

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

**REDES NEURAS ARTIFICIAIS APLICADAS À PREVISÃO
DE IRRADIÂNCIA GLOBAL HORIZONTAL NO CONTEXTO
DE CIDADES ENERGETICAMENTE INTELIGENTES**

FREDERICO PEDRO BON

São Carlos

2020

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

**REDES NEURAIS ARTIFICIAIS APLICADAS À PREVISÃO
DE IRRADIÂNCIA GLOBAL HORIZONTAL NO CONTEXTO
DE CIDADES ENERGETICAMENTE INTELIGENTES**

FREDERICO PEDRO BON

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

Orientação: Prof. Dr. Ricardo Augusto Souza Fernandes

São Carlos

2020

Pedro Bon, Frederico

Redes neurais artificiais aplicadas à previsão de Irradiância Global Horizontal no contexto de cidades energeticamente inteligentes / Frederico Pedro Bon -- 2020.
111f.

Dissertação (Mestrado) - Universidade Federal de São Carlos, campus São Carlos, São Carlos
Orientador (a): Ricardo Augusto Souza Fernandes
Banca Examinadora: Tatiane Cristina da Costa
Fernandes, Fábio Anderson Silva Borges
Bibliografia

1. Redes neurais artificiais. 2. Irradiância global horizontal. 3. Cidades inteligentes. . I. Pedro Bon, Frederico. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Ronildo Santos Prado - CRB/8 7325



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 do candidato Frederico Pedro Bon, 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.

“In principio erat Verbum, et Verbum erat apud Deum, et Deus erat Verbum. Omnia per ipsum facta sunt, et sine ipso factum est nihil, quod factum est; in ipso vita erat, et vita erat lux hominum, et lux in tenebris lucet, et tenebrae eam non comprehenderunt. ”

Ioannem1, 1.3-5

“No princípio era o Verbo, e o Verbo estava junto de Deus e o Verbo era Deus. Tudo foi feito por Ele, e sem Ele nada foi feito. Nele havia vida, e a vida era a luz dos homens. A luz resplandece nas trevas, e as trevas não a compreenderam. ”

João, 1.3-5

AGRADECIMENTOS

Todo o trabalho envolvido nas páginas que seguem é fruto de dois anos de árdua dedicação. Um tema que não conhecia muito bem a princípio, mas que agora, considero um passo largo rumo aos moldes mais sustentáveis que as nossas sociedades devem assumir em defesa da conservação e da perpetuação da casa comum e dos seres que nela habitam.

Agradeço primária e primordialmente a Deus, pelo dom da vida e pela saúde. Sem Ele e seu auxílio, eu não seria capaz de superar sozinho todas as dificuldades que despontaram pelo percurso. Foi Ele que esteve ao meu lado e me deu ânimo para não desistir dos meus sonhos. Gostaria de lembrar também das pessoas que Ele me concedeu o privilégio de conviver nesses anos e que tornaram o caminho mais brando.

À minha família, eterna gratidão. Aos meus pais que nunca duvidaram de mim e que sacrificaram vontades e desejos próprios para que esta etapa da minha vida fosse possível. À minha mãe, Vera, pela diária ligação externando saudades, carinho e apoio. Ao meu pai, Wilson, pelo constante encorajamento e pela presença desde a primeira visita à São Carlos. Aos meus avós, Júlio, Eva e Armando, *in memoriam*, que não puderam acompanhar presencialmente esta etapa da minha vida, mas que desde pequeno me apontaram os caminhos a trilhar, me ajudaram nos primeiros passos e me suportaram nas quedas. À minha avó paterna, Maria, que pôde estar presente cotidianamente. Ao meu tio Florival, *in memoriam* e às minhas tias Sandra e Cecília pela constante preocupação e cuidado. Ao Eng. Gabriel Pasquinelli, irmão que a vida me deu, agradeceu seu apoio, sua presença e os risos mais descontraídos que partilhamos nesses anos todos.

Seguindo uma ordem cronológica, gostaria de agradecer alguns amigos. *A priori*, aqueles que conheci no ensino médio e que me acompanham até hoje. À Gabriella Curtulo, Me. Gustavo Leite, Amanda Tofolo, Me. João Victor Brandt e Jadi Lorian, agradeço os laços de amizade mais longínquos que cultivei.

À Vera Favetta, Maria Alice Borrasca e Avair Fadol por cuidarem de mim como um filho e pelo desejo de continuar cuidando, independente dos ritmos e vicissitudes que a vida aprouver.

Às pessoas incríveis que conheci durante os anos de graduação. À Élide Generoso e Jessika Peres pelas conversas mais descontraídas e pelo apoio mais incondicional. Aos meus colegas de turma, Engs. Núbia Castro, David Mourão Carvalho, Murilo Del Bel, Laís Freitas,

Lucas Reis, Atos Sousa e Marília Costa pela eterna pareceria, desde os primeiros dias até a colação. À minha orientadora da graduação, Prof. Dra. Claudia Gibertoni, por abrir meus olhos ao vasto horizonte que é a pesquisa científica e por me ajudar e me acompanhar até a defesa desta dissertação.

Aos amigos que fiz em São Carlos. Ao Lucas Dettle. Você esteve comigo nos momentos difíceis e me abraçou nos felizes. Agradeço por acreditar no meu potencial quando eu mesmo duvidava, por permanecer nos meus dias e tornar-se constante. À Natalia Garcia, Edson Arthur Zancheta e Beatriz Ribeiro. Agradeço as festas mais divertidas, as conversas sem julgamentos e a leveza de uma amizade que vai me fazer sentir falta todos os dias que não puder vê-los. Ao meu colega de apartamento, Me. Jefferson Maciel pelo companheirismo e cordialidade.

