

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA URBANA

**ANÁLISE DE MUDANÇAS CLIMÁTICAS NO ESTADO DO
MARANHÃO: ESTUDO DAS TEMPERATURAS E RADIAÇÕES
SOLARES**

WANESSA KAROLINE MACIEL CARVALHO

São Carlos

2020

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA URBANA

**ANÁLISE DE MUDANÇAS CLIMÁTICAS NO ESTADO DO
MARANHÃO: ESTUDO DAS TEMPERATURAS E RADIAÇÕES
SOLARES**

WANESSA KAROLINE MACIEL CARVALHO

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Urbana da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Engenharia Urbana.

Orientador:
Prof. Dr. Ricardo Augusto Souza Fernandes

São Carlos
2020



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Exatas e de Tecnologia
Programa de Pós-Graduação em Engenharia Urbana

Folha de Aprovação

Defesa de Dissertação de Mestrado da candidata Wanessa Karoline Maciel Carvalho, realizada em 17/02/2020.

Comissão Julgadora:

Prof. Dr. Ricardo Augusto Souza Fernandes (UFSCar)

Profa. Dra. Tatiane Cristina da Costa Fernandes (UFSCar)

Prof. Dr. Fábio Anderson Silva Borges (UESPI)

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Engenharia Urbana.

*“Que nada nos limite.
Que nada nos defina.
Que nada nos sujeite.
Que a liberdade seja a
nossa própria substância.”
Simone de Beauvoir*

Agradecimentos

Agradeço à minha família por todo o apoio ao longo da minha vida. À minha mãe, pelo amor incondicional, pelos conselhos e carinhos até hoje da mesma maneira. Ao meu pai, por me ensinar a ser quem sou e por zelar pelo meu bem-estar a todo momento.

Ao homem da minha vida, Péricles, pela dedicação ao nosso amor e enorme cumplicidade todos os dias, além de me proporcionar os momentos mais lindos e felizes e ser tão inspirador. Obrigada por me incentivar neste trabalho e me apoiar todo o tempo. Te amo muito mais.

À Myrla, pela amizade mais bonita que alguém possa demonstrar. Seu carisma e companheirismo me ajudam, ao longo desses 12 anos, a preservar com alegria a nossa amizade. Aos meus amigos Carolina Guedes, Daniele Paulino, Fabiana Vases, Felipe Costa, Glenda Bárbara, Iara Oliveira, Izabel Oliveira, Jonas Neto, Mariana Rossi, Nívea Paixão e Thiago Coelho por compartilharem comigo muitos momentos bons no IFMA, em São Carlos e ao longo da vida.

Aos meus grandes companheiros de jornada no PPGEU, Frederico Pedro Bon, Andrea Oliveira e Anderson Moraes por todos os cafés compartilhados e noites em claro produzindo ciência. Ao Leonel toda a gratidão. Você foi essencial para o desenvolvimento dessa pesquisa. Aos meus amigos da IHS, por tantas aventuras e bons momentos, em qualquer lugar do mundo.

Ao Instituto Federal do Maranhão, minha segunda casa e lugar que me proporcionou tantas oportunidades e conquistas durante a graduação. Ao Institute for Housing and Urban Development Studies, por me permitir descobrir a verdadeira vocação dentro da engenharia. À Universidade Federal de São Carlos por me permitir aprender tanto com a pesquisa científica e à FAPEMA, Fundação de Amparo à Pesquisa e ao Desenvolvimento Científico e Tecnológico do Maranhão, que me permitiu desenvolver a pesquisa em outro estado, mas representando e estudando sobre o Maranhão.

A todos os professores que passaram por minha vida e que dedicam suas vidas a educar, transmitir conhecimento e formar o caráter de profissionais de sucesso. Essa é, com certeza, a profissão mais bonita e vocês merecem todo o reconhecimento. Em especial ao meu orientador Ricardo Fernandes, pelo suporte fundamental para o desenvolvimento

deste trabalho e por ser tão incentivador e compreensivo, sempre indicando os melhores caminhos.

Ao professor Anderson, por me ensinar que sonhos não são inalcançáveis, é só questão de planejamento. Aos professores Aluísio (Muchacho) Alves, André Muller, Elys Regina, Rodrigo Neves, Antônio Parga, Benedito Mota, Cláudio Leão e Elaine Araújo, pela dedicação e suporte.

A todos os demais familiares e colegas que me ajudaram e ajudam ao longo da vida. Vocês contribuem para a formação do meu caráter e me motivam a ser quem sou.

Resumo

CARVALHO, W. K. M. **Análise de Mudanças Climáticas no Estado do Maranhão: Estudo das Temperaturas e Radiações Solares**. 2020. 139p. Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Urbana, Universidade Federal de São Carlos, São Carlos, 2020.

Os eventos climáticos que representam riscos para as comunidades de forma geral são cada vez mais frequentes e surgem da variabilidade diária, sazonal e ano a ano do clima, bem como das diferenças climáticas regionais. A ciência das Mudanças Climáticas estuda modelos com o intuito de garantir a previsão de efeitos e impactos com precisão. Este trabalho teve como objetivo avaliar o comportamento das variáveis climáticas temperatura do ar e irradiação solar de cinco municípios localizados no estado do Maranhão e apresentar um modelo de previsão temporal a longo prazo (um ano a frente) destas variáveis utilizando o modelo inteligente de Redes Neurais Artificiais. Foram coletadas as amostras de cinco estações meteorológicas automáticas junto ao INMET para a série histórica de 2008 a 2019 e, para alcançar uma base de dados consistente, foram executados os processos de *data cleaning* e seleção de atributos para então montar a base de dados fonte de informações para o modelo de RNA escolhido. As bases de dados de cada município foram subdivididas por período sazonal para que fosse realizada a previsão temporal do mesmo período um ano a frente. As métricas de avaliação das previsões foram: Erro Absoluto Médio (MAE), Erro Relativo Absoluto (RAE) e Raiz do Erro Quadrático Médio (RMSE). As variáveis climáticas utilizadas para o desenvolvimento do método foram Temperatura Máxima (°C), Umidade Relativa do Ar (%), Temperatura Mínima (°C), Temperatura do Ponto de Orvalho (°C), Velocidade do Vento (m/s), Rajada Máxima de Vento (m/s), Direção do Vento (graus), Precipitação (mm) e Pressão Atmosférica da Estação (mBar) além das variáveis Irradiação Solar (kJ/m^2) e Temperatura do Ar (°C) a serem previstas. Os dados coletados foram divididos em 80% para treinamento e 20% para teste. Os resultados dos modelos de previsão de Irradiação Solar foram MAE = 0,062 kJ/m^2 , RAE = 0,00005 kJ/m^2 e RMSE = 0,0002 kJ/m^2 . Os valores das métricas de previsão de Temperatura do Ar são MAE = 0,4737 °C, RAE = 0,0003 °C e RMSE = 0,0025 °C. As bases mais consistentes para o cálculo do MAE e do RAE foram o Inverno de Imperatriz e Turiiaçu, enquanto que para o RMSE, os melhores resultados foram obtidos utilizando a base de dados do período da Primavera dos municípios de Caxias e Imperatriz.

Palavras-chave: Mudanças Climáticas. Previsão de Séries Temporais. Redes Neurais Artificiais. Temperatura do Ar. Irradiação Solar.

Abstract

CARVALHO, W. K. M. **Analysis of Climatic Changes in the State of Maranhão: Study of Temperatures and Solar Radiations.** 2020. 139p. Dissertação (Mestrado) - Programa de Pós-Graduação em Engenharia Urbana, Universidade Federal de São Carlos, São Carlos, 2020.

Climate events that represent risks to communities in general are becoming more frequent and arise due to the daily, seasonal and year-to-year variability of the climate as well as from regional climatic differences. The Science of Climate Change studies models in order to ensure prediction of effects and impacts with precision. This work aimed to evaluate the behavior of climatic variables, air temperature and solar irradiation, in five municipalities located in the state of Maranhão and to present a long-term forecast model (one year ahead) of these variables using the Artificial Neural Networks intelligent model. Samples of five automatic meteorological stations were collected from INMET for the historical series from 2008 to 2019 and, to reach a consistent database, the processes of data cleaning and feature selection were performed to assemble the information database for the chosen ANN model. The databases of each municipality were subdivided by seasonal period so that the temporal forecast for the same period could be carried out one year ahead. The metrics for evaluating the forecasts were: Mean Absolute Error (MAE), Absolute Relative Error (RAE) and Root Mean Square Error (RMSE). The climatic variables used for the development of the method were Maximum Temperature ($^{\circ}\text{C}$), Relative Air Humidity (%), Minimum Temperature ($^{\circ}\text{C}$), Dew Point Temperature ($^{\circ}\text{C}$), Wind Speed (m/s), Maximum Gust Wind (m/s), Wind Direction (degrees), Precipitation (mm) and Atmospheric Pressure of the Station (mBar) in addition to the variables Solar Irradiation (kJ/m^2) and Air Temperature ($^{\circ}\text{C}$) that were being predicted. The collected data were divided into 80% for training and 20% for testing. The results of the Solar Irradiation forecast models were $\text{MAE} = 0.062 \text{ kJ}/\text{m}^2$, $\text{RAE} = 0.00005 \text{ kJ}/\text{m}^2$ and $\text{RMSE} = 0.0002 \text{ kJ}/\text{m}^2$. Values for Air Temperature forecast metrics are $\text{MAE} = 0.4737 \text{ }^{\circ}\text{C}$, $\text{RAE} = 0.0003 \text{ }^{\circ}\text{C}$ and $\text{RMSE} = 0.0025 \text{ }^{\circ}\text{C}$. The most consistent bases for the calculation of MAE and RAE were the winter of the municipalities of Imperatriz and Turiaçu, while for the RMSE, the best results were obtained using the spring period database of the municipalities of Caxias and Imperatriz.

Keywords: Climate Change. Time Series Forecast. Artificial Neural Networks. Solar Irradiation. Air Temperature.

Lista de figuras

Figura 1 – Publicações por ano entre 2008 e 2019.	34
Figura 2 – Mapa bibliométrico por ocorrência dos termos.	35
Figura 3 – Análise de conexões do termo <i>neural network</i>	36
Figura 4 – Mapa de citações entre 2008 e 2019	39
Figura 5 – Localização do estado do Maranhão.	42
Figura 6 – Mapa climático do estado do Maranhão	43
Figura 7 – Mapa de GHI do estado do Maranhão	44
Figura 8 – Localização do município de Caxias	45
Figura 9 – Localização do município de Colinas	46
Figura 10 – Localização do município de Imperatriz	47
Figura 11 – Localização do município de São Luís	47
Figura 12 – Localização do município de Turiáçu	48
Figura 13 – Representação de um neurônio artificial	53
Figura 14 – Representação de uma função de ativação linear	54
Figura 15 – Representação de uma rede MLP	56
Figura 16 – Etapas de aplicação do método	59
Figura 17 – Fragmento do arquivo 'SÃO LUÍS' enviado pelo INMET	61
Figura 18 – Representação Gráfica de Irradiação Solar em Caxias	63
Figura 19 – Representação Gráfica da Temperatura do Ar em Caxias	63
Figura 20 – Representação Gráfica de Irradiação Solar em Colinas	64
Figura 21 – Representação Gráfica da Temperatura do Ar em Colinas	64
Figura 22 – Representação Gráfica de Irradiação Solar em Imperatriz	65
Figura 23 – Representação Gráfica da Temperatura do Ar em Imperatriz	65
Figura 24 – Representação Gráfica de Irradiação Solar em São Luís	66
Figura 25 – Representação Gráfica da Temperatura do Ar em São Luís	66
Figura 26 – Representação Gráfica de Irradiação Solar em Turiáçu	67
Figura 27 – Representação Gráfica da Temperatura do Ar em Turiáçu	67
Figura 28 – Fragmento do arquivo 'SÃO LUÍS' enviado pelo INMET	68
Figura 29 – Valores de RMSE para cada período sazonal - Caxias	79
Figura 30 – Resultado final - Irradiação Solar (Teste 1) - Caxias	80
Figura 31 – Resultado final - Temperatura do Ar (Teste 5) - Caxias	80
Figura 32 – Valores de RMSE para cada período sazonal - Colinas	82
Figura 33 – Resultado final - Irradiação Solar (Teste 4) - Colinas	83
Figura 34 – Resultado final - Temperatura do Ar (Teste 1) - Colinas	83
Figura 35 – Valores de RMSE para cada período sazonal - Imperatriz	85
Figura 36 – Resultado final - Irradiação Solar (Teste 5) - Imperatriz	86

Figura 37 – Resultado final - Temperatura do Ar (Teste 1) - Imperatriz	86
Figura 38 – Valores de RMSE para cada período sazonal - São Luís	88
Figura 39 – Resultado final - Irradiação Solar (Teste 1) - São Luís	89
Figura 40 – Resultado final - Temperatura do Ar (Seleção de Atributos) - São Luís	89
Figura 41 – Valores de RMSE para cada período sazonal - Turiaçu	91
Figura 42 – Resultado final - Irradiação Solar (Seleção de Atributos) - Turiaçu . . .	92
Figura 43 – Resultado final - Temperatura do Ar (Teste 4) - Turiaçu	92
Figura 44 – Comparativo com a literatura - Irradiação Solar	93
Figura 45 – Comparativo com a literatura - Temperatura do Ar	93
Figura 46 – Gráfico de Irradiação Solar para Caxias no período do Inverno de 2017	130
Figura 47 – Gráfico de temperatura para Caxias no período do Inverno de 2017 . .	130
Figura 48 – Gráfico de Irradiação Solar para Caxias no período da Primavera de 2018	130
Figura 49 – Gráfico de temperatura para Caxias no período da Primavera de 2018 .	130
Figura 50 – Gráfico de Irradiação Solar para Caxias no período do Verão de 2019 .	131
Figura 51 – Gráfico de temperatura para Caxias no período do Verão de 2019 . . .	131
Figura 52 – Gráfico de Irradiação Solar para Caxias no período do Outono de 2019	131
Figura 53 – Gráfico de temperatura para Caxias no período do Outono de 2019 . .	131
Figura 54 – Gráfico de Irradiação Solar para Colinas no período do Inverno de 2018	132
Figura 55 – Gráfico de temperatura para Colinas no período do Inverno de 2018 . .	132
Figura 56 – Gráfico de Irradiação Solar para Colinas no período da Primavera de 2018	132
Figura 57 – Gráfico de temperatura para Colinas no período da Primavera de 2018	132
Figura 58 – Gráfico de Irradiação Solar para Colinas no período do Verão de 2019 .	133
Figura 59 – Gráfico de temperatura para Colinas no período do Verão de 2019 . . .	133
Figura 60 – Gráfico de Irradiação Solar para Colinas no período do Outono de 2019	133
Figura 61 – Gráfico de temperatura para Colinas no período do Outono de 2019 . .	133
Figura 62 – Gráfico de Irradiação Solar para Imperatriz no período do Inverno de 2018	134
Figura 63 – Gráfico de temperatura para Imperatriz no período do Inverno de 2018	134
Figura 64 – Gráfico de Irradiação Solar para Imperatriz no período da Primavera de 2018	134
Figura 65 – Gráfico de temperatura para Imperatriz no período da Primavera de 2018	134
Figura 66 – Gráfico de Irradiação Solar para Imperatriz no período do Verão de 2019	135
Figura 67 – Gráfico de temperatura para Imperatriz no período do Verão de 2019 .	135
Figura 68 – Gráfico de Irradiação Solar para Imperatriz no período do Outono de 2019	135
Figura 69 – Gráfico de temperatura para Imperatriz no período do Outono de 2019	135
Figura 70 – Gráfico de Irradiação Solar para São Luís no período do Inverno de 2018	136
Figura 71 – Gráfico de temperatura para São Luís no período do Inverno de 2018 .	136

Figura 72 – Gráfico de Irradiação Solar para São Luís no período da Primavera de 2018	136
Figura 73 – Gráfico de temperatura para São Luís no período da Primavera de 2018	136
Figura 74 – Gráfico de Irradiação Solar para São Luís no período do Verão de 2018	137
Figura 75 – Gráfico de temperatura para São Luís no período do Verão de 2018 . .	137
Figura 76 – Gráfico de Irradiação Solar para São Luís no período do Outono de 2019	137
Figura 77 – Gráfico de temperatura para São Luís no período do Outono de 2019 .	137
Figura 78 – Gráfico de Irradiação Solar para Turiacu no período do Inverno de 2017	138
Figura 79 – Gráfico de temperatura para Turiacu no período do Inverno de 2017 . .	138
Figura 80 – Gráfico de Irradiação Solar para Turiacu no período da Primavera de 2018	138
Figura 81 – Gráfico de temperatura para Turiacu no período da Primavera de 2018	138
Figura 82 – Gráfico de Irradiação Solar para Turiacu no período do Verão de 2018 .	139
Figura 83 – Gráfico de temperatura para Turiacu no período do Verão de 2018 . . .	139
Figura 84 – Gráfico de Irradiação Solar para Turiacu no período do Outono de 2018	139
Figura 85 – Gráfico de temperatura para Turiacu no período do Outono de 2018 . .	139

Lista de tabelas

Tabela 1 – Modelos similares de previsão de Irradiação Solar	37
Tabela 2 – Modelos similares de previsão de Temperatura do Ar	38
Tabela 3 – Variáveis disponibilizadas pelo INMET	60
Tabela 4 – Análise de ausência de medições	62
Tabela 5 – Número de amostras finais	62
Tabela 6 – Tabela de pesos para 5 amostras (-5MM)	70
Tabela 7 – Tabela de pesos para 10 amostras (-10MM)	70
Tabela 8 – Tabela de pesos para 15 amostras (-15MM)	70
Tabela 9 – Combinações dos intervalos para teste sem seleção de atributos	70
Tabela 10 – Detalhamento da arquitetura da RNA	73
Tabela 11 – Detalhamento da RNA com duas camadas ocultas	73
Tabela 12 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Caxias	78
Tabela 13 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Caxias	78
Tabela 14 – Detalhamento dos melhores resultados de RMSE - Caxias	80
Tabela 15 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Colinas	81
Tabela 16 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Colinas	81
Tabela 17 – Detalhamento dos melhores resultados de RMSE - Colinas	83
Tabela 18 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Imperatriz	84
Tabela 19 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Imperatriz	84
Tabela 20 – Detalhamento dos melhores resultados de RMSE - Imperatriz	86
Tabela 21 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - São Luís	87
Tabela 22 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - São Luís	87
Tabela 23 – Detalhamento dos melhores resultados de RMSE - São Luís	89
Tabela 24 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Turiaçu	90
Tabela 25 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Turiaçu	90
Tabela 26 – Detalhamento dos melhores resultados de RMSE - Turiaçu	92
Tabela 27 – Resumo dos melhores testes	94
Tabela 28 – Melhores desempenhos das métricas de avaliação	94
Tabela 29 – Irradiação Solar para Caxias no período sazonal de Outono	109
Tabela 30 – Temperatura para Caxias no período sazonal de Outono	110
Tabela 31 – Irradiação Solar para Caxias no período sazonal de Inverno	110
Tabela 32 – Temperatura para Caxias no período sazonal de Inverno	110

Tabela 33 – Irradiação Solar para Caxias no período sazonal de Primavera	111
Tabela 34 – Temperatura para Caxias no período sazonal de Primavera	111
Tabela 35 – Irradiação Solar para Caxias no período sazonal de Verão	111
Tabela 36 – Temperatura para Caxias no período sazonal de Verão	112
Tabela 37 – Irradiação Solar para Colinas no período sazonal de Outono	112
Tabela 38 – Temperatura para Colinas no período sazonal de Outono	112
Tabela 39 – Irradiação Solar para Colinas no período sazonal de Inverno	113
Tabela 40 – Temperatura para Colinas no período sazonal de Inverno	113
Tabela 41 – Irradiação Solar para Colinas no período sazonal de Primavera	113
Tabela 42 – Temperatura para Colinas no período sazonal de Primavera	114
Tabela 43 – Irradiação Solar para Colinas no período sazonal de Verão	114
Tabela 44 – Temperatura para Colinas no período sazonal de Verão	114
Tabela 45 – Irradiação Solar para Imperatriz no período sazonal de Outono	115
Tabela 46 – Temperatura para Imperatriz no período sazonal de Outono	115
Tabela 47 – Irradiação Solar para Imperatriz no período sazonal de Inverno	116
Tabela 48 – Temperatura para Imperatriz no período sazonal de Inverno	116
Tabela 49 – Irradiação Solar para Imperatriz no período sazonal de Primavera	117
Tabela 50 – Temperatura para Imperatriz no período sazonal de Primavera	117
Tabela 51 – Irradiação Solar para Imperatriz no período sazonal de Verão	118
Tabela 52 – Temperatura para Imperatriz no período sazonal de Verão	118
Tabela 53 – Irradiação Solar para São Luís no período sazonal de Outono	119
Tabela 54 – Temperatura para São Luís no período sazonal de Outono	119
Tabela 55 – Irradiação Solar para São Luís no período sazonal de Inverno	120
Tabela 56 – Temperatura para São Luís no período sazonal de Inverno	120
Tabela 57 – Irradiação Solar para São Luís no período sazonal de Primavera	121
Tabela 58 – Temperatura para São Luís no período sazonal de Primavera	121
Tabela 59 – Irradiação Solar para São Luís no período sazonal de Verão	122
Tabela 60 – Temperatura para São Luís no período sazonal de Verão	123
Tabela 61 – Irradiação Solar para São Luís no período sazonal de Turiaçu	123
Tabela 62 – Temperatura para São Luís no período sazonal de Turiaçu	124
Tabela 63 – Irradiação Solar para São Luís no período sazonal de Inverno	124
Tabela 64 – Temperatura para São Luís no período sazonal de Inverno	124
Tabela 65 – Irradiação Solar para São Luís no período sazonal de Primavera	125
Tabela 66 – Temperatura para São Luís no período sazonal de Primavera	125
Tabela 67 – Irradiação Solar para São Luís no período sazonal de Verão	126
Tabela 68 – Temperatura para São Luís no período sazonal de Verão	126
Tabela 69 – Valores gerais de RMSE	128

Sumário

1	Introdução	19
1.1	Visão Geral	19
1.2	Objetivos	22
1.3	Justificativa e Motivação da Proposta	22
1.4	Organização do Trabalho	25
2	Revisão Bibliográfica	27
2.1	Fundamentos sobre Radiação Solar Global	28
2.2	Fundamentos sobre Temperatura do Ar	30
2.3	Análise Bibliométrica	33
3	Locais de Estudo	41
3.1	Características Gerais e Climáticas	41
3.1.1	Caxias	45
3.1.2	Colinas	45
3.1.3	Imperatriz	46
3.1.4	São Luís	47
3.1.5	Turiaçu	48
4	Séries Temporais e RNAs	49
4.1	Séries Temporais e modelos de previsão	49
4.2	Redes Neurais Artificiais	52
4.2.1	Neurônio artificial e funções de ativação	53
4.2.2	Arquitetura	54
4.2.3	Aprendizado	55
4.2.4	Rede <i>Multilayer Perceptron</i>	56
4.2.5	Algoritmos <i>Backpropagation</i> e <i>Levenberg-Marquardt</i>	57
5	Metodologia	59
5.1	Coleta dos dados	60
5.2	Tratamento dos dados	61
5.3	Comportamento dos dados	63
5.3.1	Caxias	63
5.3.2	Colinas	64
5.3.3	Imperatriz	65
5.3.4	São Luís	66
5.3.5	Turiaçu	67
5.4	Organização dos Dados	68
5.4.1	Base Inicial	68
5.4.2	Base Intermediária	68

5.4.2.1	Aplicação de <i>lags</i>	68
5.4.2.2	Aplicação de Médias Móveis Ponderadas	69
5.5	Seleção de Atributos	71
5.6	Parametrização	72
5.7	Métricas de Avaliação de Desempenho	74
5.7.1	Erro Quadrático Médio (MSE – <i>Mean Square Error</i>)	74
5.7.2	Raiz do Erro Quadrático Médio (RMSE – <i>Root Mean Square Error</i>)	75
5.7.3	Erro Médio Absoluto (MAE – <i>Mean Absolute Error</i>)	75
5.7.4	Erro Relativo Absoluto (RAE – <i>Root Absolute Error</i>)	75
6	Análise de Resultados	77
6.1	Caxias	78
6.2	Colinas	81
6.3	Imperatriz	84
6.4	São Luís	87
6.5	Turiagu	90
6.6	Análise comparativa dos resultados	93
7	Conclusões	97
8	Trabalhos Futuros	99
	Referências	101
	APÊNDICE A Seleção de Atributos	109
	APÊNDICE B Tabela-resumo de RMSE	127
	APÊNDICE C Gráficos de Irradiação Solar e Temperatura do Ar	129

Capítulo 1

Introdução

1.1 Visão Geral

No decorrer das convenções das Nações Unidas sobre Mudanças Climáticas, desde 1992, governantes e membros da comunidade científica têm discutido as consequências da interferência humana no clima e os impactos econômicos e sociais do controle das emissões dos gases de efeito estufa. Destas convenções resultaram o Protocolo de Kyoto, o Acordo de Cancún e o Acordo de Paris, sendo este último assinado em dezembro de 2015 na 21ª Conferência das Partes. Este novo acordo estabelece o compromisso de 197 países em controlar o aquecimento da atmosfera. Sua principal meta é impedir que a temperatura média global se eleve em 2°C quando comparada às temperaturas anteriores à revolução industrial. O consenso dos membros é de que manter o aquecimento abaixo deste limite até o final do século XXI deve assegurar níveis de produção de alimentos e desenvolvimento econômico compatíveis com o crescimento da população. Entretanto, de acordo com algumas projeções, pode ser necessário acelerar os esforços (ROGELJ et al., 2016).

O Painel Intergovernamental sobre Mudança Climática (do inglês, *Intergovernmental Panel on Climate Change - IPCC*) é o órgão da ONU responsável por elaborar previsões periódicas da evidência científica sobre mudança climática. Em seu último relatório publicou a síntese de cenários de emissões e disponibilizou os dados para revisão por pares. Destes cenários, a publicação de Rogelj et al. (2016) selecionou um subgrupo com as seguintes características:

- sustentam durante todo o período probabilidades maiores que 60% de manter o aquecimento abaixo de 2°C até o final do século;
- assumem que as políticas determinadas no Acordo de Cancún são realizadas;
- distribuem as reduções de emissões entre regiões, gases e setores de maneira que os

custos sejam minimizados.

Ao comparar estes cenários de custo ótimo com as estimativas de emissões na hipótese de todas as políticas do Acordo de Paris serem adotadas sem restrições, os autores encontraram uma diferença de 14 Gt $CO_2 - eq^1$ anuais (podendo oscilar entre 10-16 Gt) até 2030. Portanto, não somente as estimativas diferem dos caminhos de menor custo, como são de fato consistentes com níveis de aquecimento global médio de 2,6 a 3,1°C até 2100 (ROGELJ et al., 2016).

Por conta das transformações ambientais, o entendimento do comportamento climático tem se tornado uma tarefa fundamental para a humanidade em diversas áreas de estudo, que podem ser complexas já que dependem da disponibilidade de dados, em particular, na Meteorologia, em que essa disponibilidade implica no aumento de dificuldade no processo de previsão temporal (ANOCHI; SILVA, 2009). Com base nessas afirmações, alguns centros de pesquisa têm se dedicado à previsão de variáveis climáticas para distintos horizontes e também para diversas localidades (DIAGNE et al., 2013; INMAN; PEDRO; COIMBRA, 2013; ANTONANZAS et al., 2016).

Pesquisadores como Hooyberghs et al. (2017), têm se dedicado a avaliar o impacto das mudanças climatológicas com os custos atrelados ao conforto térmico de edificações durante períodos de calor intenso. Além disso, estes autores ainda demonstram que o ambiente sem condições climáticas adequadas pode influenciar negativamente o desempenho no trabalho, inclusive aumentando o nível de estresse.

Há ainda autores que analisam as variáveis climáticas quanto ao uso do solo, considerando a forma como as alterações do clima prejudicam o escoamento e influenciam a erosão, conforme mostrado no trabalho de Almagro et al. (2017) em que os autores verificam os impactos das mudanças climatológicas com o estudo das chuvas no território brasileiro. Ainda nesse sentido, Anache et al. (2018) analisaram o impacto das mudanças do clima no escoamento e na erosão do solo e as análises foram realizadas considerando o Cerrado Brasileiro, pois essa região tem sido dividida entre arborização nativa, plantio de cana-de-açúcar e criação de animais. Portanto, a degradação do solo dessa região pode ter efeitos econômicos diretos até mesmo nacionalmente.

Já no estudo realizado por Lin et al. (2017), os autores apresentam uma projeção de elevação da temperatura em Taiwan, ao considerar variações climatológicas de uma onda de calor, avaliada por meio do comportamento da temperatura e da umidade relativa. Foi possível então determinar tendências quanto ao nível de estresse em três grandes cidades do país. A pesquisa ainda deixa em aberto a possibilidade de essa mesma técnica ser adotada para estudos em outros países, com algumas adaptações.

Quanto maior o número de informações obtidas sobre as variáveis climáticas, mais subsídios existirão para tentar melhorar a previsão. Mas isso implica diretamente no

aumento da necessidade de recursos computacionais para manipular grandes volumes de dados, quando estes são usados em modelos de previsão que simulam a evolução dos fenômenos físicos. E ainda, o estudo dos dados históricos pode ajudar a criar padrões das condições da atmosfera e assim construir um modelo de previsão (ANOCHI; SILVA, 2009).

Técnicas de Inteligência Artificial são capazes de desempenhar um papel importante na análise, modelagem e previsão do comportamento do clima. Elas têm sido usadas para resolver de forma prática temas complicados em várias áreas de engenharia e tecnologia e são cada vez mais populares, surgindo como uma maneira alternativa para lidar com problemas complexos e mal definidos. Tais ferramentas podem aprender com exemplos, são tolerantes a falhas, ou seja, são capazes de lidar com dados ruidosos e/ou incompletos, são capazes de lidar com problemas não lineares e, uma vez treinadas, podem realizar previsões e generalizações em alta velocidade (BELU, 2012).

Os sistemas de Inteligência Artificial compreendem métodos como Redes Neurais Artificiais (RNAs), algoritmos evolutivos, Lógica *Fuzzy* e diversos sistemas híbridos, combinando duas ou mais técnicas (BELU, 2012). Os resultados apresentados em vários artigos são testemunho do potencial da inteligência artificial como uma ferramenta em muitas áreas como saúde, climatologia, engenharia e agricultura (RYAN et al., 2015; ZOU et al., 2016; MOKHTARZAD et al., 2017; ADEDE et al., 2019).

A identificação das condições que provocam a ocorrência de eventos climáticos e a realização em tempo hábil de medidas que reduzam o impacto negativo de eventos meteorológicos é essencial para a sociedade. Em Meteorologia, dados de diversas fontes, ou multivariados, são usados para previsões climáticas sendo processados por técnicas como RNAs, Árvore de Decisão e modelo Auto-regressivo Integrado de Médias Móveis (ARIMA-*Autoregressive Integrated Moving Average*) (SHAH et al., 2018). Estudos sobre a variabilidade de parâmetros climáticos locais, como temperatura e radiação solar são importantes para verificar o comportamento dessas grandezas ao longo dos anos (CHEN et al., 2011; KALOGIROU, 2013; NOI; DEGENER; KAPPAS, 2017; JALLAL et al., 2019). Desta forma, há a possibilidade de uma melhor compreensão desses sistemas e, com isso, a possibilidade de realizar previsões visando a disponibilização de recursos dentro do planejamento urbano.

Considerando as pesquisas supramencionadas e também a busca crescente por modelos de previsão cada vez mais precisos, este estudo descreve os conceitos fundamentais envolvidos na previsão de irradiação solar (ou radiação solar incidente) e temperatura do ar em 5 municípios do estado do Maranhão, analisando o comportamento do clima com o intuito de desenvolver um experimento capaz de realizar a previsão dessas duas variáveis climáticas utilizando as Redes Neurais Artificiais como técnica de Inteligência Artificial.

1.2 Objetivos

O presente trabalho tem como objetivo geral apresentar um modelo de previsão climática utilizando Redes Neurais Artificiais como ferramenta que garanta a previsão, no horizonte de um ano a frente, das variáveis radiação solar e temperatura do ar em 5 municípios do estado do Maranhão.

Dentre os objetivos específicos pode-se citar:

- Avaliar as alterações nas séries históricas dos dados climatológicos obtidas nas estações meteorológicas no estado do Maranhão;
- Desenvolver um prognóstico climatológico do estado do Maranhão, destacando características dos 4 períodos sazonais em estudo;
- Comparar os resultados obtidos com pesquisas relacionadas, analisando a aplicabilidade da metodologia proposta.

1.3 Justificativa e Motivação da Proposta

A construção de cenários climáticos futuros, sejam eles em escalas locais ou globais, sob as alterações que o aquecimento global pode provocar, é necessária para avaliar os impactos que as mudanças climáticas podem causar no ambiente. Tal avaliação envolve a necessidade de prever, com precisão, o comportamento de inúmeras variáveis ao longo de distintos períodos de tempo, com o intuito de evitar riscos que poderiam acarretar em perdas financeiras e humanas.

As alterações climáticas representam um problema clássico de mudança global em múltiplas escalas, caracterizadas por atores diversos, múltiplos estressores e múltiplas escalas de tempo (ADGER, 2006). Um número expressivo de governos já está fortemente envolvido na adaptação por meio de estruturas de governança e mecanismos institucionais atuais, por exemplo, agências de recursos hídricos que se adaptam a mudanças nos regimes de precipitação e agências agrícolas que adaptam práticas de irrigação a mudanças nas condições climáticas. Essas atividades, no entanto, muitas vezes são realizadas de forma isolada e por meio de uma abordagem fragmentada (SMITH; VOGEL; CROMWELL III, 2009).

Cientistas de diversos países vem estudando a influência dos gases de efeito estufa no aumento da temperatura e suas consequências em escala global. Porém, as pesquisas em escala regional e local ainda não são suficientes para impulsionar medidas direcionadas (WANG et al., 2011).

Com base na importância do estudo sobre fatores climáticos, com destaque para dados de temperatura e radiação solar, entende-se que tais fatores alteram várias características climáticas e têm um papel importante no desempenho de diversos setores econômicos, sociais e especialmente ambientais. Um grande número de autores apresentam motivações para o estudo dessas variáveis climáticas.

Conforme Kalogirou (2013), a radiação solar é a fonte fundamental da energia da Terra e fornece quase 99,9% da energia térmica necessária para vários processos químicos e físicos na atmosfera, oceano, terra e outros corpos d'água, além de ter um papel vital como fonte de energia renovável. No trabalho de Chen et al. (2011), os autores relataram que as medições de radiação solar são empregadas para avaliar algumas das aplicações de energia solar, como aquecimento de água, estudos agrícolas, secagem de madeira, análise de carga térmica fotovoltaica em edifícios, estudos de balanço de energia atmosférica e previsão meteorológica. Yadav e Chandel (2014) explicaram que a incidência de radiação solar é considerada o parâmetro mais essencial em aplicações de meteorologia, energia renovável e conversão de energia solar, especialmente para o dimensionamento de sistemas fotovoltaicos independentes, além de estar diretamente ligada ao aquecimento do planeta.

Outros autores destacam a importância de prever temperatura do ar. De acordo com Ustaoglu, Cigizoglu e Karaca (2008), há necessidade de prever a temperatura com precisão para evitar perigos não esperados causados pela sua variação, como geadas e secas. Para Noi, Degener e Kappas (2017), a temperatura é usada como a principal variável de entrada e afeta diretamente a precisão do monitoramento e simulações de crescimento de culturas, estudos hidrológicos, ecológicos, ambientais e mudanças climáticas. No estudo de Jallal et al. (2019), os autores afirmam que prever a temperatura do ar é um parâmetro muito importante para indicar o desempenho da instalação de sistemas solares que geram energia elétrica principalmente em regiões mais remotas.

Os estudos climáticos em ambientes urbanos têm sido realizados por diversos pesquisadores, tendo em vista que as cidades formam aglomerados urbanos crescentes e seu conforto sofre influência a partir do comportamento das variáveis climáticas. Portanto, para a identificação do papel que cada variável exerce no conforto térmico urbano é necessário o entendimento a respeito de seus comportamentos individuais presentes e futuros, já que o conforto térmico é um dos indicadores do índice de qualidade de vida e integra o conceito de sustentabilidade urbana (ALCOFORADO et al., 2005).

A previsão não constitui um fim em si, mas apenas um meio de fornecer informações para uma consequente tomada de decisões, visando determinados objetivos (MORETTIN; TOLOI, 2006). Portanto, a projeção de cenários climáticos contribuirá para estimar condições e estimulará uma tomada de decisão embasada. O método de previsão deve ser confiável em relação aos efeitos das mudanças climáticas para fomentar iniciativas de cunho científico e de formulação de políticas governamentais.

Sabendo que os cenários climáticos são elaborados a partir de simulações dos modelos usados como ferramentas para projeções de alterações, o modelo a ser utilizado nesta pesquisa busca possibilitar, por meio do estudo do comportamento da temperatura e da radiação solar ocorridas no passado, a previsão de variações com o mínimo de erro.

Nos estudos sobre o clima, métodos numéricos podem ser utilizados para prever o comportamento de diversas variáveis, em escalas de tempo que variam de algumas horas a várias estações. Os intervalos de tempo podem ser classificados como de ultra-curto ou curtíssimo prazo (15 minutos a 4 horas à frente), curto prazo (várias horas a 3 dias), médio prazo (vários dias a 1 mês) e longo prazo (1 mês à frente ou mais) (HU et al., 2018). Neste trabalho, buscou-se apresentar uma previsão de longo prazo, de um ano a frente, em escala local, determinando o comportamento do clima dos 4 períodos sazonais no ano.

Para um projeto de previsão seguro e de alto desempenho, é preciso considerar a importância de uma ferramenta computacional confiável. As Redes Neurais Artificiais surgem como um exemplo para o desenvolvimento de modelos preditivos, com capacidade de prever as variáveis usando informações detalhadas e organizadas anteriormente com a vantagem adicional de serem não lineares e particularmente robustas em encontrar e representar relações mesmo na presença de ruídos nos dados.

As RNAs podem ser aplicadas para prever o comportamento de variáveis a partir de modelos climáticos globais. Essas condições de previsão podem mudar conforme os diversos comprimentos de tempo, como de estação para estação, e mesmo de um momento para outro. Nos últimos anos, elas têm sido utilizadas por diversos autores que desenvolveram estudos sobre ferramentas para a previsão de dados climáticos, dentre eles temperatura e radiação solar incidente, objetos de estudo deste trabalho, buscando resultados eficientes que contribuam para a elaboração de propostas que visem a diminuição ou mitigação das alterações climáticas no ambiente urbano (KOCA et al., 2011; ASHRAFI et al., 2012; VENKADESH et al., 2013; MBA; MEUKAM; KEMAJOU, 2016; Rao K; PREMALATHA; NAVEEN, 2018).

Deve-se destacar ainda a relevância desta pesquisa para o estado do Maranhão com a contribuição de uma análise detalhada sobre os dados concedidos pelas equipes de profissionais das estações meteorológicas do Instituto Nacional de Meteorologia (INMET). Fazendo divisa a leste com o Piauí, a sul e sudoeste com o Tocantins e a noroeste com o Pará, o Maranhão é caracterizado geo-político-fisicamente como uma área de transição climática (FERREIRA; MORAES, 2008) e, por este motivo, foi escolhida. O estado têm influência de três climas conforme a classificação de Nimer (NIMER, 1979): úmido, semi-úmido e semi-árido. As RNAs foram empregadas no intuito de prever valores de temperatura e irradiação solar com a menor margem de erro possível nos municípios Caxias, Colinas, Imperatriz, São Luís e Turiagu, que representam cada clima do estado, bem como as duas regiões de transição entre os três climas, totalizando então cinco municípios.

Medições climatológicas indicam que a irradiação solar varia de forma temporal, ou seja, ela pode ser mais intensa em algumas áreas que em outras e pode aumentar sua intensidade por alguns meses do ano. O principal condicionamento para as variações inter anuais no Nordeste do Brasil está ligado às mudanças nos padrões climáticos do planeta como: a elevação da temperatura global e pequenas irregularidades nos ciclos sazonais da Zona de Convergência Intertropical. As mudanças no comportamento da circulação geral da atmosfera ao longo do ano provocam significativas variações na irradiação solar (LIMA, 2015).

Ao considerar que o movimento do ciclo solar induz mudanças sazonais na radiação solar incidente e na temperatura ambiente, que podem ter um impacto específico para cada período, seja para a produção de energia fotovoltaica ou para o aumento da sensação térmica e de ilhas de calor em ambientes urbanos, tornou-se conveniente estabelecer modelos de sistemas preditivos em diferentes estações do ano. Este modelo de análise permite evidenciar que fenômenos climáticos ou suas combinações em diferentes escalas de tempo e espaço podem provocar significativas variações climáticas de uma determinada região, de modo que sua média anual não evidenciaria este comportamento.

Ao propor a aplicação do modelo preditivo separadamente em cada um dos 4 períodos sazonais existentes no estado, pretende-se identificar detalhes no comportamento das variáveis climáticas com base nesses períodos e, identificando características particulares de cada um, apresentar um modelo preditivo consistente para as regiões relacionadas a esta pesquisa no estado do Maranhão.

1.4 Organização do Trabalho

No Capítulo 2 é apresentada a revisão bibliográfica sobre a importância e as tendências da previsão de irradiação solar e temperatura do ar como indicativos relevantes de caracterização das mudanças do clima. A análise bibliométrica de termos relevantes para o trabalho é discutida, mostrando as tendências de pesquisa para o tema proposto e trabalhos similares. No Capítulo 3 são analisadas as características gerais e climáticas dos locais em estudo, compreendendo a dinâmica das condições meteorológicas e destacando a importância de todos os fatores que influenciam o clima da região. No Capítulo 4, o conceito de séries temporais e a descrição do modelo de Redes Neurais Artificiais como o método de previsão são apresentados. No Capítulo 5, os aspectos metodológicos são apresentados, descrevendo a coleta, análise e tratamento dos dados. O modelo de previsão proposto é detalhado, indicando ainda as métricas de avaliação de desempenho. No Capítulo 6 são apresentados os resultados desta pesquisa, descrevendo os modelos de previsão de temperatura e irradiação solar. Por fim, o capítulo 7 apresenta as conclusões da pesquisa.

Capítulo 2

Revisão Bibliográfica

A necessidade de estudos sobre o comportamento de variáveis climáticas em cenários regionais e locais para estudos diversos leva a um amplo desenvolvimento de técnicas de previsão para preencher a lacuna entre as informações de grande escala sobre o clima. A preocupação com os danos ambientais, o compromisso de reduzir as emissões de gases de efeito de estufa e o interesse econômico na adoção de fontes renováveis de energia são fatores que impulsionam o aumento do conhecimento sobre o clima.

Ao combinar variáveis climáticas em um processo de auxílio à decisão, as capacidades de previsão e estimativa dos modelos podem contribuir para um melhor planejamento de cidades e infra-estruturas sustentáveis, para evitar locais perigosos, para minimizar os impactos ambientais e gerenciar de maneira ideal os recursos hídricos e de energia renovável (RODRIGUES *et al.*, 2018).

A partir de técnicas clássicas, as previsões são realizadas com a coleta de dados quantitativos sobre o estado atual da atmosfera e do conhecimento científico dos processos para projetar como as variáveis evoluirão. Fatores atmosféricos, o poder computacional necessário para resolver as equações que descrevem seu comportamento, o erro envolvido na medição e uma compreensão incompleta dos processos atmosféricos dificultam a consistência do método à medida que o tempo de previsão aumenta (ABHISHEK *et al.*, 2012).

Para que seja realizada a previsão, é importante fundamentar a origem e o comportamento das variáveis a serem analisadas. As características meteorológicas que se repetem de forma cíclica ao longo do tempo têm influência direta na dinâmica das condições da atmosfera em um dado local. Essa caracterização busca definir os valores das variáveis meteorológicas em um conjunto de dados, descrevendo o ritmo anual mais provável de ocorrência dos fenômenos atmosféricos. Portanto, são necessários alguns conceitos básicos para a análise dos dados de medição e previsão de radiação solar e temperatura do ar, apresentados nas seções a seguir.

2.1 Fundamentos sobre Radiação Solar Global

O Sol envia para o espaço uma grande quantidade de energia, que se propaga em todas as direções, denominada energia radiante ou radiação. A designação de radiação solar então é aquela energia que provém do Sol e é recebida pela Terra na forma de ondas eletromagnéticas. Esse tipo de radiação é a fonte primária de energia que o planeta dispõe e a sua distribuição variável no tempo e no espaço é a matriz de todos os processos atmosféricos (CRESESB, 2019). É de extrema importância porque é responsável pelos principais processos de ordem física, química e biológica, tanto animal quanto vegetal, bem como responsável direta na disposição da energia primária para todos os processos terrestres, desde a fotossíntese, até ações que provocam situações meteorológicas adversas (SOUZA; NICÁCIO; MOURA, 2005).

O fluxo de energia radiante do exterior do sol para a atmosfera da Terra, chamado de constante solar, varia sazonalmente devido à elipticidade da órbita do planeta. O caminho dessa radiação através da atmosfera varia ao longo do dia devido à mudança de posição do sol no céu. O comprimento do caminho óptico diminui com o aumento da elevação solar, de modo que a radiação na superfície terrestre é mais alta quando a elevação solar é mais alta, ou seja, ao meio-dia solar (LANDSBERG; SANDS, 2011).

