,9258	0,855
R-LSTM/T-MLP	44,2694	72,6374	0,6596	0,3029
R-LSTM/T-LSTM	43,5312	71,4829	0,6605	0,3035
R-LSTM/T-BiLSTM	43,5148	71,4559	0,6605	0,304
R-LSTM/T-	43,4912	71,4236	0,6606	0,3046
R-LSTM/T-GRU	32,9366	63,7628	0,7285	0,4839
R-LSTM/T-CNN	32,9243	63,6494	0,7285	0,4857
R-FCN+LSTM/T-MLP	47,5778	79,0794	0,693	0,222
R-FCN+LSTM/T-LSTM	47,4371	78,7237	0,6931	0,2133
R-FCN+LSTM/T-	47,3969	78,667	0,6931	0,2144
R-FCN+LSTM/T-	47,3967	78,6607	0,693	0,2146
R-FCN+LSTM/T-GRU	47,4067	78,6868	0,6927	0,214
R-FCN+LSTM/T-CNN	47,1436	78,3281	0,693	0,2212
R-GRU/T-MLP	32,728	64,1338	0,737	0,4883
R-GRU/T-LSTM	32,4652	63,5984	0,7371	0,4866
R-GRU/T-BiLSTM	32,4518	63,5729	0,7371	0,487
R-GRU/T-FCN+LSTM	32,447	63,5601	0,7371	0,4872
R-GRU/T-GRU	32,4504	63,5549	0,737	0,4873
R-GRU/T-CNN	32,3809	63,4346	0,737	0,4892
R-CNN/T-MLP	40,8388	69,8446	0,6915	0,3931
R-CNN/T-LSTM	40,5715	69,3414	0,6917	0,3896
R-CNN/T-BiLSTM	40,5571	69,3149	0,6917	0,3901
R-CNN/T-FCN+LSTM	40,5602	69,3128	0,6916	0,3901
R-CNN/T-GRU	40,5787	69,3276	0,6914	0,3899
R-CNN/T-CNN	40,4468	69,1204	0,6918	0,3935

Fonte: Elaborada pelo autor.

PLACA DE ALTA POTÊNCIA – 420W

Tabela 3 do Apêndice 3 – Métricas da potência da placa de alta potência (420W)

Configuração	MAE	RMSE	<i>r</i>	<i>R</i> ²
R-MLP/T-MLP	21,3345	36,9798	0,9266	0,8563
R-MLP/T-LSTM	21,5543	37,3616	0,926	0,8552
R-MLP/T-BiLSTM	21,5524	37,357	0,926	0,8552
R-MLP/T-FCN+LSTM	21,5509	37,3518	0,9261	0,8553
R-MLP/T-GRU	21,5524	37,3569	0,926	0,8552
R-MLP/T-CNN	21,5539	37,3558	0,926	0,8552
R-LSTM/T-MLP	48,2	79,1036	0,6594	0,3027

R-LSTM/T-LSTM	47,7155	78,3468	0,6599	0,303
R-LSTM/T-BiLSTM	47,704	78,3281	0,6599	0,3034
R-LSTM/T-FCN+LSTM	47,6876	78,3056	0,66	0,3038
R-LSTM/T-GRU	36,0744	69,8218	0,7285	0,4844
R-LSTM/T-CNN	36,0671	69,7447	0,7285	0,4855
R-FCN+LSTM/T-MLP	51,8851	86,2369	0,6932	0,2228
R-FCN+LSTM/T-LSTM	51,7975	86,0129	0,6933	0,2176
R-FCN+LSTM/T-BiLSTM	51,7714	85,976	0,6933	0,2182
R-FCN+LSTM/T-FCN+LSTM	51,7712	85,9715	0,6932	0,2183
R-FCN+LSTM/T-GRU	51,7766	85,987	0,6931	0,218
R-FCN+LSTM/T-CNN	51,6019	85,749	0,6932	0,2224
R-GRU/T-MLP	35,7007	69,966	0,737	0,4884
R-GRU/T-LSTM	35,5302	69,6204	0,7371	0,4874
R-GRU/T-BiLSTM	35,5217	69,6032	0,7371	0,4876
R-GRU/T-FCN+LSTM	35,5186	69,5945	0,7371	0,4878
R-GRU/T-GRU	35,5207	69,5907	0,737	0,4878
R-GRU/T-CNN	35,4748	69,5084	0,737	0,489
R-CNN/T-MLP	44,5409	76,1775	0,6917	0,3935
R-CNN/T-LSTM	44,3677	75,853	0,6919	0,3915
R-CNN/T-BiLSTM	44,3588	75,8359	0,6918	0,3918
R-CNN/T-FCN+LSTM	44,3608	75,8344	0,6918	0,3918
R-CNN/T-GRU	44,3727	75,8434	0,6917	0,3916
R-CNN/T-CNN	44,2862	75,7056	0,6919	0,3939