Aos meus colegas de pós-graduação e de laboratório. Sem as risadas que demos juntos e os conselhos que trocamos, o caminho até aqui teria sido mais árduo. À Me. Wanessa Karoline Maciel por estar comigo todos os dias durante os dois anos de mestrado, pelas disciplinas que cursamos juntos e por sempre me lembrar dos prazos, eterna gratidão e carinho. À Me. Ana Favretto por me inserir na rotina do laboratório e permitir que sentisse pertença a este lugar. Ao Anderson Moraes, pela ajuda de sempre e por se fazer presença nas etapas mais complicadas da pós-graduação. Ao Me. Leonel Alejandro Laboissiere, que sem toda a instrução e apoio que me deu, este trabalho não seria possível aos moldes como o é.

Aos meus professores e aos funcionários do Programa de Pós-Graduação em Engenharia Urbana por todo o auxílio nesse período. Ao Prof. Dr. Érico Masiero pelo conhecimento que me transmitiu em suas aulas e por me permitir fazer uso diário do seu espaço de pesquisa. À Profa. Dra. Katia Sakihama Ventura, que me possibilitou acompanhar suas aulas descontraídas e didáticas no estágio docência e que me fizeram valorizar e me encantar ainda mais com essa profissão que transforma vidas.

Ao meu orientador, Prof. Dr. Ricardo Augusto Souza Fernandes. Seu apoio foi incondicional desde o meu ingresso no mestrado. Na nossa primeira conversa, me ajudou a concretizar um tema de pesquisa que, confesso, estava receoso, mas que também me deu total apoio e liberdade para buscar outras possibilidades. Por fim, o senhor tinha razão, sou completamente apaixonado pela pesquisa que desenvolvi. Agradeço sua orientação acadêmica. Agradeço, também, as prontas revisões no projeto de pesquisa, em cada artigo, no exame de qualificação e por fim nesta dissertação. Ao senhor, professor, minha eterna gratidão!

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo auxílio financeiro que me disponibilizou durante o período que desenvolvi esta pesquisa, além do acesso gratuito, oportuno e essencial às bases indexadas.

Por fim, à Universidade Federal de São Carlos – UFSCar. Aqui fui prontamente acolhido junto da minha pesquisa e tive todo o suporte, acesso, orientação e condução que precisei para finalizá-la. A “fúria vermelha e branca” da chamada “melhor universidade do meu Brasil” demonstram o carinho que todo aluno desta magnífica instituição de ensino carrega no peito. Carinho este, que foi edificado junto de valores comprometidos com a construção de uma sociedade melhor, os quais, aqui aprendemos e vivemos.

RESUMO

O rápido crescimento populacional nas últimas décadas e consequente urbanização acelerada deram origem a novos problemas urbanos que as sociedades ainda não haviam enfrentado nos séculos passados. Assim, o desenvolvimento sustentável das cidades é comprometido como consequência do fracasso em atender as necessidades que surgem. Foi nesse contexto que as *smart cities* despontaram e, a partir da inteligência artificial, dos recursos digitais e das tecnologias de comunicação, estão se provando como estratégia natural de mitigação desses problemas. Entre as muitas áreas assistidas por uma *smart city*, as *smart grids* têm ganhado foco, visto que a necessidade energética mundial irá crescer em 30% até 2040. Além disso, governos e sociedade demandam dos produtores de energia uma inserção sólida das fontes renováveis, aos moldes do princípio da sustentabilidade. A matriz fotovoltaica é uma das fontes renováveis que se encaixa nessa demanda. O governo federal brasileiro estima que até 2050, 13% de todas as residências no território nacional deva ser abastecida por energia advinda da produção fotovoltaica. Porém, sua inserção é desafiada pela intermitência da produção, visto que os painéis geram energia basicamente a partir da Irradiância Global Horizontal, que não é uniforme ao longo do tempo. Assim, uma previsão precisa é benéfica já que reduz os custos e incertezas, além de evitar contrariedades decorrentes do desvio entre previsão e consumo. Com o intuito de prever Irradiância Global Horizontal hora à frente ($h+1$) no *campus* da Universidade Federal de São Carlos, localizado em Araras/SP, utilizou-se Redes Neurais Artificiais. Uma arquitetura *Multilayer Perceptron* com algoritmo de treinamento Levenberg-Marquardt e topologias de uma e duas camadas neurais foi aplicada. Os melhores resultados, em termos de Raiz do Erro Quadrático Médio normalizado (nRMSE) variaram entre 5,9% e 6,8%. Os dados utilizados como sinais de entrada na obtenção desses resultados foram irradiância global horizontal, temperatura média e velocidade do vento média. A previsão se mostrou acurada quando comparada com a literatura.

Palavras-chave: Redes neurais artificiais; previsão de séries temporais; irradiância global horizontal; cidades inteligentes.