As nuvens são o fator principal que modula a radiação solar que incide na superfície por conta das propriedades ópticas que elas possuem e que produzem um espalhamento eficiente da radiação solar. O espalhamento da radiação solar por nuvens depende de sua espessura óptica, da distribuição de tamanhos das gotículas, do conteúdo e do estado físico da água, o que muda de acordo com o tipo de nuvem (PALTRIDGE; PLATT, 1976).

Os aerossóis atmosféricos, tanto os originados da queima de biomassa quanto os produzidos nas grandes cidades, diminuem a quantidade de radiação solar que chega à superfície e são o segundo fator mais importante de modulação da radiação solar incidente, já que podem causar grande diminuição da componente direta. A variabilidade sazonal das condições meteorológicas influencia diretamente a quantidade de aerossóis em suspensão na atmosfera e também regula as características atmosféricas regionais, já que o tempo de permanência dos aerossóis na atmosfera é maior em períodos secos por conta da menor perda em processos de mistura e precipitação (PEREIRA et al., 2017).

A absorção de radiação solar na atmosfera é realizada principalmente pelo gás ozônio atmosférico na faixa de radiação ultravioleta e por vapor d'água e dióxido de carbono nas bandas do infravermelho. Essa absorção é caracterizada pelo aumento no movimento molecular interno do gás e, por consequência, em sua temperatura, fator que influencia diretamente o componente térmico da atmosfera (LIMA, 2015), ou seja, contribui para o aquecimento do planeta.

Assim que a radiação entra na atmosfera, ela passa a ser caracterizada como irradiância (*Global Horizontal Irradiance*), e pode ser absorvida ou dispersa pelas moléculas de ar, aerossóis e poeira (LANDSBERG; SANDS, 2011). A irradiância solar que incide em uma superfície é composta por componentes diretas e difusas. A irradiância normal direta (DNI) apresenta direção de incidência na linha imaginária entre a superfície e o Sol e representa a parcela que não sofreu os processos radiativos de absorção e espalhamento que ocorrem na atmosfera. A componente horizontal difusa (DHI) engloba a radiação proveniente de todas as demais direções que são decorrentes dos processos de espalhamento pelos gases e particulados presentes na atmosfera (PEREIRA et al., 2017).

A irradiância solar tem como unidade de medida usual o W/m^2 e varia em conformidade com o ângulo de incidência dos raios solares. Esse ângulo formado entre o zênite local e os raios solares, denomina-se ângulo zenital (Z). Quanto maior Z , menor será a irradiância solar (SENTELHAS; ANGELOCCI, 2012), conforme mostrado na Equação 2.1.

$$GHI = DNI \cdot \cos Z_h + DHI, \quad (2.1)$$

onde Z_h é o ângulo zenital em dado instante. O $\cos Z_h$ pode ser encontrado por meio da Equação 2.2:

$$\cos Z_h = \sen \phi \cdot \sen \gamma + \cos \phi \cdot \cos \gamma \cdot \cosh \quad (2.2)$$

em que ϕ é a latitude ($0^\circ a \pm 90^\circ$), γ é a declinação solar ($0^\circ a \pm 23,45^\circ$) e h é o ângulo horário $[(\text{Hora local} - 12) \cdot 15]$.

Por fim, a integral da irradiância no tempo é definida como irradiação solar ou radiação solar incidente ou energia radiante incidente acumulada em um intervalo de tempo e tem como unidade de medida padrão Wh/m^2 .

Neste trabalho, utilizou-se a nomenclatura *Irradiação Solar* e a notação estabelecida pelo INMET, já que os dados dessa variável foram disponibilizados em kJ/m^2 . Para efeito comparativo, o valor de 1 Wh (medida padrão) é equivalente a $3,6 \cdot 10^3 J = 3600 J = 3,6 kJ$.

A previsão precisa da Irradiação Solar em um local específico depende de vários fatores, como as condições do céu e a hora do dia. Como os dados medidos localmente nem sempre estão disponíveis, os modelos de previsão utilizando inteligência artificial são soluções viáveis. Podem ser modelos empíricos, métodos estatísticos, métodos baseados em satélite e modelos de inteligência artificial (RODRIGUES et al., 2018), como as Redes Neurais Artificiais.

É possível identificar diversos trabalhos nos quais estudos sobre radiação desempenham papéis importantes na produção de energia, crescimento da vegetação e mudanças climáticas e as RNAs têm sido amplamente utilizadas para estimar a sua incidência nos últimos anos. Por exemplo, no trabalho desenvolvido por Rahimikhoob (2010), o objetivo foi testar uma RNA para estimar a radiação solar global (GSR – *Global Solar Radiation*) em função dos dados da temperatura do ar em um ambiente semi-árido.

Na pesquisa desenvolvida por [Koca et al. \(2011\)](#), os autores utilizaram um modelo de RNA do tipo MLP com algoritmo de treinamento *Backpropagation* para estimar os parâmetros de radiação solar para sete cidades da região mediterrânea da Anatólia, na Turquia, país que tem intensidades de radiação solar suficientes para aplicações em energia solar. Utilizaram latitude, longitude, altitude, mês do ano e nebulosidade média como variáveis de entrada e, em suas considerações, os autores avaliam que o modelo de RNA é promissor para avaliar o potencial dos recursos fotovoltaicos em locais onde não existem estações de monitoramento na região mediterrânea da Turquia.

No trabalho de [Premalatha e Arasu \(2016\)](#), os autores também citaram a relevância do estudo sobre radiação solar e produção de energia limpa. Para a previsão, dados meteorológicos como latitude, longitude, altitude e a faixa de valores de radiação solar global mensal coletados nos últimos 10 anos a partir de 5 locais diferentes em toda a Índia foram usados para treinar os modelos. A partir da análise dos resultados, concluíram que a técnica e um dos algoritmos utilizados são adequados para a previsão precisa da radiação solar global média mensal.

Por fim, diversas combinações de variáveis como radiação solar global diária, temperatura mínima diária, temperatura máxima diária, diferença de temperatura máxima e mínima diária, horas de sol, horas teóricas de sol e radiação extraterrestre foram utilizadas em estudo realizado por [Rao K, Premalatha e Naveen \(2018\)](#), com dados coletados da cidade indiana de Tiruchirappalli. Os autores buscaram identificar a melhor combinação de entrada de dados para então estimar a radiação solar global média com precisão, comparando o um modelo baseado em RNA com métodos empíricos, provando que a ferramenta é mais precisa.

2.2 Fundamentos sobre Temperatura do Ar

A temperatura do ar é uma variável meteorológica, resultado de uma sensação térmica, que influencia ciclos hidrológicos, atmosféricos e energéticos ([SANIKHANI et al., 2018](#)). Mais especificamente, a temperatura do ar descreve a energia cinética ou energia de movimento dos gases que compõem o ar. Se as moléculas de gás se movem mais rapidamente, a temperatura do ar aumenta, caso contrário, diminui ([ŞAHIN, 2012](#)).

Tal variável, conceituada como descritor primário das condições ambientais terrestres ([GEIGER; ARON; TODHUNTER, 2003](#)), é convencionalmente medida em uma tela a uma altura padrão de 2 metros acima do solo. Isso ocorre porque os termômetros devem ser protegidos da luz solar direta e porque a temperatura varia com a altura acima do solo. Esse padrão busca homogeneizar as condições de medição, para que essa variável seja dependente unicamente das condições macroclimáticas, como latitude, altitude, cor-

rentes oceânicas, continentalidade/oceanidade, massas de ar e frentes, o que possibilita a comparação entre locais (LANDSBERG; SANDS, 2011).

De fato, grande parte da discussão sobre alterações do clima é dada em termos de variações na temperatura do ar próxima à superfície (HANSEN et al., 1981). A medição da variável é realizada dessa forma porque a maior parte da vida terrestre ocorre dentro da zona descrita no processo acima e a temperatura do ar regula muitos processos da superfície terrestre. Portanto, medições detalhadas das variações espaço-temporais na temperatura do ar são fundamentais para a compreensão efetiva dos processos climáticos e da vida terrestre (PRIHODKO; GOWARD, 1997).

Sua modelagem é uma tarefa primordial para aplicações práticas, como produção agrícola, projeto de edifícios com eficiência energética, aproveitamento de energia solar, avaliações de risco à saúde e análise da tendência de eventos climáticos extremos (SANIKHANI et al., 2018).

A previsão do comportamento da temperatura é primordial para o estudo da dinâmica de componentes interconectados da atmosfera e é considerada na maioria dos estudos sobre mudanças climáticas por conta da disponibilidade de dados de contínuos e robustos em muitas localizações do planeta (AHMADI et al., 2018).

A incidência de radiação solar está diretamente relacionada ao comportamento da temperatura do ar, já que o ângulo em que a radiação atinge a superfície terrestre é o fator mais importante que afeta o padrão de temperatura na Terra. Quanto mais o ângulo da radiação solar aumenta a direção em um ângulo reto, mais o ponto em que atinge fica quente. À medida que o ângulo de ataque contrai, o aquecimento diminui (ŞAHIN, 2012).

O ângulo da radiação solar que incide muda com a latitude. O sol brilha direto perto do equador, enquanto inclinado ao redor dos polos, então, a temperatura diminui quando há deslocamento do equador para os polos. Essa lei afirma que a latitude é relevante no cálculo da temperatura do ar. Além disso, o ângulo de incidência da radiação solar muda ao longo do ano, dependendo da inclinação axial e do movimento anual da Terra (ŞAHIN, 2012). A variação da temperatura do ar ao longo do dia está então diretamente ligada à incidência de energia solar e ao aquecimento da superfície do solo pelos raios solares.

O estudo do comportamento da temperatura do ar também tem uma relação (direta ou indireta) com outras variáveis climáticas importantes além de irradiação solar, como umidade do ar, velocidade do vento, precipitação, evaporação e transpiração. Portanto, uma análise de tendências da temperatura pode fornecer informações valiosas para o planejamento cuidadoso, por exemplo, da agricultura e gerenciamento de recursos hídricos em cada região do mundo (AHMADI et al., 2018).

Essa variável normalmente é medida em estações meteorológicas, com termômetros específicos, que dependem da infraestrutura regional para a coleta de dados climáticos.

A maioria das amostras de dados coletadas é pontual, cuja distribuição raramente é projetada para capturar a faixa de variabilidade climática dentro de uma região. As informações espaciais disponíveis sobre a temperatura do ar são muitas vezes limitadas, especialmente em regiões pouco povoadas e subdesenvolvidas (VANCUTSEM et al., 2010). A compensação por essa escassez de informações pode ser obtida por vários métodos computacionais, dentre eles o método de RNAs, como em pesquisas detalhadas a seguir.

A pesquisa de Smith, McClendon e Hoogenboom (2007) focou no desenvolvimento de modelos de RNA usando o algoritmo *Backpropagation* para redução do erro médio de previsão de temperatura do ar, aprimorando o modelo já existente e utilizado em estações meteorológicas da Rede de Monitoramento Ambiental Automatizado da Universidade da Geórgia, EUA. Os autores concluíram que os modelos de RNA devem ser treinados várias vezes com pesos iniciais diferentes para estabelecer os parâmetros preferidos do modelo.

O trabalho de Baboo e Shereef (2010) propôs o uso do algoritmo *Backpropagation* como modelo de previsão de temperatura e foi possível perceber que a RNA é uma ferramenta capaz de capturar e representar as relações complexas entre muitos fatores que contribuem para a temperatura e eficiente como um modelo de previsão. Os autores mostraram que o uso de RNAs apresentou bons resultados e pode ser considerado alternativa às abordagens tradicionais, capaz de determinar a relação existente entre os dados históricos fornecidos ao sistema durante a fase de treinamento.

Por conta dessa abordagem das RNAs, capazes de generalizar com sucesso padrões que não foram previamente capturados e de aprender e simular características imprevistas e não lineares de uma série temporal sem precisar de uma visão dos mecanismos subjacentes, Ashrafi et al. (2012) buscaram desenvolver um modelo neural para prever o aumento da temperatura devido às mudanças climáticas em escala regional, coletando dados de nove regiões climáticas do Irã. O aumento da temperatura média previsto usando uma rede Perceptron de Múltiplas Camadas (MLP - *Multilayer Perceptron*) com algoritmo *Backpropagation* é igual a 0,26 °C e o aumento da temperatura para a estação de Teerã é de 0,44 °C após 10 anos de integração (2008-2018) (ASHRAFI et al., 2012).

Venkadesh et al. (2013) também estudaram a previsão de temperatura do ar com base em modelos de RNA usando o algoritmo *Backpropagation* para cada horizonte de previsão. Na pesquisa, avaliaram ainda se a precisão do modelo de RNA poderia ser melhorada aplicando um Algoritmo Genético (GA) para determinar a duração e resolução dos dados de entrada para as variáveis ambientais.

Os autores Mba, Meukam e Kemajou (2016), analisaram a aplicação da RNA para previsão horária de temperatura e umidade relativa do ar em um horizonte de 24 a 168 horas em edifícios encontrados na região quente-úmida da cidade de Duala, Camarões. Os resultados mostram que a RNA pode efetivamente prever temperatura do ar e umidade relativa do ar. Os autores afirmam ainda que as maiores vantagens da RNA em comparação

com os métodos clássicos são a velocidade de cálculos e a capacidade de aprender com exemplos.

2.3 Análise Bibliométrica

A bibliometria se refere à metodologia de pesquisa empregada em biblioteconomia e ciência da informação, que utiliza análise quantitativa e estatística para descrever os padrões de distribuição de artigos dentro de um determinado tópico, campo, instituição ou país. Muitos pesquisadores utilizam estes métodos em estudos sobre tendências globais de campos específicos (VERGIDIS et al., 2005). Métodos bibliométricos têm sido aplicados para avaliar os resultados científicos ou padrões de pesquisa de autores, periódicos, países e instituições, além de identificar e quantificar a cooperação internacional e as tendências que determinado campo de pesquisa está seguindo (ABRAMO; CIRIACO; VIEL, 2018).

Com o entendimento de que a bibliometria é uma importante ferramenta de análise de impacto e relevância dos mais diversos temas até os dias atuais, esta seção realiza uma breve análise bibliométrica de alguns dos principais termos que fundamentam este trabalho, buscando evidenciar as redes de citações e sua evolução temporal, bem como os principais autores, possibilitando a inserção de pesquisas relevantes na composição do referencial teórico deste trabalho.

A fonte de coleta para a análise bibliométrica foi a plataforma online *Scopus*, escolhida por conta de sua multidisciplinaridade, com cerca de 22.600 jornais científicos indexados, possibilitando ainda a visualização da evolução do tema ao longo do tempo, bem como outras características gerais acerca do termo a ser buscado (ELSEVIER, 2019).

Assim, nesta seção buscou-se entender o panorama em que o tema desta pesquisa está inserido, suas tendências e correlações. Para isso, realizou-se uma análise bibliométrica em torno dos termos "*temperature*", "*solar radiation**", "*forecast**" e "*predict**" no período compreendido entre os anos de 2008 e 2019.¹ Ressalta-se ainda que, neste caso, optou-se por considerar a ocorrência dos termos no título, resumo e/ou palavras-chave, nos formatos de artigos e revisões e em todos os idiomas. A primeira sentença de busca inserida na base de dados *Scopus* foi:

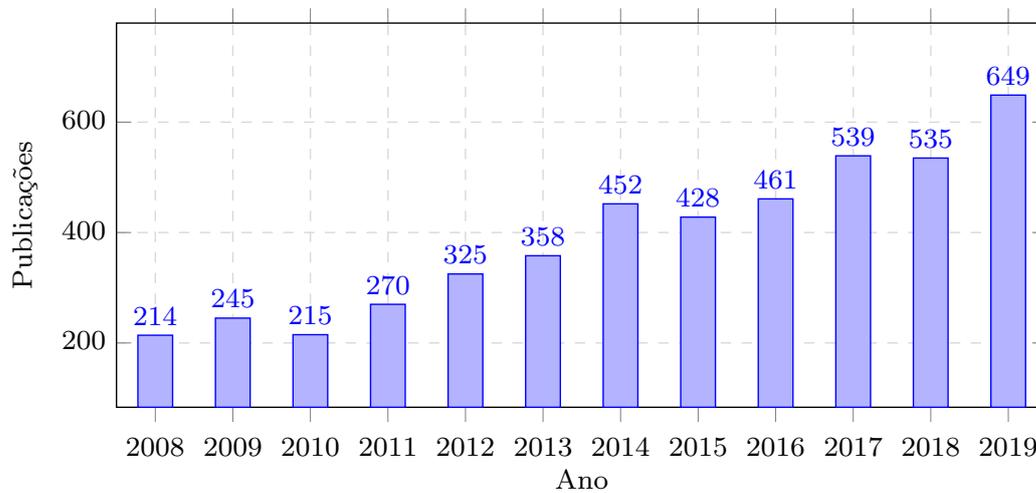
TITLE((temperature OR "solar radiation") AND ("forecast*"OR "predict*")) AND DOCTYPE (ar OR re) AND PUBYEAR > 2007 AND PUBYEAR < 2020*

Inicialmente, verificou-se a existência de 4.691 documentos que apresentavam os termos pré-selecionados. Ainda por meio de ferramenta disponível na base de dados *Scopus*, observou-se o comportamento das publicações ano a ano, como demonstrado na Figura 1,

¹ A presença do asterisco (*) permite a contagem também de possíveis variações no termo, como por exemplo sua forma no plural, abrangendo então mais trabalhos.

com 214 documentos em 2008 e, 11 anos depois, atingindo 649 publicações.

Figura 1 – Publicações por ano entre 2008 e 2019.

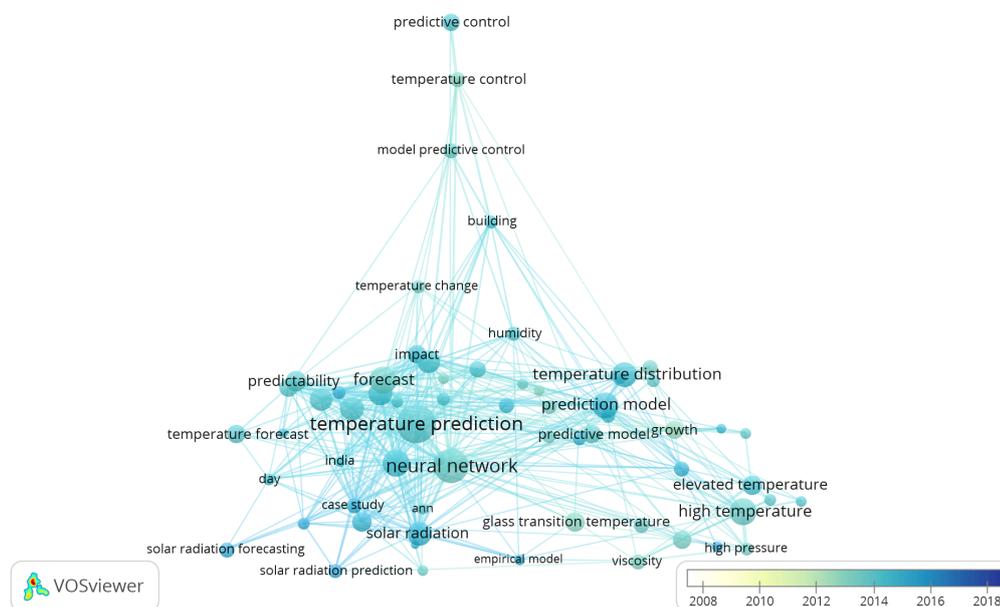


Fonte: Elaborado pela autora (2019).

Posteriormente, os dados foram compilados e exportados e inseridos no *software* de análise bibliométrica *VOSviewer* (versão 1.6.11) (ECK; WALTMAN, 2014). Optou-se por analisar a busca feita com base nos títulos dos 4.691 artigos importados para o programa, método que apresentou maior consistência na correlação de termos e, em seguida, o demonstrativo acerca dos autores que mais se destacam quanto à relevância de publicações correspondentes ao tema aqui abordado.

Ao destrinchar a análise bibliométrica com base nos títulos dos artigos, foram encontrados 3.256 termos, entre os quais 125 ocorreram pelos menos 12 vezes. Dentro dos 125 termos filtrados, são apresentados na Figura 2 os 80 mais relevantes. A seguir é apresentada a visão geral após o processamento dos dados no *VOSviewer*, sendo possível perceber a co-ocorrência de termos relevantes utilizados nesta pesquisa como "*neural network*", "*temperature prediction*", "*solar radiation forecasting*" e "*ann*". Na visualização por ano é possível perceber o uso de cada termo ao longo de um determinado período, de acordo com a data dos documentos de onde os termos foram extraídos.

Na Figura 3, é apresentada uma análise mais detalhada a respeito da relação entre os termos de busca que serviram como base para esta pesquisa e, ainda fazendo uso do *software VOSviewer*, é possível identificar a evolução dos termos por ano percebendo a temporalidade de uso de cada termo, de acordo com a data dos documentos de onde foram extraídos. Em destaque, o termo *neural network* evidencia outros termos fundamentais para este trabalho como "*climate change*", "*seasonal prediction*" e "*ann*", abreviação de "*artificial neural network*". Por meio da Figura 3 constata-se então a relevância das Redes Neurais Artificiais para o estudo de previsões climáticas de temperatura e radiação solar incidente, tendo em vista sua utilização por diversos pesquisadores.

Figura 2 – Mapa bibliométrico por ocorrência dos termos.

Fonte: Adaptado de *VOSviewer* (2019).

Atualmente, estudos sobre o clima têm motivado o interesse de cientistas de todas as partes do mundo, com trabalhos científicos impulsionados com o surgimento de marcos relacionados ao tema, crescendo em ritmo acelerado até os dias atuais. A análise anterior demonstrou a relação direta entre previsão de temperatura e radiação solar com as mudanças do clima, utilizando Redes Neurais Artificiais para previsão. Dito isto, optou-se então por realizar mais uma vez a busca na base de dados *Scopus*, visando delimitar ainda mais os resultados e destacar os principais autores e suas pesquisas. A sentença de busca inserida foi:

TITLE((ann OR "neural network") AND ("forecast*"OR "predict*"OR "model*"OR "estimat*") AND ("temperature"OR "solar radiation*")) AND DOCTYPE (ar OR re) AND PUBYEAR > 2007 AND PUBYEAR < 2020*

A seguir, são destacados na Figura 4 os principais autores que possuem trabalhos similares ao que é desenvolvido nesta pesquisa, referente aos anos de 2008 a 2019. Por meio desta análise é possível identificar 200 autores nos 73 trabalhos resultantes da busca e vários foram utilizados como referência para o desenvolvimento desta pesquisa.

A análise bibliométrica apresentada demonstrou a existência na literatura da relação direta entre ferramentas inteligentes na previsão do comportamento de variáveis climáticas. Por conta do caráter complexo das questões relacionadas às mudanças climáticas, é importante entender as interações que o tema possui com os demais, verificando se há uma relação viável, especialmente em um campo de pesquisa complexo como o de previsão climatológica, com uma grande variedade de ferramentas disponíveis para análise desse

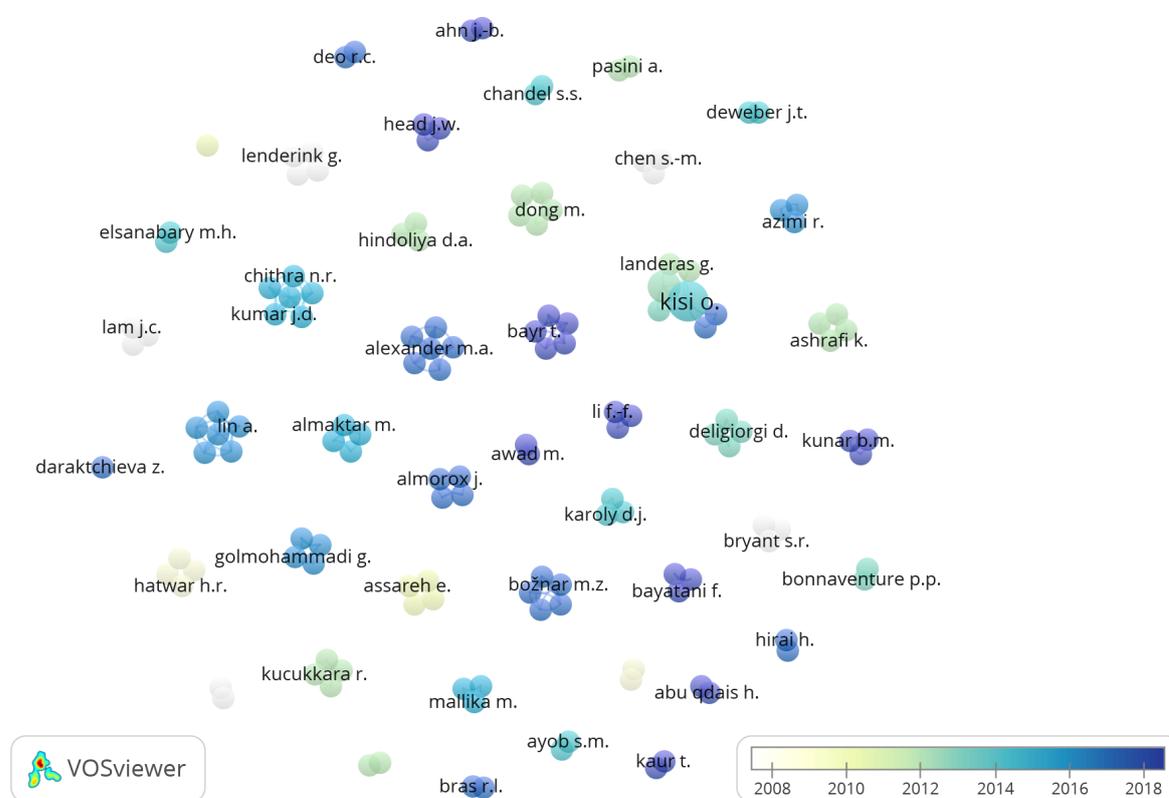
Tabela 1 – Modelos similares de previsão de Irradiação Solar

(LAM; WAN; YANG, 2008)	
Tipo de previsão:	Irradiação Solar
Local:	40 municípios da China
Horizonte:	+3 meses; +6 meses; +9 meses; +12 meses
Variáveis de entrada:	Dia; Latitude; Longitude; Altitude; Temperatura média diária e Duração normal da luz solar diária
Características da RNA:	Entre 20 e 30 anos de dados coletados; Algoritmo Backpropagation; Previsão de 4 períodos sazonais para cada município e para cada zona climática
Métricas de avaliação:	Por cidade: $GSR(MJ/m^2) = 0.41 \leq RMSE \leq 0.90$; Por zona climática $GSR(MJ/m^2) = 0.39 \leq RMSE \leq 0.95$
(ZOU et al., 2016)	
Tipo de previsão:	Irradiação Solar
Local:	10 estações na Região sudoeste da China
Horizonte:	+1 a +50 anos
Variáveis de entrada:	Irradiação Solar; Horas de duração da luz do sol; Temperatura média; Temperatura máxima; Temperatura mínima; Umidade relativa; Precipitação; Pressão do ar; Pressão do vapor de água; e Velocidade do vento
Características da RNA:	50 anos de dados em 60 estações meteorológicas comuns e comparados às medições de 10 estações exclusivas para Irradiação solar e Algoritmo Backpropagation
Métricas de avaliação:	$GSR((MJ/m^2) = 0.46 \leq RMSE \leq 0.73$
(DEO; ŞAHIN, 2017)	
Tipo de previsão:	Irradiação Solar
Local:	7 estações no estado de Queensland, Austrália
Horizonte:	+1 mês a +12 meses
Variáveis de entrada:	Altitude, Longitude, Latitude e Periodicidade solar
Características da RNA:	16 anos de dados coletados Algoritmo Levenberg-Marquardt Previsão por período sazonal
Métricas de avaliação:	$GSR(MJ/m^2) = 0.93 \leq RMSE \leq 1.85$; $GSR(MJ/m^2) = 0.62 \leq MAE \leq 1.58$
(LI; WANG, 2018)	
Tipo de previsão:	Irradiação Solar
Local:	Província de Quinghai, China
Horizonte:	+1 ano
Variáveis de entrada:	Informações contidas na sequência real de dados de irradiação solar exploradas pela técnica EMD (decomposição do modo empírico) como: termo de alta frequência, termo de baixa frequência e item de tendência
Características da RNA:	11 anos de dados coletados Algoritmo Backpropagation Previsão anual
Métricas de avaliação:	Previsão com dados diários: $GSR RMSE(kWh/m^2) = 0.58$ Previsão com médias mensais: $GSR RMSE(kWh/m^2) = 0.9843$

Tabela 2 – Modelos similares de previsão de Temperatura do Ar

(JOSHI; GANJU, 2012)	
Tipo de previsão:	Temperatura
Local:	4 observatórios na região ocidental do Himalaia
Horizonte:	+1 ano
Variáveis de entrada:	Temperatura máxima; Temperatura mínima; Temperatura do bulbo seco; Velocidade média do vento; Quantidade de nuvens; Quantidade de precipitação
Características da RNA:	20 anos de dados coletados Algoritmo Backpropagation Previsão de 1 período sazonal: inverno
Métricas de avaliação:	$T_{max} = 2.18 \leq RMSE(^{\circ}C) \leq 2.48$; $T_{min} = 1.99 \leq RMSE(^{\circ}C) \leq 2.78$
(CHITHRA et al., 2014)	
Tipo de previsão:	Temperatura máxima; Temperatura mínima
Local:	Kerala, Índia
Horizonte:	+1 a '+7 anos
Variáveis de entrada:	Umidade específica; Altura geopotencial; Temperatura do ar; Velocidade do vento; Umidade relativa; Temperatura da superfície do oceano; Pressão média do nível do mar; Pressão de superfície
Características da RNA:	16 anos de dados coletados; Algoritmo Levenberg-Marquardt; Previsão de 3 períodos sazonais para cada ano
Métricas de avaliação:	$T_{max} = 0.21 \leq RMSE(^{\circ}C) \leq 0.84$; $T_{max} = 0.35 \leq MAE(^{\circ}C) \leq 0.73$; $T_{min} = 0.47 \leq RMSE(^{\circ}C) \leq 0.93$; $T_{min} = 0.39 \leq MAE(^{\circ}C) \leq 0.81$
(SANIKHANI et al., 2018)	
Tipo de previsão:	Temperatura
Local:	45 localidades da Região Madhya Pradesh, Índia Central
Horizonte:	+1 ano
Variáveis de entrada:	Latitude, Longitude, Periodicidade ou o ciclo mensal
Características da RNA:	110 anos de dados coletados; Algoritmo Backpropagation; Previsão mensal e projeção anual
Métricas de avaliação:	$T = 0.104 \leq RMSE(^{\circ}C) \leq 0.732$
(NEZHAD; FALLAH-GHALHARY; BAYATANI, 2019)	
Tipo de previsão:	Temperatura máxima
Local:	Teerã, Irã
Horizonte:	+1 a '+18 anos
Variáveis de entrada:	Média mensal de temperatura máxima, Diferença entre temperaturas máximas e mínimas, Horas de sol, Velocidade do vento, Umidade relativa média e Temperaturas médias
Características da RNA:	60 anos de dados coletados de uma estação meteorológica; Algoritmo Backpropagation
Métricas de avaliação:	$T = 0.104 \leq RMSE(^{\circ}C) \leq 0.112$; $T = 0.26 \leq MAE(^{\circ}C) \leq 0.31$

Figura 4 – Mapa de citações entre 2008 e 2019



Fonte: Adaptado de *VOSviewer* (2019).

Capítulo 3

Locais de Estudo

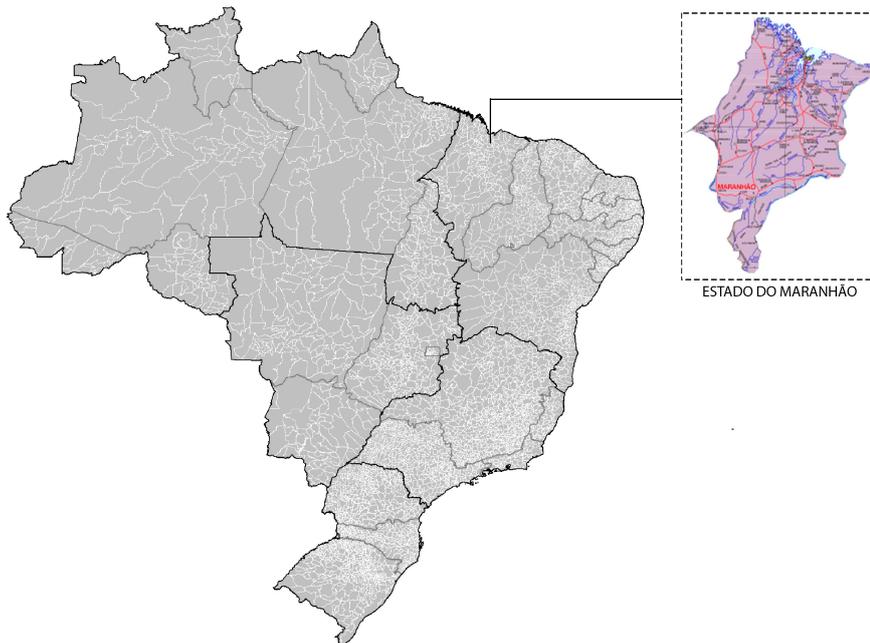
3.1 Características Gerais e Climáticas

Localizado na macrorregião Nordeste do Brasil, entre as coordenadas de 01°01' a 10°21' lat. S e 41°48' a 48°40' long. W, o estado do Maranhão (Figura 5) teve sua conformação territorial definida em 1920, caracterizando-se geo-político-fisicamente como uma área de transição (FERREIRA; MORAES, 2008). Abrange uma área de 331.983 km², limitando-se a norte com o Oceano Atlântico, a leste com o Piauí, a sul e sudoeste com o Tocantins e a noroeste com o Pará. O estado possui atualmente uma população estimada em 7.035.055 habitantes (IBGE, 2019c), densidade demográfica de 21,19 habitantes por km² e concentra 217 municípios em seu território (IBGE, 2019c). O território maranhense ocupa a segunda maior dimensão espacial do Nordeste (1.554,3 mil km²), correspondendo a 21,4% da área total dessa Região. Em relação ao Brasil, ocupa o oitavo lugar em extensão, respondendo por 3,9% da área do país (8.515,8 mil km²).

A regionalização federal do Maranhão obedece aos critérios estabelecidos pelo Instituto Brasileiro de Geografia e Estatística (IBGE), de acordo com o processo de transformação do espaço nacional e da estrutura produtiva (LEÃO; JÚNIOR, 2018), que resultou em uma divisão do Estado em 5 regiões geográficas intermediárias subdivididas em 22 regiões geográficas imediatas, compreendendo os 217 municípios.

O estado do Maranhão é formado por três biomas que caracterizam o território brasileiro, a Amazônia (34,8%), o Cerrado (64,1%) e a Caatinga (1,1%), possuindo uma diversificada e rica base de recursos naturais (LEÃO; JÚNIOR, 2018). Conforme a Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA), o Maranhão ocupa uma região transicional entre condições mais secas que caracterizam o semiárido do Nordeste para as condições úmidas do Norte e da Amazônia (EMBRAPA, 2013).

O Mapa de Climas fornecido pelo IBGE, apresentado na Figura 6, utiliza a classifi-

Figura 5 – Localização do estado do Maranhão.

Fonte: Adaptado de [IBGE \(2019a\)](#).

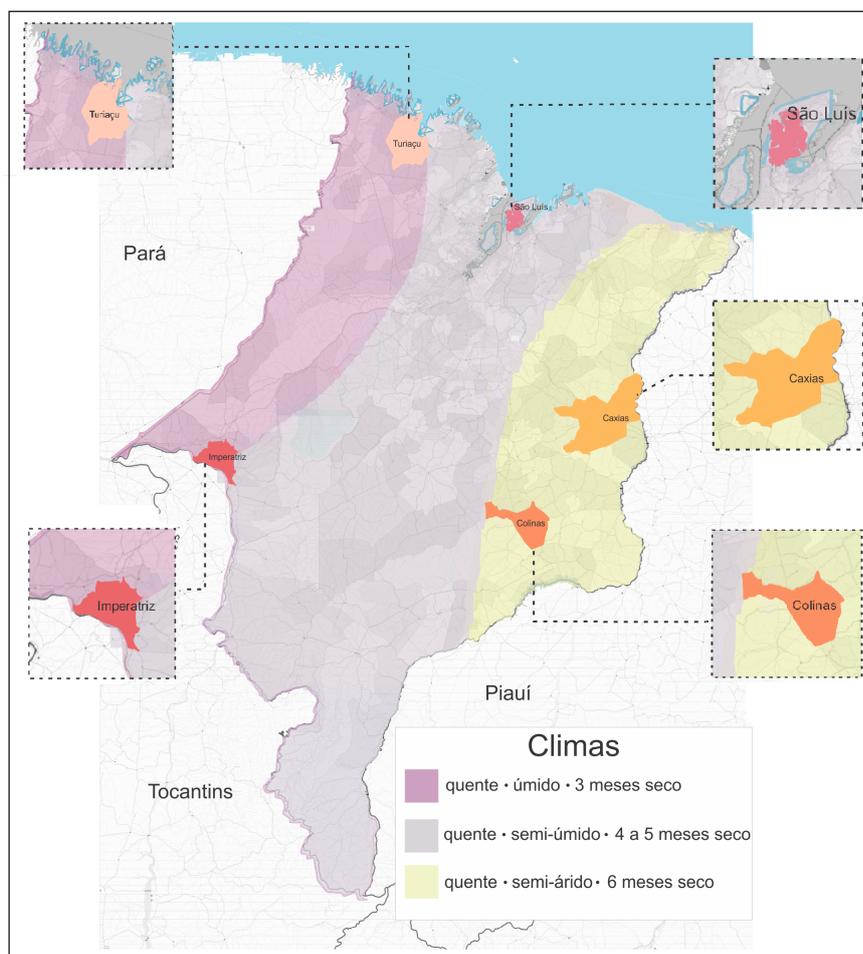
cação de Nimer (1972) e representa de maneira clara as três diferentes zonas climáticas do território maranhense agrupadas por temperatura e umidade, identificando ainda os tipos climáticos, caracterizados por tons e sobretons.

Ainda na Figura 6, são apresentadas, em destaque, as cidades objeto desta pesquisa. A motivação da escolha deu-se pelo fato de elas possuírem estações de coleta de dados do Instituto Nacional de Meteorologia e por cada uma delas representar um tipo climático do estado, tendo a oportunidade de analisar ainda duas cidades em zonas de transição entre esses 3 tipos de clima.

O método de Nimer ([NIMER, 1979](#)) classifica o clima quantitativamente, utilizando-se da temperatura e precipitação, e qualitativamente, por considerar a quantidade de meses secos (distribuição da pluviosidade) e a circulação atmosférica. Este sistema classificatório é composto por três partes:

1. Delimitação em conformidade com a variedade térmica;
2. Classificação quanto ao maior ou menor grau de umidade, considerando-se a existência ou não de estação seca ou de estação subseca;
3. Entendimento da circulação atmosférica, análise do regime da distribuição das chuvas e temperatura durante as estações e a relação com suas fontes dinâmicas de origem.

As condições climáticas no Maranhão são características de uma área de transição

Figura 6 – Mapa climático do estado do Maranhão

Fonte: Adaptado de [IBGE \(2019a\)](#).

no sentido sudeste (SE) para noroeste (NW). Os movimentos de avanço e recuo das massas de ar predominantes no estado têm maior penetração pelas partes mais baixas e pelas bacias hidrográficas perpendiculares ao litoral. Na análise da distribuição das temperaturas em relação aos meses do ano, duas condições devem ser consideradas: litoral e interior ([EMBRAPA, 2013](#)).

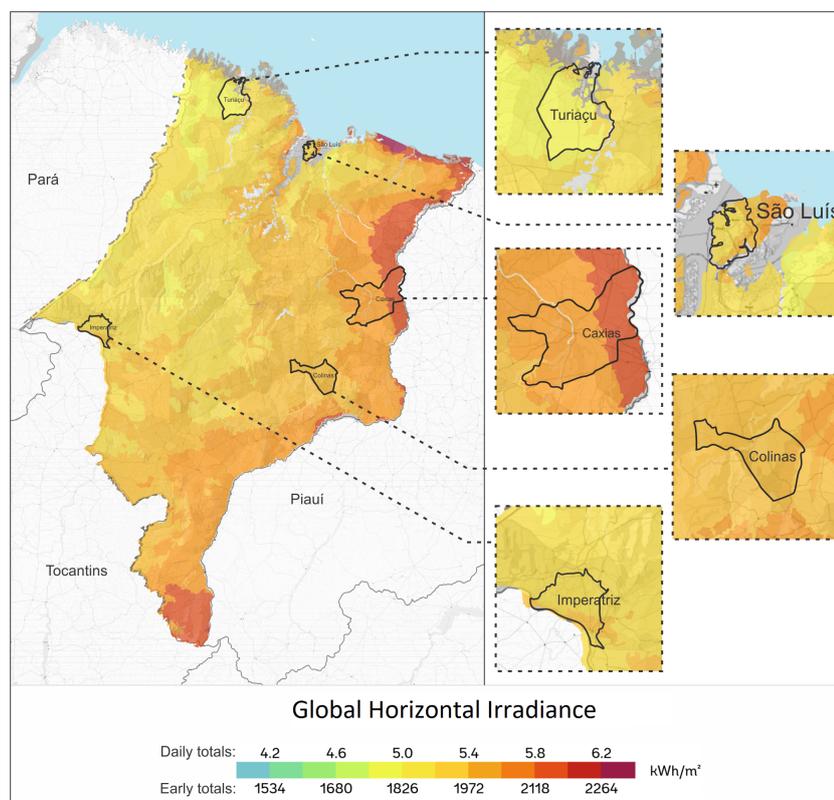
No litoral, as temperaturas mais altas ocorrem no período que antecede as chuvas, com menores médias de nebulosidade e aumento de insolação. No outono acontece o inverso, com ocorrência de temperaturas relativamente mais baixas ([UEMA, 2002](#)). No interior do estado, a redução da nebulosidade contribui para o aumento das médias das temperaturas para esse período. Além disso, o efeito de continentalidade faz com que as amplitudes térmicas sejam maiores no interior e possam apresentar-se quase como o dobro das amplitudes do litoral ([LEITE, 1978](#)).

Por meio da Figura 7 é possível notar que o estado do Maranhão apresenta alta

incidência de radiação solar, fator que lhe confere grande potencial de energia solar disponível no Brasil, com a incidência de radiação variando entre 5,0 e em 5,8 kWh/m².

A Irradiação solar é determinada pelos fatores como por exemplo, declinação solar e comprimento do dia, por propriedades atmosféricas (incluindo nebulosidade, vapor de água e aerossol) e em menor medida pelas condições da superfície (uso da terra, sombreamentos, albedo e orografia). O fluxo solar radiativo que atinge a superfície da Terra é influenciado principalmente, pela variabilidade espaço-temporal das nuvens (DUBAYAH; LOECHEL, 1997).

Figura 7 – Mapa de GHI do estado do Maranhão



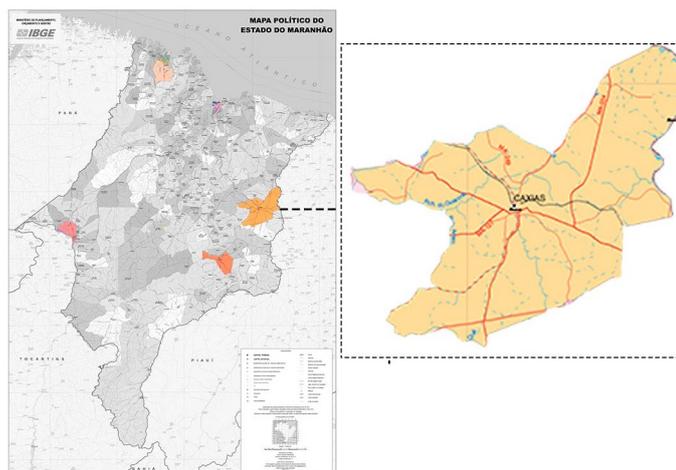
Fonte: Adaptado de SOLAR GIS (2019).

A sua localização transicional contribui para a geração de condições ambientais e socioeconômicas diversas, atualmente em fase de transformação em decorrência do desenvolvimento da região e que vem gerando impactos ambientais e sociais. Devido a isto, as características gerais do estado do Maranhão são diversificadas e tais cenários apresentam-se como indicativos para a elaboração de políticas públicas ambientais, sociais e econômicas distintas para cada situação climático-sazonal observada no estado. Então, a seguir, serão apresentados os aspectos gerais e climáticos das cinco cidades localizadas no estado do Maranhão e objetos de estudo desta pesquisa com relação a cada variável a ser prevista, proporcionando diversidade na análise dos vários componentes climáticos do estado do Maranhão.

3.1.1 Caxias

O município de Caxias, fundado em 05/07/1836 e inserido na região geográfica intermediária de Caxias e na região geográfica imediata de Caxias (IBGE, 2017), compreende uma área de 5.196 km², uma população de aproximadamente 155.129 habitantes e uma densidade demográfica de 30,12 habitantes/km², segundo dados do IBGE (2010a).

Figura 8 – Localização do município de Caxias



Fonte: Adaptado de IBGE (2019b).