Fonte: Elaborada pelo autor.

PLACA INDUSTRIAL – 670W

Tabela 4 do Apêndice 3 – Métricas da potência da placa industrial (670W)

Configuração	MAE	RMSE	r	R^2
R-MLP/T-MLP	33,8702	58,7177	0,9267	0,8564
R-MLP/T-LSTM	34,5219	59,8151	0,9258	0,8547
R-MLP/T-BiLSTM	34,5169	59,8016	0,9258	0,8547
R-MLP/T-FCN+LSTM	34,5114	59,7861	0,9258	0,8548
R-MLP/T-GRU	34,5184	59,8041	0,9258	0,8547
R-MLP/T-CNN	34,5278	59,8088	0,9257	0,8547
R-LSTM/T-MLP	77,2131	126,6984	0,6594	0,3027
R-LSTM/T-LSTM	75,75	124,4071	0,6605	0,3033
R-LSTM/T-BiLSTM	75,7189	124,3558	0,6604	0,3039
R-LSTM/T-FCN+LSTM	75,6741	124,2942	0,6606	0,3046
R-LSTM/T-GRU	57,3205	110,9786	0,7284	0,4836
R-LSTM/T-CNN	57,2947	110,7599	0,7284	0,4857
R-FCN+LSTM/T-MLP	82,9587	137,8993	0,6928	0,221
R-FCN+LSTM/T-LSTM	82,6696	137,1742	0,6929	0,2111
R-FCN+LSTM/T-BiLSTM	82,5893	137,0613	0,6929	0,2124
R-FCN+LSTM/T-FCN+LSTM	82,5894	137,0495	0,6928	0,2126
R-FCN+LSTM/T-GRU	82,6114	137,1044	0,6925	0,2119
R-FCN+LSTM/T-CNN	82,0947	136,3986	0,6928	0,22
R-GRU/T-MLP	57,0406	111,7757	0,7369	0,4882

R-GRU/T-LSTM	56,5144	110,7022	0,737	0,4862
R-GRU/T-BiLSTM	56,4878	110,6526	0,737	0,4867
R-GRU/T-FCN+LSTM	56,4782	110,6281	0,737	0,4869
R-GRU/T-GRU	56,4856	110,6187	0,7369	0,487
R-GRU/T-CNN	56,3497	110,3876	0,7369	0,4891
R-CNN/T-MLP	71,1825	121,744	0,6914	0,3928
R-CNN/T-LSTM	70,6475	120,7341	0,6915	0,3889
R-CNN/T-BiLSTM	70,6183	120,6814	0,6915	0,3894
R-CNN/T-FCN+LSTM	70,6242	120,6772	0,6914	0,3895
R-CNN/T-GRU	70,6615	120,7082	0,6912	0,3891
R-CNN/T-CNN	70,4005	120,3017	0,6916	0,3932

Fonte: Elaborada pelo autor.

APÊNDICE 4 – TESTE PADRÃO PETROLINA

As tabelas apresentadas nesse apêndice mostram a comparação entre todas as combinações de redes neurais para cada uma das placas solares para a estação de Petrolina no teste padrão, apresentado na seção “Resultados e Discussão”. Em destaque, a melhor rede pela análise multivariada das métricas.