ABSTRACT

Rapid population growth in the last decades and consequent accelerated urbanization have led to new urban problems that societies had not faced in the past centuries. Thus, the sustainable development of cities is compromised as a consequence of failure to meet the needs that arise. In this context, the smart cities emerged and, based on artificial intelligence, digital resources and communication technologies are proving themselves as a natural strategy to mitigate these problems. Among many areas served by a smart city, smart grids have gained focus, as global energy needs will grow by 30% until 2040. In addition, governments and society demand a solid insertion of renewable sources in order to guarantee the sustainability. The photovoltaic matrix is one of the renewable sources that fits this demand. The Brazilian government estimates that, until 2050, 13% of all residences in the national territory should be supplied by energy from photovoltaic production. However, its insertion is challenged by intermittent production, since the panels generate energy basically from Global Horizontal Irradiance, which is not uniform over time. Thus, an accurate forecast is beneficial because it reduces the costs and uncertainties besides avoiding annoyances due to the deviation between forecast and consumption. With the intention of predicting Global Horizontal Irradiance in the next hour ($h + 1$) on the campus of the Federal University of São Carlos, located in Araras-SP, it was used Artificial Neural Networks. A Multilayer Perceptron architecture with Levenberg-Marquardt training algorithm was used, considering one and two hidden layers. The best results, in terms of the Root Mean Square Error (nRMSE) ranged from 5.9% to 6.8%. The data used as input signals to obtain these results were global horizontal irradiance, mean temperature and average wind speed. The prediction was accurate when compared to the literature.

Keywords: Artificial neural networks; time series forecasting; global horizontal irradiance; smart cities.

LISTA DE ILUSTRAÇÕES

Figura 1 – Recorte da página de pesquisa na base Scopus.....	27
Figura 2 – Análise dos termos encontrados nos títulos.	28
Figura 3 – Análise temporal das associações ao termo “ <i>neural network</i> ”.	29
Figura 4 – Relação de autores.....	30
Figura 5 – Relação de países.	31
Figura 6 – Tanque de Classe A.....	45
Figura 7 – Consumo total de eletricidade e geração fotovoltaica na Alemanha entre 1990 e 2016.	47
Figura 8 – Mapa de irradiação global horizontal na Alemanha.	48
Figura 9 – Mapa de irradiação global horizontal no Brasil.	49
Figura 10 – Consumo total de eletricidade e geração fotovoltaica na China entre 1990 e 2016.	51
Figura 11 – Mapa de irradiação global horizontal na China.	52
Figura 12 – Sistema de compensação previsto na resolução nº687/2015 da ANEEL.	53
Figura 13 – Localização da cidade de Araras no mapa político do estado de São Paulo.....	54
Figura 14 – Horas de luz solar e crepúsculo em Araras.	55
Figura 15 – Dia solar durante o ano de 2019 em Araras.	55
Figura 16 – Categorias de nebulosidade em Araras.	56
Figura 17 – Mapa de Irradiação Global Horizontal do estado de São Paulo com enfoque em Araras.	57
Figura 18 – Relatório de Irradiação Global Horizontal e previsão de geração fotovoltaica. ...	58
Figura 19 – Comparativo entre as faixas de GHI contidas nas Figuras 8, 9, 11 e 17.....	59
Figura 20 – Comparativo entre neurônio biológico e artificial.	63
Figura 21 – Representação de um neurônio artificial.....	64
Figura 22– Rede <i>feedforward</i> com múltiplas camadas.	66
Figura 23 – Gráfico da função logística (sigmoide).	67

Figura 24 – Gráfico da função linear.....	67
Figura 25 – Visão geral da metodologia proposta.....	68
Figura 26 – EMA, UFSCar Araras.....	69
Figura 27 – Comportamento da GHI.....	72
Figura 28 – Intervalo de variação de GHI para cada hora do dia entre 2015 e 2018.....	73
Figura 29 – Representação gráfica da presença de GHI na Base Final.....	75
Figura 30 – Comparação gráfica através da métrica MAE entre previsões.....	83
Figura 31 – Comparação gráfica através da métrica RMSE entre previsões.....	84
Figura 32 – Comparação gráfica através da métrica nRMSE entre previsões.....	84
Figura 33 – Comparação gráfica entre os resultados dos testes 2 e 10.....	85
Figura 34 - Comparação de resultados com a literatura.....	85
Figura 35 – Número de coletas por faixa de GHI entre 0h e 5h e entre 20h e 23h.....	100
Figura 36 – Número de coletas por faixa de GHI às 6h.....	100
Figura 37 – Número de coletas por faixa de GHI às 7h.....	101
Figura 38 – Número de coletas por faixa de GHI às 8h.....	101
Figura 39 – Número de coletas por faixa de GHI às 9h.....	101
Figura 40 – Número de coletas por faixa de GHI às 10h.....	102
Figura 41 – Número de coletas por faixa de GHI às 11h.....	102
Figura 42 – Número de coletas por faixa de GHI às 12h.....	102
Figura 43 – Número de coletas por faixa de GHI às 13h.....	103
Figura 44 – Número de coletas por faixa de GHI às 14h.....	103
Figura 45 – Número de coletas por faixa de GHI às 15h.....	103
Figura 46 – Número de coletas por faixa de GHI às 16h.....	104
Figura 47 – Número de coletas por faixa de GHI às 17h.....	104
Figura 48 – Número de coletas por faixa de GHI às 18h.....	104
Figura 49 – Número de coletas por faixa de GHI às 19h.....	105