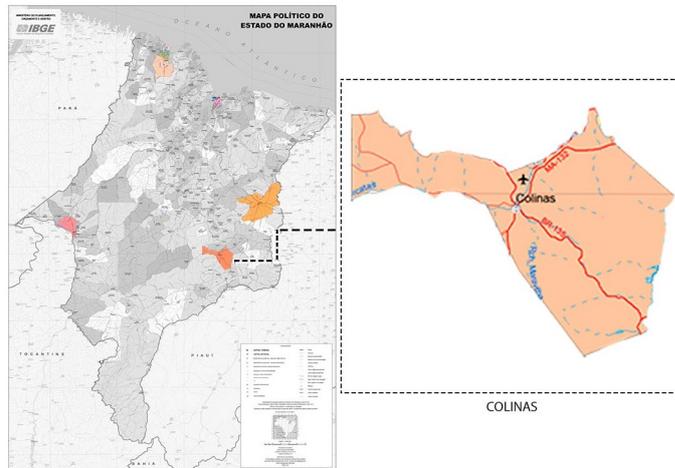
Localizado no leste maranhense, o município de Caxias representa o clima quente e semiárido conforme a classificação de Nimer (NIMER, 1979); possui clima tropical, classificado como Aw de acordo com a classificação Köppen e Geiger, ou seja, clima tropical de savana com estação seca no período em que o Sol está mais baixo (está no hemisfério oposto) e os dias são mais curtos. O índice de pluviosidade no inverno é menor que no verão e 27.4°C é a temperatura média em Caxias, com 1.391 mm de pluviosidade média anual (CLIMATE DATA, 2019).

Em Caxias, a energia solar de ondas curtas incidente diária média também passa por variações sazonais moderadas ao longo do ano.

3.1.2 Colinas

O município de Colinas foi fundado em 04/06/1870 e está inserido na região geográfica intermediária de Presidente Dutra e na região geográfica imediata de Colinas (IBGE, 2017), compreendendo uma área de 1.981 km², uma população de aproximadamente 39.132 habitantes e uma densidade demográfica de 19,76 habitantes/km² (IBGE, 2010b).

Colinas representa a transição entre o clima quente e semi-árido e o clima quente e semiúmido (NIMER, 1979); possui clima tropical e há muito menos pluviosidade no

Figura 9 – Localização do município de Colinas

Fonte: Adaptado de [IBGE \(2019b\)](#).

inverno que no verão, também é classificado como Aw de acordo com a Köppen e Geiger. Em Colinas a temperatura média é 27.1°C e a pluviosidade média anual é 1.230 mm ([CLIMATE DATA, 2019](#)).

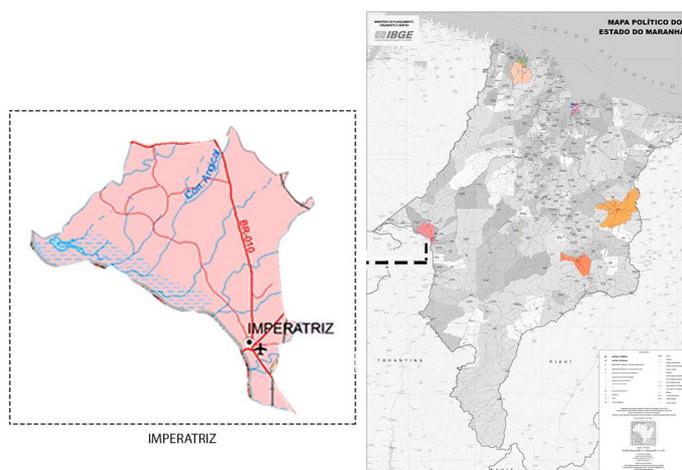
Em Colinas, a energia solar de ondas curtas incidente diária média passa por variações sazonais moderadas ao longo do ano.

3.1.3 Imperatriz

O município de Imperatriz, segundo maior centro político do estado do Maranhão, emancipado em 27/08/1856, está inserido na região geográfica intermediária de Imperatriz e na região geográfica imediata de mesmo nome ([IBGE, 2017](#)). Abrange uma área de 1.369 km², com uma população de aproximadamente 247.505 habitantes e uma densidade demográfica de 180,79 habitantes/km² ([IBGE, 2010c](#)).

Segunda cidade mais populosa do estado, Imperatriz representa a transição entre o clima quente e semiúmido e o clima quente e úmido ([NIMER, 1979](#)), tropical e há muito menos pluviosidade no inverno que no verão. De acordo com a Köppen e Geiger o clima é classificado como Aw. 26.4°C é a temperatura média em Imperatriz e 1.476 mm é a pluviosidade média anual ([CLIMATE DATA, 2019](#)).

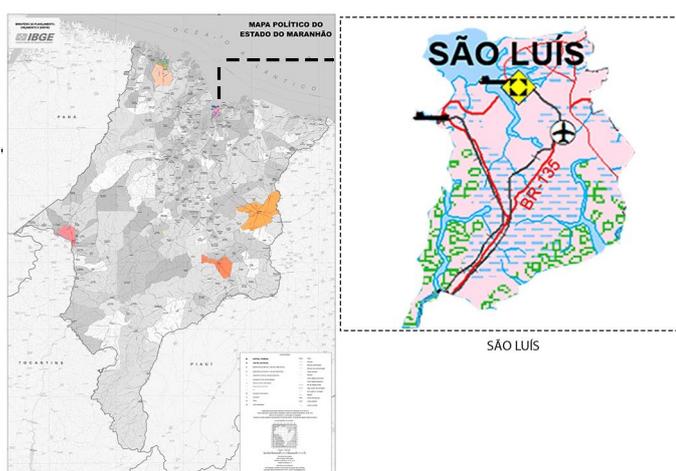
No município, a energia solar de ondas curtas incidente diária média também passa por variações sazonais moderadas ao longo do ano.

Figura 10 – Localização do município de Imperatriz

Fonte: Adaptado de [IBGE \(2019b\)](#).

3.1.4 São Luís

Capital do estado do Maranhão, o município de São Luís foi fundado em 08/09/1612, está inserido na região geográfica intermediária de São Luís e na região geográfica imediata de São Luís ([IBGE, 2017](#)). Abrange uma área de 582,97 km², com uma população de aproximadamente 1,014.837 habitantes e uma densidade demográfica de 1215,69 habitantes/km² ([IBGE, 2010d](#)).

Figura 11 – Localização do município de São Luís

Fonte: Adaptado de [IBGE \(2019b\)](#).

O município de São Luís possui um clima quente e semiúmido ([NIMER, 1979](#)), tropical e chove muito mais no verão que no inverno. O clima do local é Aw de acordo com a classificação de Köppen e Geiger. São Luís tem uma temperatura média de 27°C. A

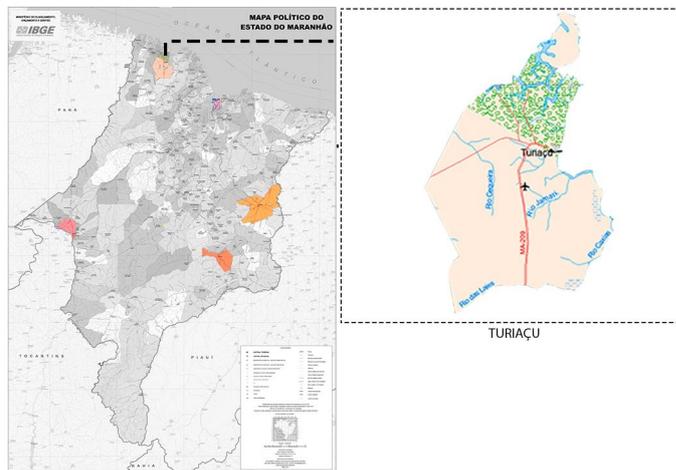
média anual de pluviosidade é de 1.896 mm (CLIMATE DATA, 2019).

No caso deste município, a energia solar de ondas curtas incidente diária média também passa por variações sazonais moderadas ao longo do ano.

3.1.5 Turiaçu

O município de Turiaçu teve sua autonomia política em 03/06/1935 e está inserido na região geográfica intermediária de São Luís e na região geográfica imediata de Pinheiro (IBGE, 2017), compreendendo uma área de 2.592 km², uma população de aproximadamente 33.933 habitantes e uma densidade demográfica de 13,16 habitantes/km² (IBGE, 2010e).

Figura 12 – Localização do município de Turiaçu



Fonte: Adaptado de IBGE (2019b).

Turiaçu, localizada na região oeste do estado, é caracterizada pelo clima quente e úmido (NIMER, 1979), tropical e chove muito menos no inverno que no verão. O clima é classificado como Aw de acordo com a Köppen e Geiger. A temperatura média anual em Turiaçu é 27°C. A pluviosidade média anual chega a 2.169 mm (CLIMATE DATA, 2019).

Assim como as cidades previamente descritas, a energia solar de ondas curtas incidente diária média do município de Turiaçu também passa por variações sazonais moderadas ao longo do ano.

Capítulo 4

Séries Temporais e RNAs

4.1 Séries Temporais e modelos de previsão

A previsão pode ser vista como um processo fundamental no desenvolvimento do planejamento, tomada de decisão e controle de processos. Para utilizar essa técnica, seja por meio de métodos estatísticos ou inteligência artificial, é fundamental que se tenha conhecimento a respeito dos dados com os quais se deseja trabalhar. A análise da série temporal vem então aumentar a capacidade de tomar decisões rápidas e precisas, buscando qualidade ao extrair informações relevantes dos dados.

Os métodos de previsão de uma série temporal podem ser divididos em métodos qualitativos e métodos quantitativos, sendo classificados quanto ao tipo de instrumento utilizado e quanto aos conceitos que formam a base de previsão (ARMSTRONG, 2000). Os métodos qualitativos também são conhecidos como intuitivos ou subjetivos, dependem da experiência acumulada por especialistas ou por um grupo de pessoas para prever a probabilidade do resultado dos eventos (ARCHER, 1980). Esses métodos são mais apropriados quando os dados são insuficientes ou inadequados para processar uma análise quantitativa (DAVIS; CHASE; AQUILANO, 2001). Já os métodos quantitativos, também chamados de objetivos ou matemáticos, se baseiam em dados históricos e assumem que estas informações de períodos passados são importantes para prever o futuro, utilizando modelos matemáticos para se chegar aos valores previstos (GAITHER; FRAZIER, 2002).

Os métodos quantitativos podem ainda ser subdivididos em causais e análise de séries temporais ou extrapolação. Os métodos causais descrevem a demanda como função de variáveis independentes, ou seja, buscam relacionar as demandas (variável dependente) com outros fatores tais como PIB, inflação, clima, perfil de população, denominados variáveis independentes e, para isso, são utilizadas técnicas de regressão linear e não linear (MURDICK; GEORGOFF, 1993). As séries temporais ou históricas são formadas por conjuntos de observações sequenciais no tempo acerca de um fenômeno, com a variável

tempo podendo ser substituída por outra, como espaço, profundidade, etc, em que as observações vizinhas são, em geral, dependentes e o estudo de séries temporais pretende analisar e modelar essa dependência. Uma série temporal pode ainda ser definida como um conjunto de observações de qualquer fenômeno aleatório ordenadas no tempo, em que o espaço de tempo entre os dados disponíveis possui a mesma distância (horário, diário, semanal, mensal, trimestral, anual, etc.) (BAYER; SOUZA, 2010).

Séries temporais e modelos dinâmicos podem ser utilizados em quatro áreas de aplicação distintas (BOX et al., 2015):

- A previsão de valores de uma série temporal dados valores anteriores e correntes;
- A determinação da função de transferência de um sistema sujeito a inércia – a determinação de um modelo entrada-saída (*input-output*) que permite mostrar no resultado de um sistema o efeito de qualquer série de valores da entrada dada;
- O uso de variáveis de entrada, indicadores nos modelos de funções de transferência para a representação e avaliação dos efeitos de eventos de intervenção invulgares no comportamento da série temporal;
- O desenho de esquemas de controle, por meio dos quais os potenciais desvios dos valores de saída do sistema obtidos a partir de um objetivo pretendido poderão, se possível, ser compensados pelo ajustamento dos valores de entrada da série.

Bayer e Souza (2010) conceituam ainda a análise de séries temporais como o estudo que consiste em buscar alguma relação de dependência existente temporalmente nos dados, identificando o mecanismo gerador da série com o objetivo de extrair periodicidades relevantes nas observações, descrever o seu comportamento e fazer previsões.

Morettin e Tolo (2006) destacam os objetivos da análise de séries temporais, como o de investigar o mecanismo gerador da série temporal, descrever o comportamento da série verificando a existência de tendências, ciclos e variações sazonais, procurar periodicidades relevantes nos dados e fazer previsões de valores futuros da série (de curto ou longo prazo).

Morettin e Tolo (2006) afirmam que uma das suposições mais frequentes a respeito de séries temporais é a de que elas sejam estacionárias, ou seja, se desenvolvam “no tempo aleatoriamente ao redor de uma média e variância constantes, refletindo alguma forma de equilíbrio estável”. Entretanto, segundo os mesmos autores, a maioria das séries encontradas não é estacionária. Como exemplo desse tipo de série está aquela que flutua com inclinação positiva ou negativa ao redor de uma reta (tendência linear). Caso a série observada não seja estacionária, ou seja, possua variância desestabilizada, é necessário transformar os dados tomando-se diferenças sucessivas da série original até se obter uma série estacionária.

Segundo [Makridakis, Wheelwright e Hyndman \(1998\)](#), existem quatro tipos de padrões de séries temporais:

- Horizontal: quando os valores dos dados flutuam ao redor de uma média constante. Representam movimentos ascendentes e descendentes da série após a ocorrência de um efeito de tendência, um efeito cíclico ou de um efeito sazonal;
- Inclinado (tendência): quando se verifica um crescimento ou decréscimo, em longo prazo, no valor dos dados. Produzem mudanças graduais a longo prazo e são normalmente provocadas, por exemplo, pelo crescimento constante da população, pelo efeito da competição ou por outros fatores que falham na tentativa de produzir mudanças repentinas, mas produzem variações graduais e regulares ao longo do tempo;
- Cíclico: está presente em uma série temporal quando os dados exibem crescimentos e quedas que não se repetem em um intervalo de tempo fixo. Provocam oscilações de subida e de queda nas séries, de forma suave e repetitiva ao longo da componente de tendência;
- Sazonal: são as oscilações de subida e de queda que sempre ocorrem em um determinado período do ano, do mês, da semana ou do dia. A diferença essencial entre as componentes sazonais e cíclicas é que as sazonais possuem movimentos facilmente previsíveis, ocorrendo em intervalos regulares de tempo, por exemplo, ano a ano, mês a mês, semana a semana ou mesmo dia a dia. Já os movimentos cíclicos tendem a ser irregulares, ocorrendo sobre um período de muitos anos.

Os modelos para as séries temporais podem ainda ser divididos em duas classes, conforme o número de parâmetros envolvidos. Os modelos paramétricos, para os quais este número de parâmetros é finito e a análise é feita no domínio do tempo. Dentre estes modelos os mais frequentemente usados são os modelos de erro (ou de regressão), os modelos auto-regressivos e de médias móveis (ARMA), os modelos auto-regressivos integrados e de médias móveis (ARIMA), modelos de memória longa (AFIRMA), modelos estruturais e modelos não lineares. Os modelos não-paramétricos, que envolvem um número infinito de parâmetros, os mais utilizados são a função de autocovariância (ou autocorrelação) e sua Transformada de Fourier, ou espectro. Do ponto de vista matemático, essas funções são pares de Fourier e são, portanto, equivalentes ([MORETTIN; TOLOI, 2006](#)).

Como as previsões baseadas em séries temporais partem do princípio de que a demanda futura será uma projeção do passado, um dos objetivos da análise de séries temporais é obter modelos de previsão baseados na avaliação dos dados históricos ([VIGLIONI, 2007](#)).

Para realizar uma análise (ou previsão) de uma série temporal utilizando procedimentos estatísticos, uma modelagem matemática é necessária. Aliado a isto, tem-se o fato

de que as técnicas estatísticas para previsão e tomada de decisão não têm bons resultados para muitas aplicações que possuem tamanho de amostras restrito e com alguma não linearidade no conjunto de dados (REFENES et al., 1993).

Em função deste desempenho, considerado apenas moderado, dos métodos estatísticos convencionais para previsão de séries temporais, surgiu a necessidade de procurar formas alternativas de previsão. As Redes Neurais Artificiais, dentre as muitas técnicas que surgiram, destacam-se por conta de sua habilidade de aprendizado e sua capacidade de generalização, associação e busca paralela. Estas qualidades as tornam capazes de identificar e assimilar as características mais marcantes das séries, tais como sazonalidade, periodicidade, tendências, entre outras, na maioria das vezes camufladas por ruídos, sem necessitar de um complexo passo da formulação teórica, imprescindível para os procedimentos estatísticos (ROITMAN, 2001).

4.2 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs) são sistemas inspirados na estrutura de funcionamento do cérebro e dos neurônios biológicos. Foram desenvolvidas por conta da observação em torno da facilidade e eficácia com o que o cérebro realiza tarefas difíceis e complexas. As RNAs resolvem problemas onde é difícil criar modelos adequados à realidade ou, então, situações que mudam muito (problemas não lineares), sem a necessidade de se definir regras ou modelos explícitos. São capazes de aprender com a experiência e fazer generalizações baseadas no seu conhecimento previamente acumulado. Ainda são capazes de atuar como mapeadores universais de funções multivariadas, com custo computacional que cresce apenas linearmente com o número de variáveis (BRAGA; LUDEMIR; CARVALHO, 2007).

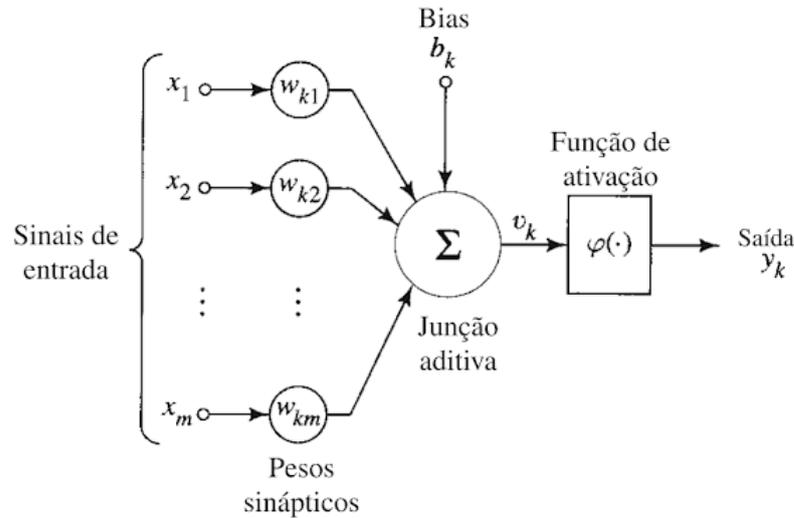
A vantagem da simulação da Rede Neural Artificial em relação a um modelo matemático padrão é que ela não requer o conhecimento dos parâmetros internos do sistema, envolve menos esforço computacional e oferece uma solução compacta para problemas de múltiplas variáveis (BELU, 2012).

As RNAs se desenvolveram rapidamente em suas aplicações às mudanças climáticas globais e fatores relacionados ao meio ambiente. Abordagens baseadas em RNAs têm sido aplicadas cada vez mais à hidrologia, ecologia, mudanças na qualidade do ar urbano e na previsão de dados climáticos, dentre eles temperatura e irradiação solar (ASHRAFI et al., 2012; KOCA et al., 2011; MBA; MEUKAM; KEMAJOU, 2016; VENKADESH et al., 2013; ZHUANG et al., 2013).

4.2.1 Neurônio artificial e funções de ativação

Um neurônio artificial é uma tentativa de modelagem do comportamento de um neurônio biológico. Conforme a Figura 13, que é a base de um neurônio artificial, é possível identificar três elementos básicos do modelo de um neurônio (HAYKIN, 2007):

Figura 13 – Representação de um neurônio artificial



Fonte: Haykin (2007)

1. Um conjunto de sinapses, onde cada uma é caracterizada por determinado peso. Especificamente, um sinal de entrada x_j da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} ;
2. Uma soma para adicionar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio. A operação descrita constitui um *combinador linear*;
3. Uma função de ativação (chamada de φ) para limitar a amplitude da saída do neurônio. A função de ativação é capaz de restringir (ou limitar) a amplitude permitida do sinal de saída para algum valor finito.

O modelo de neurônio inclui também o *bias*, denotado por b_k . O *bias* tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente.

Em termos matemáticos, o neurônio pode ser escrito da seguinte maneira:

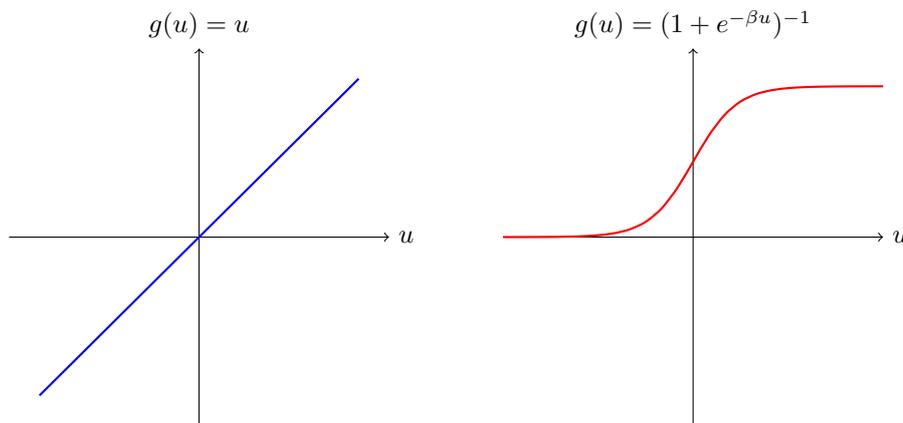
$$u_k = \sum_{j=1}^m w_{kj} x_j \quad (4.1)$$

$$y_k = \varphi(u_k + b_k) \quad (4.2)$$

onde x_1, x_2, \dots, x_m são os sinais de entrada; $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos do neurônio k ; u_k é a saída do combinador linear devido aos sinais de entrada, b_k é o *bias*; $\varphi(\cdot)$ é a função de ativação; e y_k é o sinal de saída do neurônio. O uso do *bias* b_k tem o efeito de transformar u_k em uma função afim, ou seja, $v_k = u_k + b_k$.

O objetivo da função de ativação é limitar a saída do neurônio dentro de um intervalo que tenha valores razoáveis a serem assumidos por sua própria imagem funcional. As funções de ativação utilizadas neste trabalho são descritas na sequência:

Figura 14 – Representação de uma função de ativação linear



Fonte: Elaborado pela autora.

4.2.2 Arquitetura

As Redes Neurais Artificiais se diferenciam pela sua arquitetura e pela forma como os pesos associados às conexões são ajustados durante o processo de aprendizado (HAYKIN, 2007).

A arquitetura de uma rede neural artificial define a forma como seus diversos neurônios estão arranjados em relação a outros neurônios. Esses arranjos são estruturados essencialmente através do direcionamento das conexões sinápticas dos neurônios (SILVA; SPATTI; FLAUZINO, 2010).

Para definir a arquitetura de determinada RNA, são considerados parâmetros como o tipo de conexão entre os nós, em que se tem uma rede fracamente (ou parcialmente) conectada ou uma rede completamente conectada. Outro parâmetro é o número de camadas da rede, que pode ser de camada única ou de de múltiplas camadas. Por fim, uma RNA pode ainda ser caracterizada pela topologia da rede, que pode ser *feedforward* (acíclica) ou *feedback* (cíclica) (SILVA; SPATTI; FLAUZINO, 2010).

A respeito da topologia de uma RNA, sabe-se que ela depende da forma como os neurônios se conectam para formar uma rede, ou seja, as diferentes estruturas que eles

podem assumir. Na topologia de redes do tipo *feedforward*, os dados de entrada alimentam a rede e são propagados para frente até que as saídas dos nós da última camada sejam obtidas, considerando-se fixos todos os parâmetros da rede. Já na fase do tipo *feedback*, o desvio entre a resposta desejada e a resposta fornecida pela rede é utilizado para ajustar os pesos das conexões da rede, ou seja, as saídas dos neurônios são realimentadas e servem como sinais de entrada para outros neurônios.

4.2.3 Aprendizado

O aprendizado de uma RNA decorre do conjunto de passos ordenados que visam o treinamento da rede através da apresentação de amostras às suas unidades visíveis. Ele é o algoritmo que modifica o valor dos pesos para garantir que a RNA responda adequadamente ao problema proposto (SILVA; SPATTI; FLAUZINO, 2010).

Já o objetivo do treinamento consiste em atribuir os pesos sinápticos com valores apropriados, de modo a produzir o conjunto de saídas desejadas ou ao menos consistentes com um intervalo de erro estabelecido (FREEMAN, 1991). O treinamento de uma RNA é classificado em dois tipos:

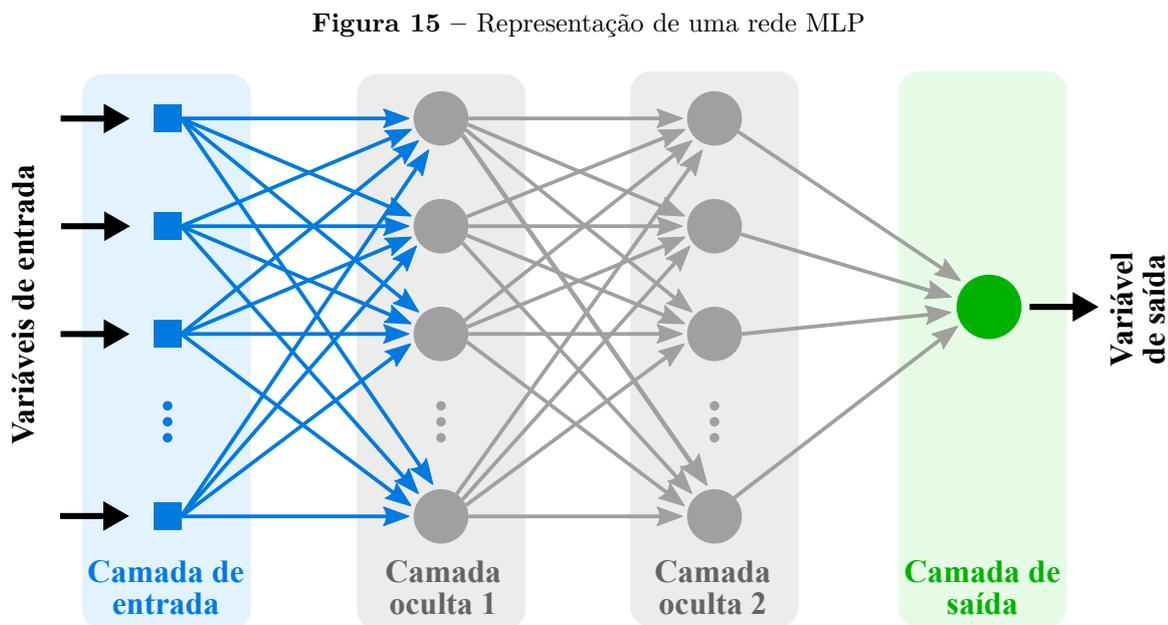
- Não supervisionado – não há um supervisor que acompanhe o processo ou não há exemplo da função a ser aprendida pela rede. Neste caso, a própria rede deve se organizar para analisar as características dos componentes das amostras, identificando subconjuntos (*clusters*) que contenham similaridades (SILVA; SPATTI; FLAUZINO, 2010).
- Supervisionado – teve sua primeira estratégia desenvolvida por Donald Hebb em 1949 e consiste em fornecer as entradas e saídas desejadas para a rede com o objetivo de ajustar seus parâmetros. A saída corrente é comparada com a saída desejada, ajustando-se os pesos das conexões para diminuir o erro em cada entrada na rede. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a Regra Delta e a sua generalização para redes de múltiplas camadas e o algoritmo *Backpropagation* (BRAGA; LUDEMIR; CARVALHO, 2007);

O principal atrativo de uma RNA para solucionar problemas é o de possuir a capacidade de aprender através de exemplos e generalizar a informação aprendida. A generalização está associada à capacidade de a rede aprender por meio de um conjunto reduzido de exemplos e em seguida dar respostas coerentes para dados não-conhecidos (BRAGA; LUDEMIR; CARVALHO, 2007).

4.2.4 Rede Multilayer Perceptron

Introduzindo uma nova abordagem para o problema de reconhecimento de padrões, Rosenblatt, em 1958, apresentou um novo método de aprendizagem supervisionada, o *perceptron*. Este é o tipo mais simples de RNA usada como um classificador linear e possui somente um neurônio com pesos sinápticos ajustáveis e *bias*, limitado a realizar a classificação de padrões com somente duas classes (HAYKIN, 2007).

As redes *perceptron* de múltiplas camadas, ou *Multilayer Perceptron* (MLP), possuem pelo menos uma camada intermediária de neurônios, escondida entre a camada de entrada e a camada de saída. Sendo assim, o número de neurônios cresce pois há, pelo menos, duas camadas de neurônios distribuídos entre essa nova camada intermediária e a de saída (SILVA; SPATTI; FLAUZINO, 2010), como demonstrado na figura a seguir.



Fonte: Elaborado pela autora.

Em resumo, uma rede neural MLP, possui três características principais. A primeira identifica que os neurônios das camadas ocultas possuem uma função de ativação não linear do tipo sigmoideal, função logística ou tangente hiperbólica e os neurônios da camada de saída possuem uma função de ativação linear. Além disso, a rede possui uma ou mais camadas escondidas e, por fim, possui um alto grau de conexão (HAYKIN, 2007).

Para ajustar os pesos e o *bias* de cada neurônio desse tipo de rede, é utilizado o treinamento supervisionado e o algoritmo de aprendizado aplicado durante o treinamento da rede é chamado de algoritmo de retropropagação do erro, ou *Backpropagation*.

4.2.5 Algoritmos *Backpropagation* e *Levenberg-Marquardt*

O treinamento de uma rede MLP utilizando o algoritmo *Backpropagation*, também conhecido como Regra Delta Generalizada, consiste em dois passos através de todas as camadas da rede (SILVA; SPATTI; FLAUZINO, 2010):

- Propagação adiante (fase *forward*): um vetor de entrada é aplicado aos nós da rede e seu efeito é propagado camada a camada, por meio dos pesos sinápticos que permanecem fixos, até a camada de saída produzindo uma resposta;
- Propagação reversa (fase *backward*): os sinais da camada de saída são comparados à saída desejada, produzindo um sinal de erro que se propaga desde a camada de saída até a camada de entrada alterando os pesos sinápticos para que a resposta fornecida pela rede se aproxime da resposta desejada.

De acordo com Luenberger e Ye (2008), algoritmos de treinamento (responsáveis pelo aprendizado da RNA) de primeira ordem são conhecidos por serem ineficientes no tratamento de problemas de larga escala, pois apresentam taxas de convergência baixas, muitas lentas e que exigem grande esforço computacional, como é o caso algoritmo *Backpropagation*.

Por conta disso, e do fato de que os dados para treinamento geralmente apresentam grande dimensionalidade, existe a possibilidade de utilizar um método de otimização de segunda ordem, ou algoritmo *Levenberg-Marquardt* (SILVA; SPATTI; FLAUZINO, 2010). Nos métodos de segunda ordem, além do vetor gradiente da função objetivo, faz-se uso também da matriz hessiana (matriz de derivadas de segunda ordem) da função erro.

O algoritmo *Levenberg-Marquardt* foi desenvolvido com base no gradiente descendente e nos algoritmos de Gauss-Newton e é amplamente aplicado para estimar os parâmetros do modelo de RNA. Oferece uma boa aproximação para as dificuldades não-lineares de minimização de mínimos quadrados; onde a função objetivo a ser minimizada é dada pela seguinte equação (JALLAL et al., 2019):

$$J(w) = \frac{1}{2} \sum_{j=1}^N (\hat{y} - y_j)^2 \quad (4.3)$$

em que N é o número de amostras.

O gradiente da função objetivo é dado por:

$$\nabla J = \begin{pmatrix} \frac{\partial J}{\partial w_1} \\ \vdots \\ \frac{\partial J}{\partial w_n} \end{pmatrix} \quad (4.4)$$

em que n representa o número de parâmetros não identificados. O algoritmo LM, com base nos parâmetros que atualizam a equação, é dado pela seguinte expressão:

$$w_k = w^{k-1} \pm (H(w^{k-1}) + \mu_k I)^{-1} \nabla J(w^{k-1}) \quad (4.5)$$

A matriz $H(w^{k-1})$ é a hessiana da função de desempenho, I é a matriz de identidade e μ_k é a taxa de passos. Já μ_k diminui após cada diminuição bem-sucedida registrada pela função objetivo e aumenta no caso inverso (RAMESH; VANATHI; GUNAVATHI, 2008).

Neste capítulo, foi apresentada uma conceituação básica sobre séries temporais e RNAs. Sendo assim, as características do método computacional aplicado, baseadas nesses conceitos, serão apresentadas a seguir.

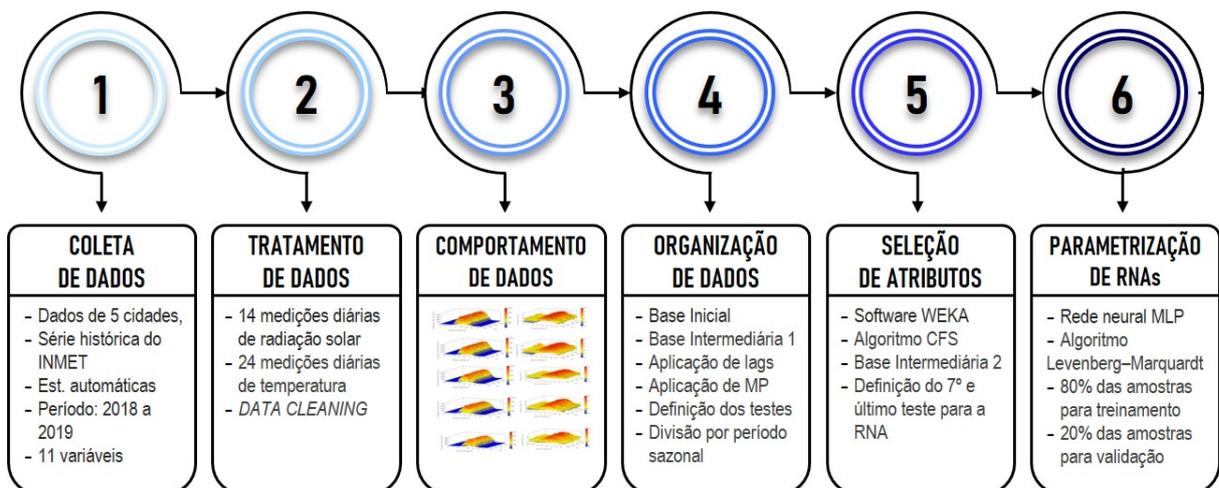
Capítulo 5

Metodologia

O principal objetivo desta pesquisa é utilizar a técnica de Redes Neurais Artificiais para prever os componentes climáticos irradiação solar e temperatura do ar para 5 cidades no estado do Maranhão, com o horizonte de um ano a frente, e utilizando os dados históricos correspondentes ao período 2008-2019 (dados de entrada), cerca de 70 mil medições, coletadas 24h por dia.

É importante mencionar que a análise detalhada da série a ser prevista e o tratamento adequado dos dados são fatores primordiais para a obtenção de resultados consistentes e satisfatórios utilizando estes modelos computacionais. São apresentadas a seguir as etapas de desenvolvimento deste estudo, detalhando como foi realizada a aplicação do método de utilização dos dados e do modelo computacional, para a obtenção de resultados de previsão temporal.

Figura 16 – Etapas de aplicação do método



Fonte: Elaborado pela autora.

5.1 Coleta dos dados

Para a realização da previsão climática, foi utilizada neste trabalho a série histórica extraída da base de dados do INMET, importante órgão do Ministério da Agricultura, Pecuária e Abastecimento, responsável pelas pesquisas que envolvem assuntos relacionados ao monitoramento, análise e previsão de tempo e de clima no território brasileiro. O INMET representa o Brasil junto à Organização Meteorológica Mundial (OMM) e, por delegação desta Organização, é responsável pelo tráfego das mensagens coletadas pela rede de observação meteorológica da América do Sul e os demais centros meteorológicos que compõem o Sistema de Vigilância Meteorológica Mundial (INMET, 2018).

O Sistema de Coleta e Distribuição de Dados Meteorológicos do Instituto é dotado de estações de sondagem de ar superior (radiossonda); estações meteorológicas de superfície (EMS), operadas manualmente; e estações meteorológicas automáticas (EMA), que coleta, de minuto em minuto, as informações meteorológicas representativas da área em que está localizada. A cada hora, estes dados são integralizados e disponibilizados para serem transmitidos, via satélite ou telefonia celular, para a sede do INMET, em Brasília. O conjunto dos dados recebidos é validado, através de um controle de qualidade e armazenado em um banco de dados.

Os dados meteorológicos das cinco cidades objetos deste estudo foram solicitados ao INMET e enviados em formato *xlsx* via *e-mail*, pois o site do Instituto só disponibiliza as informações coletadas nos últimos 365 dias. Para obter uma base de dados consistente, optou-se por utilizar os dados das EMAs porque possuíam medições 24h por dia, ampliando a quantidade de informações sobre o clima de cada município selecionado. No estado do Maranhão, as estações foram instaladas entre 2007 e 2008, então optando pela padronização, o período de coleta utilizado neste trabalho foi iniciado em 2008.

Além das variáveis de interesse para esta pesquisa, Temperatura do Ar ($^{\circ}\text{C}$) e Irradiação Solar (kJ/m^2), foram disponibilizadas ainda outras nove variáveis meteorológicas que contribuíram para a análise das características de cada região, bem como para o aprimoramento da etapa de previsão climática. São elas:

Tabela 3 – Variáveis disponibilizadas pelo INMET

Temperatura Máxima ($^{\circ}\text{C}$)	Umidade Relativa do Ar (%)
Temperatura Mínima ($^{\circ}\text{C}$)	Temperatura do Ponto de Orvalho ($^{\circ}\text{C}$)
Velocidade do Vento (m/s)	Rajada Máxima de Vento (m/s)
Direção do Vento (graus)	Precipitação (mm)
Pressão Atmosférica da Estação (mBar)	

Elaborado pela autora (2019).

5.2 Tratamento dos dados

Conforme [Pereira et al. \(2017\)](#), a variação da radiação solar na superfície em todas as regiões do país depende da localização em relação ao equador, da composição atmosférica e das características climáticas, como precipitação e cobertura das nuvens. Por conta de tais fatores, é o Nordeste brasileiro a região com maior média anual de radiação solar. Como consequência, temperaturas médias altas também são características da região.

Ao considerar tais características, foi possível iniciar o tratamento das informações, fazendo reconhecimento de medições que estivessem fora do padrão, como valores muito mais baixos ou altos em relação ao comumente medido nas regiões em estudo.

As amostras registradas e enviadas pelo INMET apresentavam inicialmente a configuração de hora em UTC (*Coordinated Universal Time*), fuso horário de referência e pelo qual se calculam as todas as zonas horárias. O Brasil possui 4 delas e mais especificamente, o estado do Maranhão está em zona de UTC-3 (ou horário de Brasília), o que significa menos 3 horas em relação ao horário disposto em UTC.

É apresentada na Figura 17 a configuração inicial das bases de dados, com recorte apenas da variável Irradiação Solar, formato que se estende às demais variáveis climáticas fornecidas.

Figura 17 – Fragmento do arquivo 'SÃO LUÍS' enviado pelo INMET

	RADIACAO GLOBAL (KJ/M²)													
HORA UTC	0900	1000	1100	1200	1300	1400	1500	1600	1700	1800	1900	2000	2100	2200
01-jan-2008	NULL	106.8	580.4	1335.5	1502.5	1197.9	1434.4	1181.0	856.4	1112.5	1024.2	498.0	272.8	NULL
02-jan-2008	NULL	NULL	510.4	1191.3	1219.3	1692.3	1780.5	1882.2	1662.4	1395.9	851.5	453.6	146.6	NULL
03-jan-2008	NULL	193.3	890.5	1383.1	1326.8	1516.9	1693.9	1677.3	806.2	283.8	404.5	480.2	170.4	NULL
04-jan-2008	NULL	89.2	588.1	870.5	1374.4	1344.7	1900.2	2983.2	1489.0	2380.7	1091.4	606.1	184.7	NULL
05-jan-2008	NULL	NULL	278.7	1116.9	1583.0	2377.9	2348.5	2645.3	2223.7	2419.2	1787.8	1064.4	279.6	NULL

Elaborado pela autora (2019).

Para Irradiação Solar, o intervalo de medição possui 14 amostras por dia, das 09h00 às 21h00 (em UTC) o mesmo que das 06h00 às 19h00 (no horário de Brasília). No caso da variável Temperatura e das demais apresentadas anteriormente, as medições foram coletadas 24h por dia. Para visualização e análise das informações sobre as variáveis climáticas, utilizou-se o *software* Microsoft Excel®.

Sabe-se que as previsões de eventos meteorológicos são complexas pela necessidade de análise de grande volume de dados e, visto que as informações concedidas não são homogêneas, com ausência ou inconsistência de alguns períodos de medição, houve a

necessidade de uma organização das bases de dados para processamento das mesmas.

A princípio realizou-se o processo conhecido como *data cleaning*, ou limpeza dos dados, excluindo-se das planilhas as imagens, cabeçalhos, legendas e os dias que continham campos preenchidos com os termos **NULL** ou **NA**, ou seja, não continham medições por conta de problemas técnicos ou manutenções nas estações meteorológicas. No caso das medições de radiação solar, foram excluídos os dados dos horários de 06h00 e 19h00 pois apresentavam taxas de ausência de medição acima de 85% nos 5 municípios, como apresentado na Tabela 4.

Tabela 4 – Análise de ausência de medições

Município	Taxa de ausência para 06h	Taxa de ausência para 19h
Caxias	90,6%	90,41%
Colinas	91,54%	93,44%
Imperatriz	88,30%	93,38%
São Luís	86,21%	89,85%
Turialva	90,36%	99,08%

Elaborado pela autora (2019).

Em seguida, optou-se por desconsiderar os dias incompletos, ou seja, que não possuíam todos os horários, permanecendo assim apenas aqueles com todas as medições diárias. Na Tabela 5 e figuras a seguir, é possível verificar o quantitativo final que compõe a base de dados de cada município:

Tabela 5 – Número de amostras finais

Município	Amostra inicial (dias)	Amostra final (dias)	Amostra final (horas)
Caxias	4005	3286	78864
Colinas	4045	3159	75816
Imperatriz	4141	3019	72456
São Luís	4564	3202	76848
Turialva	4038	3050	73200

Elaborado pela autora (2019).

Com este quantitativo de medições, foi possível então gerar gráficos para as variáveis Irradiação Solar e Temperatura do ar utilizando o pacote PGFPlots, incluso no software *LaTeX*, buscando promover clara visualização dos comportamentos das amostras fornecidas para este estudo em cada uma das cinco cidades.

5.3 Comportamento dos dados

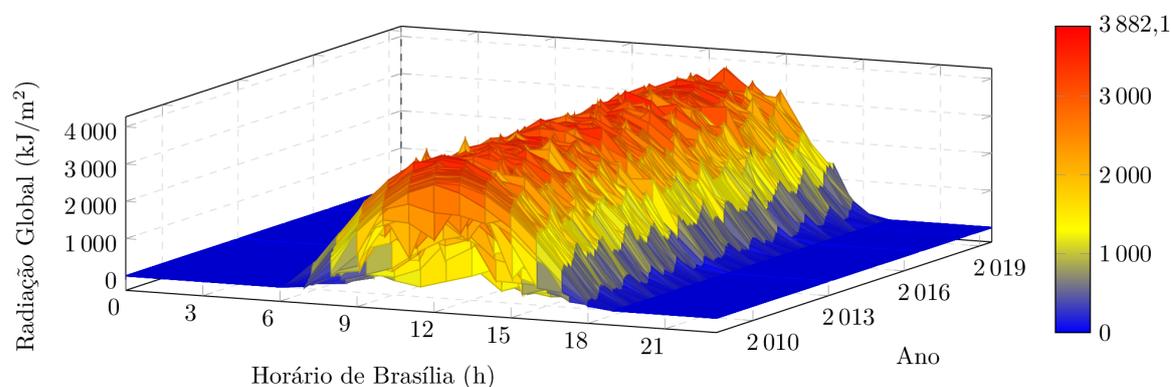
5.3.1 Caxias

As coordenadas geográficas da estação automática de onde foram extraídos os dados são:

Latitude: 04°49'S	Longitude: 43°20'W	Altitude: 76m
-------------------	--------------------	---------------

Foram elaborados gráficos ¹ com os valores de Irradiação Solar e Temperatura do Ar. Em Caxias, o valor mínimo de Irradiação Solar medido foi de $0,2 \text{ kJ/m}^2$ e o máximo foi de $3882,1 \text{ kJ/m}^2$.