PLACA DE BAIXA POTÊNCIA – 200W

Tabela 1 do Apêndice 4 – Métricas da potência da placa de baixa potência (200W)

Configuração	MAE	RMSE	r	R^2
R-MLP/T-MLP	14,8847	25,3902	0,9275	0,4829
R-MLP/T-LSTM	14,989	25,6084	0,9273	0,4803
R-MLP/T-BiLSTM	14,9999	25,6276	0,9273	0,4795
R-MLP/T-FCN+LSTM	14,9897	25,6122	0,9273	0,4802
R-MLP/T-GRU	14,977	25,5916	0,9273	0,481
R-MLP/T-CNN	15,0404	25,6885	0,9273	0,4771
R-LSTM/T-MLP	11,584	19,7546	0,9268	0,6943
R-LSTM/T-LSTM	11,4519	19,52	0,9271	0,6956
R-LSTM/T-BiLSTM	11,4535	19,5221	0,9271	0,6956
R-LSTM/T-FCN+LSTM	11,4333	19,4908	0,9271	0,6965
R-LSTM/T-GRU	11,4306	19,4878	0,927	0,6966
R-LSTM/T-CNN	11,3827	19,4087	0,9272	0,6991
R-FCN+LSTM/T-MLP	20,3745	32,3293	0,8351	0,1811
R-FCN+LSTM/T-LSTM	20,2347	32,1078	0,8346	0,1765
R-FCN+LSTM/T-BiLSTM	20,2407	32,1186	0,8346	0,176
R-FCN+LSTM/T-FCN+LSTM	20,215	32,0755	0,8346	0,1782
R-FCN+LSTM/T-GRU	20,2148	32,0826	0,8344	0,1778
R-FCN+LSTM/T-CNN	20,16	31,9883	0,8345	0,1826
R-GRU/T-MLP	11,9308	20,9487	0,9015	0,6562
R-GRU/T-LSTM	11,804	20,7222	0,9017	0,657
R-GRU/T-BiLSTM	11,8029	20,7207	0,9018	0,657
R-GRU/T-FCN+LSTM	11,7894	20,6967	0,9018	0,6578
R-GRU/T-GRU	11,7841	20,688	0,9017	0,6581
R-GRU/T-CNN	11,7403	20,6112	0,9019	0,6607
R-CNN/T-MLP	19,5601	32,4086	0,839	0,1771
R-CNN/T-LSTM	19,4037	32,1548	0,8391	0,1741
R-CNN/T-BiLSTM	19,4065	32,1623	0,8391	0,1737
R-CNN/T-FCN+LSTM	19,3832	32,1197	0,8391	0,1759
R-CNN/T-GRU	19,3805	32,1219	0,8389	0,1758
R-CNN/T-CNN	19,3186	32,0165	0,8391	0,1812

Fonte: Elaborada pelo autor.

PLACA DE MÉDIA POTÊNCIA – 360W

Tabela 2 do Apêndice 4 – Métricas da potência da placa de média potência (360W)