LISTA DE TABELAS

Tabela 1 – Revisão da Literatura entre 2014 e 2019.	36
Tabela 2 – Coeficiente k_p do Método do Tanque de Classe A.	45
Tabela 3 - Variação de GHI para cada hora do dia entre 2015 e 2018.....	74
Tabela 4 – Combinações de variáveis para teste sem seleção de atributos.	76
Tabela 5 – Seleção de atributos.	78
Tabela 6 – Detalhamento das RNAs aplicadas.....	78
Tabela 7 – Quantidade de neurônios nas redes com 2 camadas escondidas.	79
Tabela 8 – Resultados obtidos no teste 2.....	82
Tabela 9 – Comparação entre os resultados dos testes 2 e 10.	84
Tabela 10 – Número de coletas de GHI por faixa horária para valores entre 0,0 MJ/m ² e 1,4 MJ/m ²	97
Tabela 11 – Número de coletas de GHI por faixa horária para valores entre 1,5 MJ/m ² e 3,0 MJ/m ²	98
Tabela 12 – Número de coletas de GHI por faixa horária para valores entre 3,1 MJ/m ² e 4,5 MJ/m ²	99
Tabela 13 – Resultados obtidos no Teste 1.	106
Tabela 14 – Resultados obtidos no Teste 2.	106
Tabela 15 – Resultados obtidos no Teste 3.	107
Tabela 16 – Resultados obtidos no Teste 4.	107
Tabela 17 – Resultados obtidos no Teste 5.	108
Tabela 18 – Resultados obtidos no Teste 6.	108
Tabela 19 – Resultados obtidos no Teste 7.	109
Tabela 20 – Resultados obtidos no Teste 8.	109
Tabela 21 – Resultados obtidos no Teste 9.	110
Tabela 22 – Resultados obtidos no Teste 10.	110

SUMÁRIO

1	INTRODUÇÃO	20
1.1	CONSIDERAÇÕES INICIAIS	20
1.2	OBJETIVOS	22
1.2.1	Objetivos gerais	22
1.2.2	Objetivos específicos	22
1.3	JUSTIFICATIVA	23
1.4	ORGANIZAÇÃO	26
2	REVISÃO DA LITERATURA.....	27
2.1	ANÁLISE BIBLIOMÉTRICA	27
2.2	MÉTODOS PARA PREVISÃO DE GHI	31
2.3	MÉTODOS BASEADOS EM INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE SÉRIES TEMPORAIS EM <i>SMART GRIDS</i>	34
3	RADIAÇÃO SOLAR E COMPONENTES ASSOCIADAS	41
3.1	IRRADIÂNCIA GLOBAL HORIZONTAL	41
3.2	EVAPOTRANSPIRAÇÃO (Eto)	43
4	LEVANTAMENTOS DE GHI.....	46
4.1	COMPARATIVO ENTRE ALEMANHA E BRASIL.....	46
4.2	COMPARATIVO ENTRE CHINA E BRASIL.....	49
4.3	CARACTERIZAÇÃO DA GERAÇÃO FOTOVOLTAICA EM ARARAS/SP53	
4.3.1	Caracterização legal.....	53
4.3.2	Caracterização geográfica.....	54
4.3.3	Caracterização climática.....	54
5	TÉCNICAS DE ANÁLISES DE SÉRIES TEMPORAIS	60
5.1	REDES NEURAIS ARTIFICIAIS	62
5.1.1	Neurônio artificial.....	63
5.1.2	Arquitetura de rede neural artificial.....	65

5.1.3	Topologias de redes neurais artificiais	65
5.1.4	Funções de ativação.....	66
6	METODOLOGIA PROPOSTA.....	68
6.1	FORMAÇÃO E PRÉ-PROCESSAMENTO DA BASE DE DADOS INICIAL.....	69
6.2	FORMAÇÃO DA BASE DE DADOS FINAL.....	73
6.2.1	Identificação dos horários de previsão	73
6.2.2	Determinação dos atrasos (<i>lags</i>).....	76
6.3	COMBINAÇÃO DE DADOS	76
6.3.1	SELEÇÃO DE ATRIBUTOS	77
6.4	APLICAÇÃO DAS REDES NEURAS ARTIFICIAS.....	78
6.5	MÉTRICAS DE AVALIAÇÃO DOS MODELOS PREDITIVOS	79
7	RESULTADOS E DISCUSSÃO	82
8	CONCLUSÕES	87
8.1	CONCLUSÕES GERAIS.....	87
8.2	TRABALHOS FUTUROS	87

1 INTRODUÇÃO

1.1 CONSIDERAÇÕES INICIAIS

O Brasil, um país de dimensão continental, abarca mais de 8 milhões de quilômetros quadrados, conforme a Resolução nº 02, de 29/06/2017 do Diário Oficial da União nº 124 de 30/06/2017 (BRASIL, 2017a). O país concentra, ainda, uma população aproximada de 190 milhões de pessoas, de acordo com o Censo Demográfico de 2010 do Instituto Brasileiro de Geografia e Estatística, com projeções de alcançar 210 milhões em 2019 e seu ápice em 2047, com mais de 233 milhões de pessoas (IBGE, 2010a).

O crescimento da população mundial e dos padrões de expectativa de vida têm expandido de forma significativa, sendo que até 2050, 70% da população mundial irá residir nas áreas urbanas (MOHANTY; CHOPPALI; KOUGIANOS, 2016). No caso brasileiro, cerca de 84% da população habita os centros urbanos desde 2010 (IBGE, 2010a), de acordo com os padrões de classificação vigentes.