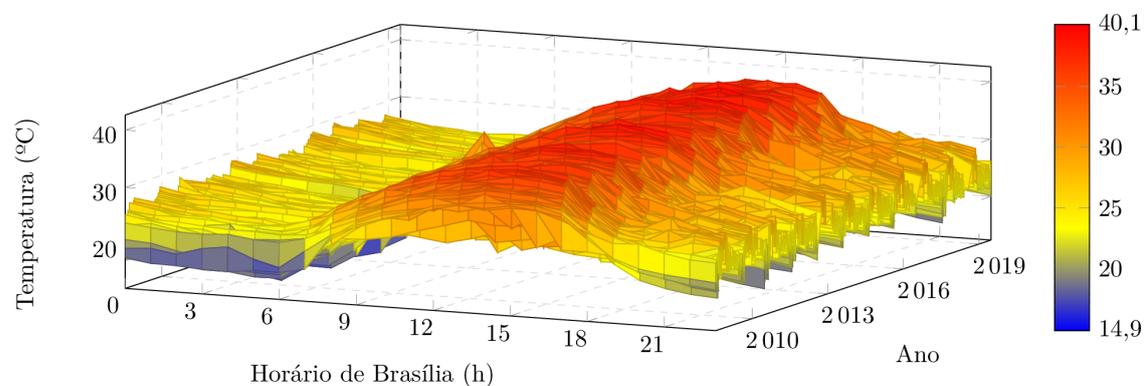
Figura 18 – Representação Gráfica de Irradiação Solar em Caxias



Elaborado pela autora (2019).

Para Temperatura do Ar, ao longo desses 11 anos, o valor mínimo registrado foi de $14,9^\circ\text{C}$ e o valor máximo, de $40,1^\circ\text{C}$.

Figura 19 – Representação Gráfica da Temperatura do Ar em Caxias



Elaborado pela autora (2019).

¹ Para elaboração dos gráficos desta seção, utilizou-se o pacote *PGFPlots*, disponível no *software LaTeX*

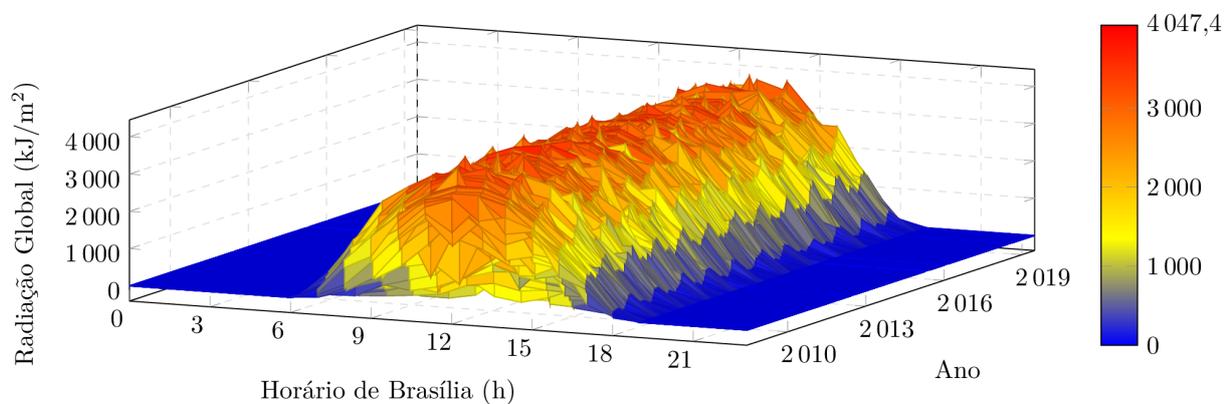
5.3.2 Colinas

As coordenadas geográficas da estação automática de onde foram extraídos os dados são:

Latitude: 06°02'S	Longitude: 44°14'W	Altitude: 179m
-------------------	--------------------	----------------

Em Colinas, o valor mínimo de Irradiação Solar medido foi de $2,5 \text{ kJ/m}^2$, enquanto que o valor máximo foi de $4047,4 \text{ kJ/m}^2$, considerando as medições entre 7h00min e 18h00min. Os valores máximos são observados entre 11h00min e 14h00min.

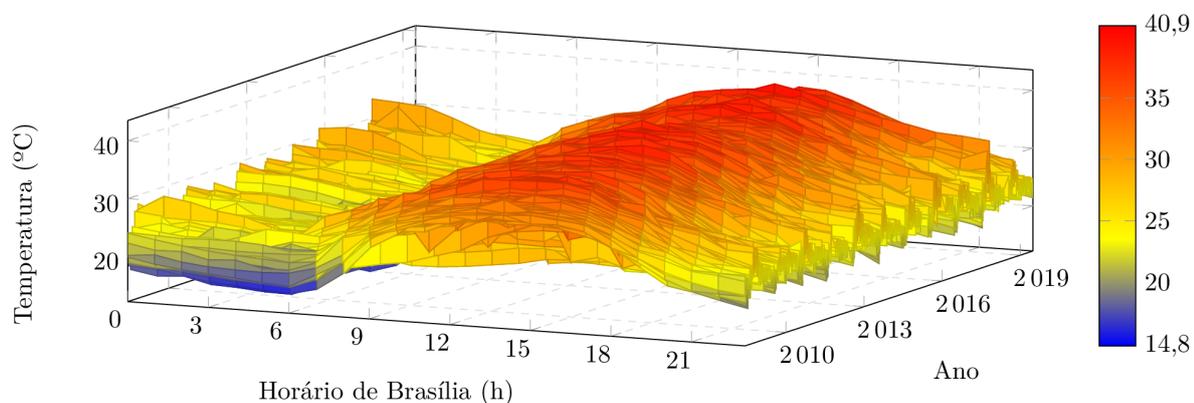
Figura 20 – Representação Gráfica de Irradiação Solar em Colinas



Elaborado pela autora (2019).

Para Temperatura do Ar, ao longo desses 11 anos, o valor mínimo registrado foi de $14,8^\circ\text{C}$ e o valor máximo, de $40,9^\circ\text{C}$, amplitude bastante similar à encontrada na cidade de Caxias.

Figura 21 – Representação Gráfica da Temperatura do Ar em Colinas



Elaborado pela autora (2019).

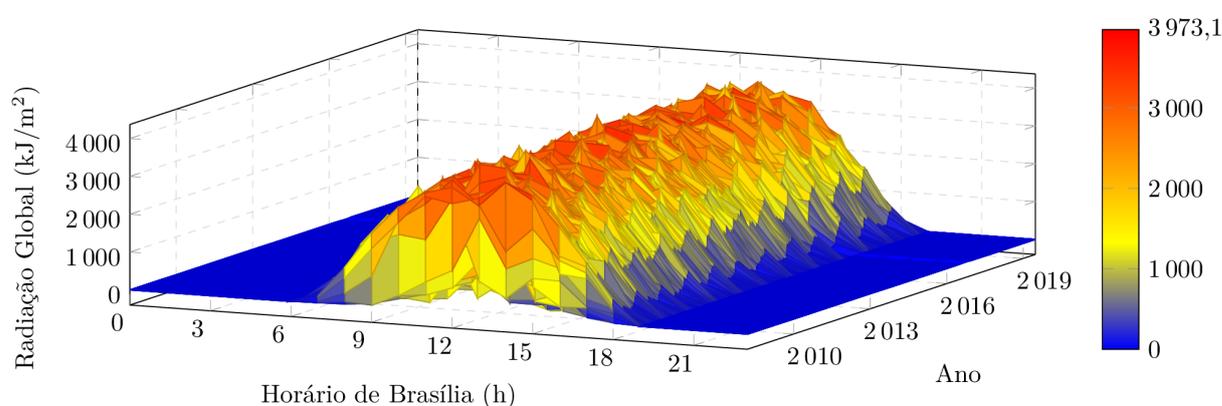
5.3.3 Imperatriz

As coordenadas geográficas da estação automática de onde foram extraídos os dados são:

Latitude: 05°33'S	Longitude: 47°27'W	Altitude: 126m
-------------------	--------------------	----------------

Em Imperatriz, o valor mínimo de Irradiação Solar medido foi de $1,6 \text{ kJ/m}^2$, enquanto que o valor máximo foi de $3973,1 \text{ kJ/m}^2$.

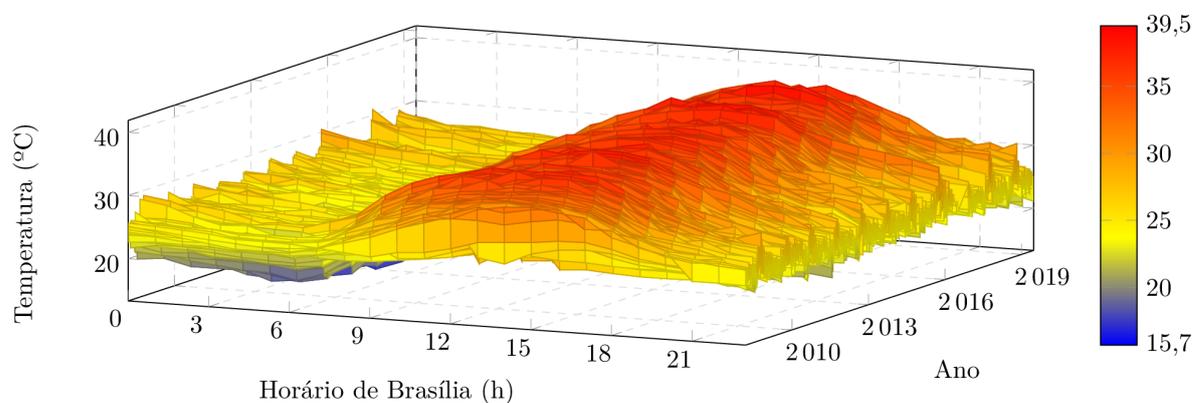
Figura 22 – Representação Gráfica de Irradiação Solar em Imperatriz



Elaborado pela autora (2019).

Para Temperatura do Ar, no período em estudo, o valor mínimo registrado foi de $15,7^\circ\text{C}$ e o valor máximo, de $39,5^\circ\text{C}$. Por meio do gráfico, é possível perceber a amplitude térmica bastante evidente.

Figura 23 – Representação Gráfica da Temperatura do Ar em Imperatriz



Elaborado pela autora (2019).

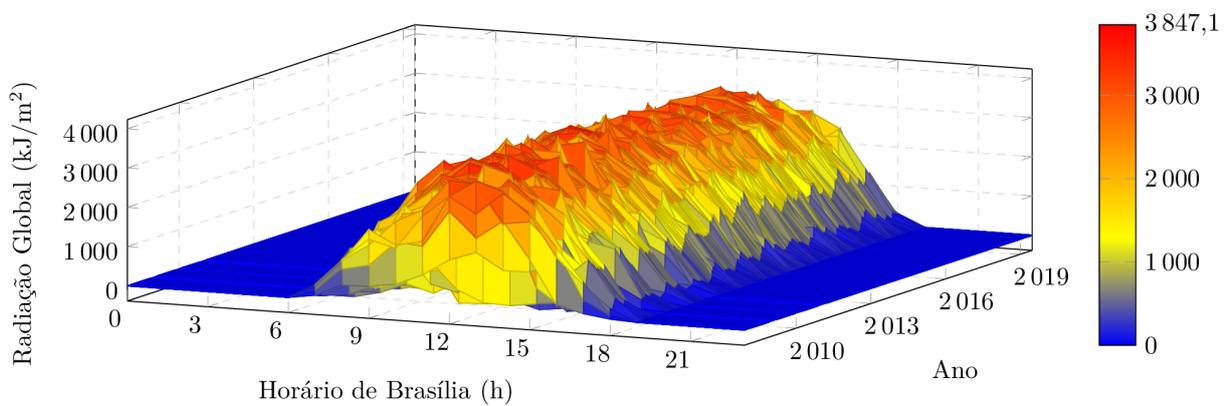
5.3.4 São Luís

As coordenadas geográficas da estação automática de onde foram extraídos os dados são:

Latitude: 02°31'S	Longitude: 44°12'W	Altitude: 56m
-------------------	--------------------	---------------

Em São Luís, o valor mínimo de Irradiação Solar medido foi de $5,1 \text{ kJ/m}^2$, enquanto que o valor máximo foi de $3847,1 \text{ kJ/m}^2$.

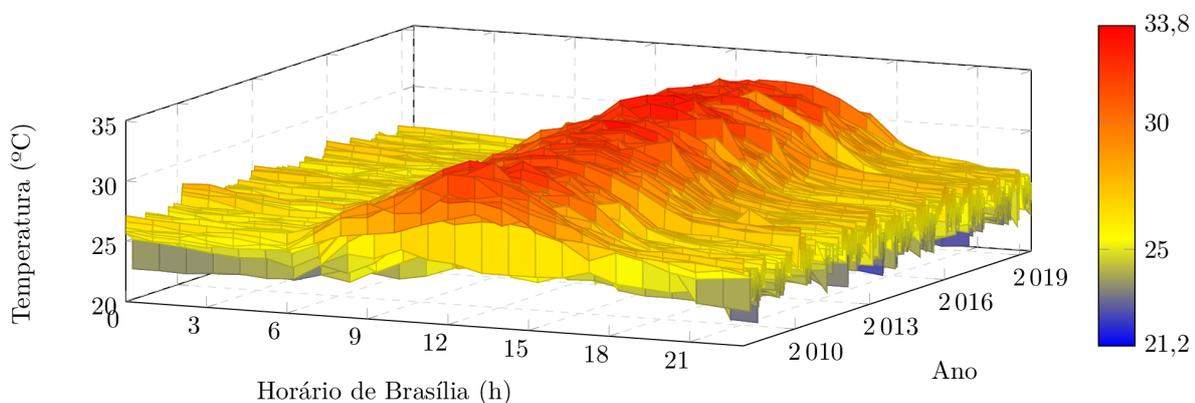
Figura 24 – Representação Gráfica de Irradiação Solar em São Luís



Elaborado pela autora (2019).

Para Temperatura do Ar, ao longo desses 11 anos, o valor mínimo registrado foi de $21,2^\circ\text{C}$, no período da madrugada, e o valor máximo, de $33,8^\circ\text{C}$. Pelo fato de estar em uma região litorânea, a amplitude térmica do município é menor se comparada aos demais, localizados no interior do estado.

Figura 25 – Representação Gráfica da Temperatura do Ar em São Luís



Elaborado pela autora (2019).

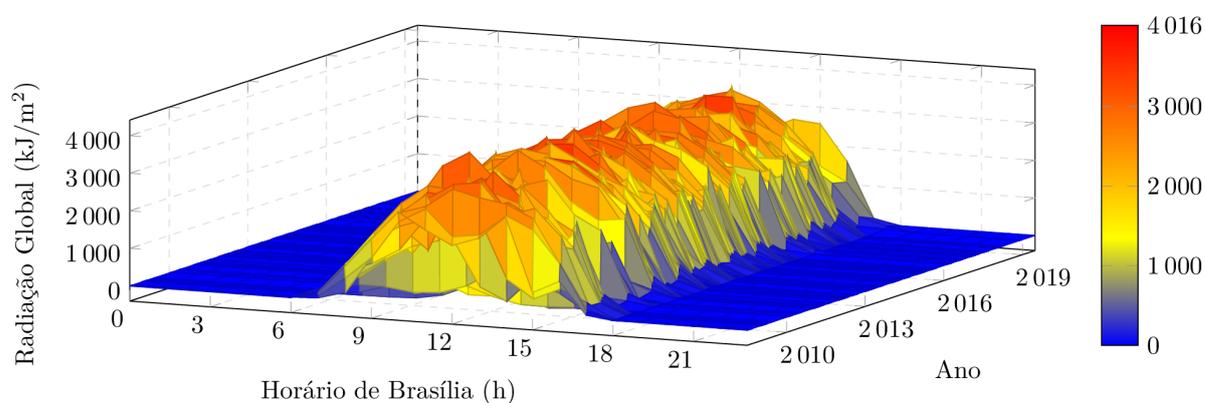
5.3.5 Turiacu

As coordenadas geográficas da estação automática de onde foram extraídos os dados são:

Latitude: 01°39'S	Longitude: 45°22'W	Altitude: 41m
-------------------	--------------------	---------------

Em Turiacu, o valor mínimo de Irradiação Solar medido foi de $1,4 \text{ kJ}/\text{m}^2$, enquanto que o valor máximo foi de $4016 \text{ kJ}/\text{m}^2$. Pelo gráfico é possível notar picos altos de incidência de radiação solar.

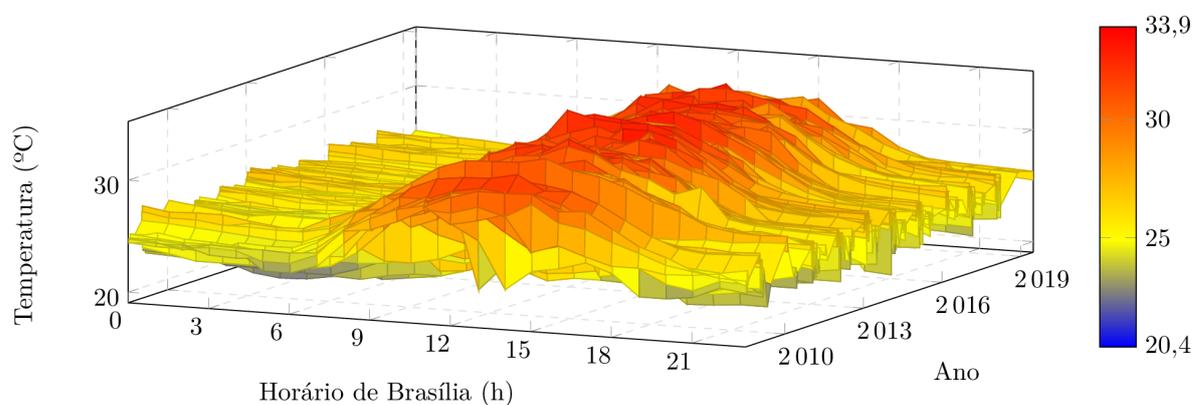
Figura 26 – Representação Gráfica de Irradiação Solar em Turiacu



Elaborado pela autora (2019).

Para Temperatura do Ar, ao longo desses 11 anos, o valor mínimo registrado foi de $20,4^\circ\text{C}$, no período da madrugada, e o valor máximo, de $33,9^\circ\text{C}$. O município também é afetado pelo fator litorâneo. Pode-se perceber novamente, pela configuração do gráfico, o aumento da temperatura ao longo do período de dados coletados.

Figura 27 – Representação Gráfica da Temperatura do Ar em Turiacu



Elaborado pela autora (2019).

5.4 Organização dos Dados

5.4.1 Base Inicial

Após a definição do período de estudo, da organização e tratamento das medições coletadas, deu-se início a formação das 5 bases de dados iniciais. O método foi aplicado para as 5 cidades, sem qualquer distinção, e buscou em um primeiro momento transpor os dados de hora e compatibilizá-los ao lado da data, para que as bases iniciais adquirissem a configuração para a seleção de atributos e posteriormente para o processamento das RNAs. É importante mencionar que, para compatibilizar as medições de Irradiação Solar com as demais variáveis, foi necessário inserir "zeros" aos 12 horários em que não havia medição dessa variável. Na Figura 28 são apresentadas todas as variáveis meteorológicas fornecidas pelo INMET reorganizadas.

Figura 28 – Fragmento do arquivo 'SÃO LUÍS' enviado pelo INMET

DATA	HORARIO	RADIAÇÃO GLOBAL (KJ/M²)	TEMPERA TURA DO AR (°C)	TEMP. MAXIMA (°C)	TEMP. MINIMA (°C)	UMIDADE RELATIVA (%)	TEMP. DO PONTO DE ORVALHO (°C)	TEMP. MAXIMA DO PONTO DE ORVALHO (°C)	TEMP. MINIMA DO PONTO DE ORVALHO (°C)	UMIDADE RELATIVA MAXIMA (%)	UMIDADE RELATIVA MINIMA (%)	PRESSAO ATMOSFERICA RICA (hPa)	PRESSAO ATMOSFERICA MAXIMA (hPa)	PRESSAO ATMOSFERICA MINIMA (hPa)	VELOCIDADE DO VENTO (m/s)	DIRECAO DO VENTO (graus)	PRECIPITACAO (mm)	RAJADA MAXIMA DO VENTO (m/s)
14/fev08	0	0	25.5	26.2	25.5	88	23.3	23.3	23.2	88	84	1002.9	1002.9	1002.2	0.2	50	0	3
14/fev08	100	0	25.1	25.5	25.1	90	23.4	23.4	23.2	90	87	1003.6	1003.7	1002.9	0	52	0	1.5
14/fev08	200	0	25	25.1	24.9	89	23	23.4	22.9	90	88	1003.8	1004	1003.6	0.4	42	0	1.9
14/fev08	300	0	25.2	25.3	25	89	23.3	23.3	23	89	88	1003.7	1003.8	1003.6	0.1	67	0	2.6
14/fev08	400	0	25.5	25.5	25.2	89	23.4	23.5	23.3	90	88	1003	1003.7	1003	0.2	43	0	1.9
14/fev08	500	0	25.4	25.5	25.4	89	23.5	23.7	23.5	90	89	1002.5	1003	1002.4	0.2	45	0	1.5
14/fev08	600	0	25.2	25.5	25.2	91	23.6	23.7	23.5	91	89	1002	1002.5	1002	0	64	0	1.6
14/fev08	700	0	25.3	25.3	25	90	23.7	23.8	23.5	92	90	1002	1002.1	1002	0.8	31	0	2.5
14/fev08	800	0	25.5	25.5	25.3	88	23.4	23.6	23.4	90	88	1002.3	1002.3	1002	0.6	36	0	2.5
14/fev08	900	0	24.8	25.5	24.8	89	22.8	23.4	22.8	89	88	1002.7	1002.7	1002.3	0.3	51	0	2.4
14/fev08	1000	150.8	25.7	25.7	24.7	87	23.4	23.5	22.8	90	87	1003.4	1003.4	1002.7	0	53	0	1.9
14/fev08	1100	602.2	27	27	25.7	82	23.8	23.8	23	87	80	1004.2	1004.2	1003.4	0.4	68	0	2.2
14/fev08	1200	1299	27.9	28.1	27	74	22.9	24	22.8	83	73	1004.4	1004.4	1004.2	2.4	47	0	5.4

Elaborado pela autora (2019).

5.4.2 Base Intermediária

5.4.2.1 Aplicação de lags

A etapa seguinte permitiu a definição das janelas de deslizamento, atrasos ou *lags*, em inglês. Conforme Davis, Chase e Aquilano (2001), existe frequentemente uma autocorrelação, que indica que a demanda esperada em qualquer ponto é altamente correlacionada com seus valores da série histórica da demanda. Ou seja, a aplicação de *lags* permite que, a cada bloco, sejam definidas novas entradas utilizando atrasos significativos para a série em estudo e conferindo ao sistema uma importante característica dinâmica. Esta técnica permite a investigação dos atrasos significativos das séries, ou seja, as próprias séries predefinidas para a composição da Base Inicial deslocadas para trás.

Considerando que esta pesquisa tem como objetivo apresentar uma previsão anual para cada período sazonal para as variáveis Irradiação Solar e Temperatura do ar, optou-se por caracterizar os atrasos com a notação mensal. Portanto, o momento a ser previsto foi definido como M e os deslocamentos da janela $M - 1$, $M - 2$, $M - 12$ e $M - 13$, indicando o atraso de 1, 2, 12 e 13 meses em relação ao momento M . A escolha dos atrasos $M - 1$ e $M - 2$ se deve ao fato de englobarem períodos de transição entre os períodos sazonais, bom identificador de mudança de comportamento das variáveis. Já os *lags* $M - 12$ e $M - 13$ têm o objetivo de coleta as informações históricas do ano anterior.

Adicionalmente, optou-se por calcular ainda Médias Móveis Ponderadas, considerando os intervalos supramencionados, para criar então a Base Intermediária 1. A subseção 5.4.2.2 a seguir detalha o procedimento de cálculo da técnica e a definição de novos *lags* com base nela.

5.4.2.2 Aplicação de Médias Móveis Ponderadas

O uso de Médias Móveis em um grande volume de dados consiste em corrigir o valor de cada parcela de dados utilizando a média dos valores das parcelas vizinhas. Calcula-se a média móvel simples pela média aritmética, onde a soma dos valores é dividida pela quantidade dos mesmos. Tem como vantagem a diminuição dos ruídos, para que fique mais fácil determinar a tendência das amostras medidas. Já a Média Móvel Ponderada (MM), técnica utilizada nesta pesquisa, utiliza uma constante de suavização que, quanto maior o seu valor, mais rápido o modelo reagirá a variações elevadas, já que os pesos atribuídos a períodos mais recentes serão maiores que os atribuídos aos mais antigos (SILVA, 2003). O cálculo da Média Móvel Ponderada é dado pela fórmula a seguir:

$$MM = \frac{p_1 \cdot x_{-1} + p_2 \cdot x_{-2} + \dots + p_n \cdot x_{-n}}{p_1 + p_2 + \dots + p_n} \quad (5.1)$$

onde MM é a Média Móvel Ponderada, p_1, p_2, \dots, p_n são os pesos e $x_{-1}, x_{-2}, \dots, x_{-n}$ são os valores dos dados imediatamente anteriores à x , ou seja, àquele que se deseja prever. Na Média Móvel Ponderada, os valores das amostras mais recentes são multiplicados por um peso maior e esse peso diminui aritmeticamente.

Resolveu-se então testar 3 modelos de médias ponderadas, considerando que o método favorece as características das amostras mais próximas àquela em estudo, abrindo a possibilidade ainda de identificar grande relevância deste método no tratamento dos dados analisados a partir da Seleção de Atributos, técnica detalhada na seção a seguir.

Nas Tabelas 6, 7 e 8, são apresentados os pesos correspondentes aos testes realizados utilizando as amostras de 5, de 10 e de 15 dados imediatamente anteriores àquele que se deseja prever. Portanto, os valores de p_1, p_2, \dots, p_n serão multiplicadores de $x_{-1}, x_{-2}, \dots, x_{-n}$, respectivamente e ao final divididos pela soma de dos 5, 10 ou 15 pesos atribuídos.

Tabela 6 – Tabela de pesos para 5 amostras (-5MM)

Peso	p1	p2	p3	p4	p5
Valor	5	4	3	2	1

Tabela 7 – Tabela de pesos para 10 amostras (-10MM)

Peso	p1	p2	p3	p4	p5	p6	p7	p8	p9	p10
Valor	10	9	8	7	6	5	4	3	2	1

Tabela 8 – Tabela de pesos para 15 amostras (-15MM)

Peso	p1	p2	p3	p4	p5	p6	p7	p8	p9	p10	p11	p12	p13	p14	p15
Valor	15	14	13	12	11	10	9	8	7	6	5	4	3	2	1

Após o cálculo de mais *lags* utilizando a técnica MM em 3 configurações distintas, foi possível apresentar uma proposta com combinações destes intervalos, originando assim os testes utilizados como entradas para as RNAs na categoria Sem Seleção de Atributos, a Base Intermediária 1. Para uma amostra de valor X em um certo momento M , os *lags* finais são: X_{M-1} , X_{M-2} , X_{M-12} e X_{M-13} , indicando atrasos de 1, 2, 12 e 13 meses e X_{MM-5} , X_{MM-10} e X_{MM-15} , calculados por meio das Médias Móveis e indicando atrasos de 5, 10 e 15 dados diretamente anteriores ao valor X no momento M que se quer prever. Na Tabela 9 são apresentados os *lags* combinados entre si em 6 possibilidades e utilizados no processo de previsão tanto de irradiação como de temperatura:

Tabela 9 – Combinações dos intervalos para teste sem seleção de atributos

Nº do teste	Composição dos testes
01	X_{M-1} do conjunto de variáveis + X_{M-2} da variável a ser prevista + X_{M-12} da variável a ser prevista + X_{M-13} da variável a ser prevista
02	X_{M-1} do conjunto de variáveis + X_{M-2} da variável a ser prevista + X_{MM-5} + X_{MM-10} + X_{MM-15} da variável a ser prevista
03	X_{M-1} Irradiação Solar e Temperatura + X_{M-2} da variável a ser prevista
04	X_{M-1} Irradiação Solar e Temperatura + X_{M-2} da variável a ser prevista + X_{MM-5} + X_{MM-10} + X_{MM-15} do conjunto de variáveis
05	X_{M-1} + X_{M-2} + X_{M-12} + X_{M-13} da variável a ser prevista + X_{MM-5} + X_{MM-10} + X_{MM-15} da variável a ser prevista
06	X_{M-1} + X_{M-2} + X_{M-12} + X_{M-13} do conjunto de variáveis + X_{MM-5} + X_{MM-10} + X_{MM-15} da variável a ser prevista

Por fim, com os *lags* e os testes já definidos, partiu-se para a organização trimestral dos dados, seguindo a definição de períodos sazonais. De acordo com os critérios de divisão

desses períodos em meteorologia, as quatro estações do ano correspondem aos intervalos de tempo em meses, como de março a maio, de junho a agosto, de setembro a novembro e de dezembro a fevereiro no calendário gregoriano, respectivamente (HU et al., 2018). Optou-se, portanto, por utilizar as características sazonais, para prever os principais fatores meteorológicos, como irradiação solar e temperatura ambiente.

Para rearranjar as informações da Base Intermediária 1 descrita anteriormente para as Bases Intermediárias 2 de cada município, foi necessário subdividir cada ano, de 2008 a 2019, em 4 períodos sazonais e em seguida reagrupá-los em 4 planilhas distintas, com o intuito de aprimorar a previsão utilizando as características particulares de cada uma dessas épocas. Com as bases subdivididas, foi possível então aplicar a técnica de seleção de atributos para a montagem do 7º e último teste a ser utilizado pela RNA para prever as variáveis.

5.5 Seleção de Atributos

Sabe-se que a técnica de seleção de atributos tem a capacidade de reduzir a dimensionalidade da base de dados (TANG; ALELYANI; LIU, 2014), visto que somente os atributos mais relevantes são considerados, enquanto são evitados os redundantes (DASH; LIU, 1997).

Conforme Guyon e Elisseeff (2003), há muitos benefícios potenciais da seleção de atributos como, por exemplo, a facilidade na visualização e compreensão de dados, reduzindo os requisitos de medição, armazenamento e tempo de treinamento, e a utilização para melhorar o desempenho da previsão. Para Saeys, Inza e Larrañaga (2007), os objetivos da seleção de atributos são múltiplos e dentre eles destaca-se o fato de evitar o sobreajuste e melhorar o desempenho de modelos preditivos. Dentre as técnicas mais utilizadas para avaliar um conjunto de atributos, pode-se destacar o algoritmo *Correlation-based Feature Selection* (CFS), que será empregado nessa pesquisa por meio do *software* WEKA®.

O algoritmo CFS classifica os subconjuntos de atributos de acordo com medidas de avaliação de separabilidade (HALL, 1999). Esse algoritmo avalia a importância de um subconjunto de atributos em função da predição individual de cada atributo e do grau de correlação entre eles. O CFS seleciona um subconjunto de atributos de forma explícita, avaliando cada atributo individualmente e, por fim, atribui uma pontuação com base em sua importância (KOPRINSKA; RANA; AGELIDIS, 2015).

Após a definição da configuração da Base Intermediária 2, indicando os períodos sazonais e a inserção dos *lags* predefinidos e das Médias Móveis Ponderadas, foram inseridas no *software* WEKA 4 planilhas para cada município, agora em formato *.csv*, com os resultados da seleção de atributos detalhados no Apêndice A, por conta do grande volume de planilhas distintas.

O processo de seleção de atributos teve como objetivo montar o 7º e último teste, identificando as variáveis que mais contribuem com o processo de previsão, conforme o processamento do algoritmo. É importante ressaltar que há outras variáveis medidas juntamente com Irradiação Solar e Temperatura, extraídas da mesma fonte do INMET. Com isso, foi possível observar quais foram as mais relevantes para os períodos sazonais e levando em conta as características de cada município.

Na inserção dos atributos de ambas as variáveis optou-se por excluir o campo "Data" que constava nas planilhas e, em seguida, foram então realizados os testes excluindo os campos "Data" e "Hora", que apresentaram resultados idênticos aos primeiros, não havendo influência do atributo "Hora" para o processamento no WEKA.

5.6 Parametrização

A definição dos 6 testes e, em seguida, a adição da seleção de atributos para a montagem do 7º e último teste permitiram a organização da Base Final, nomenclatura adotada para indicar os dados de entrada na RNA. Nesta pesquisa, o processamento das redes para previsão de Irradiação Solar e Temperatura foi realizado separadamente, embora todas as etapas anteriores de organização dos dados tenham sido aplicadas de maneira idêntica para ambas as variáveis. Para o processamento das RNAs foi utilizado o ambiente de desenvolvimento *MATLAB*, porque dispõe de funções desenvolvidas exclusivamente para determinadas tarefas de processamento de séries, operações matriciais e interface funcional.

Neste projeto, a estrutura do modelo utilizada para realizar a previsão das variáveis é composta por uma rede neural *Multilayer Perceptron* (MLP) e o algoritmo Levenberg-Marquardt, que representa um método gradiente de segunda ordem, baseado em mínimos quadrados para modelos não lineares e pode ser incorporado ao algoritmo *Back-propagation* para potencializar a eficiência do processo de treinamento (SILVA; SPATTI; FLAUZINO, 2010).

O desempenho da RNA depende da arquitetura e da escolha dos seus parâmetros de treinamento. A definição dos parâmetros é influenciada por resultados de pesquisas similares, mas é comum a experimentação empírica, em que os parâmetros da topologia são modificados até alcançar uma solução pode ser considerada ideal para o problema em questão.

Para selecionar a melhor estrutura, foi utilizada a RNA que possuía duas camadas intermediárias. Foi estabelecido um número de épocas no treinamento da RNA de 450, e a porcentagem de dados destinada ao treinamento do método foi de 80%, com os 20% destinados à validação do modelo. O treinamento consiste em apresentar parte do conjunto de dados para a RNA para que os pesos dos neurônios sejam ajustados de acordo com

o comportamento da série temporal. Já a validação é utilizada para que a RNA não reconheça somente os padrões do conjunto de treinamento.

Os padrões utilizados para selecionar a estrutura ideal para a RNA foram o Erro Médio Absoluto (MAE), o Erro Relativo Absoluto (RAE), a Raiz do Erro Quadrático Médio (RMSE) e sua versão normalizada, o nRMSE, todos detalhados na seção 5.7.

Após o tratamento dos dados, apresentado nas seções anteriores, na Tabela 10 são apresentadas as parametrizações das RNAs utilizadas na etapa de previsão de Irradiação Solar e Temperatura do Ar.

Tabela 10 – Detalhamento da arquitetura da RNA

Arquitetura	Multilayer Perceptron
Algoritmo de Treinamento	Levenberg-Marquardt
Topologia	1 Camada Oculta e 2 Camadas Ocultas
Função de Ativação na Camada Oculta	Logística/Sigmoide
Função de Ativação na Camada de Saída	Linear
Erro Quadrático Médio	$10e^{-12}$
Critério de Parada	$1e^{-15}$
Taxa de Aprendizado	$1e^{-6}$
Máximo de Épocas	450
Porcentagem Destinada ao Treinamento da RNA	80%
Porcentagem Destinada à Validação da RNA	20%

Também para ambas as variáveis, com 1 camada neural escondida, foram utilizados 3, 6, 9, 12, 15 e 18 neurônios. Já no caso de duas camadas neurais ocultas, utilizou-se as configurações apresentadas na Tabela 11.

Tabela 11 – Detalhamento da RNA com duas camadas ocultas

1ª Camada Oculta	2ª Camada Oculta
3	3, 6, 9, 12, 15, 18
6	3, 6, 9, 12, 15
9	3, 6, 9, 12
12	3, 6, 9
15	3, 6

Portanto, para cada uma das 5 cidades alvos deste estudo, foi proposta a realização de 6 testes sem seleção de atributos, descritos na seção 5.4 e 1 teste com seleção de atributos, descrito na seção 5.5. Cada teste foi executado 8 vezes. O desempenho dos resultados da previsão temporal com as características acima detalhadas foi analisado conforme o desempenho das métricas descritas a seguir, na seção 5.7.

5.7 Métricas de Avaliação de Desempenho

Sabe-se que a verificação dos resultados de um processo de previsão é mais confiável quando há boa quantidade e qualidade dos dados utilizados. Diversos métodos foram desenvolvidos para resumir os erros gerados por uma técnica de previsão particular. A maioria destas medidas envolve o cálculo da média de alguma função da diferença entre um valor real e o valor predito. Estas diferenças entre valores observados e valores previstos são frequentemente referenciadas como resíduos. Um resíduo é, portanto, a diferença entre um valor real e seu valor previsto (HANKE; WICHERN, 2009).

Na tomada de decisão, conforme indica Chopra e Meindl (2004), deve se fazer uma análise completa dos erros em uma previsão para que se possa utilizar as análises de erros para determinar se o modelo de previsão adotado está prevendo detalhadamente o componente sistemático e também para que seja possível estimar o erro da previsão. Sendo assim, para melhor analisar as previsões realizadas neste trabalho, foram utilizadas algumas métricas para avaliação da previsão que estão detalhadas na sequência.

5.7.1 Erro Quadrático Médio (MSE – *Mean Square Error*)

Inicialmente, para efeito explicativo, destaca-se o erro de previsão, que para o período t é dado por E_t , e representado pela expressão abaixo, onde F_t é a previsão de demanda e D_t é a demanda real observada (CHOPRA; MEINDL, 2004). Seu equacionamento é dado por:

$$E_t = F_t - D_t \quad (5.2)$$

O MSE estima a variação do erro de previsão. É utilizado quando a soma simples do erros ao quadrado apresenta valores muito grandes, fator que pode causar dificuldade de interpretação.

$$MSE = \frac{1}{n} \sum_{t=1}^n E_t^2 \quad (5.3)$$

onde n é o número de intervalos de tempo.

O valor de MSE é sempre um número real, sendo que um MSE igual a 0 (zero) indica uma exata adequação do modelo para os dados medidos do sistema, mas um valor de MSE menor que 0,01 pode ser considerado suficiente para a maioria das aplicações práticas em previsão de séries temporais (NAGELKERKE, 1991).

5.7.2 Raiz do Erro Quadrático Médio (RMSE – *Root Mean Square Error*)

O RMSE é uma medida absoluta de erro com características semelhantes às do MSE, que penaliza muito mais os erros maiores. Assim, uma técnica que apresente ótimos resultados na maioria das previsões, mas que tenha erros elevados em uma previsão específica, irá fornecer um alto RMSE. A sua expressão característica é dada por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n \frac{|F_t - D_t|^2}{F_t}} \quad (5.4)$$

5.7.3 Erro Médio Absoluto (MAE – *Mean Absolute Error*)

O MAE é adotado principalmente para os modelos baseados em RNA. Calcula o valor médio dos erros em um conjunto de valores provenientes de métodos de previsão, em função do número de observações, como está definido na equação:

$$MAE = \frac{1}{n} \sum_{t=1}^n |D_t - F_t| \quad (5.5)$$

5.7.4 Erro Relativo Absoluto (RAE – *Root Absolute Error*)

A métrica RAE corresponde ao erro absoluto total, onde os erros são normalizados pelos erros do preditor simples que prevê a média dos valores observados, representado pela fórmula:

$$RAE = \frac{\sum_{t=1}^n |F_t - D_t|}{\sum_{t=1}^n |\bar{F}_t - D_t|} \quad (5.6)$$

Ao final, cada planilha continha as medições referentes às duas variáveis que se deseja prever, temperatura e radiação solar, e as demais variáveis com informações coletadas juntamente com as duas primeiras ao longo desses 11 anos.

As cinco cidades selecionadas para esta pesquisa abrangem os três tipos climáticos encontrados no Maranhão, com o objetivo de aproveitar a variedade climática que o estado possui para a realização de uma análise detalhada.

Capítulo 6

Análise de Resultados

Este módulo é destinado às análises dos resultados obtidos por meio da técnica de Redes Neurais Artificiais para previsão climática de Temperatura do Ar e Irradiação Solar, avaliando seu desempenho em termos das métricas de avaliação encontradas.

Esta etapa realiza a previsão de longo prazo empregando um modelo de Redes Neurais Artificiais, estabelecendo parâmetros e critérios e utilizando uma arquitetura *Multilayer Perceptron* (MLP) que consiste em redes neurais de várias camadas, onde cada uma possui uma função específica. O aprendizado foi feito por meio de algoritmo de otimização para resolução de problemas de minimização de funções não-lineares *Levenberg-Marquardt*.

Foi possível avaliar as alterações nas séries históricas dos dados obtidos nas estações meteorológicas dos municípios de Caxias, Colinas, Imperatriz, São Luís e Turiaçu. A busca pela arquitetura ideal da RNA para o processamento da previsão de cada variável foi feita por um processo de tentativa e erro, variando-se o número de camadas ocultas e de neurônios ocultos. O desenvolvimento de um modelo sazonal buscou aproveitar as características similares durante o ano, criando redes especialistas em prever 4 diferentes períodos.

Foram avaliadas 3 métricas de erro para a análise do modelo de previsão de cada variável: MAE, RAE e RMSE. Os resultados serão detalhados para os 4 períodos sazonais de cada município destacando, conforme os valores das métricas, a composição do teste mais acurado. Os melhores resultados da métrica RMSE serão então comparados com os estudos que compõem o quadro apresentado na seção 2.3, buscando identificar se o erro de previsão se enquadra como resultado satisfatório. O processamento das RNAs foi realizado com base nos 7 testes indicados na seção anterior. Os 6 primeiros testes organizados com base na literatura e considerando as variáveis disponíveis e técnicas de melhoramento das amostras aplicadas. O 7º e último teste foi organizado com base no processo de seleção de atributos e as variáveis selecionadas estão organizadas no Apêndice A.

6.1 Caxias

O processamento da previsão usando as Redes Neurais Artificiais foi executado e os parâmetros utilizados para análise de desempenho são apresentados a seguir. Os melhores resultados para cada período sazonal estão destacados em negrito:

Tabela 12 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Caxias

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[2 9]	[6 5]	[5 9]	[4 15]	16	[4 3]	3
	MAE (kJ/m^2)	0,8481	2,0974	0,8120	0,9977	0,1200	0,8597	1,3719
	RAE (kJ/m^2)	0,0107	0,0265	0,0103	0,0126	0,0015	0,0109	0,0173
	RMSE (kJ/m^2)	0,0135	2,3688	0,0574	0,1442	0,0301	0,0260	0,6760
OUTONO	TOPOLOGIA	[4 14]	[4 14]	[2 5]	[7 4]	[4 15]	9	[7 11]
	MAE (kJ/m^2)	6,1197	6,1011	4,5146	1,2919	0,9753	1,2336	0,4002
	RAE (kJ/m^2)	0,0060	0,0090	0,0045	0,0090	0,0070	0,0080	0,0036
	RMSE (kJ/m^2)	7,0435	7,4977	2,7690	2,5661	1,9222	2,4368	0,1076
INVERNO	TOPOLOGIA	[3 15]	[6 11]	[2 4]	[2 14]	[2 16]	[2 11]	[2 4]
	MAE (kJ/m^2)	5,1595	2,4737	4,8518	3,3112	3,7903	3,4141	1,2941
	RAE (kJ/m^2)	0,0316	0,0105	0,0297	0,0203	0,0232	0,0209	0,0076
	RMSE (kJ/m^2)	6,8625	3,2771	6,4469	4,4070	5,0466	4,5494	1,4719
PRIMAVERA	TOPOLOGIA	[5 3]	[4 3]	[7 4]	[6 7]	[3 14]	[2 14]	[7 10]
	MAE (kJ/m^2)	3,1699	3,1722	3,1758	3,1936	3,2210	3,1812	3,1338
	RAE (kJ/m^2)	0,2496	0,2498	0,2501	0,2515	0,2536	0,2505	0,2468
	RMSE (kJ/m^2)	0,0002	0,0065	0,0141	0,0064	0,0326	0,0040	0,0382

Tabela 13 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Caxias

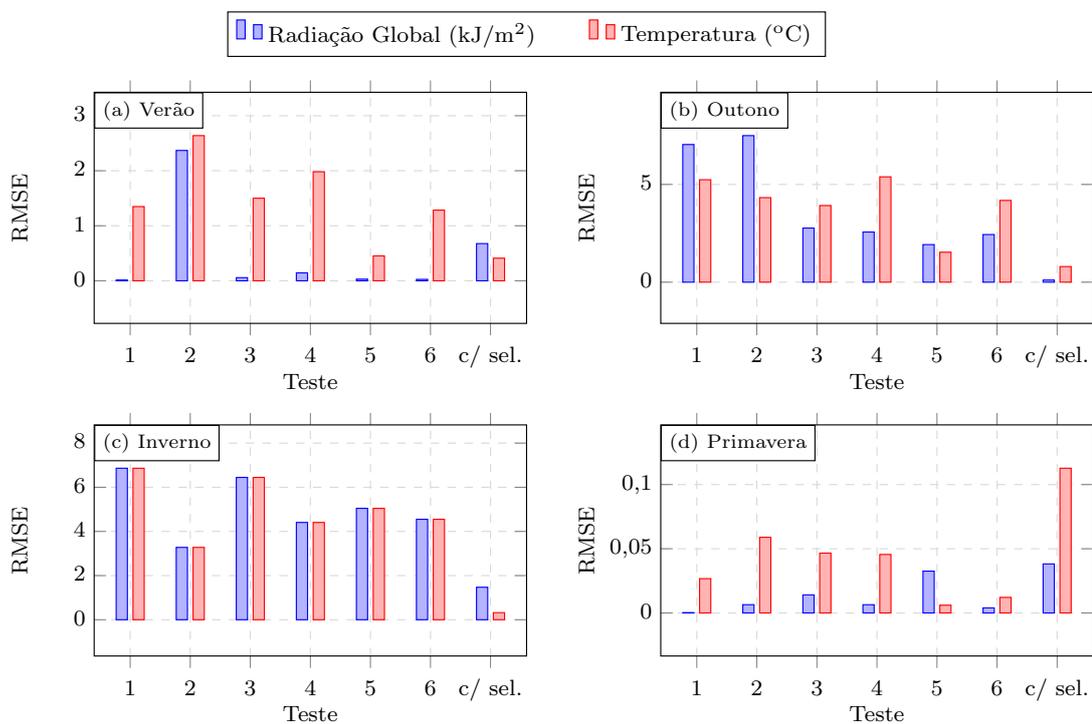
		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[2]	[4 3]	[2 15]	[16]	[2 14]	[5 4]	[5 9]
	MAE ($^{\circ}C$)	0,6803	1,3269	0,7578	0,9977	0,8151	0,6478	0,4925
	RAE ($^{\circ}C$)	0,0016	0,0032	0,0018	0,0024	0,0019	0,0015	0,0011
	RMSE ($^{\circ}C$)	1,3490	2,6383	1,5012	1,9818	0,4528	1,2850	0,4111
OUTONO	TOPOLOGIA	[2 17]	[6 7]	[7 12]	[7 10]	[2 13]	[7 11]	[4 11]
	MAE ($^{\circ}C$)	2,6357	2,1697	1,9761	2,7070	2,8991	2,1092	2,3858
	RAE ($^{\circ}C$)	0,0026	0,0020	0,0020	0,0027	0,0029	0,0021	0,0024
	RMSE ($^{\circ}C$)	5,2412	4,3255	3,9210	5,3894	1,5332	4,1827	0,7975
INVERNO	TOPOLOGIA	[3 15]	[6 11]	[2 4]	[2 14]	[2 16]	[2 11]	[2 4]
	MAE ($^{\circ}C$)	3,4397	1,6491	3,2346	2,2075	2,5269	2,2761	0,7732
	RAE ($^{\circ}C$)	0,3158	0,1055	0,2969	0,2026	0,2320	0,2089	0,0070
	RMSE ($^{\circ}C$)	6,8625	3,2771	6,4469	4,4070	5,0466	4,5494	0,3207
PRIMAVERA	TOPOLOGIA	[4 13]	[5 10]	[3 13]	[7 8]	[2 16]	[3 11]	[17]
	MAE ($^{\circ}C$)	4,4182	4,4902	4,4500	4,4574	4,4583	4,4007	4,4879
	RAE ($^{\circ}C$)	0,3167	0,3219	0,3190	0,3195	0,3196	0,3155	0,3217
	RMSE ($^{\circ}C$)	0,0267	0,0589	0,0466	0,0456	0,0061	0,0121	0,1127

Investigando as particularidades dos resultados encontrados, pode-se notar que para os 4 períodos sazonais, em geral, a função de seleção de atributos contribuiu para a

obtenção de erros baixos e 3 deles, tanto para Temperatura do Ar quanto para Irradiação Solar.