Configuração	MAE	RMSE	r	R^2
R-MLP/T-MLP	28,5718	48,7114	0,9276	0,4839
R-MLP/T-LSTM	28,8525	49,298	0,9274	0,4802
R-MLP/T-BiLSTM	28,8823	49,3506	0,9273	0,4791
R-MLP/T-FCN+LSTM	28,8544	49,3079	0,9273	0,48
R-MLP/T-GRU	28,8193	49,2515	0,9273	0,4812
R-MLP/T-CNN	28,9939	49,5184	0,9273	0,4756
R-LSTM/T-MLP	22,3362	38,0903	0,9269	0,6942
R-LSTM/T-LSTM	21,9763	37,4517	0,9273	0,6962
R-LSTM/T-BiLSTM	21,9806	37,4572	0,9272	0,6961
R-LSTM/T-FCN+LSTM	21,9265	37,3735	0,9273	0,6974
R-LSTM/T-GRU	21,9201	37,3663	0,9271	0,6975
R-LSTM/T-CNN	21,7932	37,1572	0,9274	0,7009
R-FCN+LSTM/T-MLP	39,2572	62,293	0,8353	0,182
R-FCN+LSTM/T-LSTM	38,8757	61,6885	0,8347	0,1756
R-FCN+LSTM/T-BiLSTM	38,8916	61,7173	0,8345	0,1749
R-FCN+LSTM/T-FCN+LSTM	38,8224	61,601	0,8347	0,178
R-FCN+LSTM/T-GRU	38,8227	61,6215	0,8343	0,1774
R-FCN+LSTM/T-CNN	38,6773	61,3708	0,8345	0,1841
R-GRU/T-MLP	22,9998	40,3843	0,9016	0,6562
R-GRU/T-LSTM	22,6551	39,7681	0,902	0,6574
R-GRU/T-BiLSTM	22,6522	39,764	0,902	0,6575
R-GRU/T-FCN+LSTM	22,6159	39,6995	0,902	0,6586
R-GRU/T-GRU	22,6021	39,6772	0,9019	0,659
R-GRU/T-CNN	22,4861	39,4734	0,9021	0,6625
R-CNN/T-MLP	37,6963	62,4544	0,8391	0,1778
R-CNN/T-LSTM	37,2696	61,7617	0,8393	0,1737
R-CNN/T-BiLSTM	37,2771	61,7819	0,8392	0,1731
R-CNN/T-FCN+LSTM	37,2144	61,6671	0,8393	0,1762
R-CNN/T-GRU	37,2078	61,674	0,839	0,176
R-CNN/T-CNN	37,0434	61,3936	0,8393	0,1835

Fonte: Elaborada pelo autor.

PLACA DE ALTA POTÊNCIA – 420W

Tabela 3 do Apêndice 4 – Métricas da potência da placa de alta potência (420W)

Configuração	MAE	RMSE	r	R^2
R-MLP/T-MLP	31,2729	53,3533	0,9275	0,483
R-MLP/T-LSTM	31,4584	53,7416	0,9273	0,4808
R-MLP/T-BiLSTM	31,4775	53,7752	0,9273	0,4802
R-MLP/T-FCN+LSTM	31,4599	53,7484	0,9273	0,4807
R-MLP/T-GRU	31,4377	53,7127	0,9273	0,4814

R-MLP/T-CNN	31,5478	53,8805	0,9273	0,4781
R-LSTM/T-MLP	24,2997	41,4352	0,9268	0,6945
R-LSTM/T-LSTM	24,0676	41,0232	0,9271	0,6956
R-LSTM/T-BiLSTM	24,0706	41,027	0,927	0,6955
R-LSTM/T-FCN+LSTM	24,0344	40,9709	0,9271	0,6964
R-LSTM/T-GRU	24,0292	40,9649	0,927	0,6965
R-LSTM/T-CNN	23,9425	40,822	0,9271	0,6986
R-FCN+LSTM/T-MLP	42,7497	67,828	0,835	0,1813
R-FCN+LSTM/T-LSTM	42,5049	67,4404	0,8347	0,1773
R-FCN+LSTM/T-BiLSTM	42,5156	67,4598	0,8346	0,1769
R-FCN+LSTM/T-FCN+LSTM	42,4699	67,3832	0,8347	0,1787
R-FCN+LSTM/T-GRU	42,469	67,395	0,8344	0,1785
R-FCN+LSTM/T-CNN	42,3702	67,2256	0,8345	0,1826
R-GRU/T-MLP	25,0279	43,942	0,9015	0,6564
R-GRU/T-LSTM	24,805	43,5441	0,9017	0,657
R-GRU/T-BiLSTM	24,8031	43,5415	0,9017	0,6571
R-GRU/T-FCN+LSTM	24,7791	43,4988	0,9017	0,6578
R-GRU/T-GRU	24,7692	43,4827	0,9017	0,658
R-GRU/T-CNN	24,6901	43,344	0,9018	0,6602
R-CNN/T-MLP	41,0342	67,9857	0,839	0,1775
R-CNN/T-LSTM	40,7601	67,5411	0,8391	0,1749
R-CNN/T-BiLSTM	40,7652	67,5547	0,8391	0,1746
R-CNN/T-FCN+LSTM	40,7238	67,4791	0,8391	0,1764
R-CNN/T-GRU	40,7184	67,4821	0,8389	0,1763
R-CNN/T-CNN	40,6069	67,2926	0,8391	0,1809

Fonte: Elaborada pelo autor.