Assim, com a contínua expansão das populações urbanas, surgiram necessidades latentes em aspectos relacionados à própria vida urbana, como governança ambiental, segurança pública, planejamento urbano, instalação industrial, utilização de recursos, conservação de energia, controle de tráfego, assistência domiciliar, comunicação interpessoal, atividades sociais e entretenimentos (HE; STOJMENOVIC; GU, 2014). O fracasso em atender qualquer uma dessas necessidades pode ameaçar o desenvolvimento sustentável de uma cidade (HE; STOJMENOVIC; GU, 2014), de modo que a criação de cidades inteligentes (*smart cities*, do inglês), foi uma estratégia natural para mitigar esses problemas provenientes da rápida urbanização e do rápido crescimento populacional urbano (MOHANTY; CHOPPALI; KOUGIANOS, 2016).

Uma definição um tanto simplista e bem coerente afirma que uma cidade inteligente é um lugar onde as redes tradicionais e os serviços são mais flexíveis, eficientes e sustentáveis, a partir do uso da informação, dos recursos digitais e das tecnologias de telecomunicação, com o intuito de melhorar as operações em vista do benefício dos habitantes (MOHANTY; CHOPPALI; KOUGIANOS, 2016). Tal definição se apresenta calcada na informação, nos recursos digitais e na tecnologia, estreitando assim a relação entre o bom funcionamento das cidades e a energia elétrica, necessária ao funcionamento desses recursos.

Neste panorama, sabe-se que a necessidade energética mundial crescerá em 30% para uma população que salta de 7,4 bilhões para mais de 9,0 bilhões de pessoas até 2040 (IEA,

2017) e que fatores geográficos, históricos e socioeconômicos, condicionam a demanda energética em uma localidade. No caso brasileiro, a demanda atual é de 509,10 bilhões de KWh e representa aproximadamente 9,1% da demanda da China, que chega ao patamar de 5,56 trilhões de KWh e é a maior de todas, em escala global (EUA, 2017). O Brasil está em nona posição entre as dez nações que mais consomem energia elétrica (EUA, 2017), um grupo que reúne nações desenvolvidas e em desenvolvimento.

A integração de fontes renováveis intensifica o complexo gerenciamento da rede devido à intermitência e à sua natureza imprevisível (VOYANT et al., 2017). As fontes fotovoltaicas dependem primordialmente da energia solar, que corresponde à conversão da luz solar em formas de energia utilizáveis (IEA, 2019a). As formas mais estabelecidas de conversão são a energia elétrica fotovoltaica, a energia elétrica térmica e/ou o aquecimento por meio de tecnologias solares (IEA, 2019a).

Quando se trata de energias renováveis, vale ressaltar que radiação solar é um termo genérico, cunhado para se referir a toda radiação eletromagnética emitida pelo Sol (EUA, 2013), principalmente a Irradiância Global Horizontal ou Irradiação Global Horizontal, ambas associadas e popularmente conhecidas pela sigla inglesa GHI. A irradiância diz respeito a uma parcela instantânea de radiação recebida de forma direta do Sol por unidade de área (W/m^2) (BRASIL, 2019b). Enquanto a irradiação é a irradiância integrada em um intervalo de tempo, geralmente em hora (Wh/m^2).

As fontes fotovoltaicas não são capazes de gerar eletricidade de forma contínua e confiável o tempo todo, pois dependem do nível de radiação solar, que varia e que pode ser insatisfatório à produção durante partes do dia (ÜÇTUĞ; AZAPAGIC, 2018). Essa natureza traz à tona problemas como flutuação de tensão e instabilidade de potência (VOYANT et al., 2017).

Governos, acordos firmados em âmbito internacional e a própria sociedade pressionam os produtores de energia a caminharem rumo aos moldes mais sustentáveis. A geração fotovoltaica através de sua natureza renovável adequa-se a tais princípios. Por exemplo, um sistema com painéis solares e baterias de lítio para armazenamento poluem entre 1,6 e 82,6 vezes menos do que um sistema de geração termoelétrica (ÜÇTUĞ; AZAPAGIC, 2018). Porém, o gerenciamento de redes com demandas tão ascendentes requer o desenvolvimento de métodos e algoritmos de previsão cada vez mais inteligentes (KANKAL et al., 2011).

A ausência ou ineficiência desses métodos já tem despontado algumas consequências, principalmente no cenário internacional. Na Austrália, até o ano de 2016, mais de 1,6 milhões de residências registraram painéis fotovoltaicos e solicitaram subsídio. A alta penetração de sistemas fotovoltaicos nas redes de baixa de tensão do país causou contrariedades como a sobrecarga térmica de cabos e transformadores. Nestes termos, o governo tem passado por impasses ao criar políticas para limitar uma população que espera livre acesso tanto às redes como também ao subsídio (CURRIE et al., 2019).

Assim, a predição da geração e do consumo é de vital importância para o desenvolvimento dos países, para a edificação de políticas coerentes e para as organizações envolvidas (KANKAL et al., 2011). É essencial para o operador do sistema elétrico estar ciente do balanço preciso entre a produção de energia e o consumo em qualquer momento, sendo muitas vezes complicado manter esse balanço, até mesmo a partir do uso das fontes de energia convencionais e mais controláveis (VOYANT et al., 2017).

A partir do cenário estabelecido, é pertinente entender as novas considerações sobre as matrizes renováveis, com enfoque na consolidação da energia elétrica advinda da matriz fotovoltaica. É pertinente também, considerar a progressiva viabilidade da sua instalação, através da previsão da radiação incidente, utilizando séries históricas. A correlação destes critérios para a cidade de Araras/SP é a proposta deste trabalho.