Optou-se por analisar mais especificamente os resultados dos cálculos de RMSE, a raiz do erro quadrático médio, por conta da facilidade de encontrar, na literatura, estudos comparativos de desempenho, sem deixar de considerar as particularidades de cada rede neural e suas variáveis. Na Figura 29 a seguir, é apresentado o desempenho da métrica RMSE para as variáveis Temperatura do Ar e Irradiação Solar nos 4 períodos sazonais estudados.

Figura 29 – Valores de RMSE para cada período sazonal - Caxias



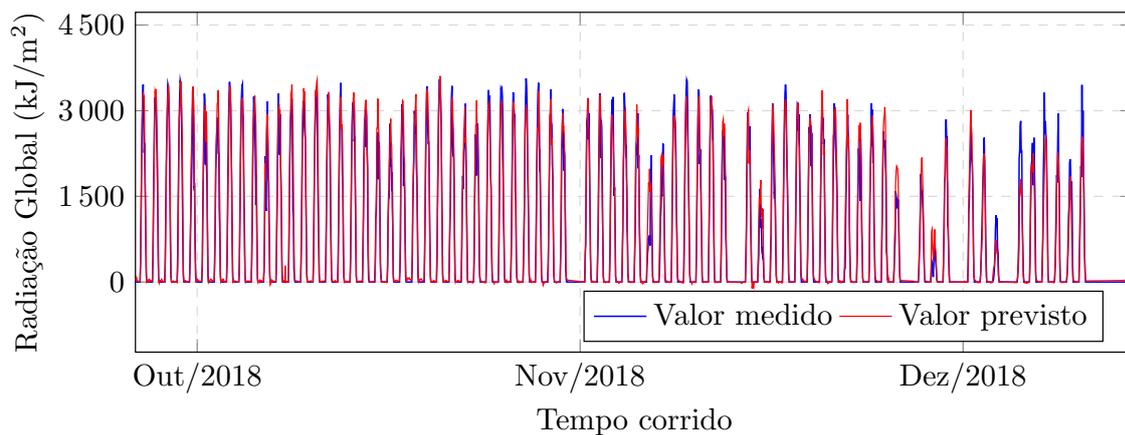
Fonte: Elaborado pela autora.

Por meio da Figura 29, foi possível notar que mesmo com o bom desempenho dos resultados dos testes baseados na seleção de atributos, a configuração da previsão para o período de primavera foi a que apresentou os índices mais baixos quando comparados aos demais períodos. Os testes que apresentaram melhor resultado são o Teste 1 para previsão de Irradiação Solar e o Teste 5 para previsão de Temperatura do Ar, ambos na primavera, com suas configurações detalhadas na Tabela 14:

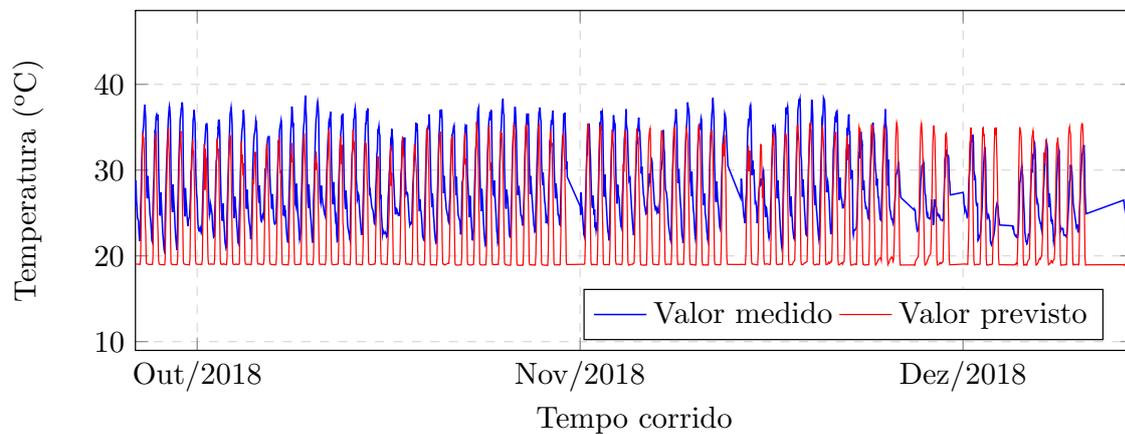
As configurações acima forneceram maior grau de exatidão para prever então, a primavera de um ano a frente dessas duas variáveis. Para melhor exemplificar o impacto da métrica RMSE no processo, o comportamento do erro é demonstrado nas figuras a seguir, que representam trechos das amostras utilizadas em sua forma real e estimada pelo cálculo do erro:

Tabela 14 – Detalhamento dos melhores resultados de RMSE - Caxias

Irradiação Solar 0,0002 kJ/m^2	Período sazonal	Primavera
	Detalhes do teste	T1: X_{M-1} do conjunto de variáveis + X_{M-2} da variável a ser prevista + X_{M-12} da variável a ser prevista + X_{M-13} da variável a ser prevista
	Execução	Nº 2
	Topologia	[5 3]
Temp. Ar 0,006 °C	Período sazonal	Primavera
	Detalhes do teste	T5: $X_{M-1} + X_{M-2} + X_{M-12} + X_{M-13}$ da variável a ser prevista + $X_{MM-5} + X_{MM-10} + X_{MM-15}$ da variável a ser prevista
	Execução	Nº 7
	Topologia	[2 16]

Figura 30 – Resultado final - Irradiação Solar (Teste 1) - Caxias

Fonte: Elaborado pela autora.

Figura 31 – Resultado final - Temperatura do Ar (Teste 5) - Caxias

Fonte: Elaborado pela autora.

6.2 Colinas

Seguindo com os resultados, é apresentado o desempenho da previsão usando as Redes Neurais Artificiais conforme os parâmetros preestabelecidos:

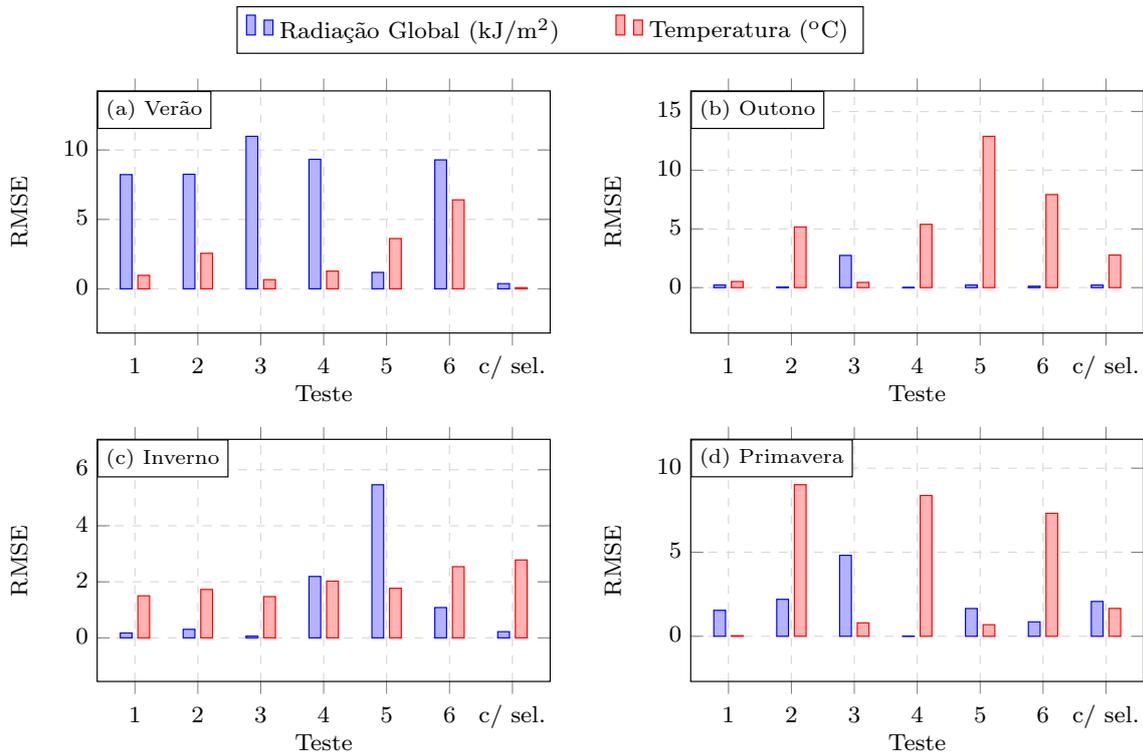
Tabela 15 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Colinas

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[2 3]	[2 17]	[2 8]	[2 6]	[4 12]	[5 14]	2
	MAE (kJ/m^2)	4,1294	4,1436	5,5080	4,6829	0,6128	4,6633	0,2021
	RAE (kJ/m^2)	0,0156	0,0157	0,0208	0,0177	0,0023	0,0176	0,0008
	RMSE (kJ/m^2)	8,2277	8,2525	10,9865	9,3303	1,1830	9,2899	0,3733
OUTONO	TOPOLOGIA	[3 3]	[5 12]	[4 2]	[6 3]	[5 2]	[6 4]	[4 14]
	MAE (kJ/m^2)	2,7304	2,7082	4,0143	2,6802	2,8908	2,8323	1,1407
	RAE (kJ/m^2)	0,0849	0,0842	0,1249	0,0834	0,0899	0,0881	0,0144
	RMSE (kJ/m^2)	0,2252	0,0523	2,7433	0,0009	0,2241	0,1204	0,2202
INVERNO	TOPOLOGIA	[3 10]	[6 3]	[7 8]	[4 12]	8	16	[4 14]
	MAE (kJ/m^2)	0,2611	0,3951	0,7101	1,1334	2,7371	0,7566	1,1407
	RAE (kJ/m^2)	0,001	0,003	0,005	0,007	0,0018	0,005	0,0144
	RMSE (kJ/m^2)	0,1746	0,3045	0,0642	2,1919	5,4638	1,0816	0,2202
PRIMAVERA	TOPOLOGIA	3	[7 6]	3	[5 8]	4	[3 5]	15
	MAE (kJ/m^2)	0,7996	1,1221	4,4805	2,2779	1,0319	1,5264	2,1226
	RAE (kJ/m^2)	0,0013	0,0018	0,0071	0,0036	0,0016	0,0024	0,0033
	RMSE (kJ/m^2)	1,5452	2,1996	4,8169	0,0135	1,6523	0,8591	2,0732

Tabela 16 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Colinas

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[2 11]	[2 17]	[2 11]	[2 17]	[3 2]	[2 13]	11
	MAE ($^{\circ}C$)	0,5104	1,3008	0,4948	0,6592	1,8368	3,2252	0,676
	RAE ($^{\circ}C$)	0,0023	0,0058	0,0016	0,0029	0,0081	0,0143	0,0003
	RMSE ($^{\circ}C$)	0,9702	2,5581	0,6605	1,2772	3,6226	6,4095	0,0863
OUTONO	TOPOLOGIA	[2 9]	[2 15]	3	7	3	[7 10]	[3 13]
	MAE ($^{\circ}C$)	2,7756	4,8771	2,4948	2,8499	9,2165	4,1259	1,5680
	RAE ($^{\circ}C$)	0,0171	0,0300	0,0154	0,0175	0,0568	0,0254	0,0037
	RMSE ($^{\circ}C$)	0,5246	5,1736	0,4463	5,3917	12,8879	7,9272	2,7801
INVERNO	TOPOLOGIA	[7 4]	[7 10]	[6 10]	[4 14]	[2 8]	16	[3 13]
	MAE ($^{\circ}C$)	1,9305	1,0185	2,3770	1,1133	1,0678	2,3483	1,5680
	RAE ($^{\circ}C$)	0,0012	0,0066	0,0015	0,0072	0,0057	0,0015	0,0037
	RMSE ($^{\circ}C$)	1,5006	1,7274	1,4729	2,0245	1,7717	2,5408	2,7801
PRIMAVERA	TOPOLOGIA	15	[5 10]	[2 12]	[2 9]	[2 13]	[5 13]	14
	MAE ($^{\circ}C$)	1,2314	5,6628	1,7832	4,4096	0,4871	3,8428	1,1752
	RAE ($^{\circ}C$)	0,0065	0,0298	0,0094	0,0232	0,0026	0,0202	0,0062
	RMSE ($^{\circ}C$)	0,0350	9,0194	0,7988	8,3778	0,6900	7,3172	1,6602

No caso de Colinas, houveram respostas distintas quanto ao desempenho do RMSE em relação aos testes. Na Figura 32 a seguir, é apresentado o desempenho da métrica RMSE para as variáveis Temperatura do Ar e Irradiação Solar nos 4 períodos sazonais estudados.

Figura 32 – Valores de RMSE para cada período sazonal - Colinas

Fonte: Elaborado pela autora.

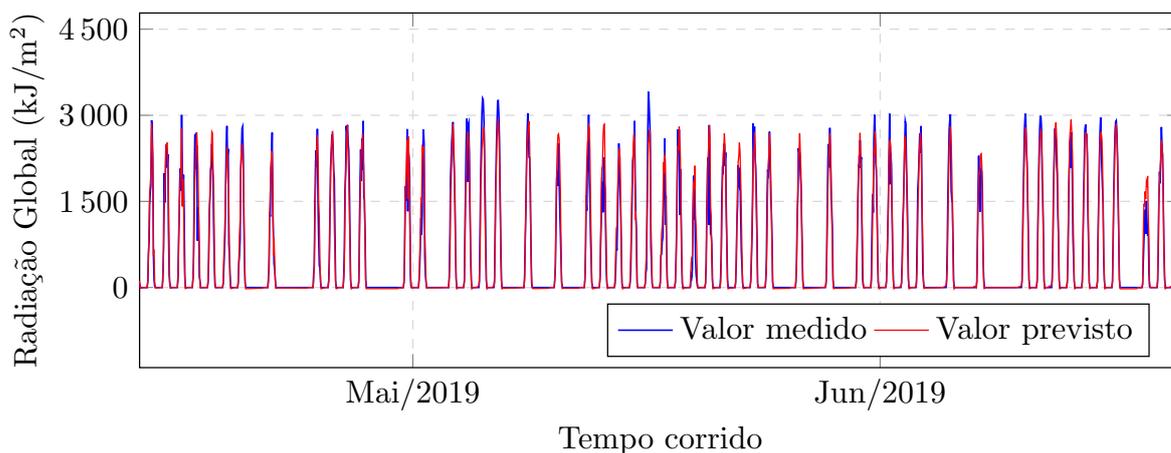
De forma mais específica, os testes com seleção de atributos apresentaram os melhores resultados na previsão das variáveis no período do verão. No outono, o melhor desempenho para prever Irradiação Solar foi o do Teste 4 e Teste 3 para Temperatura do Ar. No inverno, os menores valores do RMSE foram fornecidos com base no Teste 3 e, por fim, na primavera, o Teste 4 obteve maior sucesso para Irradiação Solar e o Teste 1 para Temperatura do Ar.

Novamente, para previsão de Temperatura do Ar, os dados do período sazonal primavera apresentaram maior consistência e menor RMSE. No caso da previsão de Irradiação Solar, os valores do erro foram muito similares, porém a melhor configuração foi a do Teste 4, no período sazonal do outono. Suas configurações estão detalhadas a seguir:

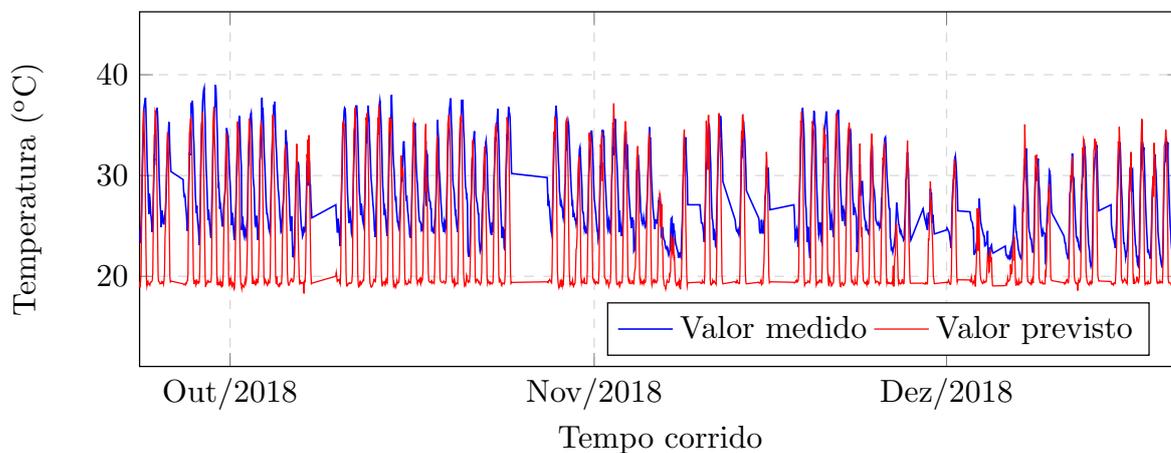
Pela Figura 33, nota-se o desempenho consistente do modelo preditivo de menor RMSE para Irradiação Solar. Apesar de apresentar o melhor resultado, o RMSE da variável Temperatura do Ar é mais alto quando comparado ao melhor RMSE destrinchado na seção anterior. No gráfico de Temperatura do Ar a seguir, é possível notar as inconsistências que aumentam o erro nos trechos das amostras comparadas em sua forma real e estimada pelo cálculo do erro:

Tabela 17 – Detalhamento dos melhores resultados de RMSE - Colinas

Irradiação Solar $0,0008 \text{ kJ/m}^2$	Período sazonal	Outono
	Detalhes do teste	T4: X_{M-1} Irradiação Solar e Temperatura do Ar + X_{M-2} da variável a ser prevista + X_{MM-5} + X_{MM-10} + X_{MM-15} do conjunto de variáveis
	Execução	Nº 1
	Topologia	[6 3]
Temp. Ar $0,035 \text{ }^\circ\text{C}$	Período sazonal	Primavera
	Detalhes do teste	T1: X_{M-1} do conjunto de variáveis + X_{M-2} da variável a ser prevista + X_{M-12} da variável a ser prevista + X_{M-13} da variável a ser prevista
	Execução	Nº 3
	Topologia	[15]

Figura 33 – Resultado final - Irradiação Solar (Teste 4) - Colinas

Fonte: Elaborado pela autora.

Figura 34 – Resultado final - Temperatura do Ar (Teste 1) - Colinas

Fonte: Elaborado pela autora.

6.3 Imperatriz

Para o município de Imperatriz, são apresentados os resultados das métricas que indicam o desempenho da previsão de cada período sazonal usando as Redes Neurais Artificiais.

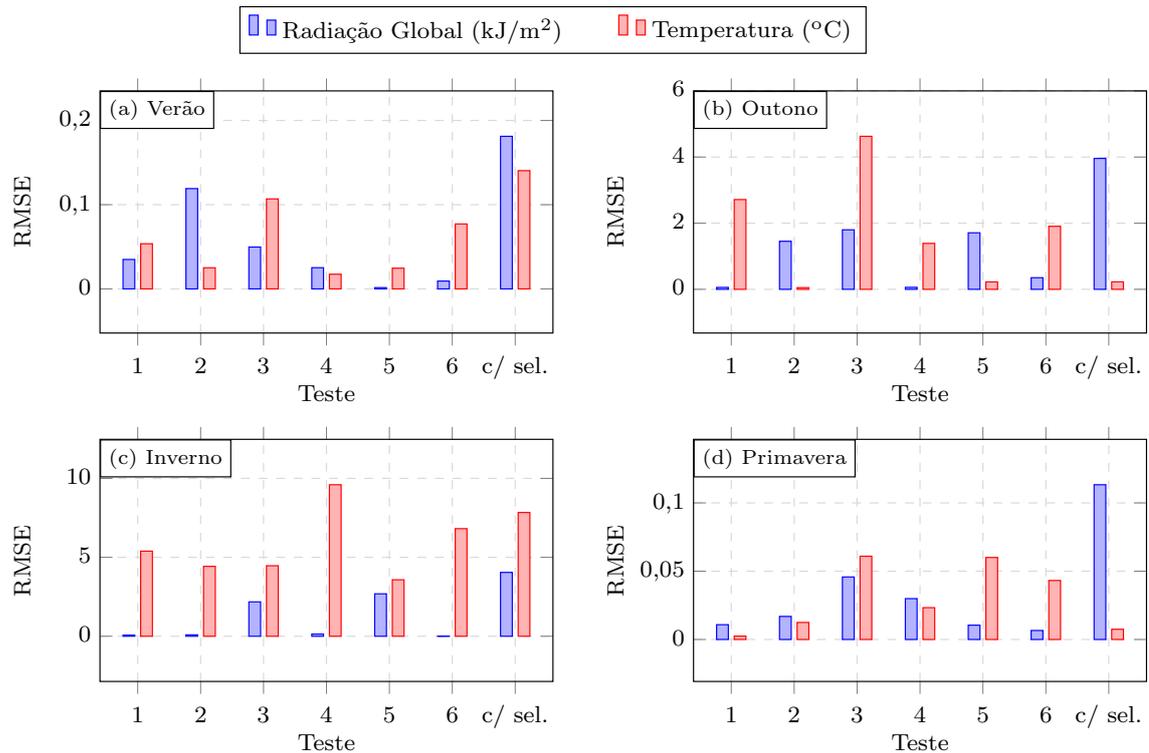
Tabela 18 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Imperatriz

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[7 5]	15	[4 8]	[2 14]	2	[3 15]	[5 9]
	MAE (kJ/m^2)	3,1154	3,2090	3,1721	3,0972	3,0928	3,1905	3,2986
	RAE (kJ/m^2)	0,2316	0,2386	0,2358	0,2303	0,2299	0,2372	0,2453
	RMSE (kJ/m^2)	0,0350	0,1191	0,0497	0,0252	0,0015	0,0093	0,1812
OUTONO	TOPOLOGIA	[5 2]	[5 12]	[6 7]	[6 3]	[5 5]	[7 8]	[4 10]
	MAE (kJ/m^2)	2,4417	3,8185	0,9142	2,9544	4,1025	3,6487	5,6042
	RAE (kJ/m^2)	0,0028	0,0044	0,0010	0,0034	0,0047	0,0042	0,0064
	RMSE (kJ/m^2)	0,0576	1,4534	1,7995	0,0600	1,7090	0,3508	3,9586
INVERNO	TOPOLOGIA	[7 3]	[6 5]	[2 9]	15	[7 11]	[4 13]	9
	MAE (kJ/m^2)	0,0626	0,1473	1,0969	0,2516	3,8633	0,0752	2,4277
	RAE (kJ/m^2)	0,00005	0,0001	0,0008	0,0002	0,0029	0,0001	0,0018
	RMSE (kJ/m^2)	0,0724	0,0893	2,1770	0,1387	2,6882	0,0112	4,0450
PRIMAVERA	TOPOLOGIA	[4 11]	[5 11]	[6 9]	16	16	[3 12]	[5 8]
	MAE (kJ/m^2)	2,5457	2,5035	2,6091	2,5832	2,5663	2,4951	2,6139
	RAE (kJ/m^2)	0,2012	0,1979	0,2062	0,2042	0,2029	0,1972	0,2066
	RMSE (kJ/m^2)	0,0108	0,0169	0,0458	0,0299	0,0105	0,0066	0,1133

Tabela 19 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Imperatriz

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[2 8]	[4 14]	[4 7]	[7 11]	[2 16]	6	[3 2]
	MAE ($^{\circ}C$)	3,0682	2,9071	3,0402	3,0019	2,6655	3,0011	3,0209
	RAE ($^{\circ}C$)	0,2316	0,2194	0,2294	0,2266	0,2012	0,2265	0,2280
	RMSE ($^{\circ}C$)	0,0536	0,0251	0,1069	0,0174	0,0246	0,0772	0,1404
OUTONO	TOPOLOGIA	[5 6]	[2 5]	[6 13]	14	[5 12]	[7 7]	[3 10]
	MAE ($^{\circ}C$)	4,7199	4,5824	2,3387	5,3059	3,8073	1,4232	4,8296
	RAE ($^{\circ}C$)	0,0097	0,0094	0,0048	0,0109	0,0078	0,0029	0,0099
	RMSE ($^{\circ}C$)	2,7140	0,0509	4,6275	1,3890	0,2242	1,9061	0,2258
INVERNO	TOPOLOGIA	[4 12]	4	[3 3]	[4 8]	[6 11]	[4 14]	6
	MAE ($^{\circ}C$)	2,7034	2,2573	2,2384	4,8321	4,2023	3,4390	3,9394
	RAE ($^{\circ}C$)	0,0018	0,0015	0,0015	0,0033	0,0029	0,0023	0,0027
	RMSE ($^{\circ}C$)	5,3920	4,4288	4,4661	9,5977	3,5774	6,8160	7,8399
PRIMAVERA	TOPOLOGIA	[5 5]	[2 16]	[6 9]	[6 11]	[7 4]	[5 11]	[3 3]
	MAE ($^{\circ}C$)	2,1712	2,2083	2,1739	2,1764	2,1860	2,2084	2,1784
	RAE ($^{\circ}C$)	0,1765	0,1795	0,1767	0,1769	0,1777	0,1795	0,1771
	RMSE ($^{\circ}C$)	0,0025	0,0125	0,0610	0,0233	0,0601	0,0432	0,0075

Conforme a tabela de erros apresentada anteriormente, o desempenho dos testes para cada período sazonal foi variado. Para um maior detalhamento, na Figura 35 a seguir, as variações da métrica RMSE são comparados entre os 4 períodos sazonais para as variáveis Temperatura do Ar e Irradiação Solar.

Figura 35 – Valores de RMSE para cada período sazonal - Imperatriz

Fonte: Elaborado pela autora.

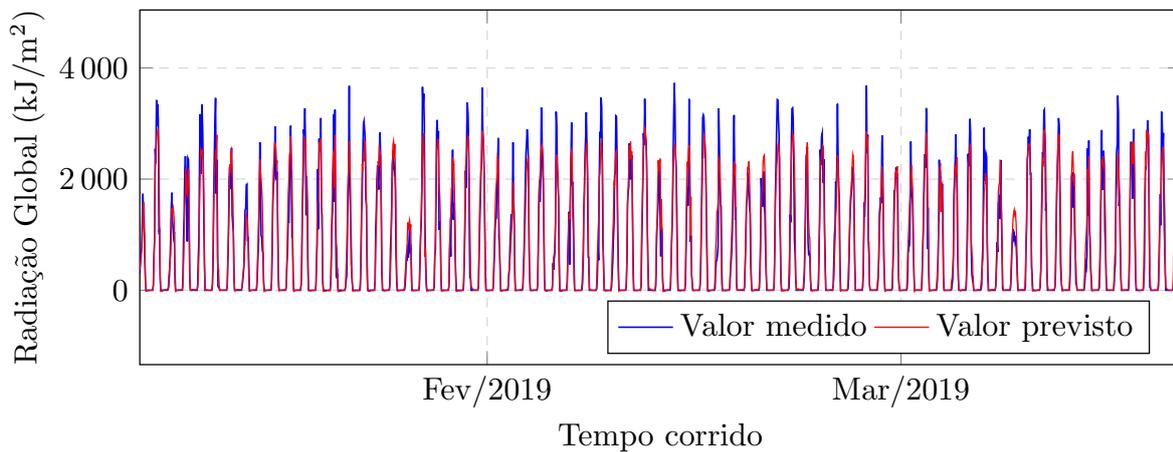
Por meio da figura anterior nota-se que o melhor resultado de RMSE para previsão de Irradiação Solar usando dados do verão foi com o Teste 5, enquanto que, para Temperatura do Ar, o Teste 4 obteve melhores resultados. Para o outono, os testes 1 e 2 resultaram em um RMSE mais baixo para Irradiação Solar e Temperatura do Ar, respectivamente. No inverno, os valores de RMSE de Irradiação Solar apresentaram certa consistência entre 4 testes, com o melhor resultado sendo o do Teste 6. Já as previsões de Temperatura do Ar obtiveram valores mais altos de RMSE se comparados à outra variável e mesmo aos desempenhos da previsão em outros períodos sazonais.

No geral, para previsão de Irradiação Solar, as configurações determinadas no Teste 5 do verão obtiveram melhores resultados. E novamente para previsão de Temperatura do Ar, o desempenho dos testes no período da primavera resultou em valores de RMSE mais baixos, com destaque para o Teste 1. As configurações de ambos os testes estão detalhadas na Tabela 20:

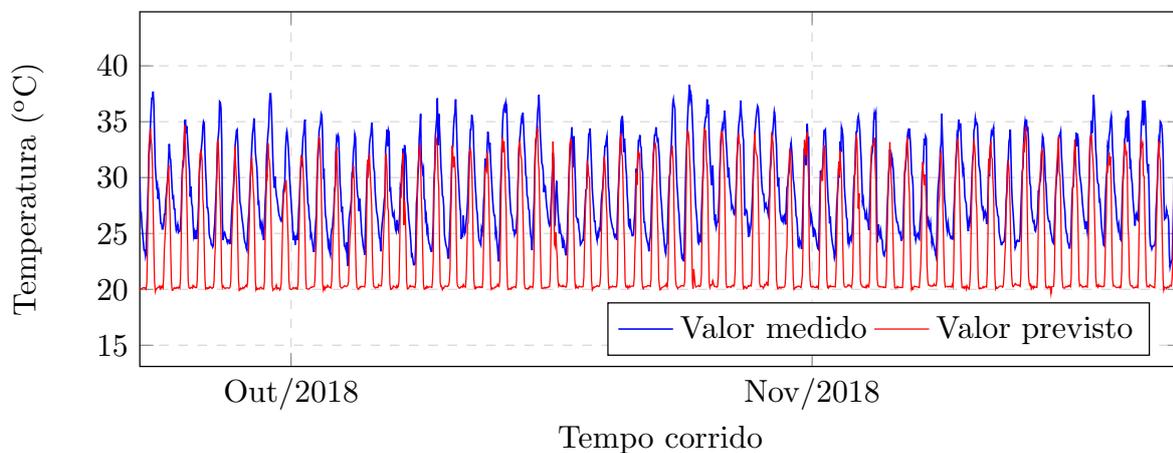
Por meio da Figura 36, são detalhados dois trechos: o primeiro entre fevereiro e março de 2019, período que corresponde ao final do verão, em que o menor valor de erro para Irradiação Solar foi encontrado; o segundo trecho detalha dois meses da primavera de 2018, onde a previsão de Temperatura do Ar teve melhor desempenho.

Tabela 20 – Detalhamento dos melhores resultados de RMSE - Imperatriz

Irradiação Solar $0,0015 \text{ kJ/m}^2$	Período sazonal	Verão
	Detalhes do teste	T5: $X_{M-1} + X_{M-2} + X_{M-12} + X_{M-13}$ da variável a ser prevista + $X_{MM-5} + X_{MM-10} + X_{MM-15}$ da variável a ser prevista
	Execução	Nº 6
	Topologia	[2]
Temp. Ar $0,0025 \text{ }^\circ\text{C}$	Período sazonal	Primavera
	Detalhes do teste	T1: X_{M-1} do conjunto de variáveis + X_{M-2} da variável a ser prevista + X_{M-12} da variável a ser prevista + X_{M-13} da variável a ser prevista
	Execução	Nº 7
	Topologia	[5 5]

Figura 36 – Resultado final - Irradiação Solar (Teste 5) - Imperatriz

Fonte: Elaborado pela autora.

Figura 37 – Resultado final - Temperatura do Ar (Teste 1) - Imperatriz

Fonte: Elaborado pela autora.

6.4 São Luís

Para o município de São Luís, a seguir são apresentados os valores calculados para as métricas de avaliação do desempenho da previsão de cada período sazonal usando as Redes Neurais Artificiais.

Tabela 21 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - São Luís

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[2 2]	9	[3 4]	[5 10]	[5 4]	[3 3]	[3 2]
	MAE (kJ/m^2)	2,4814	2,6277	1,5143	1,4917	1,9679	1,4998	2,6002
	RAE (kJ/m^2)	0,0479	0,0507	0,1221	0,1203	0,1587	0,1210	0,0501
	RMSE (kJ/m^2)	0,0054	0,2488	0,0750	0,1803	1,0460	0,0770	0,1762
OUTONO	TOPOLOGIA	9	16	[5 4]	[6 13]	[6 12]	[6 6]	14
	MAE (kJ/m^2)	0,5782	0,3786	0,5473	0,3401	0,3618	0,2110	0,4316
	RAE (kJ/m^2)	0,0057	0,0037	0,0054	0,0034	0,0036	0,0021	0,0043
	RMSE (kJ/m^2)	1,1172	0,7197	1,0550	0,6432	0,6837	0,3838	0,8256
INVERNO	TOPOLOGIA	[5 6]	[6 11]	[3 7]	17	[4 15]	[5 6]	[5 8]
	MAE (kJ/m^2)	3,3640	2,6122	1,9596	2,3140	2,7325	2,7230	3,3388
	RAE (kJ/m^2)	0,0042	0,0032	0,0024	0,0029	0,0034	0,0034	0,0042
	RMSE (kJ/m^2)	2,7643	4,8263	3,8203	0,1457	4,9089	0,1287	1,8071
PRIMAVERA	TOPOLOGIA	[6 2]	[7 2]	[5 6]	7	[5 2]	17	[4 14]
	MAE (kJ/m^2)	1,9517	1,5249	1,4651	1,4608	1,4478	1,5783	1,4595
	RAE (kJ/m^2)	0,1574	0,1230	0,1182	0,1178	0,1168	0,1273	0,1177
	RMSE (kJ/m^2)	0,6610	0,1105	0,0645	0,0302	0,0337	0,0527	0,0075

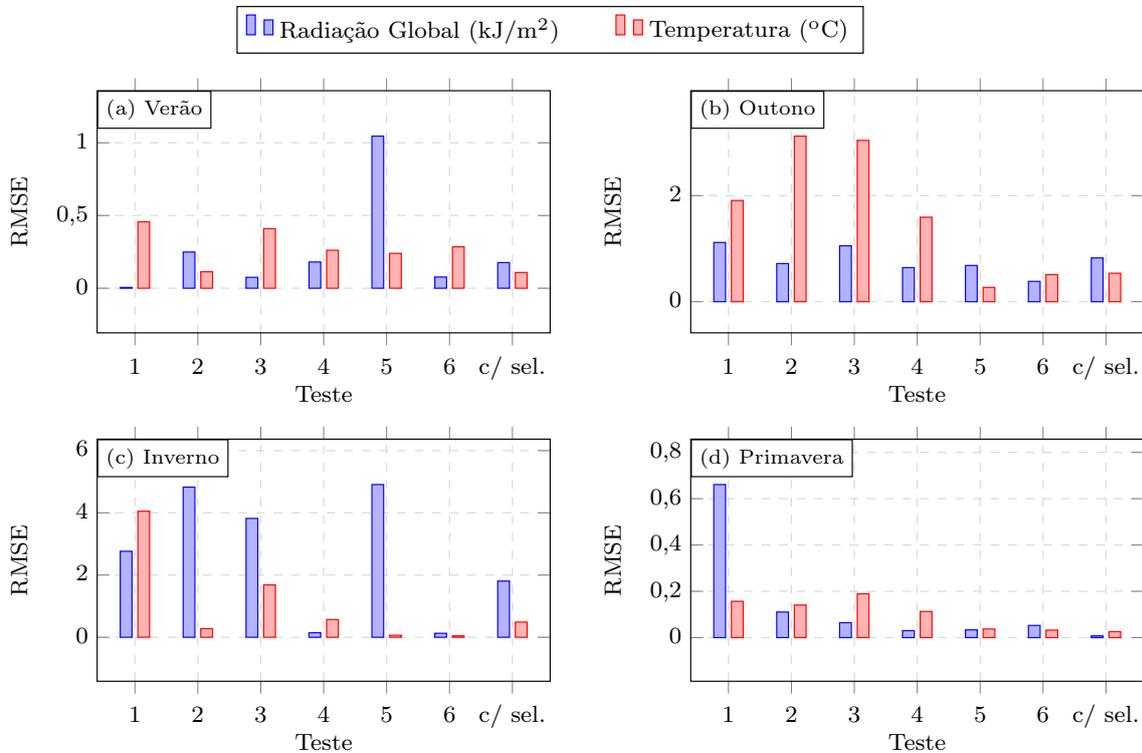
Tabela 22 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - São Luís

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[7 10]	[3 11]	[6 8]	[4 2]	[6 6]	[5 5]	4
	MAE ($^{\circ}C$)	2,4895	1,2462	1,4132	1,3258	1,3389	1,3324	2,5724
	RAE ($^{\circ}C$)	0,0066	0,1026	0,1163	0,1091	0,1102	0,1097	0,0068
	RMSE ($^{\circ}C$)	0,4566	0,1131	0,4095	0,2612	0,2395	0,2849	0,1084
OUTONO	TOPOLOGIA	[3 8]	[7 2]	[2 2]	4	[6 5]	[7 7]	[4 10]
	MAE ($^{\circ}C$)	0,9763	1,7735	1,5436	0,8185	0,4930	0,5192	0,5111
	RAE ($^{\circ}C$)	0,0020	0,0036	0,0031	0,0016	0,0008	0,0010	0,0010
	RMSE ($^{\circ}C$)	1,9086	3,1225	3,0421	1,5934	0,2695	0,5123	0,5372
INVERNO	TOPOLOGIA	[2 12]	[2 9]	[7 11]	[2 4]	[6 3]	[2 12]	[6 4]
	MAE ($^{\circ}C$)	2,1420	2,2666	0,9563	0,4890	2,5941	2,2229	2,4791
	RAE ($^{\circ}C$)	0,0037	0,0039	0,0016	0,0007	0,0044	0,0038	0,0042
	RMSE ($^{\circ}C$)	4,0523	0,2778	1,6829	0,5692	0,0643	0,0451	0,4879
PRIMAVERA	TOPOLOGIA	9	[6 6]	[6 9]	[3 11]	[7 5]	[6 5]	[5 8]
	MAE ($^{\circ}C$)	1,0696	1,2637	1,3301	1,2462	1,2131	1,1893	1,2471
	RAE ($^{\circ}C$)	0,0880	0,1040	0,1095	0,1026	0,0998	0,0979	0,1026
	RMSE ($^{\circ}C$)	0,1569	0,1408	0,1892	0,1131	0,0371	0,0325	0,0256

Ao analisar a tabela, os melhores resultados das métricas predominam em configurações do Teste 6 e da Seleção de Atributos. Na Figura 38 a seguir, é apresentado

o comportamento da métrica RMSE e comparado entre os 4 períodos sazonais para as variáveis Temperatura do Ar e Irradiação Solar.

Figura 38 – Valores de RMSE para cada período sazonal - São Luís



Fonte: Elaborado pela autora.

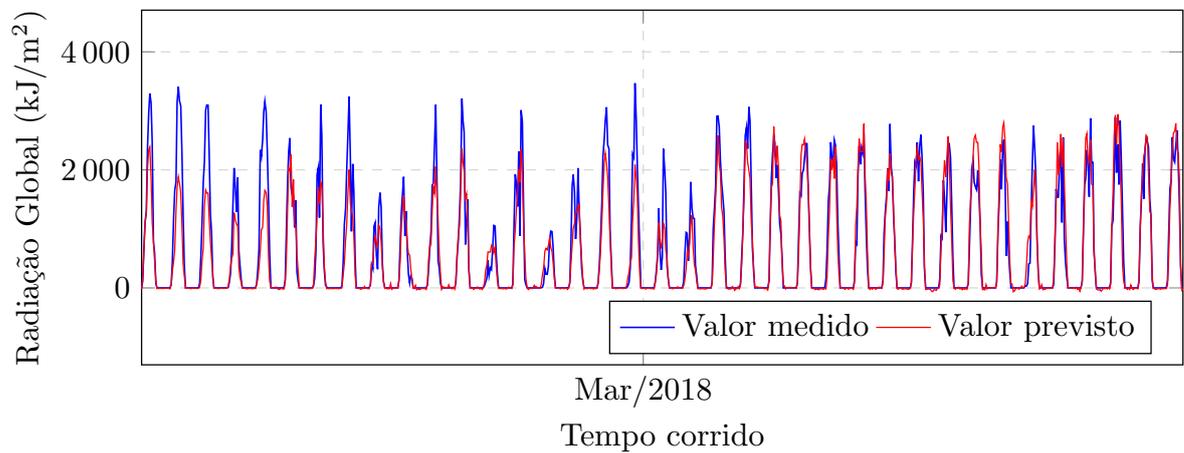
Ao destrinchar a análise da figura anterior, nota-se que novamente os valores de RMSE no período do inverno são consideravelmente mais altos que os resultados dos demais períodos, além de serem muito discrepantes entre si, o que segue a tendência dos valores nos municípios já analisados. É possível notar que os menores valores de erro foram os resultados da previsão no período do verão e da primavera.

Para a previsão de Irradiação Solar, as configurações determinadas no Teste 1 do verão obtiveram melhores resultados. Mais uma vez, para previsão de Temperatura do Ar, os testes no período da primavera resultaram em valores de RMSE mais baixos, em que o teste com Seleção de Atributos teve o melhor desempenho. As configurações de ambos os testes estão detalhadas na Tabela 23:

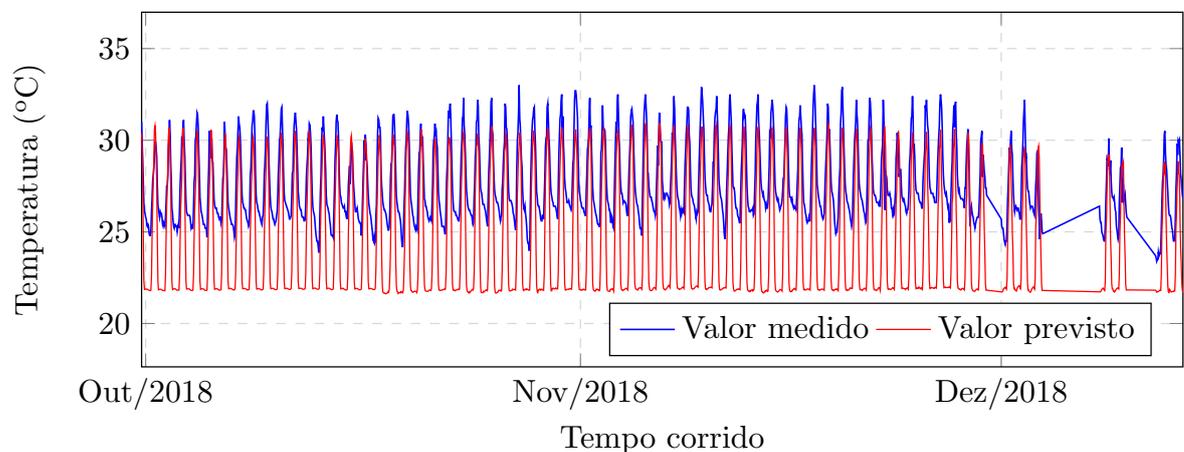
Na Figura 39, são destacados os comparativos entre os valores medidos e os valores previstos tanto para Irradiação Solar quanto para Temperatura do Ar. Nota-se maior similaridade entre os valores no trecho que detalha a Irradiação Solar. Os valores de erro mais altos para Temperatura do Ar são maiores que os de Irradiação Solar por conta de alguns *gaps* notados na Base Final, no período da primavera em São Luís.