PLACA INDUSTRIAL – 670W

Tabela 4 do Apêndice 4 – Métricas da potência da placa industrial (670W)

Configuração	MAE	RMSE	r	R^2
R-MLP/T-MLP	49,779	84,8707	0,9276	0,4821
R-MLP/T-LSTM	50,3325	86,0264	0,9273	0,4779
R-MLP/T-BiLSTM	50,3925	86,1326	0,9272	0,4766
R-MLP/T-FCN+LSTM	50,3359	86,0456	0,9272	0,4777
R-MLP/T-GRU	50,2647	85,931	0,9273	0,4791
R-MLP/T-CNN	50,62	86,4751	0,9272	0,4725
R-LSTM/T-MLP	38,9693	66,4865	0,9268	0,6932
R-LSTM/T-LSTM	38,2474	65,2057	0,9272	0,6955
R-LSTM/T-BiLSTM	38,2554	65,216	0,9272	0,6954
R-LSTM/T-FCN+LSTM	38,1498	65,0525	0,9272	0,697
R-LSTM/T-GRU	38,1388	65,0407	0,9271	0,6971
R-LSTM/T-CNN	37,8945	64,6371	0,9273	0,7008
R-FCN+LSTM/T-MLP	68,4803	108,7023	0,8352	0,1798
R-FCN+LSTM/T-LSTM	67,7128	107,4835	0,8345	0,1727
R-FCN+LSTM/T-BiLSTM	67,7437	107,5397	0,8343	0,1718
R-FCN+LSTM/T-FCN+LSTM	67,6072	107,3097	0,8345	0,1754
R-FCN+LSTM/T-GRU	67,61	107,3532	0,8341	0,1747