1.2 OBJETIVOS

1.2.1 Objetivos gerais

O objetivo geral desta pesquisa é prever Irradiância Global Horizontal em curto prazo ($h+1$) no *campus* da Universidade Federal de São Carlos (UFSCar) na cidade de Araras/SP. Será utilizada para previsão a série histórica contendo 13 diferentes dados meteorológicos horários e diários coletados entre janeiro/2015 e novembro/2018 pela estação meteorológica automática (EMA) pertencente ao Grupo de Estudos em Tecnologia de Irrigação (GETI), no próprio *campus*.

1.2.2 Objetivos específicos

Face ao exposto, torna-se necessário:

- Comparar os índices de GHI na localidade de previsão (Araras/SP) com outras localidades que são referência em geração fotovoltaica para identificar a viabilidade da geração;

- Comparar brevemente as principais políticas públicas nas localidades de referência com as brasileiras, identificando os aspectos legais e econômicos que incentivaram a geração fotovoltaica;
- Identificar os principais modelos utilizados para predição de GHI;
- Identificar entre os modelos uma abordagem baseada em inteligência artificial extensamente aplicada pela literatura;
- Identificar as combinações de dados meteorológicos que venham produzindo resultados acurados de acordo com a literatura;
- Propor combinações entre os de dados meteorológicos constantes na base de dados baseadas nas combinações da literatura;
- Avaliar as combinações através de métricas de erro (MAE, RMSE e nRMSE).

1.3 JUSTIFICATIVA

Os diferentes componentes de uma cidade inteligente incluem transporte inteligente, redes de energia inteligentes, assistência médica inteligente e tecnologia inteligente (MOHANTY; CHOPPALI, KOUGIANOS, 2016). Entretanto, as ferramentas ainda são desprovidas de infraestrutura, para que suas tecnologias digitais se traduzam em melhores serviços públicos para os habitantes e em melhor aproveitamento dos recursos, com redução dos impactos ambientais (MOHANTY; CHOPPALI, KOUGIANOS, 2016).

Em 2015, a 21ª Conferência das Partes (*Conference of the Parties*, COP21 – do inglês) da Convenção Quadro das Nações Unidas sobre Mudanças Climáticas (*United Nations Framework Convention on Climate Change* – UNFCCC, do inglês), firmou o Acordo de Paris, que é um marco na luta contra o aquecimento global (UNCC, 2018). Foram 196 países signatários, entre eles o Brasil, que se comprometeram em reduzir as emissões de gases catalisadores do efeito estufa a nível zero, durante a segunda metade do século 21 (UNCC, 2018). É o mais recente acordo, que pressiona os países rumo à adoção de energias renováveis e motiva a pesquisa científica, com intuito de estabelecer meios de gerenciar e integrar esses sistemas de geração intermitentes às redes de energia existentes (ANTONANZAS et al., 2016).

As dimensões continentais do Brasil muitas vezes dificultam a entrega de energia aos consumidores finais, demandando por longas linhas de transmissão e sistemas de distribuição robustos. Em algumas localidades mais isoladas, a energia elétrica sequer chega. O Censo Demográfico de 2010 do IBGE: Domicílios Particulares Permanentes, por Existência de

Energia Elétrica, demonstra que dos 57 milhões de domicílios brasileiros, 98% já são abastecidos por energia da rede (IBGE, 2010b). Porém, 551 mil domicílios dependem de energia de outra fonte e 728 mil ainda não possuem acesso à energia elétrica (IBGE, 2010b).

Numa cidade inteligente, as redes inteligentes (*smart grids*, do inglês) contam com as microrredes (*microgrids*, do inglês), as quais têm suas próprias fontes de geração de energia e, em alguns casos, tecnologias para armazenamento. A geração de energia elétrica fotovoltaica pode ser usada como ótimo exemplo de micro (ou mini) rede. Como já acontece pelo país e também pelo mundo, o próprio usuário pode produzir a energia que irá consumir independente à rede, só que desta vez, de forma renovável. Cabe informar que a resolução nº 687/2015 da ANEEL (Agência Nacional de Energia Elétrica) define microgeração como as unidades geradoras em que a potência instalada é menor ou igual a 75 kW, enquanto a minigeração, em termos de energia renovável, refere-se as unidades com potência instalada entre 75 kW e 5 MW (BRASIL, 2015a).

No Brasil, pequenas usinas fotovoltaicas têm se espalhado para abastecer comunidades isoladas, nas quais a população não tem acesso à linha de transmissão. Alguns casos de êxito, nestes termos, podem ser referenciados. São Sebastião do Rio Preto, no município de Autazes; Terra Nova no município de Barcelos; Nossa Senhora do Carmo no município de São José; Santa Luzia e Santa Maria no município de Maués e Aracari, Bom Jesus do Puduari e Sobrado no município de Airão são exemplos no estado do Amazonas. Nesses locais, 12 pequenas usinas abastecem as populações em um sistema que conta com captação da energia e banco de baterias com autonomia de até dois dias (AMAZONAS ENERGIA, 2018).

No estado do Pará, o município de Porto do Moz, localizado em meio à Floresta Amazônica, provê desde 2017, o acesso à energia elétrica de cerca de 2.300 famílias ribeirinhas utilizando 2.334 painéis fotovoltaicos que abastecem as residências, escolas públicas e postos de saúde. Antes, os moradores não tinham acesso à energia ou se utilizavam de pequenos geradores a diesel (ÓRIGO ENERGIA, 2017).