Tabela 23 – Detalhamento dos melhores resultados de RMSE - São Luís

Irradiação Solar $0,0053(kJ/m^2)$	Período sazonal	Verão
	Detalhes do teste	T1: X_{M-1} do conjunto de variáveis + X_{M-2} da variável a ser prevista + X_{M-12} da variável a ser prevista + X_{M-13} da variável a ser prevista
	Execução	Nº 8
	Topologia	[2 2]
Temp. Ar $0,025(kJ/m^2)$	Período sazonal	Primavera
	Detalhes do teste	Com Seleção de Atributos: (Tabela 57)
	Execução	Nº 2
	Topologia	[5 8]

Figura 39 – Resultado final - Irradiação Solar (Teste 1) - São Luís

Fonte: Elaborado pela autora.

Figura 40 – Resultado final - Temperatura do Ar (Seleção de Atributos) - São Luís

Fonte: Elaborado pela autora.

6.5 Turiaçu

Por fim, para o último município estudado, a seguir são apresentados os valores das métricas de avaliação da previsão de cada período sazonal usando as Redes Neurais Artificiais.

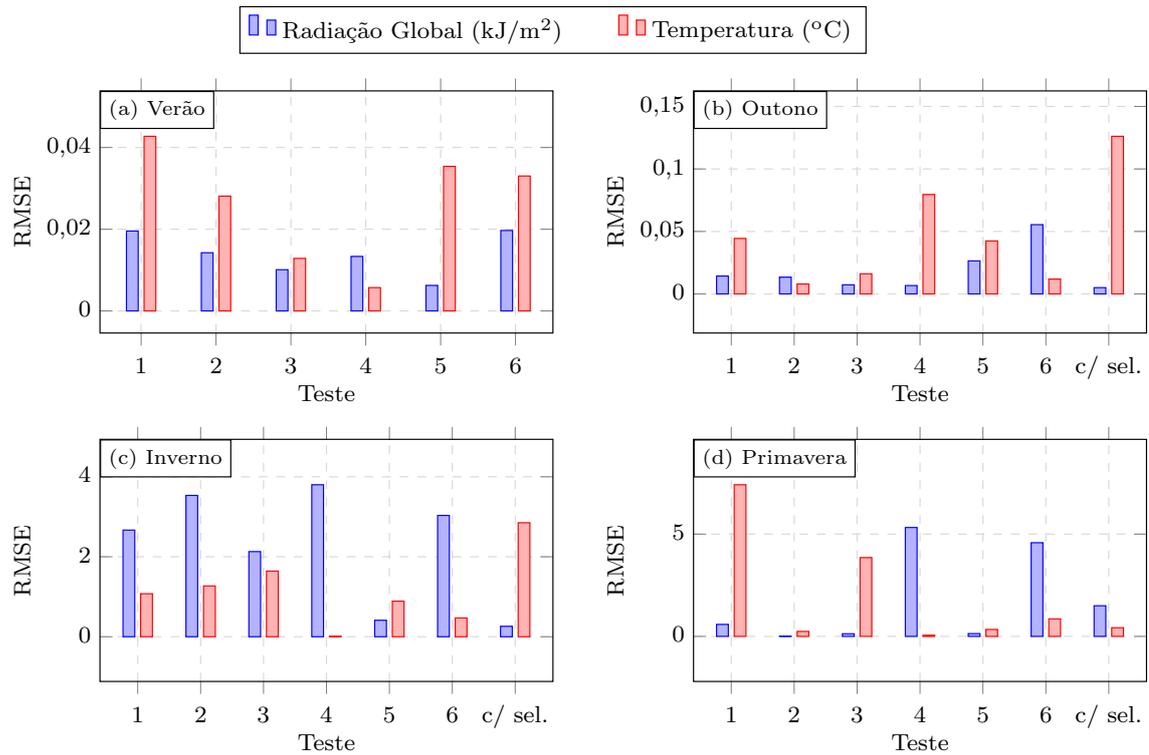
Tabela 24 – Resultados dos testes para previsão de Irradiação Solar (kJ/m^2) - Turiaçu

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[6 4]	[2 2]	[2 8]	[5 5]	13	8	6
	MAE (kJ/m^2)	2,5210	2,5225	2,5080	2,5224	2,4369	2,5298	3,3779
	RAE (kJ/m^2)	0,1985	0,1986	0,1975	0,1986	0,1919	0,1992	0,2660
	RMSE (kJ/m^2)	0,0196	0,0142	0,0101	0,0133	0,0062	0,0197	2,2919
OUTONO	TOPOLOGIA	[3 10]	[2 16]	[3 4]	10	[4 9]	[2 15]	[3 8]
	MAE (kJ/m^2)	1,7124	1,6188	1,6310	1,5958	1,6094	1,6076	1,6226
	RAE (kJ/m^2)	0,1370	0,1295	0,1305	0,1277	0,1288	0,1286	0,1298
	RMSE (kJ/m^2)	0,0143	0,0134	0,0073	0,0067	0,0264	0,0554	0,0050
INVERNO	TOPOLOGIA	[5 12]	[4 11]	[2 5]	15	[2 4]	12	11
	MAE (kJ/m^2)	1,3386	1,7705	1,0677	1,9044	0,2145	1,5199	0,1341
	RAE (kJ/m^2)	0,0014	0,0019	0,0011	0,0020	0,0002	0,0016	0,0001
	RMSE (kJ/m^2)	2,6669	3,5343	2,1295	3,8013	0,4124	3,0336	0,2610
PRIMAVERA	TOPOLOGIA	[2 16]	5	13	[5 10]	[6 4]	[7 8]	[3 7]
	MAE (kJ/m^2)	2,0714	2,0285	1,9015	4,6625	1,9637	2,5793	2,8051
	RAE (kJ/m^2)	0,0114	0,0112	0,0105	0,0257	0,0108	0,0142	0,0154
	RMSE (kJ/m^2)	0,5866	0,0155	0,1285	5,3216	0,1370	4,5785	1,4983

Tabela 25 – Resultados dos testes para previsão de Temperatura do Ar ($^{\circ}C$) - Turiaçu

		T1	T2	T3	T4	T5	T6	C/ selec.
VERÃO	TOPOLOGIA	[2 5]	[5 9]	[6 8]	[2 4]	[6 3]	13	[4 5]
	MAE ($^{\circ}C$)	2,3105	2,3617	2,3142	2,3117	2,2424	2,2163	2,6695
	RAE ($^{\circ}C$)	0,1848	0,1889	0,1851	0,1849	0,1794	0,1773	0,2136
	RMSE ($^{\circ}C$)	0,0427	0,0281	0,0129	0,0057	0,0354	0,0330	0,7445
OUTONO	TOPOLOGIA	[2 8]	[4 13]	[6 11]	10	[3 15]	[3 16]	[3 2]
	MAE ($^{\circ}C$)	1,7047	1,6882	1,7058	1,7349	1,7298	1,7120	1,7632
	RAE ($^{\circ}C$)	0,1353	0,1340	0,1354	0,1377	0,1373	0,1359	0,1399
	RMSE ($^{\circ}C$)	0,0444	0,0080	0,0161	0,0796	0,0424	0,0119	0,1261
INVERNO	TOPOLOGIA	[4 3]	17	[3 13]	[2 6]	[6 8]	[6 11]	[7 11]
	MAE ($^{\circ}C$)	1,0240	1,0530	1,2800	0,4737	2,5357	1,3959	1,4312
	RAE ($^{\circ}C$)	0,0007	0,0007	0,0008	0,0003	0,0017	0,0009	0,0009
	RMSE ($^{\circ}C$)	1,0757	1,2708	1,6426	0,0166	0,8907	0,4710	2,8514
PRIMAVERA	TOPOLOGIA	[3 14]	[5 10]	3	[2 11]	[6 5]	[3 9]	10
	MAE ($^{\circ}C$)	5,1203	1,7823	3,3885	1,6247	1,5629	2,1047	1,9130
	RAE ($^{\circ}C$)	0,0095	0,0033	0,0063	0,0030	0,0029	0,0039	0,0035
	RMSE ($^{\circ}C$)	7,4105	0,2426	3,8527	0,0582	0,3381	0,8572	0,4246

Pelos resultados apresentados nas Tabelas 24 e 25, percebe-se uma variabilidade dos testes que obtiveram os menores valores das métricas. Na Figura 41, é detalhado o comportamento da métrica RMSE para cada um dos 4 períodos sazonais para as variáveis Irradiação Solar e Temperatura do Ar.

Figura 41 – Valores de RMSE para cada período sazonal - Turiacu

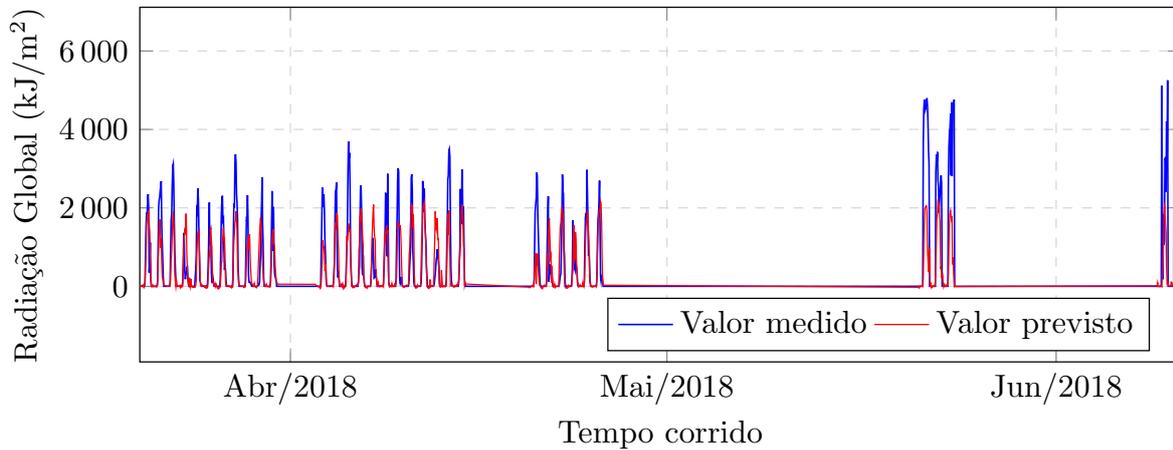
Fonte: Elaborado pela autora.

Novamente, a maioria dos valores de RMSE calculados para o período do inverno são mais altos que os demais períodos. Neste caso, as bases mais consistentes para previsão foram as do outono e do verão. Para os últimos 4 municípios, os melhores resultados de RMSE haviam sido obtidos ao utilizar a base de dados da primavera. Novamente esse período sazonal obteve um bom desempenho quando comparado aos demais, porém o valor do erro pouquíssimo acima daquele obtido quando testada a base de dados do verão. O valor mais baixo de RMSE para prever Irradiação Solar resultou do teste com Seleção de Atributos, enquanto que para Temperatura do Ar, o teste 4 no período do verão obteve o melhor desempenho. As configurações de ambos os testes estão detalhadas a seguir:

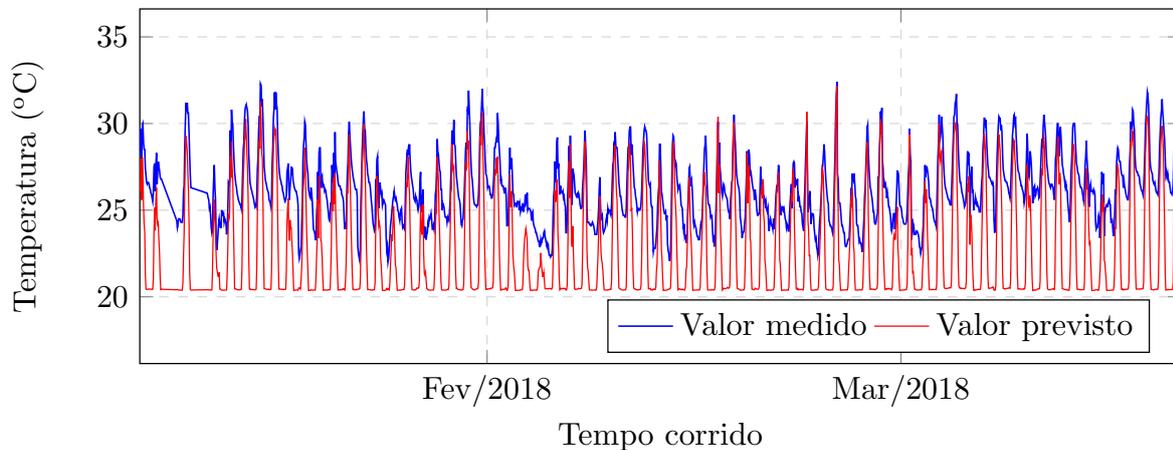
Na Figura 42, são apresentadas as medições reais e os valores previstos tanto para Irradiação Solar quanto para Temperatura do Ar. A Base Final utilizada para previsão temporal no período do outono possuía diversas falhas. Ainda assim, com os padrões do teste com Seleção de Atributos, foi possível acompanhar o comportamento da série no trecho apresentado abaixo, que corresponde ao outono de 2018. Observa-se consistência também no comparativo entre as amostras medidas e previstas da variável Temperatura do Ar.

Tabela 26 – Detalhamento dos melhores resultados de RMSE - Turiáu

Irradiação Solar 0,0050(kJ/m ²)	Período sazonal	Outono
	Detalhes do teste	Com Seleção de Atributos (Tabela 61)
	Execução	Nº 2
	Topologia	[3 8]
Temp. Ar 0,0057(°C)	Período sazonal	Verão
	Detalhes do teste	T4: X_{M-1} Irradiação Solar e Temperatura do Ar + X_{M-2} da variável a ser prevista + X_{MM-5} + X_{MM-10} + X_{MM-15} do conjunto de variáveis
	Execução	Nº 6
	Topologia	[2 4]

Figura 42 – Resultado final - Irradiação Solar (Seleção de Atributos) - Turiáu

Fonte: Elaborado pela autora.

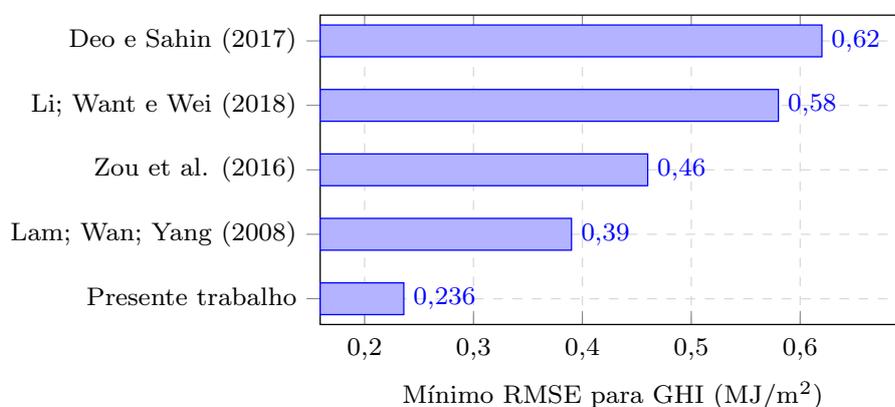
Figura 43 – Resultado final - Temperatura do Ar (Teste 4) - Turiáu

Fonte: Elaborado pela autora.

6.6 Análise comparativa dos resultados

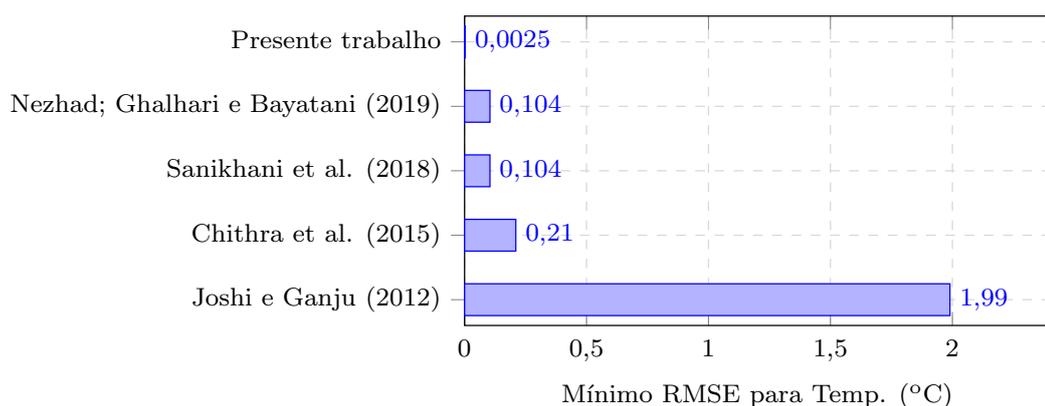
Por fim, foi possível comparar os melhores resultados obtidos no processo de previsão dessas duas variáveis com outras pesquisas similares encontradas na literatura e que embasaram este trabalho. Para visualizar melhor a comparação dos resultados, no caso da variável Irradiância Solar, o menor valor encontrado de $0,000236 \text{ kJ/m}^2$ foi convertido para a mesma unidade das pesquisas selecionadas, MJ/m^2 . O valor final foi, portanto, de $0,236 \text{ MJ/m}^2$. Os detalhes sobre cada pesquisa estão descritos na Tabela 1 e na Tabela 2 do Capítulo 2.

Figura 44 – Comparativo com a literatura - Irradiação Solar



Fonte: Elaborado pela autora.

Figura 45 – Comparativo com a literatura - Temperatura do Ar



Fonte: Elaborado pela autora.

Neste capítulo foram destrinchados os resultados encontrados para previsão de Irradiação Solar e Temperatura do Ar em 5 municípios do estado do Maranhão. O método de previsão foi desenvolvido com base na divisão dos anos de amostras cedidos por períodos sazonais, ou seja, verão, outono, inverno e primavera. Com isso, foi estabelecida

a organização dos processamentos por meio de testes montados com base nas variáveis disponíveis e nas técnicas de melhoramento das informações, como as Médias Móveis Ponderadas, utilizadas para suavizar o vasto banco de dados, correlacionando o valor da amostra com os valores passados e atribuindo maior importância àqueles mais próximos. Na Tabela 27, são resumidos os testes que apresentaram melhor desempenho para cada município:

Tabela 27 – Resumo dos melhores testes

	Irradiação Solar	Temperatura do Ar
Caxias	Teste 1	Teste 5
Colinas	Teste 4	Teste 1
Imperatriz	Teste 5	Teste 1
São Luís	Teste 1	Sel. Atrib.
Turiação	Sel. Atrib.	Teste 4

Por meio da tabela-resumo, nota-se a predominância do Teste 1 como aquele que apresenta os melhores resultados para os dois tipos de previsão. Sua composição é a seguinte:

X_{M-1} do conjunto de variáveis + X_{M-2} da variável a ser prevista + X_{M-12} da variável a ser prevista + X_{M-13} da variável a ser prevista

Ou seja, a previsão mais consistente foi obtida com base no comportamento de todas as 11 variáveis no mês anterior e no comportamento exclusivo da variável a ser prevista 2 meses antes, no mesmo mês do ano anterior e no mês anterior a ele. Dentre todas as configurações testadas, saiu do Teste 1 o melhor resultado de RMSE calculado neste trabalho. Na ?? são destacados os menores valores, ou melhor desempenho, de cada métrica de avaliação.

Tabela 28 – Melhores desempenhos das métricas de avaliação

Métrica	Variável	Resultado	Teste	Topologia	Per.Sazonal	Município
MAE	Irradiação (kJ/m^2)	0,0626	Teste 1	[7 3]	Inverno	Imperatriz
	Temperatura ($^{\circ}C$)	0,4737	Teste 4	[2 6]	Inverno	Turiação
RAE	Irradiação (kJ/m^2)	0,00005	Teste 1	[7 3]	Inverno	Imperatriz
	Temperatura ($^{\circ}C$)	0,0003	Teste 4	[2 6]	Inverno	Turiação
RMSE	Irradiação (kJ/m^2)	0,0002	Teste 1	[5 3]	Primavera	Caxias
	Temperatura ($^{\circ}C$)	0,0025	Teste 1	[5 5]	Primavera	Imperatriz

Quanto às demais métricas de avaliação, foi possível perceber um padrão quanto aos melhores resultados. O menor valor de MAE e de RAE para a variável Irradiação Solar foi obtido por meio da configuração do Teste 1, utilizando os dados do período sazonal de Inverno na cidade de Imperatriz. Já no caso da variável Temperatura do Ar, os menores valores de ambas as métricas foram obtidos por meio da configuração do Teste 4 também no período sazonal de Inverno mas agora utilizando a base de dados de Turiação.

Por conta do levantamento das pesquisas que utilizavam métodos similares de previsão, foi possível estabelecer um comparativo e verificar a boa acurácia do método aplicado neste trabalho, mesmo havendo dificuldade na busca de trabalhos que tivessem como objetivo prever ambas as variáveis em uma escala de tempo maior.

Capítulo 7

Conclusões

Este estudo teve como objetivo a proposição de um modelo utilizando Irradiação Solar e Temperatura do Ar utilizando dados horários agrupados em períodos sazonais como variáveis de entrada para a previsão climática utilizando a técnica de Redes Neurais Artificiais. A estrutura do modelo foi aplicada para um horizonte anual em 5 municípios do estado do Maranhão, região ainda pouco explorada no que tange o método aqui aplicado. Foi possível abordar ainda como projeções de variáveis climáticas a nível regional e local são fundamentais para o estudo sobre alterações do clima e como seu comportamento futuro pode alterar o meio.

Neste trabalho utilizou-se ainda a técnica de Análise Bibliométrica para identificar qual a tendência de estudos relacionados ao campo de previsão de Irradiação Solar e Temperatura do Ar. Foi possível então comprovar a forte correlação entre o termo *redes neurais* e as variáveis anteriores, além da relação direta com o termo *mudanças climáticas*.

As informações utilizadas para a modelagem foram cedidas pelo INMET e foram necessárias adequações para torná-las aptas para o processamento da RNA. Ao desenvolver o método, buscou-se tornar a base de dados o mais confiável possível, utilizando processos de *data cleaning*, suavização das medições com a aplicação de médias móveis e por fim a aplicação do método de seleção de atributos para indicar as variáveis mais relevantes para o modelo de previsão conforme o algoritmo CFS.

Com base nas variáveis climáticas disponíveis, foram organizados 6 testes, que, juntamente com aquele definido pela seleção de atributos formaram as bases de entrada para a RNA. A parametrização do modelo definiu a arquitetura *Multilayer Perceptron* como a ideal para o processo de previsão e foram calculadas 3 métricas de avaliação, MAE, RAE e RMSE, definidas para verificar os erros de previsão e, com isso, avaliar se ela foi bem-sucedida.

Foi aplicado então o método baseado em RNAs para prever, em longo prazo (um ano a frente) o comportamento das variáveis com base nas características de cada período

sazonal. Optou-se por analisar os resultados por cada município, ou seja, detalhando as métricas das duas variáveis em cada período sazonal. Os resultados obtidos utilizaram as configurações do Teste 1, em especial com o processamento da base de dados do período sazonal da primavera, obtendo melhor desempenho para a previsão de Irradiação Solar e Temperatura do Ar.

A métrica de avaliação do erro RMSE foi utilizada para efeito comparativo com outros trabalhos similares na literatura por conta de sua popularidade no que tange a análise de métodos de previsão temporal. Os resultados são promissores por conta do desempenho do modelo. O RMSE mínimo obtido para previsão de Irradiação Solar foi de $0,00023 \text{ kJ}/\text{m}^2$, enquanto que para previsão de Temperatura do Ar, o menor erro calculado foi de $0,0025 \text{ }^\circ\text{C}$. Ambos, quando comparados aos resultados encontrados na literatura, indicam que o método aplicado nesta pesquisa foi bastante positivo e promissor.

Capítulo 8

Trabalhos Futuros

Ao longo do desenvolvimento deste trabalho e da análise dos resultados alcançados, observou-se a necessidade de estudos complementares que poderão levar a maiores aperfeiçoamentos das previsões de irradiação solar e temperatura do ar a nível local. De fato, foi possível obter resultados satisfatórios utilizando a RNA como ferramenta prognóstica de ambas as variáveis climáticas e é importante continuar com as pesquisas nesta área, já que a técnica apresentou potencial para previsão.

No entanto, para garantir mais eficiência na previsão, sugere-se algumas possíveis alternativas que possibilitem minimizar os erros avaliados.

- Buscar fontes de dados alternativas que possam complementar as informações concedidas pelo INMET. Sabe-se que para que um modelo de previsão seja consistente, é necessário que se faça uso de uma base de dados robusta e consistente, portanto, minimizar em parte a carência de dados em alguns trechos com falta de amostras é fundamental;
- Verificar a relevância de novos testes para o modelo de previsão, selecionando conjuntos de preditores individuais para cada época do ano. Neste trabalho, os modelos de testes foram organizados de forma fixa com base nos dados fornecidos, de maneira que possam ser consideradas outras variáveis que estejam mais bem relacionadas com a incidência de radiação solar e a variação de temperatura em períodos sazonais distintos;
- Pode-se verificar ainda se a organização do modelo em períodos diários distintos proporciona ganhos na previsão de ambas as variáveis, tendo em vista os picos diários de irradiação e temperatura durante algumas horas ao longo do dia;
- Treinar RNAs utilizando outras arquiteturas, tipos de treinamentos e critérios de acerto das previsões temporais do modelo;

- Incluir novos preditores observados nas estações meteorológicas, tais como parâmetros geográficos e topográficos, que também podem ser importantes para caracterizar a variabilidade da irradiação solar e temperatura do ar;
- Testar novos métodos de previsão e comparar seu desempenho ao modelos apresentado neste trabalho, verificando a consistência dos resultados de acordo com a literatura;
- Extrapolar os resultados para identificar se haverá alteração climática relevante em um período de tempo maior, buscando sempre a confiabilidade do modelo para que haja confiança na tomada de decisão.

Referências

ABHISHEK, K. et al. Weather forecasting model using artificial neural network. **Procedia Technology**, v. 4, p. 311 – 318, 2012. 2nd International Conference on Computer, Communication, Control and Information Technology(C3IT-2012) on February 25 - 26, 2012.

ABRAMO, G.; CIRIACO, A. D.; VIEL, F. The field-standardized average impact of national research systems compared to world average: the case of italy. **Scientometrics**, v. 88, n. 2, p. 599–615, 2018.

ADEDE, C. et al. Model ensembles of artificial neural networks and support vector regression for improved accuracy in the prediction of vegetation conditions and droughts in four northern kenya counties. **ISPRS International Journal of Geo-Information**, v. 8, n. 12, 2019.

ADGER, W. N. Vulnerability. **Global Environmental Change**, v. 16, n. 3, p. 268 – 281, 2006.

ŞAHİN, M. Modelling of air temperature using remote sensing and artificial neural network in turkey. **Advances in Space Research**, v. 50, n. 7, p. 973 – 985, 2012. ISSN 0273-1177.

AHMADI, F. et al. Spatiotemporal trend and abrupt change analysis of temperature in iran. **Meteorological Applications**, v. 25, n. 2, p. 314–321, 2018.

ALCOFORADO, M.-J. et al. Orientações climáticas para o ordenamento em lisboa. In: _____. [S.l.: s.n.], 2005. p. 83p.

ALMAGRO, A. et al. Projected climate change impacts in rainfall erosivity over brazil. **Scientific Reports**, v. 7, n. 1, p. 1–12, 2017.

ANACHE, J. et al. Land use and climate change impacts on runoff and soil erosion at the hillslope scale in the brazilian cerrado. **Science of the Total Environment**, v. 622-623, p. 140–151, 2018.

ANOCHI, J. A.; SILVA, J. D. S. Uso de Redes Neurais Artificiais e Teoria de Conjuntos Aproximativos no estudo de padrões climáticos sazonais. **Learning & Nonlinear Models - Revista da Sociedade Brasileira de Redes Neurais**, v. 7, n. 2, p. 83–91, 2009.

ANTONANZAS, J. et al. Review of photovoltaic power forecasting. **Solar Energy**, v. 136, p. 78–111, 2016.

ARCHER, B. Forecasting demand: Quantitative and intuitive techniques. **International Journal of Tourism Management**, v. 1, n. 1, p. 5 – 12, 1980.

ARMSTRONG, J. S. Strategic planning and forecasting fundamentals. **The Strategic Management Handbook**, p. 2–1,2–32, 2000.

ASHRAFI, K. et al. Prediction of climate change induced temperature rise in regional scale using neural network. **International Journal of Environmental Research**, v. 6, n. 3, p. 677–688, 2012.

BABOO, S. S.; SHEREEF, K. An efficient weather forecasting system using artificial neural network. **International Journal of Environmental Science and Development**, v. 1, p. 321–326, 2010.

BAYER, F.; SOUZA, A. Wavelets e modelos tradicionais de previsão: um estudo comparativo. **Revista Brasileira de Biometria**, v. 28, p. 40–61, 2010.

BELU, R. Artificial intelligence techniques for solar energy and photovoltaic applications. **Handbook of Research on Solar Energy Systems and Technologies**, v. 3, p. 376–436, 01 2012.

BOX, G. E. P. et al. **Time Series Analysis: Forecasting and Control**. 5. ed. New Jersey, USA: Wiley Series in Probability and Statistics, 2015. ISBN 9781118674925.

BRAGA, A. P.; LUDEMIR, T. B.; CARVALHO, A. **Redes neurais artificiais: teoria e aplicações**. 2. ed. São Paulo: LTC Editora, 2007. ISBN 9788521615644.

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

CHITHRA, N. et al. Prediction of the likely impact of climate change on monthly mean maximum and minimum temperature in the chaliyar river basin, india, using ann-based models. **Theoretical and Applied Climatology**, v. 121, p. 581–590, 08 2014.

CHOPRA, S.; MEINDL, P. **Gerenciamento da cadeia de suprimentos: estratégia, planejamento e operação**. São Paulo: Pearson Education do Brasil, 2004. ISBN 9788587918246.

CLIMATE DATA. **Dados climáticos para cidades mundiais**. 2019. Disponível em: <<https://pt.climate-data.org/>>.

CRESESB. **Tutorial de Energia Solar Fotovoltaica**. 2019. Disponível em: <http://www.cresesb.cepel.br/index.php?section=com_content&lang=pt&cid=301>.

DASH, M.; LIU, H. Feature selection for classification. **Intelligent Data Analysis**, v. 1, p. 131–156, 1997.

DAVIS, M.; CHASE, R.; AQUILANO, N. **Fundamentos Da Administracao Da Producao**. [S.l.]: Bookman, 2001. ISBN 9788573075243.

DEO, R. C.; ŞAHIN, M. Forecasting long-term global solar radiation with an ann algorithm coupled with satellite-derived (modis) land surface temperature (lst) for regional locations in queensland. **Renewable and Sustainable Energy Reviews**, v. 72, p. 828 – 848, 2017.

- DIAGNE, M. et al. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews**, v. 27, p. 65–76, 2013.
- DUBAYAH, R.; LOECHEL, S. Modeling topographic solar radiation using GOES data. **Journal of Applied Meteorology**, v. 36, p. 141–154, 1997.
- ECK, N. J. van; WALTMAN, L. Visualizing bibliometric networks. In: _____. **Measuring Scholarly Impact: Methods and Practice**. Cham: Springer International Publishing, 2014. p. 285–320. ISBN 978-3-319-10377-8.
- ELSEVIER. **Sobre a solução Scopus**. 2019. Disponível em: <<https://www.elsevier.com/pt-br/solutions/scopus>>.
- EMBRAPA. **Relatório do diagnóstico do macrozoneamento ecológico-econômico do Estado do Maranhão**. Campinas, SP: Empresa Brasileira de Pesquisa Agropecuária, 2013. 324 p.
- FERREIRA, A. J. d. A.; MORAES, A. C. R. **Políticas territoriais e a reorganização do espaço maranhense**. 2008. Dissertação (Mestrado) — Universidade de São Paulo, 2008.
- FREEMAN, J. A. **Neural Networks: Algorithms, Applications, And Programming Techniques**. Michigan, EUA: Pearson Education, 1991. (Computation and neural systems series). ISBN 9788131708088.
- GAITHER, N.; FRAZIER, G. **Operations Management**. [S.l.]: South-Western/Thomson Learning, 2002. ISBN 9780324066852.
- GEIGER, R.; ARON, R.; TODHUNTER, P. **The Climate Near the Ground**. Rowman & Littlefield, 2003. (G - Reference, Information and Interdisciplinary Subjects Series). ISBN 9780742518575. Disponível em: <<https://books.google.com.br/books?id=KaJHBv9FbYIC>>.
- GUYON, I.; ELISSEEFF, A. An introduction to variable and feature selection. **The Journal of Machine Learning Research**, v. 3, p. 1157–1182, 2003.
- HALL, M. A. **Correlation-Based Feature Selection for Machine Learning**. 1999. Tese (Doutorado) — The University of Waikato, Hamilton, New Zealand, 1999.
- HANKE, J.; WICHERN, D. **Business Forecasting**. 9. ed. New York: Pearson/Prentice Hall, 2009. ISBN 9780132301206.
- HANSEN, J. et al. Climate impact of increasing atmospheric carbon dioxide. **Science**, v. 213, n. 4511, p. 957–966, 1981.
- HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Hamilton, Ontário, Canadá: Artmed, 2007. ISBN 9788577800865.
- HOOYBERGHS, H. et al. Influence of climate change on summer cooling costs and heat stress in urban office buildings. **Climatic Change**, v. 144, n. 4, p. 721–735, 2017.
- HU, Y. et al. A seasonal model using optimized multi-layer neural networks to forecast power output of pv plants. **Energies**, v. 11, n. 2, 2018.

- IBGE. **Panorama do Município de Caxias**. 2010. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/caxias/panorama>>.
- _____. **Panorama do Município de Colinas**. 2010. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/colinas/panorama>>.
- _____. **Panorama do Município de Imperatriz**. 2010. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/imperatriz/panorama>>.
- _____. **Panorama do Município de São Luís**. 2010. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/saoluis/panorama>>.
- _____. **Panorama do Município de Turiacu**. 2010. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/turiacu/panorama>>.
- _____. **Brasil - Mapas Físicos e Ambientais**. 2019. Disponível em: <<http://mapasinterativos.ibge.gov.br/sigibge/>>.
- _____. **Mapa Político do Estado do Maranhão**. 2019. Disponível em: <<https://cidades.ibge.gov.br/brasil/ma/turiacu/panorama>>.
- _____. **Panorama do Estado do Maranhão**. 2019. Disponível em: <<https://cidades.ibge.gov.br/>>.
- IBGE, C. d. G. **Divisão regional do Brasil em regiões geográficas imediatas e regiões geográficas intermediárias**. Rio de Janeiro: IBGE, 2017. 83 p. ISBN 9788524044182.
- INMAN, R.; PEDRO, H.; COIMBRA, C. Solar forecasting methods for renewable energy integration. **Progress in Energy and Combustion Science**, v. 39, n. 6, p. 535–576, 2013.
- INMET. **BDMEP - Dados Históricos**. 2018. Disponível em: <<http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep>>.
- JALLAL, M. A. et al. Air temperature forecasting using artificial neural networks with delayed exogenous input. In: **2019 International Conference on Wireless Technologies, Embedded and Intelligent Systems (WITS)**. Fez, Morocco: IEEE, 2019. p. 1–6.
- JOSHI, P.; GANJU, A. Maximum and minimum temperature prediction over western himalaya using artificial neural network. **Mausam**, v. 63, p. 283–290, 04 2012.
- KALOGIROU, S. Artificial neural networks and genetic algorithms for the modeling, simulation, and performance prediction of solar energy systems. **Green Energy and Technology**, v. 129, p. 225–245, 08 2013.
- KOCA, A. et al. Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of Anatolia in Turkey. **Expert Systems with Applications**, v. 38, n. 7, p. 8756–8762, 2011.
- KOPRINSKA, I.; RANA, M.; AGELIDIS, V. Correlation and instance based feature selection for electricity load forecasting. **Knowledge-Based Systems**, v. 82, p. 29–40, 2015.

- LAM, J. C.; WAN, K. K.; YANG, L. Solar radiation modelling using anns for different climates in china. **Energy Conversion and Management**, v. 49, n. 5, p. 1080 – 1090, 2008.
- LANDSBERG, J.; SANDS, P. Chapter 2 - weather and energy balance. In: **Physiological Ecology of Forest Production**. [S.l.]: Elsevier, 2011, (Terrestrial Ecology, v. 4). p. 13 – 48.
- LEITE, A. C. Normais de temperaturas máxima, média e mínima estimadas em função da latitude, longitude e altitude para o Estado do Maranhão. São Luís, MA: EMAPA, 1978.
- LEÃO, H. C. R. S.; JÚNIOR, A. S. B. Perfil Econômico do Maranhão. **Diário Econômico do Escritório Técnico de Estudos Econômicos do Nordeste**, v. 3, p. 1–27, 2018.
- LI, F.-F.; WANG, S.-Y. Long term rolling prediction model for solar radiation combining empirical mode decomposition (emd) and artificial neural network (ann) techniques. **Journal of Renewable and Sustainable Energy**, v. 10, p. 013704, 02 2018.
- LIMA, F. J. L. **Previsão de Irradiação Solar no Nordeste do Brasil empregando o modelo WRF por Redes Neurais Artificiais (RNAs)**. 2015. Tese (Doutorado) — Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2015.
- LIN, C. Y. et al. Climate variability of heat wave and projection of warming scenario in taiwan. **Climatic Change**, v. 145, n. 3-4, p. 305–320, 2017.
- LUENBERGER, D. G.; YE, Y. **Linear and Nonlinear Programming**. 3. ed. Stanford, CA, USA: Springer, 2008. ISBN 9780387745022.
- MAKRIDAKIS, S. G.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications**. [S.l.]: Wiley, 1998. (Wiley series in management). ISBN 9780471532330.
- MBA, L.; MEUKAM, P.; KEMAJOU, A. Application of artificial neural network for predicting hourly indoor air temperature and relative humidity in modern building in humid region. **Energy and Buildings**, v. 121, p. 32–42, 2016.
- MOKHTARZAD, M. et al. Drought forecasting by ann, anfis, and svm and comparison of the models. **Environmental Earth Sciences**, v. 76, n. 21, 10 2017.
- MORETTIN, P.; TOLOI, C. de C. **Análise de séries temporais**. [S.l.]: Edgard Blucher, 2006. (ABE Projeto Fisher). ISBN 9788521203896.
- MURDICK, R. G.; GEORGOFF, D. M. Forecasting: A systems approach. **Technological Forecasting and Social Change**, v. 44, n. 1, p. 1 – 16, 1993.
- NAGELKERKE, N. A more general definition of the coefficient of determination. **Biometrika**, v. 78, p. 691–692, 1991.
- NEZHAD, E.; FALLAH-GHALHARY, G.-A.; BAYATANI, F. Forecasting maximum seasonal temperature using artificial neural networks “tehran case study”. **Asia-Pacific Journal of Atmospheric Sciences**, p. 145–153, 01 2019.

- NIMER, E. Ensaio de um novo método de classificação climática: contribuição à climatologia intertropical e subtropical, especialmente do Brasil. **Boletim de Geografia**, v. 31, n. 277, p. 141–153, 1979.
- NOI, P. T.; DEGENER, J.; KAPPAS, M. Comparison of multiple linear regression, cubist regression, and random forest algorithms to estimate daily air surface temperature from dynamic combinations of modis lst data. **Remote Sensing**, v. 9, n. 5, 2017.
- PALTRIDGE, G.; PLATT, C. **Radiative processes in meteorology and climatology**. [S.l.]: Elsevier Scientific Pub. Co., 1976. (Developments in atmospheric science). ISBN 9780444414441.
- PEREIRA, E. et al. **Atlas Brasileiro de Energia Solar – 2ª Edição**. [S.l.: s.n.], 2017. ISBN 978-85-17-00089-8.
- PREMALATHA, N.; ARASU, A. V. Prediction of solar radiation for solar systems by using ann models with different back propagation algorithms. **Journal of Applied Research and Technology**, v. 14, n. 3, p. 206 – 214, 2016.
- PRIHODKO, L.; GOWARD, S. N. Estimation of air temperature from remotely sensed surface observations. **Remote Sensing of Environment**, v. 60, n. 3, p. 335 – 346, 1997. ISSN 0034-4257.
- RAHIMIKHOOB, A. Estimating global solar radiation using artificial neural network and air temperature data in a semi-arid environment. **Renewable Energy**, v. 35, n. 9, p. 2131–2135, 2010.
- RAMESH, J.; VANATHI, P.; GUNAVATHI, K. Fault classification in phase-locked loops using back propagation neural networks. **Etri Journal - ETRI J**, v. 30, p. 546–554, 08 2008.
- Rao K, D. V. S. K.; PREMALATHA, M.; NAVEEN, C. Analysis of different combinations of meteorological parameters in predicting the horizontal global solar radiation with ann approach: A case study. **Renewable and Sustainable Energy Reviews**, v. 91, p. 248–258, 2018.
- REFENES, A. N. et al. Currency exchange rate prediction and neural network design strategies. **Neural Computing & Applications**, v. 1, n. 1, p. 46–58, 1993.
- RODRIGUES, E. et al. Estimation of renewable energy and built environment-related variables using neural networks – a review. **Renewable and Sustainable Energy Reviews**, v. 94, p. 959 – 988, 2018.
- ROGELJ, J. et al. Paris agreement climate proposals need a boost to keep warming well below 2°C. **Nature**, v. 534, n. 7609, p. 631–639, 2016.
- ROITMAN, V. L. **Um modelos computacional de Redes Neurais para predição do índice de desemprego aberto**. 2001. Tese (Doutorado) — Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2001.
- RYAN, S. J. et al. Mapping physiological suitability limits for malaria in africa under climate change. **Vector-Borne and Zoonotic Diseases**, v. 15, n. 12, p. 718–725, 2015.

- SAEYS, Y.; INZA, I.; LARRAÑAGA, P. A review of feature selection techniques in bioinformatics. **Bioinformatics**, v. 23, n. 19, p. 2507–2517, 2007.
- SANIKHANI, H. et al. Survey of different data-intelligent modeling strategies for forecasting air temperature using geographic information as model predictors. **Computers and Electronics in Agriculture**, v. 152, p. 242 – 260, 2018.
- SENTELHAS, P. C.; ANGELOCCI, L. R. **Radiação Solar - Balanço de Energia**. 2012. Disponível em: <http://www.leb.esalq.usp.br/leb/aulas/lce306/Aula5_2012.pdf>.
- SHAH, U. et al. Rainfall prediction: Accuracy enhancement using machine learning and forecasting techniques. In: **2018 Fifth International Conference on Parallel, Distributed and Grid Computing (PDGC)**. [S.l.: s.n.], 2018. p. 776–782.
- SILVA, C. S. da. **Previsão Multivariada da Demanda Horária de Água em Sistemas Urbanos de Abastecimento**. 2003. Tese (Doutorado) — Universidade Estadual de Campinas, Campinas, São Paulo, 2003.
- SILVA, I. N. D.; SPATTI, D. H.; FLAUZINO, R. A. **REDES NEURAIIS ARTIFICIAIS: PARA ENGENHARIA E CIENCIAS APLICADAS - CURSO PRATICO**. São Paulo: ARTLIBER, 2010. ISBN 9788588098534.
- SMITH, B. A.; MCCLENDON, R. W.; HOOGENBOOM, G. Improving air temperature prediction with artificial neural networks. **International Journal of Computational Intelligence**, v. 3, p. 179–186, 2007.
- SMITH, J.; VOGEL, J.; CROMWELL III, J. E. An architecture for government action on adaptation to climate change. an editorial comment. **Climatic Change**, v. 95, p. 53–61, 2009.
- SOLAR GIS. **Solar resource maps of Brazil**. 2019. Disponível em: <<https://solargis.com/maps-and-gis-data/download/brazil>>.
- SOUZA, J. L. D.; NICÁCIO, R. M.; MOURA, M. A. L. Global solar radiation measurements in maceió, brazil. **Renewable Energy**, v. 30, n. 8, p. 1203 – 1220, 2005.
- TANG, J.; ALELYANI, S.; LIU, H. Feature selection for classification: A review. In: **Data Classification: Algorithms and Applications**. [S.l.: s.n.], 2014.
- UEMA. **Atlas do Maranhão**. São Luís, MA: GEPLAN, 2002. 44 p.
- USTAOGLU, B.; CIGIZOGLU, H. K.; KARACA, M. Forecast of daily mean, maximum and minimum temperature time series by three artificial neural network methods. **Meteorological Applications**, v. 15, n. 4, p. 431–445, 2008.
- VANCUTSEM, C. et al. Evaluation of modis land surface temperature data to estimate air temperature in different ecosystems over africa. **Remote Sensing of Environment**, v. 114, n. 2, p. 449 – 465, 2010.
- VENKADESH, S. et al. A genetic algorithm to refine input data selection for air temperature prediction using artificial neural networks. **Applied Soft Computing Journal**, v. 13, n. 5, p. 2253–2260, 2013.