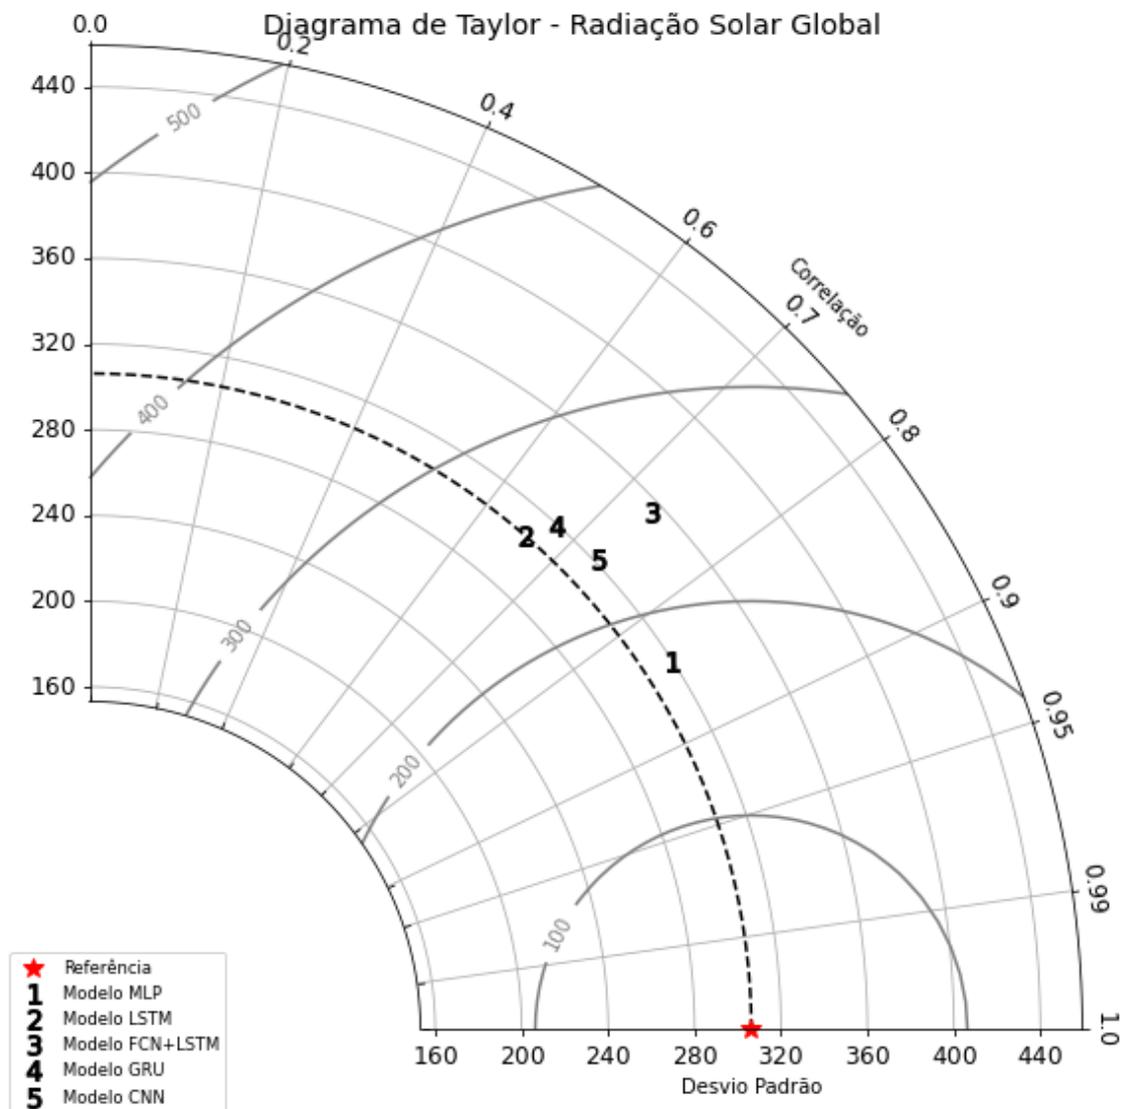
R-FCN+LSTM/T-CNN	67,3287	106,8656	0,8343	0,1822
R-GRU/T-MLP	40,1324	70,4941	0,9014	0,6551
R-GRU/T-LSTM	39,4423	69,2585	0,9018	0,6565
R-GRU/T-BiLSTM	39,4364	69,2501	0,9019	0,6566
R-GRU/T-FCN+LSTM	39,3648	69,1232	0,9019	0,6578
R-GRU/T-GRU	39,3394	69,0816	0,9018	0,6583
R-GRU/T-CNN	39,1152	68,6874	0,9021	0,6621
R-CNN/T-MLP	65,7892	109,032	0,839	0,1748
R-CNN/T-LSTM	64,9315	107,6373	0,8391	0,1703
R-CNN/T-BiLSTM	64,9461	107,6767	0,839	0,1697
R-CNN/T-FCN+LSTM	64,8223	107,4497	0,8392	0,1732
R-CNN/T-GRU	64,8114	107,4662	0,8388	0,173
R-CNN/T-CNN	64,4929	106,921	0,8391	0,1813

Fonte: Elaborada pelo autor.