Na grande São Paulo, desde 2017, os Parques Villa-Lobos e Cândido Portinari, localizados na zona oeste da capital paulista são totalmente abastecidos por energia fotovoltaica. A iluminação externa é feita por postes que geram a própria luz enquanto a demanda interna é abastecida por mais de 3 mil placas sobre 264 vagas para veículos. Neste sistema, os parques injetam o excedente na rede de baixa tensão durante o dia e usam energia da rede durante a noite, período em que não produzem (BRASIL, 2017c).

Além da produção de energia em moldes renováveis através das microrredes, a produção em larga escala também é possível. O ciclo de contratações de energia fotovoltaica em Leilões de Energia de Reserva começou em 2014, com 94 empreendimentos contratados até 2016 (BRASIL, 2016). Em agosto de 2019, a representatividade da geração fotovoltaica na matriz brasileira era de apenas 1,31% (BRASIL, 2019a), mas segundo projeções da Empresa de Pesquisa Energética (EPE), até 2050, 13% de todo o abastecimento das residências no Brasil deverá ser feito a partir de painéis fotovoltaicos (BRASIL, 2015b).

Muito se discute sobre o preço de implantação da alternativa fotovoltaica no Brasil. O Plano Decenal de Expansão de Energia (PDE) 2026 calcula que o custo atual de investimento (CAPEX) para a opção fotovoltaica centralizada no país gira em torno de US\$1.300/kW, valor inferior ao praticado pelos Estados Unidos (1.490 US\$/kW), que é o segundo maior produtor mundial (BRASIL, 2016). O PDE 2026 estima ainda que, no período 2017-2026, os custos de implantação de sistemas de geração fotovoltaicos reduzam entre 30% e 40%, e na melhor perspectiva, a partir de 2023, o valor para implantação atinja o patamar de US\$ 800/kW, valor altamente competitivo com as demais fontes adotadas no país (BRASIL, 2016).

A dependência atrelada a uma ou poucas fontes, como é o caso atual do Brasil, sujeita a cadeia produtiva, serviços de transporte, saúde e segurança a alguns pré-requisitos, como um ciclo regulado de chuvas que enchem as barragens e reservatórios e um fornecimento contínuo e a preços acessíveis dos combustíveis necessários à produção térmica de energia (IEA, 2018). Contudo, em alguns cenários, o país enfrentará complicações energéticas relativas ao esgotamento da geração hidrelétrica até 2045 (BRASIL, 2015b). A diversificação da matriz se mostra cada vez mais urgente, alinhando ainda mais as fontes renováveis às recentes necessidades relativas à produção e consumo de energia nos moldes adequados ao panorama mundial.

Nesse contexto, as aplicações crescentes de energia fotovoltaica nos sistemas elétricos, postulam benefícios econômicos, mas também tratam da instabilidade de fornecimento em cenários nos quais as previsões são imprecisas (ANTONANZAS et al., 2016). Uma previsão precisa é benéfica não apenas para os operadores do sistema e para os consumidores, já que ela reduz os custos e incertezas, mas também para os gerenciadores que podem evitar contrariedades decorrentes do desvio entre previsão e consumo (ANTONANZAS et al., 2016). Assim, a variabilidade do recurso solar e a incerteza associada às previsões, estão por

trás dos problemas, que precisam ser lidados em função da manutenção da estabilidade das redes (ANTONANZAS et al., 2016).

Substituir uma fonte que está abastecendo a rede por outra, demanda certa antecedência/planejamento. Uma planta de geração hidroelétrica leva aproximadamente 5 minutos para ser inicializada, enquanto, uma planta nuclear levar cerca de 40 horas (VOYANT et al., 2017). Deste modo, em termos de predição, os fornecedores de energia elétrica estão interessados em diversos horizontes, com o intuito de promover a economia de combustíveis fósseis, gerenciar as centrais de distribuição já instaladas e aumentar o nível de integração dos sistemas de energia renovável às redes elétricas (PAOLI et al., 2010).

Além disso, ainda se faz necessária à previsão da potência dos sistemas fotovoltaicos para a efetiva operação da rede, estimar as reservas, preparar e agendar a inicialização dos outros sistemas geradores, gerenciar os congestionamentos produtivos, gerir o armazenamento a partir da produção estocástica e comercializar energia no mercado (VOYANT et al., 2017).

Tal cenário tem incentivado o desenvolvimento de muitos estudos com a intenção de apurar a eficácia das previsões (ANTONANZAS et al., 2016) de modo que muitos pesquisadores têm demonstrado a habilidade das RNAs na predição de séries temporais com dados meteorológicos (PAOLI et al., 2010).

1.4 ORGANIZAÇÃO

Este trabalho está organizado na forma de capítulos. O capítulo 1 corresponde aos aspectos introdutórios da pesquisa. O capítulo 2 apresenta a revisão da literatura e abrange métodos de previsão baseados em RNA no contexto de *Smart Grids*. O capítulo 3 trata dos conceitos associados à radiação solar. O capítulo 4 aborda as principais definições acerca da irradiância solar global e compara os índices de Araras/SP com os índices de outras localidades de referência. O capítulo 5 busca compreender os principais métodos de análise e de previsão usados em séries temporais. O capítulo 6 descreve a metodologia proposta. O capítulo 7 apresenta os resultados e discussões. O capítulo 8 fornece as conclusões referentes à execução da pesquisa. Em seguida, dispõem-se as referências bibliográficas e os apêndices do trabalho.