- VERGIDIS, P. I. et al. Bibliometric analysis of global trends for research productivity in microbiology. **European journal of clinical microbiology & infectious diseases**, v. 24, p. 342–346, 2005.
- VIGLIONI, G. M. C. **Metodologia Para Previsão de Demanda Ferroviária Utilizando Data Mining**. 2007. Dissertação (Mestrado) — Instituto Militar de Engenharia - IME, Rio de Janeiro, 2007.
- WANG, P. et al. Thermal effect on pollutant dispersion in an urban street Canyon. **International Journal of Environmental Research**, v. 5, n. 3, p. 813–820, 2011.
- YADAV, A.; CHANDEL, S. Solar radiation prediction using artificial neural network techniques: A review. **Renewable and Sustainable Energy Reviews**, v. 33, p. 772–781, 05 2014.
- ZHUANG, Y. et al. Global remote sensing research trends during 1991–2010: a bibliometric analysis. **Scientometrics**, v. 96, n. 1, p. 203–219, 2013.
- ZOU, L. et al. Estimation of global solar radiation using an artificial neural network based on an interpolation technique in southeast china. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 146, p. 110 – 122, 2016.

Apêndice A

Seleção de Atributos

Tabela 29 – Irradiação Solar para Caxias no período sazonal de Outono

OUTONO	
Selected attributes: 3,6,9,12,18,29,31,33,39,42,53,56,62,64,67,73,78,79,84	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	UMIDADE RELATIVA DO AR (%) –1M
Atributo 03	VELOCIDADE DO VENTO (m/s) –1M
Atributo 04	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 05	TEMPERATURA DO PONTO DE ORVALHO (°C) –12M
Atributo 06	TEMPERATURA DO PONTO DE ORVALHO (°C) –11M
Atributo 07	VELOCIDADE DO VENTO (m/s) –11M
Atributo 08	PRECIPITACAO (mm) –11M
Atributo 09	UMIDADE RELATIVA DO AR (%) –12M
Atributo 10	VELOCIDADE DO VENTO (m/s) –12M
Atributo 11	VELOCIDADE DO VENTO (m/s) –13M
Atributo 12	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 13	TEMPERATURA DO PONTO DE ORVALHO (°C) –5MP
Atributo 14	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 15	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 16	TEMPERATURA DO PONTO DE ORVALHO (°C) –10MP
Atributo 17	RAJADA MÁXIMA DE VENTO (m/s) –10MP
Atributo 18	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 19	TEMPERATURA DO PONTO DE ORVALHO (°C) –15MP

Tabela 30 – Temperatura para Caxias no período sazonal de Outono

OUTONO	
Selected attributes: 58,64,69,80,81,86	
Atributo 01	TEMPERATURA DO AR (°C) –5MP
Atributo 02	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 03	TEMPERATURA DO AR (°C) –10MP
Atributo 04	TEMPERATURA DO AR (°C) –15MP
Atributo 05	TEMPERATURA MAXIMA (°C) –15MP
Atributo 06	VELOCIDADE DO VENTO (m/s) –15MP

Tabela 31 – Irradiação Solar para Caxias no período sazonal de Inverno

INVERNO	
Selected attributes: 18,20,23,34,41,44,53,56,63,64,67,74,79,85	
Atributo 01	TEMPERATURA DO PONTO DE ORVALHO (°C) –2M
Atributo 02	VELOCIDADE DO VENTO (m/s) –2M
Atributo 03	RAJADA MÁXIMA DE VENTO (m/s) –2M
Atributo 04	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 05	PRESSAO ATMOSFERICA (hPa) –12M
Atributo 06	PRECIPITACAO (mm) –12M
Atributo 07	VELOCIDADE DO VENTO (m/s) –13M
Atributo 08	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 09	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 10	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 11	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 12	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 13	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 14	PRESSAO ATMOSFERICA (hPa) –15MP

Tabela 32 – Temperatura para Caxias no período sazonal de Inverno

INVERNO	
Selected attributes: 22,33,58,63,69,80	
Atributo 01	PRECIPITACAO (mm) –2M
Atributo 02	PRECIPITACAO (mm) –11M
Atributo 03	TEMPERATURA DO AR (°C) –5MP
Atributo 04	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 05	TEMPERATURA DO AR (°C) –10MP
Atributo 06	TEMPERATURA DO AR (°C) –15MP

Tabela 33 – Irradiação Solar para Caxias no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 9,20,30,34,42,45,56,63,64,67,74,79,85	
Atributo 01	VELOCIDADE DO VENTO (m/s) –1M
Atributo 02	VELOCIDADE DO VENTO (m/s) –2M
Atributo 03	PRESSAO ATMOSFERICA (hPa) –11M
Atributo 04	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 05	VELOCIDADE DO VENTO (m/s) –12M
Atributo 06	RAJADA MÁXIMA DE VENTO (m/s) –12M
Atributo 07	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 08	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 09	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 10	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 11	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 12	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 13	PRESSAO ATMOSFERICA (hPa) –15MP

Tabela 34 – Temperatura para Caxias no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 58,59,69,80,86	
Atributo 01	TEMPERATURA DO AR (°C) –5MP
Atributo 02	TEMPERATURA MAXIMA (°C) –5MP
Atributo 03	TEMPERATURA DO AR (°C) –10MP
Atributo 04	TEMPERATURA DO AR (°C) –15MP
Atributo 05	VELOCIDADE DO VENTO (m/s) –15MP

Tabela 35 – Irradiação Solar para Caxias no período sazonal de Verão

VERÃO	
Selected attributes: 11,14,17,20,23,25,27,36,45,62,73,79,84	
Atributo 01	PRECIPITACAO (mm) –1M
Atributo 02	TEMPERATURA DO AR (°C) –2M
Atributo 03	UMIDADE RELATIVA DO AR (%) –2M
Atributo 04	VELOCIDADE DO VENTO (m/s) –2M
Atributo 05	RAJADA MÁXIMA DE VENTO (m/s) –2M
Atributo 06	TEMPERATURA DO AR (°C) –11M
Atributo 07	TEMPERATURA MINIMA (°C) –11M
Atributo 08	TEMPERATURA DO AR (°C) –12M
Atributo 09	RAJADA MÁXIMA DE VENTO (m/s) –12M
Atributo 10	TEMPERATURA DO PONTO DE ORVALHO (°C) –5MP
Atributo 11	TEMPERATURA DO PONTO DE ORVALHO (°C) –10MP
Atributo 12	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 13	TEMPERATURA DO PONTO DE ORVALHO (°C) –15MP

Tabela 36 – Temperatura para Caxias no período sazonal de Verão

VERÃO	
Selected attributes: 58,80,81,86	
Atributo 01	TEMPERATURA DO AR (°C) –5MP
Atributo 02	TEMPERATURA DO AR (°C) –15MP
Atributo 03	TEMPERATURA MAXIMA (°C) –15MP
Atributo 04	VELOCIDADE DO VENTO (m/s) –15MP

Tabela 37 – Irradiação Solar para Colinas no período sazonal de Outono

OUTONO	
Selected attributes: 3,8,12,14,19,22,33,34,42,47,62,63,64,67,74,75,78,79,85,86	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	PRESSAO ATMOSFERICA (hPa) –1M
Atributo 03	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 04	TEMPERATURA DO AR (°C) –2M
Atributo 05	PRESSAO ATMOSFERICA (hPa) –2M
Atributo 06	PRECIPITACAO (mm) –2M
Atributo 07	PRECIPITACAO (mm) –11M
Atributo 08	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 09	VELOCIDADE DO VENTO (m/s) –12M
Atributo 10	TEMPERATURA DO AR (°C) –13M
Atributo 11	TEMPERATURA DO PONTO DE ORVALHO (°C) –5MP
Atributo 12	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 13	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 14	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 15	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 16	VELOCIDADE DO VENTO (m/s) –10MP
Atributo 17	RAJADA MÁXIMA DE VENTO (m/s) –10MP
Atributo 18	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 19	PRESSAO ATMOSFERICA (hPa) –15MP
Atributo 20	VELOCIDADE DO VENTO (m/s) –15MP

Tabela 38 – Temperatura para Colinas no período sazonal de Outono

OUTONO	
Selected attributes: 33,58,59,64,69,80,81	
Atributo 01	PRECIPITACAO (mm) –11M
Atributo 02	TEMPERATURA DO AR (°C) –5MP
Atributo 03	TEMPERATURA MAXIMA (°C) –5MP
Atributo 04	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 05	TEMPERATURA DO AR (°C) –10MP
Atributo 06	TEMPERATURA DO AR (°C) –15MP
Atributo 07	TEMPERATURA MAXIMA (°C) –15MP

Tabela 39 – Irradiação Solar para Colinas no período sazonal de Inverno

INVERNO	
Selected attributes: 8,12,23,34,36,57,63,74,79	
Atributo 01	PRESSAO ATMOSFERICA (hPa)–1M
Atributo 02	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 03	RAJADA MÁXIMA DE VENTO (m/s) –2M
Atributo 04	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 05	TEMPERATURA DO AR (°C) –12M
Atributo 06	IRRADIAÇÃO SOLAR (kJ/m ²) –5MP
Atributo 07	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 08	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 09	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP

Tabela 40 – Temperatura para Colinas no período sazonal de Inverno

INVERNO	
Selected attributes: 7,33,58,80,81	
Atributo 01	TEMPERATURA DO PONTO DE ORVALHO (°C) –1M
Atributo 02	PRECIPITACAO (mm) –11M
Atributo 03	TEMPERATURA DO AR (°C) –5MP
Atributo 04	TEMPERATURA DO AR (°C) –15MP
Atributo 05	TEMPERATURA MAXIMA (°C) –15MP

Tabela 41 – Irradiação Solar para Colinas no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 3,9,20,23,25,31,36,42,53,56,63,64,67,74,79	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	VELOCIDADE DO VENTO (m/s) –1M
Atributo 03	VELOCIDADE DO VENTO (m/s) –M
Atributo 04	RAJADA MÁXIMA DE VENTO (m/s) –2M
Atributo 05	TEMPERATURA DO AR (°C) –11M
Atributo 06	VELOCIDADE DO VENTO (m/s) –11M
Atributo 07	TEMPERATURA DO AR (°C) –12M
Atributo 08	VELOCIDADE DO VENTO (m/s) –12M
Atributo 09	VELOCIDADE DO VENTO (m/s) –13M
Atributo 10	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 11	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 12	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 13	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 14	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 15	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP

Tabela 42 – Temperatura para Colinas no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 58,59,69,80,86	
Atributo 01	TEMPERATURA DO AR (°C) –5MP
Atributo 02	TEMPERATURA MAXIMA (°C) –5MP
Atributo 03	TEMPERATURA DO AR (°C) –10MP
Atributo 04	TEMPERATURA DO AR (°C) –15MP
Atributo 05	VELOCIDADE DO VENTO (m/s) –15MP

Tabela 43 – Irradiação Solar para Colinas no período sazonal de Verão

VERÃO	
Selected attributes: 3,6,9,11,25,28,31,34,47,53,56,63,79,86,89	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	UMIDADE RELATIVA DO AR (%) –1M
Atributo 03	VELOCIDADE DO VENTO (m/s) –1M
Atributo 04	PRECIPITACAO (mm) –1M
Atributo 05	TEMPERATURA DO AR (°C) –11M
Atributo 06	UMIDADE RELATIVA DO AR (%) –11M
Atributo 07	VELOCIDADE DO VENTO (m/s) –11M
Atributo 08	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 09	TEMPERATURA DO AR (°C) –13M
Atributo 10	VELOCIDADE DO VENTO (m/s) –13M
Atributo 11	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 12	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 13	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 14	VELOCIDADE DO VENTO (m/s) –15MP
Atributo 15	RAJADA MÁXIMA DE VENTO (m/s) –15MP

Tabela 44 – Temperatura para Colinas no período sazonal de Verão

VERÃO	
Selected attributes: 58,80,81,86	
Atributo 01	TEMPERATURA DO AR (°C) –5MP
Atributo 02	TEMPERATURA DO AR (°C) –15MP
Atributo 03	TEMPERATURA MAXIMA (°C) –15MP
Atributo 04	VELOCIDADE DO VENTO (m/s) –15MP

Tabela 45 – Irradiação Solar para Imperatriz no período sazonal de Outono

OUTONO	
Selected attributes: 6,11,14,18,28,33,40,42,51,56,63,67,74,79	
Atributo 01	UMIDADE RELATIVA DO AR (%) –1M
Atributo 02	PRECIPITACAO (mm) –1M
Atributo 03	TEMPERATURA DO AR (°C) –2M
Atributo 04	TEMPERATURA DO PONTO DE ORVALHO (°C) –2M
Atributo 05	UMIDADE RELATIVA DO AR (%) –11M
Atributo 06	PRECIPITACAO (mm) –11M
Atributo 07	TEMPERATURA DO PONTO DE ORVALHO (°C) –12M
Atributo 08	VELOCIDADE DO VENTO (m/s) –12M
Atributo 09	TEMPERATURA DO PONTO DE ORVALHO (°C) –13M
Atributo 10	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 11	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 12	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 13	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 14	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP

Tabela 46 – Temperatura para Imperatriz no período sazonal de Outono

OUTONO	
Selected attributes: 32,58,64,69,70,80,81,89	
Atributo 01	DIRECAO DO VENTO (graus) –11M
Atributo 02	TEMPERATURA DO AR (°C) –5MP
Atributo 03	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 04	TEMPERATURA DO AR (°C) –10MP
Atributo 05	TEMPERATURA MAXIMA (°C) –10MP
Atributo 06	TEMPERATURA DO AR (°C) –15MP
Atributo 07	TEMPERATURA MAXIMA (°C) –15MP
Atributo 08	RAJADA MÁXIMA DE VENTO (m/s) –15MP

Tabela 47 – Irradiação Solar para Imperatriz no período sazonal de Inverno

INVERNO	
Selected attributes: 12,17,20,23,25,34,42,45,52,56,57,63,64,67,74,79,85	
Atributo 01	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 02	UMIDADE RELATIVA DO AR (%) –2M
Atributo 03	VELOCIDADE DO VENTO (m/s) –2M
Atributo 04	RAJADA MÁXIMA DE VENTO (m/s) –2M
Atributo 05	TEMPERATURA DO AR (°C) –11M
Atributo 06	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 07	VELOCIDADE DO VENTO (m/s) –12M
Atributo 08	RAJADA MÁXIMA DE VENTO (m/s) –12M
Atributo 09	PRESSAO ATMOSFERICA (hPa) –13M
Atributo 10	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 11	IRRADIAÇÃO SOLAR (kJ/m ²) –5MP
Atributo 12	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 13	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 14	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 15	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 16	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 17	PRESSAO ATMOSFERICA (hPa) –15MP

Tabela 48 – Temperatura para Imperatriz no período sazonal de Inverno

INVERNO	
Selected attributes: 18,58,59,64,69,77,80	
Atributo 01	TEMPERATURA DO PONTO DE ORVALHO (°C) –2M
Atributo 02	TEMPERATURA DO AR (°C) –5MP
Atributo 03	TEMPERATURA MAXIMA (°C) –5MP
Atributo 04	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 05	TEMPERATURA DO AR (°C) –10MP
Atributo 06	PRECIPITACAO (mm) –10MP
Atributo 07	TEMPERATURA DO AR (°C) –15MP

Tabela 49 – Irradiação Solar para Imperatriz no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 8,9,12,20,23,28,29,31,34,41,42,45,47,53,56,63,67,74,79,85	
Atributo 01	PRESSAO ATMOSFERICA (hPa) –1M
Atributo 02	VELOCIDADE DO VENTO (m/s) –1M
Atributo 03	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 04	VELOCIDADE DO VENTO (m/s) –2M
Atributo 05	RAJADA MÁXIMA DE VENTO (m/s) –2M
Atributo 06	UMIDADE RELATIVA DO AR (%) –11M
Atributo 07	TEMPERATURA DO PONTO DE ORVALHO (°C) –11M
Atributo 08	VELOCIDADE DO VENTO (m/s) –11M
Atributo 09	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 10	PRESSAO ATMOSFERICA (hPa) –12M
Atributo 11	VELOCIDADE DO VENTO (m/s) –12M
Atributo 12	RAJADA MÁXIMA DE VENTO (m/s) –12M
Atributo 13	TEMPERATURA DO AR (°C) –13M
Atributo 14	VELOCIDADE DO VENTO (m/s) –13M
Atributo 15	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 16	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 17	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 18	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 19	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 20	PRESSAO ATMOSFERICA (hPa) –15MP

Tabela 50 – Temperatura para Imperatriz no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 3,20,25,29,31,42,47,58,59,60,62,69,70,73,80,81,86,89	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	VELOCIDADE DO VENTO (m/s) –2M
Atributo 03	TEMPERATURA DO AR (°C) –11M
Atributo 04	TEMPERATURA DO PONTO DE ORVALHO (°C) –11M
Atributo 05	VELOCIDADE DO VENTO (m/s) –11M
Atributo 06	VELOCIDADE DO VENTO (m/s) –12M
Atributo 07	TEMPERATURA DO AR (°C) –13M
Atributo 08	TEMPERATURA DO AR (°C) –5MP
Atributo 09	TEMPERATURA MAXIMA (°C) –5MP
Atributo 10	TEMPERATURA MINIMA (°C) –5MP
Atributo 11	TEMPERATURA DO PONTO DE ORVALHO (°C) –5MP
Atributo 12	TEMPERATURA DO AR (°C) –10MP
Atributo 13	TEMPERATURA MAXIMA (°C) –10MP
Atributo 14	TEMPERATURA DO PONTO DE ORVALHO (°C) –10MP
Atributo 15	TEMPERATURA DO AR (°C) –15MP
Atributo 16	TEMPERATURA MAXIMA (°C) –15MP
Atributo 17	VELOCIDADE DO VENTO (m/s) –15MP
Atributo 18	RAJADA MÁXIMA DE VENTO (m/s) –15MP

Tabela 51 – Irradiação Solar para Imperatriz no período sazonal de Verão

VERÃO	
Selected attributes: 9,12,14,17,20,22,31,34,36,42,45,47,50,56,62,63,64,73,74,79,84	
Atributo 01	VELOCIDADE DO VENTO (m/s) –1M
Atributo 02	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 03	TEMPERATURA DO AR (°C) –2M
Atributo 04	UMIDADE RELATIVA DO AR (%) –2M
Atributo 05	VELOCIDADE DO VENTO (m/s) –2M
Atributo 06	PRECIPITACAO (mm) –2M
Atributo 07	VELOCIDADE DO VENTO (m/s) –11M
Atributo 08	RAJADA MÁXIMA DE VENTO (m/s) –11M
Atributo 09	TEMPERATURA DO AR (°C) –12M
Atributo 10	VELOCIDADE DO VENTO (m/s) –12M
Atributo 11	RAJADA MÁXIMA DE VENTO (m/s) –12M
Atributo 12	TEMPERATURA DO AR (°C) –13M
Atributo 13	UMIDADE RELATIVA DO AR (%) –13M
Atributo 14	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 15	TEMPERATURA DO PONTO DE ORVALHO (°C) –5MP
Atributo 16	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 17	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 18	TEMPERATURA DO PONTO DE ORVALHO (°C) –10MP
Atributo 19	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 20	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 21	TEMPERATURA DO PONTO DE ORVALHO (°C) –15MP

Tabela 52 – Temperatura para Imperatriz no período sazonal de Verão

VERÃO	
Selected attributes: 9,14,42,47,58,59,62,69,70,75,80,81,82,84,86,89	
Atributo 01	VELOCIDADE DO VENTO (m/s) –1M
Atributo 02	TEMPERATURA DO AR (°C) –2M
Atributo 03	VELOCIDADE DO VENTO (m/s) –12M
Atributo 04	TEMPERATURA DO AR (°C) –13M
Atributo 05	TEMPERATURA DO AR (°C) –5MP
Atributo 06	TEMPERATURA MAXIMA (°C) –5MP
Atributo 07	TEMPERATURA DO PONTO DE ORVALHO (°C) –5MP
Atributo 08	TEMPERATURA DO AR (°C) –10MP
Atributo 09	TEMPERATURA MAXIMA (°C) –10MP
Atributo 10	VELOCIDADE DO VENTO (m/s) –10MP
Atributo 11	TEMPERATURA DO AR (°C) –15MP
Atributo 12	TEMPERATURA MAXIMA (°C) –15MP
Atributo 13	TEMPERATURA MINIMA (°C) –15MP
Atributo 14	TEMPERATURA DO PONTO DE ORVALHO (°C) –15MP
Atributo 15	VELOCIDADE DO VENTO (m/s) –15MP
Atributo 16	RAJADA MÁXIMA DE VENTO (m/s) –15MP

Tabela 53 – Irradiação Solar para São Luís no período sazonal de Outono

OUTONO	
Selected attributes: 3,4,6,8,11,14,15,17,20,25,26,28,36,37,39,47,52,63,66,74,77,79,85,88	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	TEMPERATURA MAXIMA (°C) –1M
Atributo 03	UMIDADE RELATIVA DO AR (%) –1M
Atributo 04	PRESSAO ATMOSFERICA (hPa) –1M
Atributo 05	PRECIPITACAO (mm) –1M
Atributo 06	TEMPERATURA DO AR (°C) –2M
Atributo 07	TEMPERATURA MAXIMA (°C) –2M
Atributo 08	UMIDADE RELATIVA DO AR (%) –2M
Atributo 09	VELOCIDADE DO VENTO (m/s) –2M
Atributo 10	TEMPERATURA DO AR (°C) –11M
Atributo 11	TEMPERATURA MAXIMA (°C) –11M
Atributo 12	UMIDADE RELATIVA DO AR (%) –11M
Atributo 13	TEMPERATURA DO AR (°C) –12M
Atributo 14	TEMPERATURA MAXIMA (°C) –12M
Atributo 15	UMIDADE RELATIVA DO AR (%) –12M
Atributo 16	TEMPERATURA DO AR (°C) –13M
Atributo 17	PRESSAO ATMOSFERICA (hPa) –13M
Atributo 18	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 19	PRECIPITACAO (mm) –5MP
Atributo 20	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 21	PRECIPITACAO (mm) –10MP

Tabela 54 – Temperatura para São Luís no período sazonal de Outono

OUTONO	
Selected attributes: 4,7,25,36,40,52,58,59,60,64,69,70,80,81,82	
Atributo 01	TEMPERATURA MAXIMA (°C) –1M
Atributo 02	TEMPERATURA DO PONTO DE ORVALHO (°C) –1M
Atributo 03	TEMPERATURA DO AR (°C) –11M
Atributo 04	TEMPERATURA DO AR (°C) –12M
Atributo 05	TEMPERATURA DO PONTO DE ORVALHO (°C) –12M
Atributo 06	PRESSAO ATMOSFERICA (hPa) –13M
Atributo 07	TEMPERATURA DO AR (°C) –5MP
Atributo 08	TEMPERATURA MAXIMA (°C) –5MP
Atributo 09	TEMPERATURA MINIMA (°C) –5MP
Atributo 10	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 11	TEMPERATURA DO AR (°C) –10MP
Atributo 12	TEMPERATURA MAXIMA (°C) –10MP
Atributo 13	TEMPERATURA DO AR (°C) –15MP
Atributo 14	TEMPERATURA MAXIMA (°C) –15MP
Atributo 15	TEMPERATURA MINIMA (°C) –15MP

Tabela 55 – Irradiação Solar para São Luís no período sazonal de Inverno

INVERNO	
Selected attributes: 7,9,11,12,17,20,23,25,38,44,55,59,60,66,67,77,79,88	
Atributo 01	TEMPERATURA DO PONTO DE ORVALHO (°C) –1M
Atributo 02	VELOCIDADE DO VENTO (m/s) –1M
Atributo 03	PRECIPITACAO (mm) –1M
Atributo 04	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 05	UMIDADE RELATIVA DO AR (%) –2M
Atributo 06	VELOCIDADE DO VENTO (m/s) –2M
Atributo 07	RAJADA MÁXIMA DE VENTO (m/s) –2M
Atributo 08	TEMPERATURA DO AR (°C) –11M
Atributo 09	TEMPERATURA MINIMA (°C) –12M
Atributo 10	PRECIPITACAO (mm) –12M
Atributo 11	PRECIPITACAO (mm) –13M
Atributo 12	TEMPERATURA MAXIMA (°C) –5MP
Atributo 13	TEMPERATURA MINIMA (°C) –5MP
Atributo 14	PRECIPITACAO (mm) –5MP
Atributo 15	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 16	PRECIPITACAO (mm) –10MP
Atributo 17	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 18	PRECIPITACAO (mm) –15MP

Tabela 56 – Temperatura para São Luís no período sazonal de Inverno

INVERNO	
Selected attributes: 40,58,69,80,81	
Atributo 01	TEMPERATURA DO PONTO DE ORVALHO (°C) –12M
Atributo 02	TEMPERATURA DO AR (°C) –5MP
Atributo 03	TEMPERATURA DO AR (°C) –10MP
Atributo 04	TEMPERATURA DO AR (°C) –15MP
Atributo 05	TEMPERATURA MAXIMA (°C) –15MP

Tabela 57 – Irradiação Solar para São Luís no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 3,8,22,30,44,52,61,63,67,74,78,79,85	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	PRESSAO ATMOSFERICA (hPa) –1M
Atributo 03	PRECIPITACAO (mm) –2M
Atributo 04	PRESSAO ATMOSFERICA (hPa) –11M
Atributo 05	PRECIPITACAO (mm) –12M
Atributo 06	PRESSAO ATMOSFERICA (hPa) –13M
Atributo 07	UMIDADE RELATIVA DO AR (%) –5MP
Atributo 08	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 09	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 10	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 11	RAJADA MÁXIMA DE VENTO (m/s) –10MP
Atributo 12	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 13	PRESSAO ATMOSFERICA (hPa) –15MP

Tabela 58 – Temperatura para São Luís no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 54,58,69,74,80	
Atributo 01	DIRECAO DO VENTO (graus) –13M
Atributo 02	TEMPERATURA DO AR (°C) –5MP
Atributo 03	TEMPERATURA DO AR (°C) –10MP
Atributo 04	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 05	TEMPERATURA DO AR (°C) –15MP

Tabela 59 – Irradiação Solar para São Luís no período sazonal de Verão

VERÃO	
Selected attributes: 3,4,6,14,15,16,17,19,20,25,26,27,28,33,36,37 38,44,47,48,49,50,52,55,56,63,74,79,85	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	TEMPERATURA MAXIMA (°C) –1M
Atributo 03	UMIDADE RELATIVA DO AR (%) –1M
Atributo 04	TEMPERATURA DO AR (°C) –2M
Atributo 05	TEMPERATURA MAXIMA (°C) –2M
Atributo 06	TEMPERATURA MINIMA (°C) –2M
Atributo 07	UMIDADE RELATIVA DO AR (%) –2M
Atributo 08	PRESSAO ATMOSFERICA (hPa) –2M
Atributo 09	VELOCIDADE DO VENTO (m/s) –2M
Atributo 10	TEMPERATURA DO AR (°C) –11M
Atributo 11	TEMPERATURA MAXIMA (°C) –11M
Atributo 12	TEMPERATURA MINIMA (°C) –11M
Atributo 13	UMIDADE RELATIVA DO AR (%) –11M
Atributo 14	PRECIPITACAO (mm) –11M
Atributo 15	TEMPERATURA DO AR (°C) –12M
Atributo 16	TEMPERATURA MAXIMA (°C) –12M
Atributo 17	TEMPERATURA MINIMA (°C) –12M
Atributo 18	PRECIPITACAO (mm) –12M
Atributo 19	TEMPERATURA DO AR (°C) –13M
Atributo 20	TEMPERATURA MAXIMA (°C) –13M
Atributo 21	TEMPERATURA MINIMA (°C) –13M
Atributo 22	UMIDADE RELATIVA DO AR (%) –13M
Atributo 23	PRESSAO ATMOSFERICA (hPa) –13M
Atributo 24	PRECIPITACAO (mm) –13M
Atributo 25	RAJADA MÁXIMA DE VENTO (m/s) –13M
Atributo 26	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 27	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 28	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 29	PRESSAO ATMOSFERICA (hPa) –15MP

Tabela 60 – Temperatura para São Luís no período sazonal de Verão

VERÃO	
Selected attributes: 9,14,19,25,58,59,60,64,69,70,80	
Atributo 01	VELOCIDADE DO VENTO (m/s) –1M
Atributo 02	TEMPERATURA DO AR (°C) –2M
Atributo 03	PRESSAO ATMOSFERICA (hPa) –2M
Atributo 04	TEMPERATURA DO AR (°C) –11M
Atributo 05	TEMPERATURA DO AR (°C) –5MP
Atributo 06	TEMPERATURA MAXIMA (°C) –5MP
Atributo 07	TEMPERATURA MINIMA (°C) –5MP
Atributo 08	VELOCIDADE DO VENTO (m/s) –5MP
Atributo 09	TEMPERATURA DO AR (°C) –10MP
Atributo 10	TEMPERATURA MAXIMA (°C) –10MP
Atributo 11	TEMPERATURA DO AR (°C) –15MP

Tabela 61 – Irradiação Solar para São Luís no período sazonal de Turiaçu

OUTONO	
Selected attributes: 4,7,14,15,17,18,19,25,26,27,28,33,36,37,38,39,41,51,63,66,74,77,79,84,85,88	
Atributo 01	TEMPERATURA MAXIMA (°C) –1M
Atributo 02	TEMPERATURA DO PONTO DE ORVALHO (°C) –1M
Atributo 03	TEMPERATURA DO AR (°C) –2M
Atributo 04	TEMPERATURA MAXIMA (°C) –2M
Atributo 05	UMIDADE RELATIVA DO AR (%) –2M
Atributo 06	TEMPERATURA DO PONTO DE ORVALHO (°C) –2M
Atributo 07	PRESSAO ATMOSFERICA (hPa) –2M
Atributo 08	TEMPERATURA DO AR (°C) –11M
Atributo 09	TEMPERATURA MAXIMA (°C) –11M
Atributo 10	TEMPERATURA MINIMA (°C) –11M
Atributo 11	UMIDADE RELATIVA DO AR (%) –11M
Atributo 12	PRECIPITACAO (mm) –11M
Atributo 13	TEMPERATURA DO AR (°C) –12M
Atributo 14	TEMPERATURA MAXIMA (°C) –12M
Atributo 15	TEMPERATURA MINIMA (°C) –12M
Atributo 16	UMIDADE RELATIVA DO AR (%) –12M
Atributo 17	PRESSAO ATMOSFERICA (hPa) –12M
Atributo 18	TEMPERATURA DO PONTO DE ORVALHO (°C) –13M
Atributo 19	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 20	PRECIPITACAO (mm) –5MP
Atributo 21	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 22	PRECIPITACAO (mm) –10MP
Atributo 23	IRRADIAÇÃO SOLAR kJ/m ²) –15MP
Atributo 24	TEMPERATURA DO PONTO DE ORVALHO (°C) –15MP
Atributo 25	PRESSAO ATMOSFERICA (hPa) –15MP
Atributo 26	PRECIPITACAO (mm) –15MP

Tabela 62 – Temperatura para São Luís no período sazonal de Turiaçu

OUTONO	
Selected attributes: 32,58,59,80,81,88	
Atributo 01	DIRECAO DO VENTO (graus) –11M
Atributo 02	TEMPERATURA DO AR (°C) –5MP
Atributo 03	TEMPERATURA MAXIMA (°C) –5MP
Atributo 04	TEMPERATURA DO AR (°C) –15MP
Atributo 05	TEMPERATURA MAXIMA (°C) –15MP
Atributo 06	PRECIPITACAO (mm) –15MP

Tabela 63 – Irradiação Solar para São Luís no período sazonal de Inverno

INVERNO	
Selected attributes: 3,4,9,11,12,14,15,17,22,25,28,37,44,47,48,50,66,77,79,88	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	TEMPERATURA MAXIMA (°C) –1M
Atributo 03	VELOCIDADE DO VENTO (m/s) –1M
Atributo 04	PRECIPITACAO (mm) –1M
Atributo 05	RAJADA MÁXIMA DE VENTO (m/s) –1M
Atributo 06	TEMPERATURA DO AR (°C) –2M
Atributo 07	TEMPERATURA MAXIMA (°C) –2M
Atributo 08	UMIDADE RELATIVA DO AR (%) –2M
Atributo 09	PRECIPITACAO (mm) –2M
Atributo 10	TEMPERATURA DO AR (°C) –11M
Atributo 11	UMIDADE RELATIVA DO AR (%) –11M
Atributo 12	TEMPERATURA MAXIMA (°C) –12M
Atributo 13	PRECIPITACAO (mm) –12M
Atributo 14	TEMPERATURA DO AR (°C) –13M
Atributo 15	TEMPERATURA MAXIMA (°C) –13M
Atributo 16	UMIDADE RELATIVA DO AR (%) –13M
Atributo 17	PRECIPITACAO (mm) –5MP
Atributo 18	PRECIPITACAO (mm) –10MP
Atributo 19	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 20	PRECIPITACAO (mm) –15MP

Tabela 64 – Temperatura para São Luís no período sazonal de Inverno

INVERNO	
Selected attributes: 18,69,70,80	
Atributo 01	TEMPERATURA DO PONTO DE ORVALHO (°C) –2M
Atributo 02	TEMPERATURA DO AR (°C) –10MP
Atributo 03	TEMPERATURA MAXIMA (°C) –10MP
Atributo 04	TEMPERATURA DO AR (°C) –15MP

Tabela 65 – Irradiação Solar para São Luís no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 3,6,8,14,26,36,37,38,39,41,50,52,63,67,74,79,85	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	UMIDADE RELATIVA DO AR (%) –1M
Atributo 03	PRESSAO ATMOSFERICA (hPa) –1M
Atributo 04	TEMPERATURA DO AR (°C) –2M
Atributo 05	TEMPERATURA MAXIMA (°C) –11M
Atributo 06	TEMPERATURA DO AR (°C) –12M
Atributo 07	TEMPERATURA MAXIMA (°C) –12M
Atributo 08	TEMPERATURA MINIMA (°C) –12M
Atributo 09	UMIDADE RELATIVA DO AR (%) –12M
Atributo 10	PRESSAO ATMOSFERICA (hPa) –12M
Atributo 11	UMIDADE RELATIVA DO AR (%) –13M
Atributo 12	PRESSAO ATMOSFERICA (hPa) –13M
Atributo 13	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 14	RAJADA MÁXIMA DE VENTO (m/s) –5MP
Atributo 15	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 16	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 17	PRESSAO ATMOSFERICA (hPa) –15MP

Tabela 66 – Temperatura para São Luís no período sazonal de Primavera

PRIMAVERA	
Selected attributes: 10,33,55,80,88	
Atributo 01	DIRECAO DO VENTO (graus)–1M
Atributo 02	PRECIPITACAO (mm) –11M
Atributo 03	PRECIPITACAO (mm) –13M
Atributo 04	TEMPERATURA DO AR (°C) –15MP
Atributo 05	PRECIPITACAO (mm) –15MP

Tabela 67 – Irradiação Solar para São Luís no período sazonal de Verão

VERÃO	
Selected attributes: 3,4,6,8,11,14,15,16,17,19,20,33,36,37,39,41,52,55,63,66,74,77,79,85,88	
Atributo 01	TEMPERATURA DO AR (°C) –1M
Atributo 02	TEMPERATURA MAXIMA (°C) –1M
Atributo 03	UMIDADE RELATIVA DO AR (%) –1M
Atributo 04	PRESSAO ATMOSFERICA (hPa) –1M
Atributo 05	PRECIPITACAO (mm) –1M
Atributo 06	TEMPERATURA DO AR (°C) –2M
Atributo 07	TEMPERATURA MAXIMA (°C) –2M
Atributo 08	TEMPERATURA MINIMA (°C) –2M
Atributo 09	UMIDADE RELATIVA DO AR (%) –2M
Atributo 10	PRESSAO ATMOSFERICA (hPa) –2M
Atributo 11	VELOCIDADE DO VENTO (m/s) –2M
Atributo 12	PRECIPITACAO (mm) –11M
Atributo 13	TEMPERATURA DO AR (°C) –12M
Atributo 14	TEMPERATURA MAXIMA (°C) –12M
Atributo 15	UMIDADE RELATIVA DO AR (%) –12M
Atributo 16	PRESSAO ATMOSFERICA (hPa) –12M
Atributo 17	PRESSAO ATMOSFERICA (hPa) –13M
Atributo 18	PRECIPITACAO (mm) –13M
Atributo 19	PRESSAO ATMOSFERICA (hPa) –5MP
Atributo 20	PRECIPITACAO (mm) –5MP
Atributo 21	PRESSAO ATMOSFERICA (hPa) –10MP
Atributo 22	PRECIPITACAO (mm) –10MP
Atributo 23	IRRADIAÇÃO SOLAR (kJ/m ²) –15MP
Atributo 24	PRESSAO ATMOSFERICA (hPa) –15MP
Atributo 25	PRECIPITACAO (mm) –15MP

Tabela 68 – Temperatura para São Luís no período sazonal de Verão

VERÃO	
Selected attributes: 14,19,40,58,59,60,69,70,80,81	
Atributo 01	TEMPERATURA DO AR (°C) –2M
Atributo 02	PRESSAO ATMOSFERICA (hPa) –2M
Atributo 03	TEMPERATURA DO PONTO DE ORVALHO (°C) –12M
Atributo 04	TEMPERATURA DO AR (°C) –5MP
Atributo 05	TEMPERATURA MAXIMA (°C) –5MP
Atributo 06	TEMPERATURA MINIMA (°C) –5MP
Atributo 07	TEMPERATURA DO AR (°C) –10MP
Atributo 08	TEMPERATURA MAXIMA (°C) –10MP
Atributo 09	TEMPERATURA DO AR (°C) –15MP
Atributo 10	TEMPERATURA MAXIMA (°C) –15MP

Apêndice B

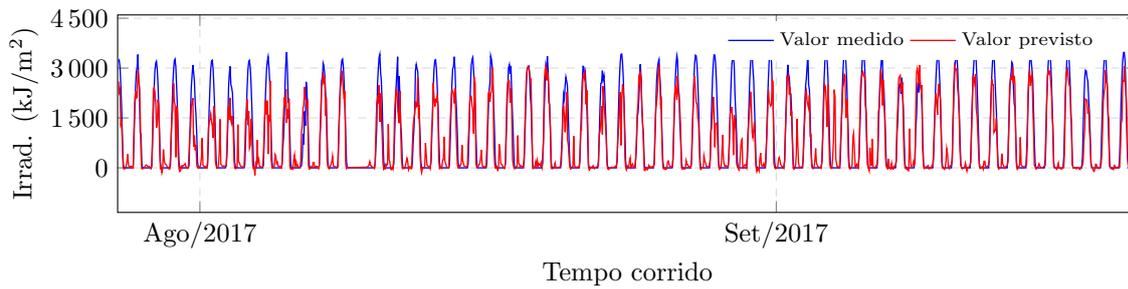
Tabela-resumo de RMSE

Tabela 69 – Valores gerais de RMSE

Caxias:		Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	C/ seleção
Verão	Irradiação	0,01354	2,36875	0,05736	0,14418	0,03007	0,02601	0,67601
	Temperatura	1,34900	2,63833	1,50121	1,98177	0,45278	1,28499	0,41112
Outono	Irradiação	7,04349	7,49771	2,76899	2,56612	1,92223	2,43682	0,10756
	Temperatura	5,24122	4,32545	3,92098	5,38936	1,53317	4,18272	0,79745
Inverno	Irradiação	6,86247	3,27709	6,44687	4,40704	5,04656	4,54940	1,47192
	Temperatura	6,86247	3,27709	6,44687	4,40704	5,04656	4,54940	0,32069
Primavera	Irradiação	0,00024	0,00645	0,01410	0,00643	0,03259	0,00398	0,03820
	Temperatura	0,02673	0,05894	0,04662	0,04556	0,00606	0,01214	0,11272
Colinas:		Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	C/ seleção
Verão	Irradiação	8,22770	8,25247	10,98648	9,33034	1,18300	9,28988	0,37329
	Temperatura	0,97024	2,55814	0,66053	1,27724	3,62259	6,40947	0,08631
Outono	Irradiação	0,22520	0,05226	2,74331	0,00087	0,22415	0,12044	0,22021
	Temperatura	0,52456	5,17360	0,44627	5,39171	12,88789	7,92724	2,78014
Inverno	Irradiação	0,17461	0,30455	0,06421	2,19186	5,46376	1,08156	0,22021
	Temperatura	1,50057	1,72737	1,47291	2,02447	1,77171	2,54080	2,78014
Primavera	Irradiação	1,54522	2,19960	4,81689	0,01355	1,65233	0,85905	2,07319
	Temperatura	0,03503	9,01944	0,79881	8,37780	0,69003	7,31719	1,66016
Imperatriz:		Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	C/ seleção
Verão	Irradiação	0,03497	0,11911	0,04974	0,02521	0,00154	0,00933	0,18119
	Temperatura	0,05364	0,02510	0,10688	0,01745	0,02463	0,07718	0,14044
Outono	Irradiação	0,05757	1,45345	1,79951	0,06000	1,70899	0,35081	3,95860
	Temperatura	2,71404	0,05090	4,62746	1,38904	0,22416	1,90607	0,22578
Inverno	Irradiação	0,07241	0,08934	2,17696	0,13872	2,68815	0,01117	4,04504
	Temperatura	5,39199	4,42876	4,46614	9,59773	3,57742	6,81603	7,83989
Primavera	Irradiação	0,01083	0,01689	0,04578	0,02992	0,01049	0,00659	0,11329
	Temperatura	0,00250	0,01248	0,06097	0,02330	0,06005	0,04320	0,00749
São Luís:		Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	C/ seleção
Verão	Irradiação	0,00539	0,24882	0,07496	0,18026	1,04597	0,07705	0,17624
	Temperatura	0,45657	0,11312	0,40947	0,26115	0,23950	0,28493	0,10835
Outono	Irradiação	1,11716	0,71969	1,05497	0,64322	0,68369	0,38384	0,82560
	Temperatura	1,90865	3,12247	3,04213	1,59335	0,26945	0,51228	0,53718
Inverno	Irradiação	2,76431	4,82631	3,82026	0,14572	4,90892	0,12872	1,80706
	Temperatura	4,05233	0,27777	1,68287	0,56920	0,06432	0,04511	0,48794
Primavera	Irradiação	0,66099	0,11052	0,06450	0,03020	0,03366	0,05267	0,00754
	Temperatura	0,15688	0,14078	0,18922	0,11312	0,03709	0,03247	0,02564
Turiçu:		Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	C/ seleção
Verão	Irradiação	0,01956	0,01424	0,01009	0,01334	0,00624	0,01969	2,29190
	Temperatura	0,04273	0,02810	0,01285	0,00570	0,03538	0,03302	0,74447
Outono	Irradiação	0,01434	0,01343	0,00731	0,00671	0,02645	0,05544	0,00505
	Temperatura	0,04441	0,00798	0,01613	0,07958	0,04242	0,01191	0,12613
Inverno	Irradiação	2,66691	3,53433	2,12947	3,80127	0,41237	3,03355	0,26099
	Temperatura	1,07574	1,27084	1,64263	0,01662	0,89075	0,47105	2,85136
Primavera	Irradiação	0,58659	0,01547	0,12854	5,32162	0,13697	4,57853	1,49833
	Temperatura	7,41047	0,24259	3,85275	0,05822	0,33815	0,85724	0,42458

Apêndice C

Gráficos de Irradiação Solar e Temperatura do Ar

Figura 46 – Gráfico de Irradiação Solar para Caxias no período do Inverno de 2017

Fonte: Elaborado pela autora (2019)