APÊNDICE 5 – DIAGRAMAS DE TAYLOR – TESTE PADRÃO

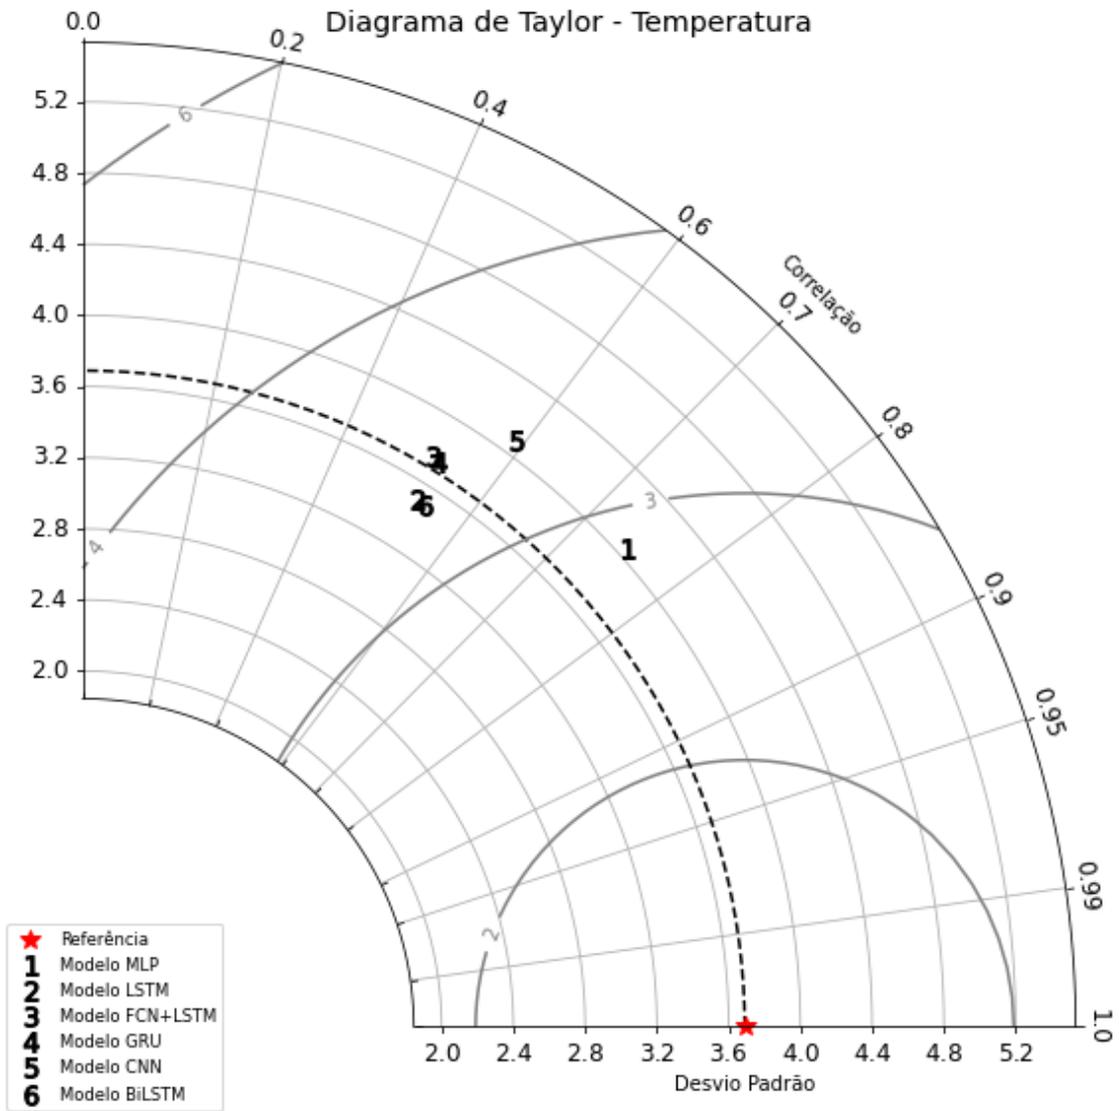
As figuras abaixo são referentes ao diagrama de Taylor. O mesmo demonstra em uma única figura o desvio padrão e a correlação de Pearson para cada valor em relação ao dado original. Com isso foram criados os diagramas de Taylor para a radiação solar global e temperatura para as cidades de Ibotirama e Petrolina respectivamente.

Figura 1 do Apêndice 5 – Diagrama de Taylor da previsão da radiação solar global (W/m^2) na estação de Ibotirama



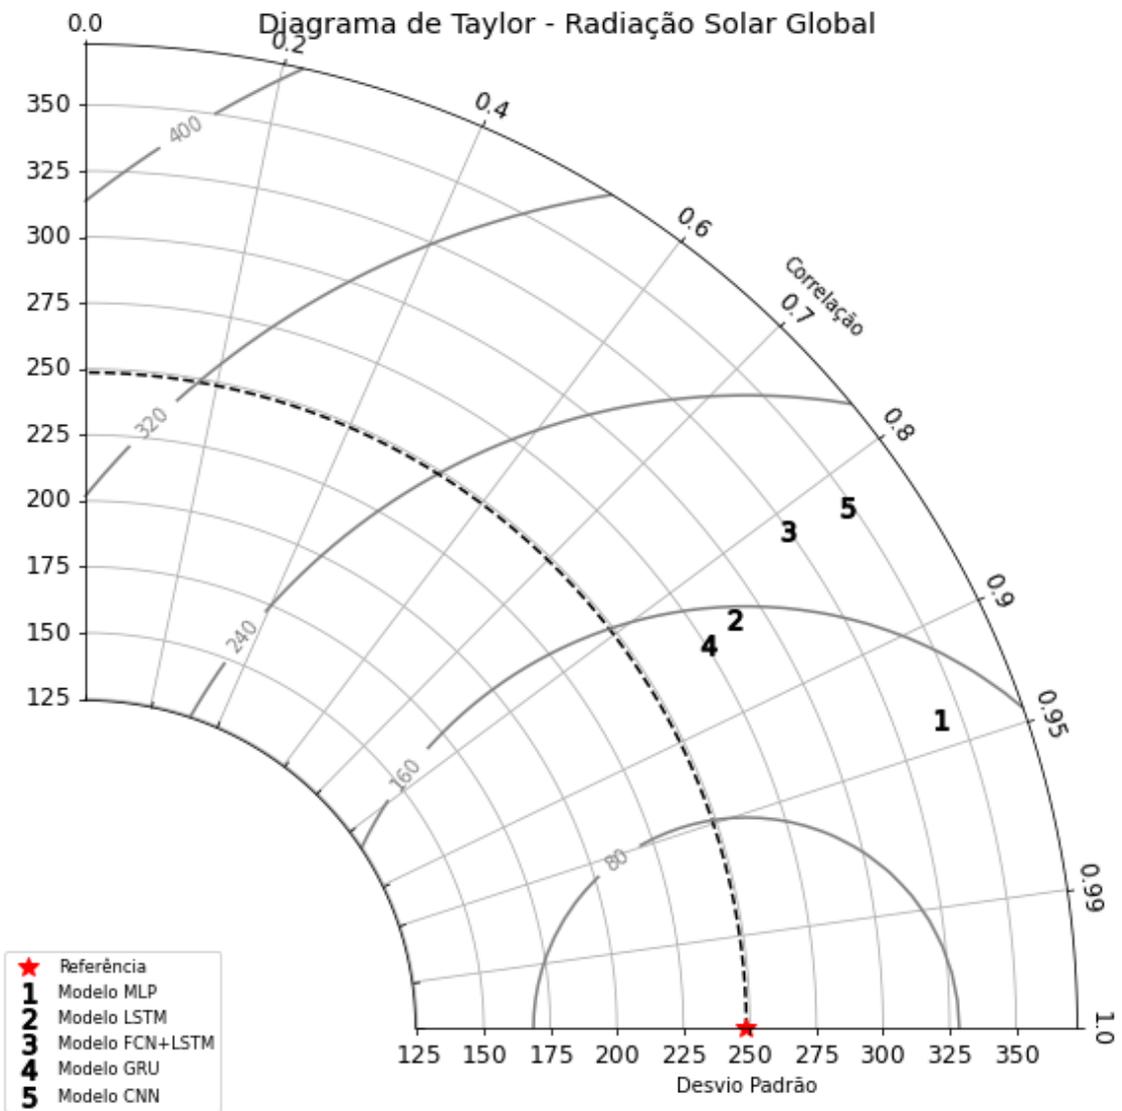
Fonte: Elaborada pelo autor.

Figura 2 do Apêndice 5 – Métrica no Horizonte de previsão da temperatura (°C) na estação de Ibotirama



Fonte: Elaborada pelo autor.

Figura 3 do Apêndice 5 – Métrica no Horizonte de previsão da radiação solar global (W/m^2) na estação de Petrolina



Fonte: Elaborada pelo autor.

Figura 4 do Apêndice 5 – Métrica no Horizonte de previsão da temperatura (°C) na estação de Petrolina