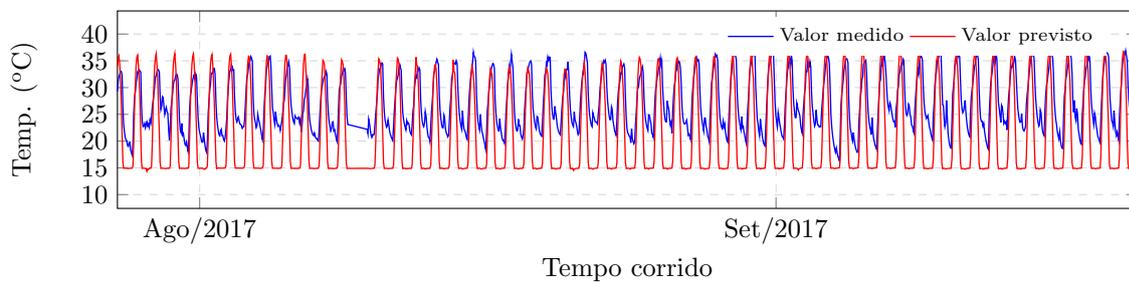
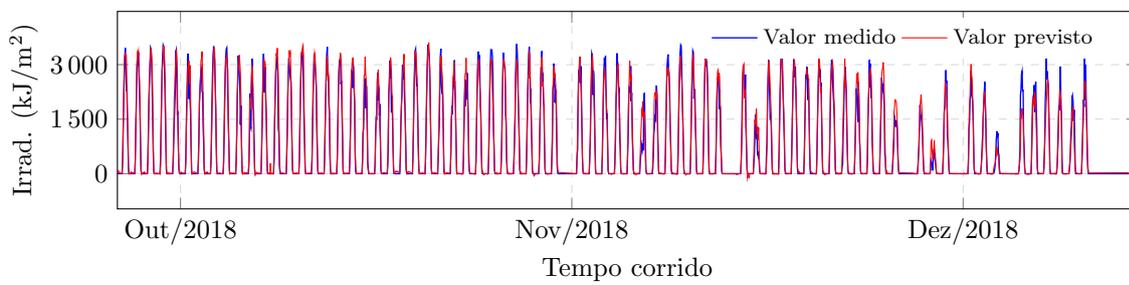
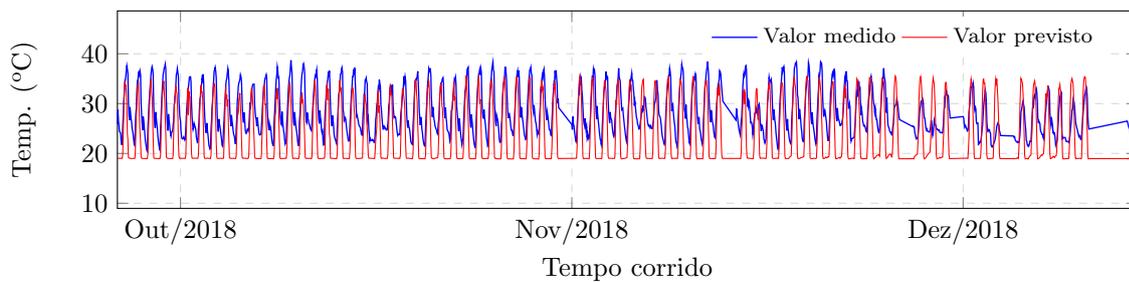
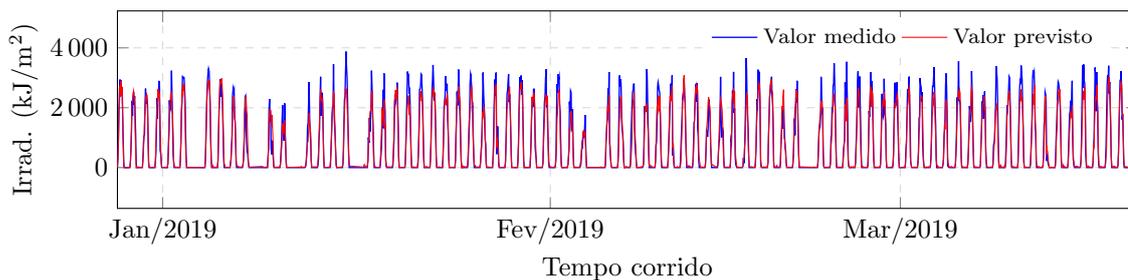
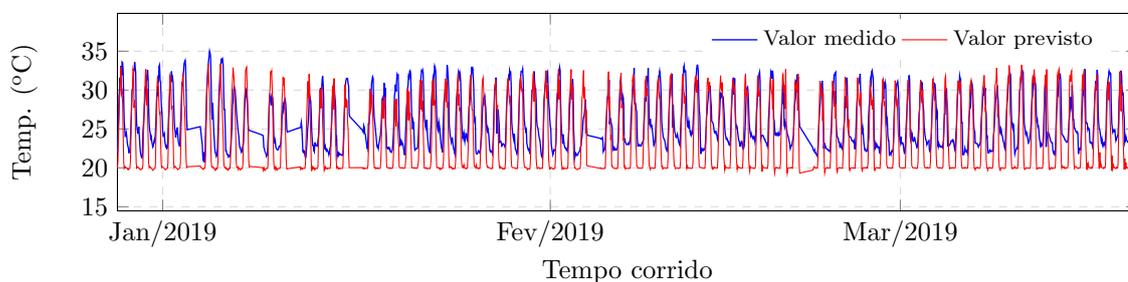
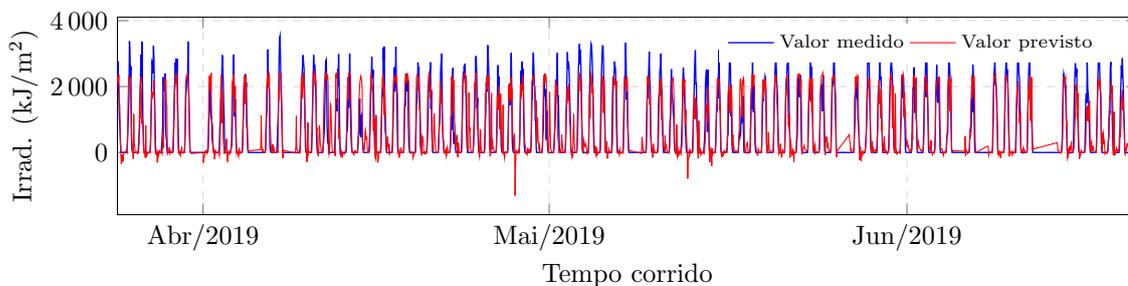
Figura 47 – Gráfico de temperatura para Caxias no período do Inverno de 2017**Figura 48** – Gráfico de Irradiação Solar para Caxias no período da Primavera de 2018**Figura 49** – Gráfico de temperatura para Caxias no período da Primavera de 2018

Figura 50 – Gráfico de Irradiação Solar para Caxias no período do Verão de 2019

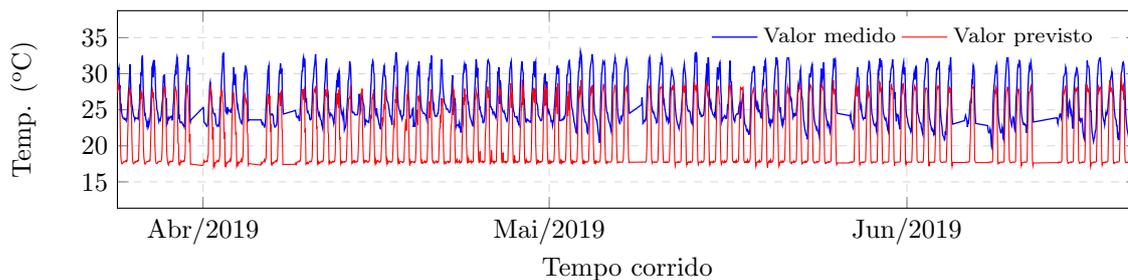
Fonte: Elaborado pela autora (2019)

Figura 51 – Gráfico de temperatura para Caxias no período do Verão de 2019

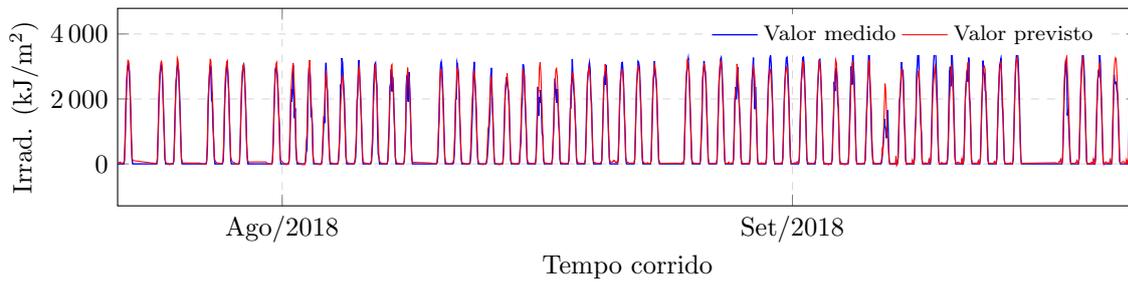
Fonte: Elaborado pela autora (2019)

Figura 52 – Gráfico de Irradiação Solar para Caxias no período do Outono de 2019

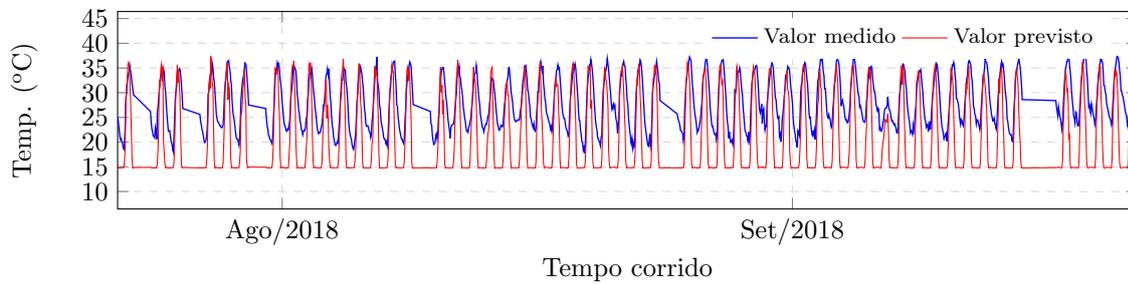
Fonte: Elaborado pela autora (2019)

Figura 53 – Gráfico de temperatura para Caxias no período do Outono de 2019

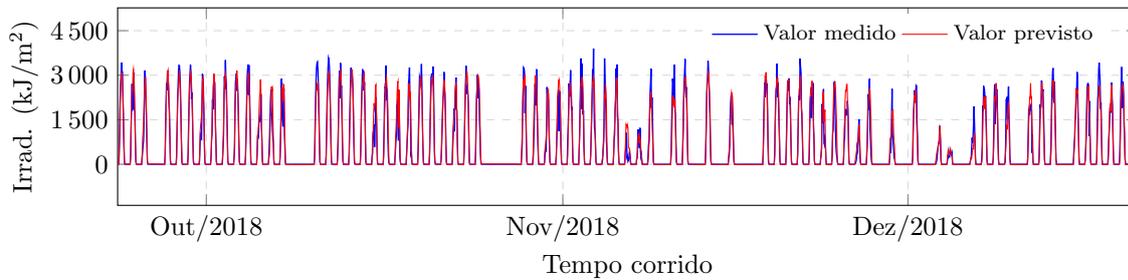
Fonte: Elaborado pela autora (2019)

Figura 54 – Gráfico de Irradiação Solar para Colinas no período do Inverno de 2018

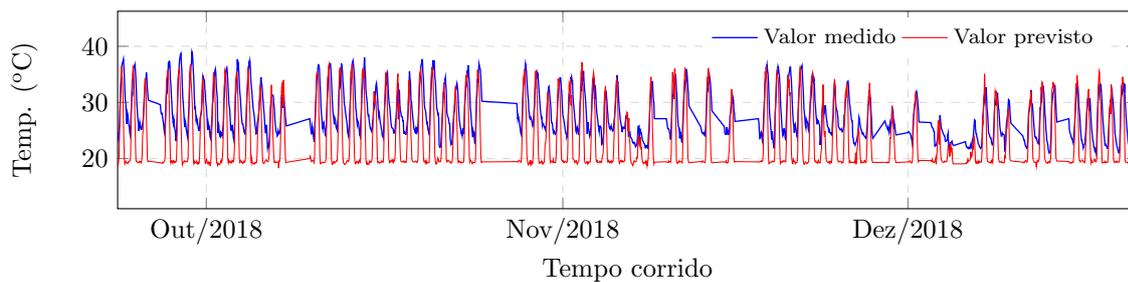
Fonte: Elaborado pela autora (2019)

Figura 55 – Gráfico de temperatura para Colinas no período do Inverno de 2018

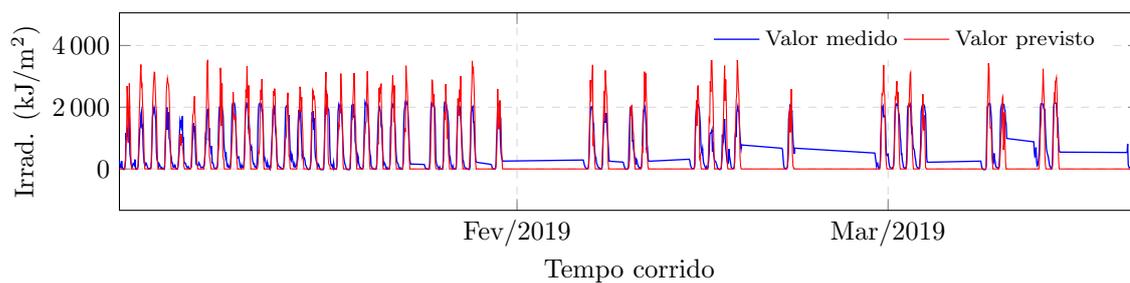
Fonte: Elaborado pela autora (2019)

Figura 56 – Gráfico de Irradiação Solar para Colinas no período da Primavera de 2018

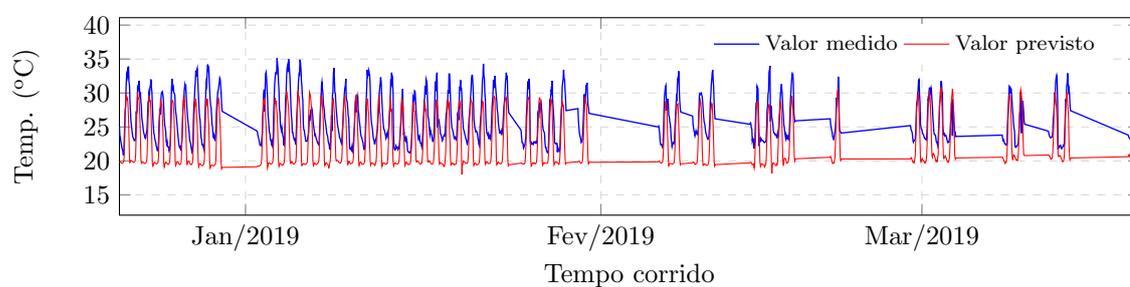
Fonte: Elaborado pela autora (2019)

Figura 57 – Gráfico de temperatura para Colinas no período da Primavera de 2018

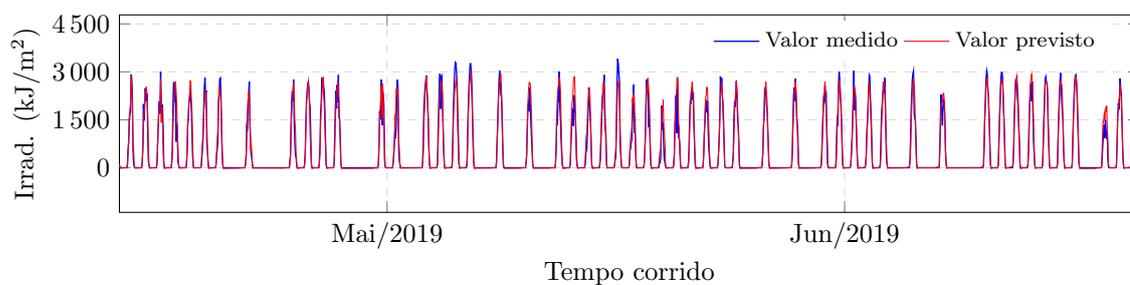
Fonte: Elaborado pela autora (2019)

Figura 58 – Gráfico de Irradiação Solar para Colinas no período do Verão de 2019

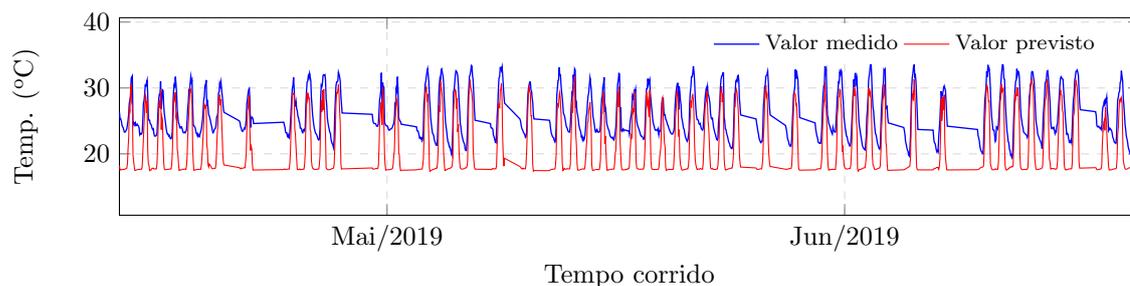
Fonte: Elaborado pela autora (2019)

Figura 59 – Gráfico de temperatura para Colinas no período do Verão de 2019

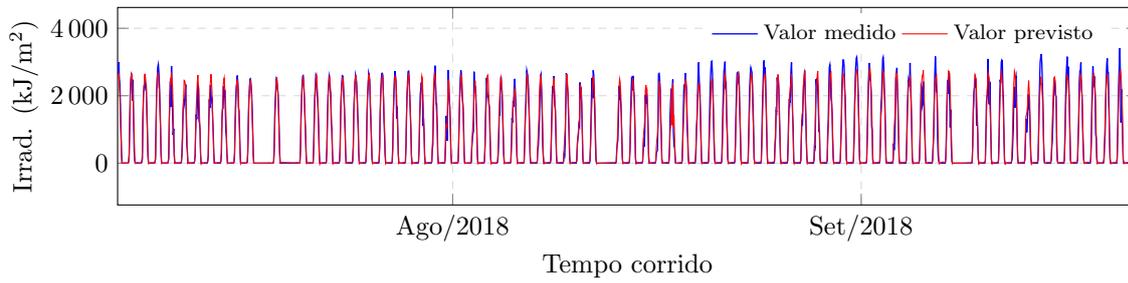
Fonte: Elaborado pela autora (2019)

Figura 60 – Gráfico de Irradiação Solar para Colinas no período do Outono de 2019

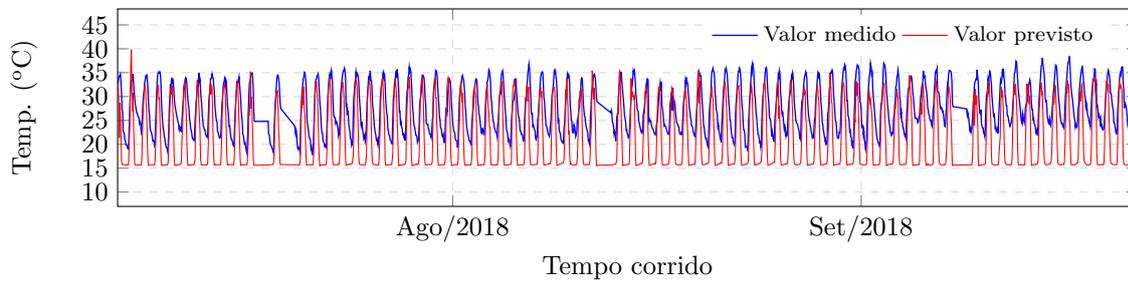
Fonte: Elaborado pela autora (2019)

Figura 61 – Gráfico de temperatura para Colinas no período do Outono de 2019

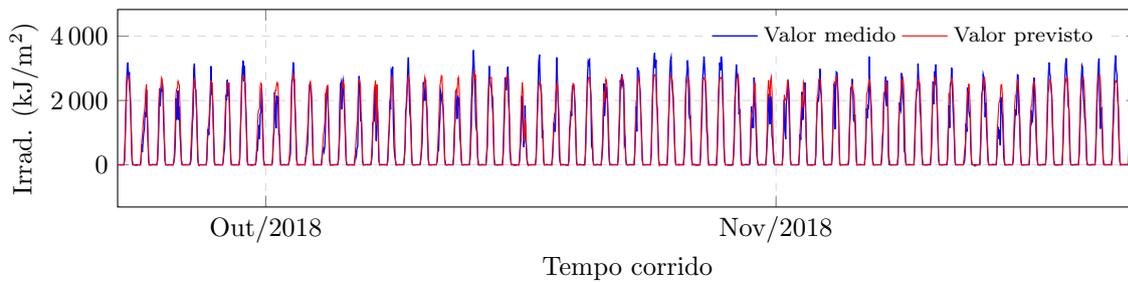
Fonte: Elaborado pela autora (2019)

Figura 62 – Gráfico de Irradiação Solar para Imperatriz no período do Inverno de 2018

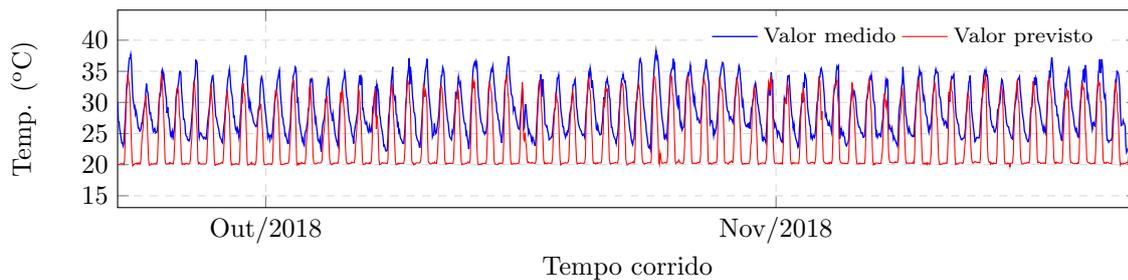
Fonte: Elaborado pela autora (2019)

Figura 63 – Gráfico de temperatura para Imperatriz no período do Inverno de 2018

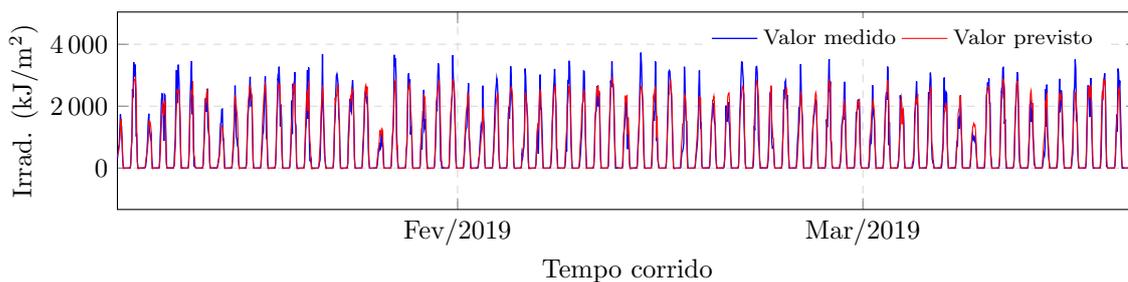
Fonte: Elaborado pela autora (2019)

Figura 64 – Gráfico de Irradiação Solar para Imperatriz no período da Primavera de 2018

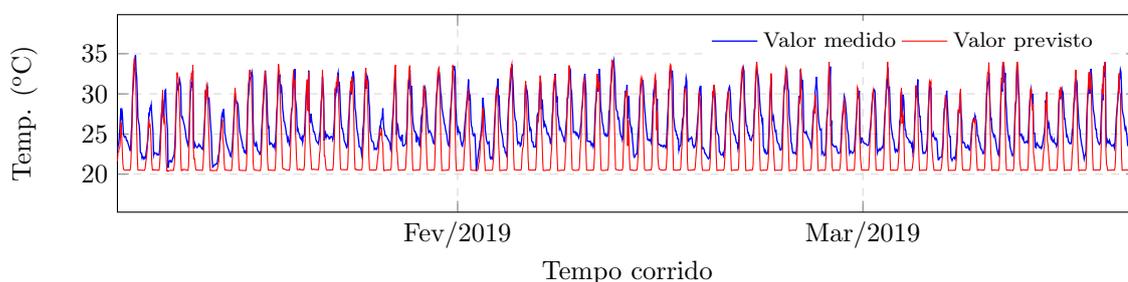
Fonte: Elaborado pela autora (2019)

Figura 65 – Gráfico de temperatura para Imperatriz no período da Primavera de 2018

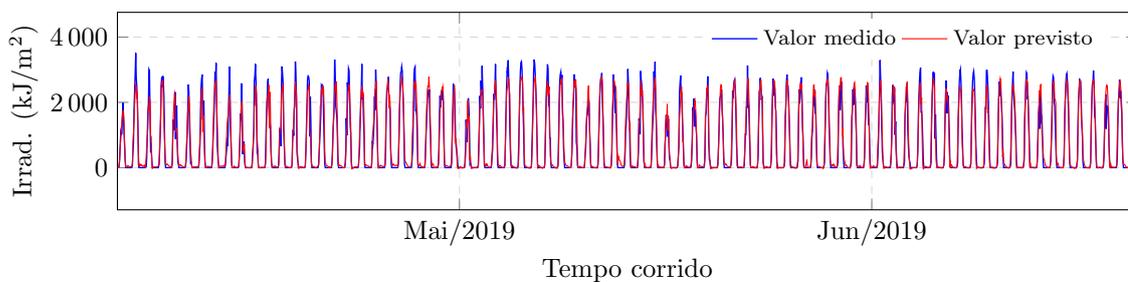
Fonte: Elaborado pela autora (2019)

Figura 66 – Gráfico de Irradiação Solar para Imperatriz no período do Verão de 2019

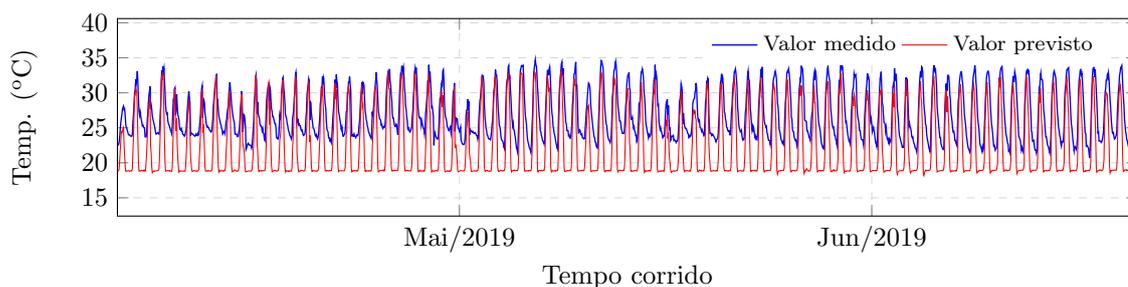
Fonte: Elaborado pela autora (2019)

Figura 67 – Gráfico de temperatura para Imperatriz no período do Verão de 2019

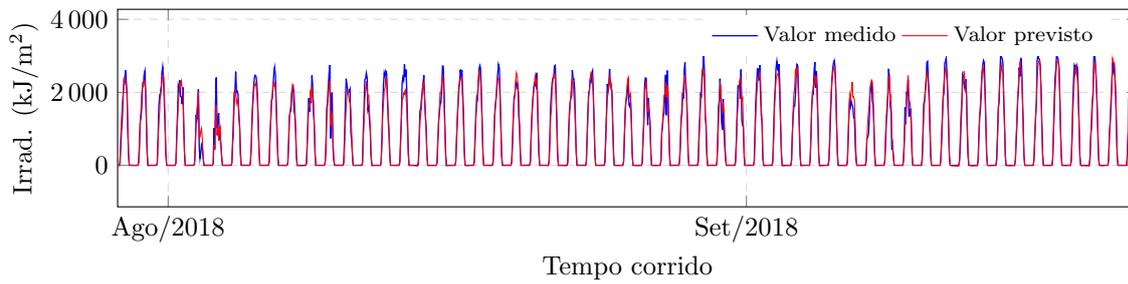
Fonte: Elaborado pela autora (2019)

Figura 68 – Gráfico de Irradiação Solar para Imperatriz no período do Outono de 2019

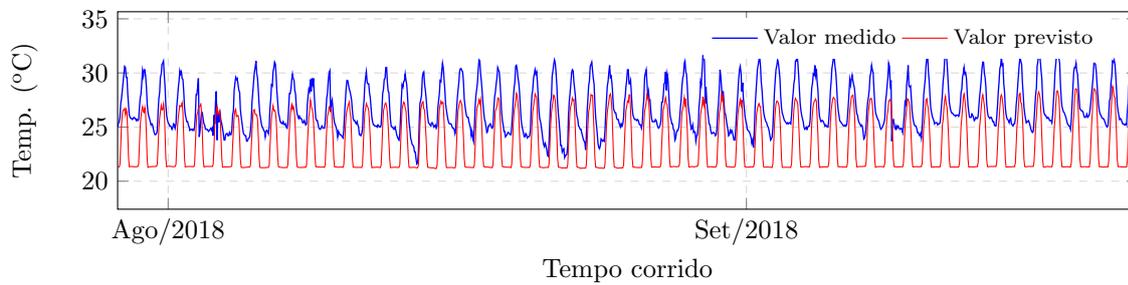
Fonte: Elaborado pela autora (2019)

Figura 69 – Gráfico de temperatura para Imperatriz no período do Outono de 2019

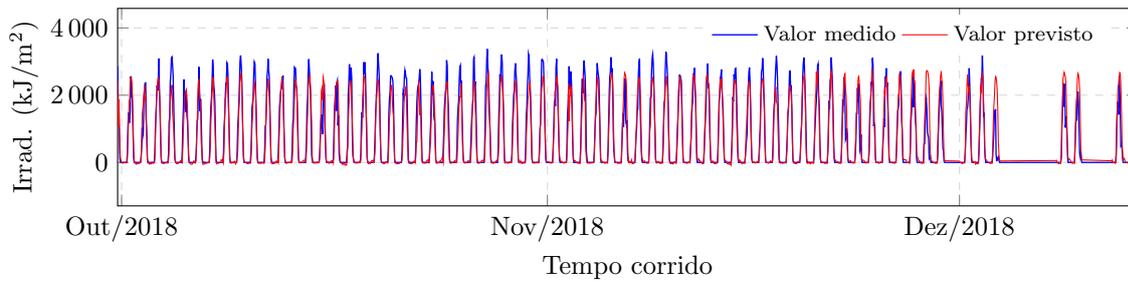
Fonte: Elaborado pela autora (2019)

Figura 70 – Gráfico de Irradiação Solar para São Luís no período do Inverno de 2018

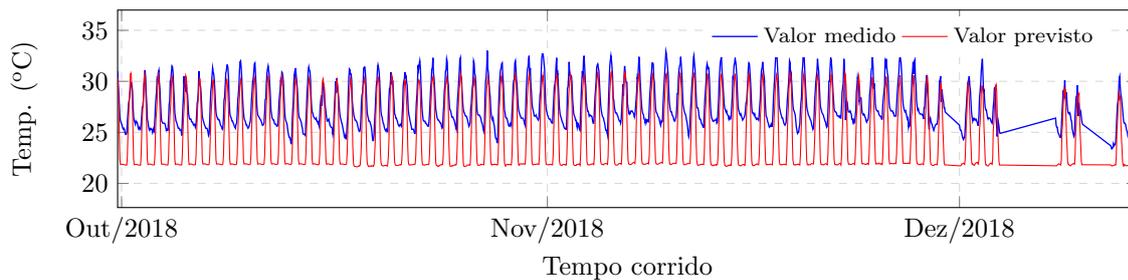
Fonte: Elaborado pela autora (2019)

Figura 71 – Gráfico de temperatura para São Luís no período do Inverno de 2018

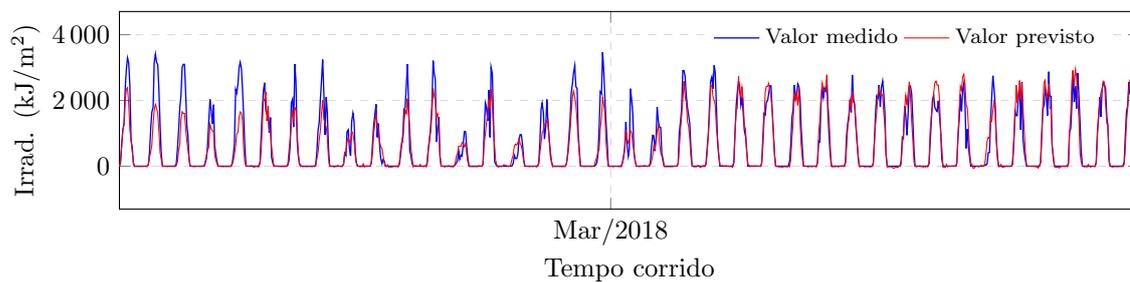
Fonte: Elaborado pela autora (2019)

Figura 72 – Gráfico de Irradiação Solar para São Luís no período da Primavera de 2018

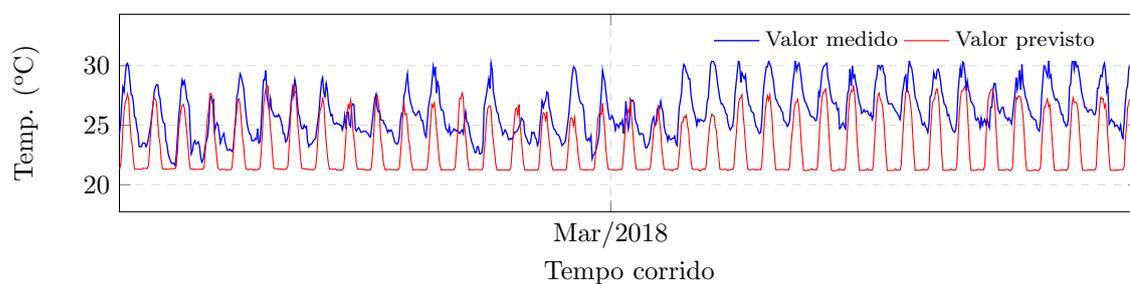
Fonte: Elaborado pela autora (2019)

Figura 73 – Gráfico de temperatura para São Luís no período da Primavera de 2018

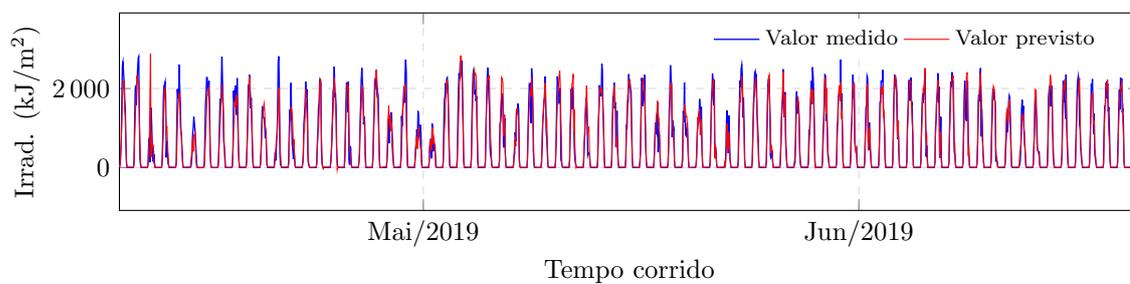
Fonte: Elaborado pela autora (2019)

Figura 74 – Gráfico de Irradiação Solar para São Luís no período do Verão de 2018

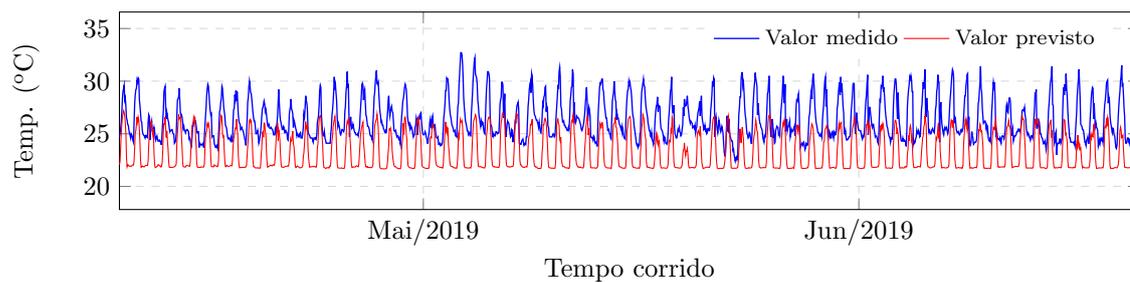
Fonte: Elaborado pela autora (2019)

Figura 75 – Gráfico de temperatura para São Luís no período do Verão de 2018

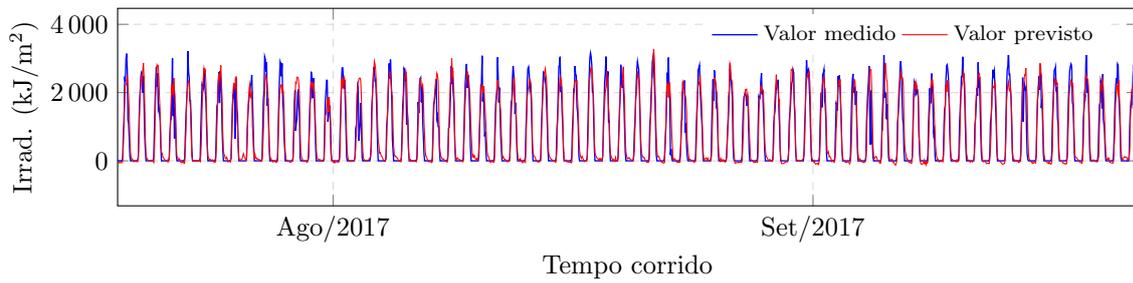
Fonte: Elaborado pela autora (2019)

Figura 76 – Gráfico de Irradiação Solar para São Luís no período do Outono de 2019

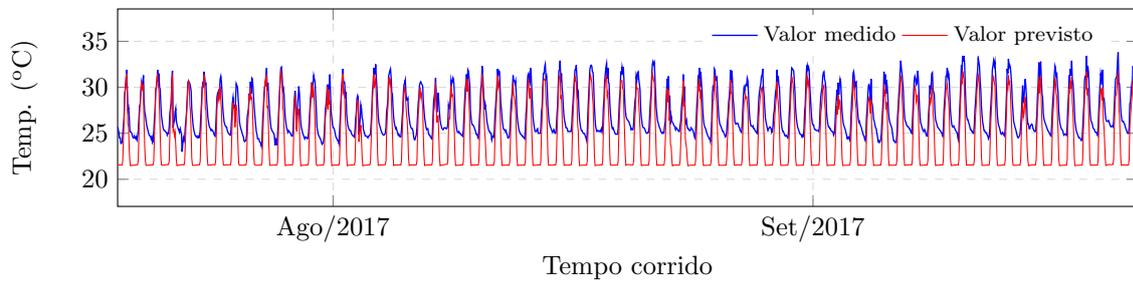
Fonte: Elaborado pela autora (2019)

Figura 77 – Gráfico de temperatura para São Luís no período do Outono de 2019

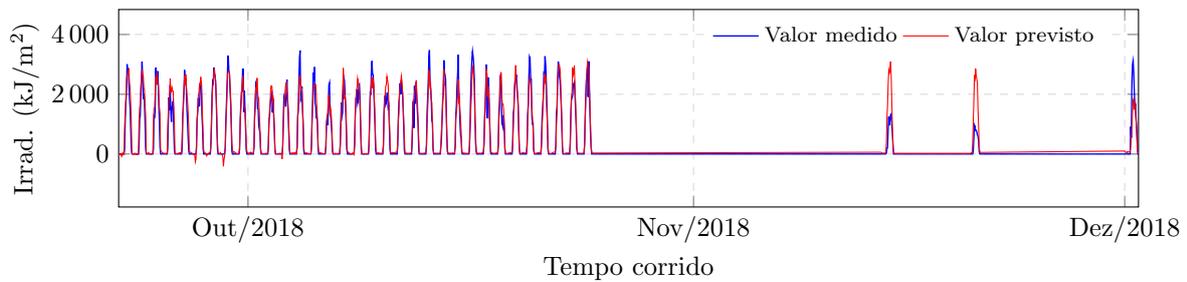
Fonte: Elaborado pela autora (2019)

Figura 78 – Gráfico de Irradiação Solar para Turiagu no período do Inverno de 2017

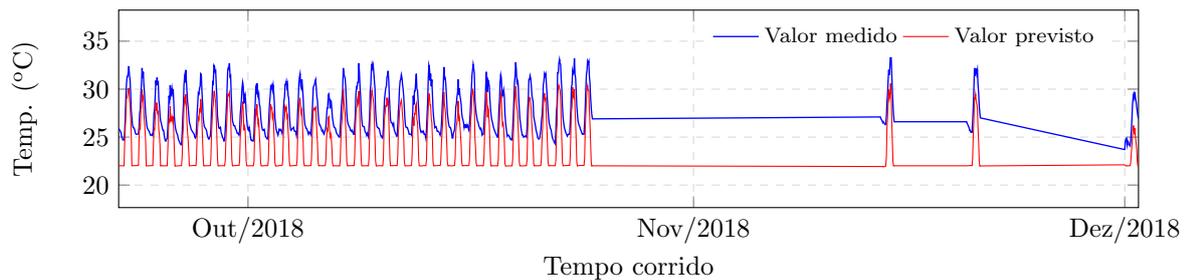
Fonte: Elaborado pela autora (2019)

Figura 79 – Gráfico de temperatura para Turiagu no período do Inverno de 2017

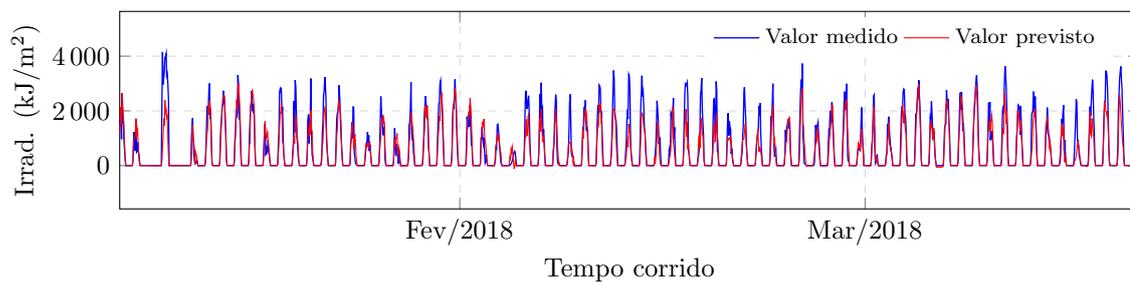
Fonte: Elaborado pela autora (2019)

Figura 80 – Gráfico de Irradiação Solar para Turiagu no período da Primavera de 2018

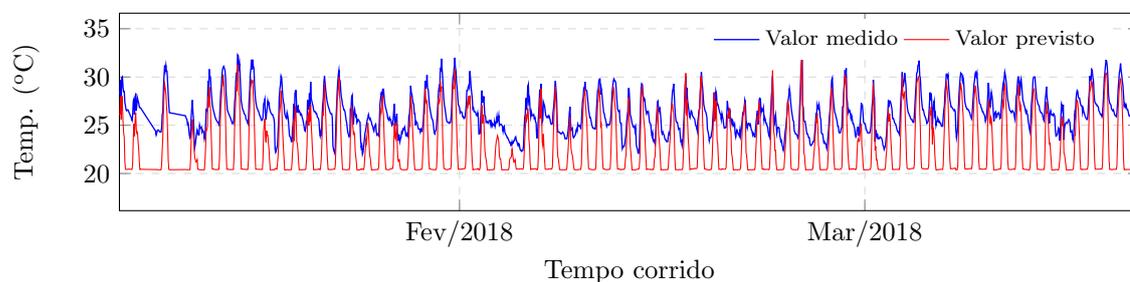
Fonte: Elaborado pela autora (2019)

Figura 81 – Gráfico de temperatura para Turiagu no período da Primavera de 2018

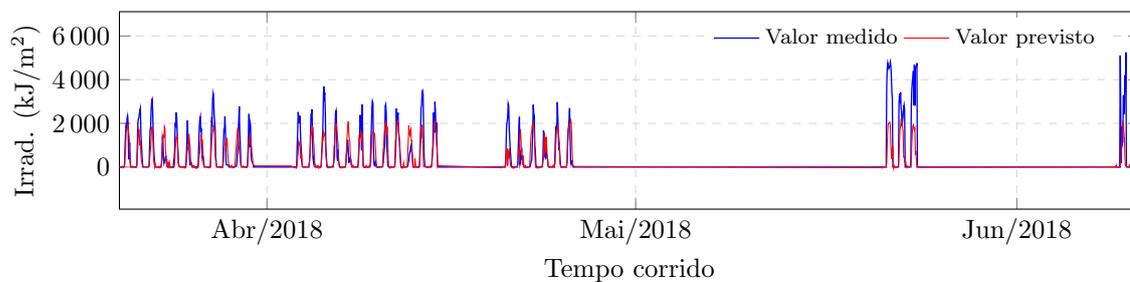
Fonte: Elaborado pela autora (2019)

Figura 82 – Gráfico de Irradiação Solar para Turiacu no período do Verão de 2018

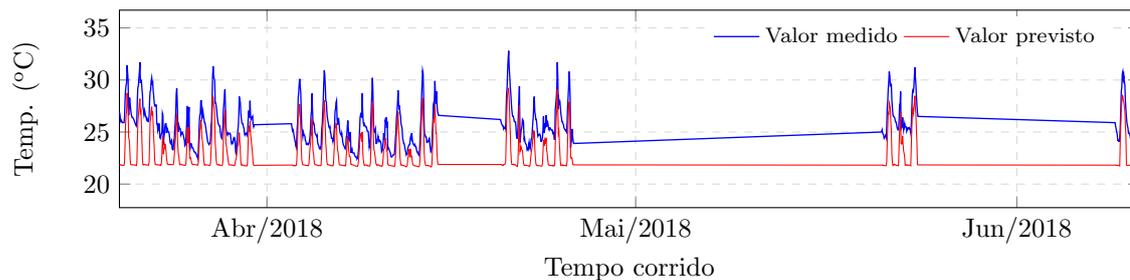
Fonte: Elaborado pela autora (2019)

Figura 83 – Gráfico de temperatura para Turiacu no período do Verão de 2018

Fonte: Elaborado pela autora (2019)

Figura 84 – Gráfico de Irradiação Solar para Turiacu no período do Outono de 2018

Fonte: Elaborado pela autora (2019)

Figura 85 – Gráfico de temperatura para Turiacu no período do Outono de 2018

Fonte: Elaborado pela autora (2019)