2 REVISÃO DA LITERATURA

As seções que seguem, intentam primariamente expor em um panorama geral, a relação entre as RNAs e as *smart grids*. Em sequência, as aplicações das RNAs na previsão de radiação incidente para geração fotovoltaica. Por fim, estabelecido o estado da arte, comparar os modelos preditivos de maior sucesso em termos de curto prazo através das principais métricas de avaliação de erros no tema abordado.

2.1 ANÁLISE BIBLIOMÉTRICA

É um método de desenvolvimento quantitativo que possibilita a análise da evolução histórica de determinada área da ciência (MARX et al., 2016). Tem sido aplicada principalmente para estruturar e avaliar resultados recuperados em uma pesquisa que muitas vezes podem referir-se a termos, autores, periódicos, países e institutos (ABRAMO, 2011).

Neste trabalho, foram recuperadas informações referentes há onze anos (2008 – 2018) na base indexada Scopus. O termo pesquisado foi “*solar radiation forecast**” ou “previsão de radiação solar”, em português, conforme a Figura 1. O caractere asterisco (*) foi usado com a intenção de englobar duas terminologias mais comuns e que são relativas ao tempo verbal: *forecast* e *forecasting*. A busca retornou 2.751 resultados.

Efetuada a pesquisa, um arquivo .CSV foi obtido da base. Nele constam 5 blocos de dados, a saber: informações referentes a citação, informações bibliográficas, informações referentes a resumos e palavras chave, informações relativas a financiamento e um bloco de informações gerais. O arquivo .CSV foi anexado no *software* de análise bibliométrica VOSviewer versão 1.6.11.

Figura 1 – Recorte da página de pesquisa na base Scopus.

TITLE-ABS-KEY (solar AND radiation AND forecast*) AND (LIMIT-TO (PUBYEAR, 2018) OR LIMIT-TO (PUBYEAR, 2017) OR LIMIT-TO (PUBYEAR, 2016) OR LIMIT-TO (PUBYEAR, 2015) OR LIMIT-TO (PUBYEAR, 2014) OR LIMIT-TO (PUBYEAR, 2013) OR LIMIT-TO (PUBYEAR, 2012) OR LIMIT-TO (PUBYEAR, 2011) OR LIMIT-TO (PUBYEAR, 2010) OR LIMIT-TO (PUBYEAR, 2009) OR LIMIT-TO (PUBYEAR, 2008))

2,751 document results

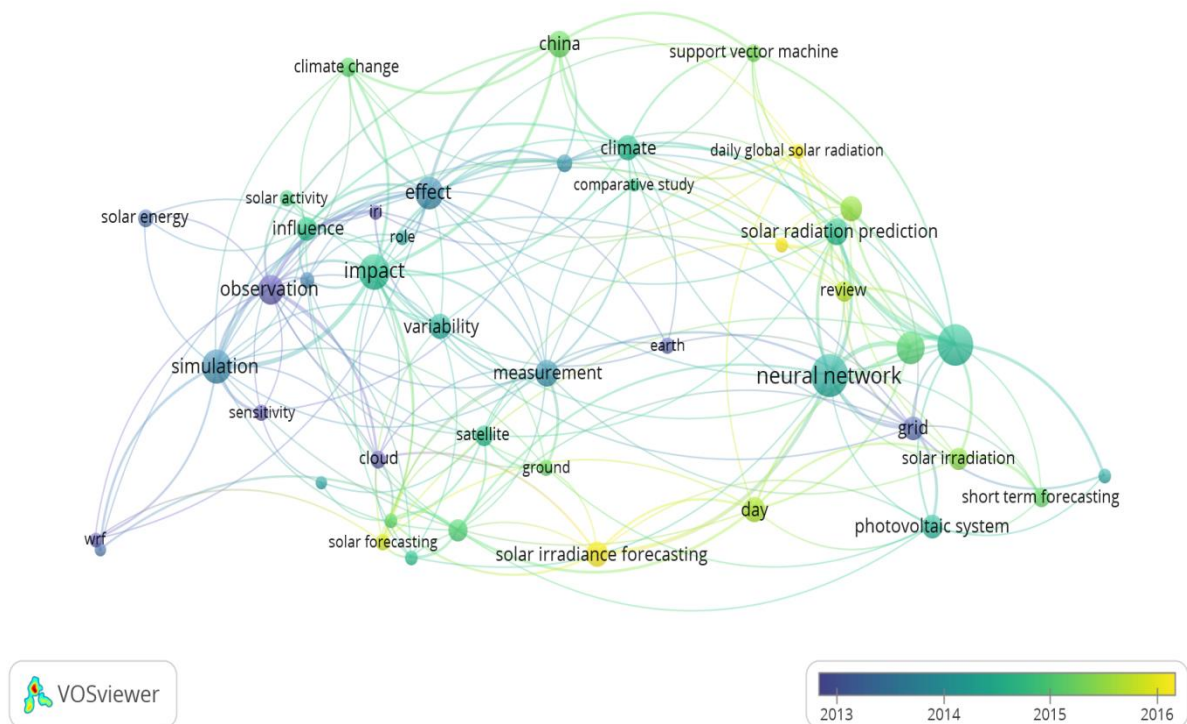
[View Less ^](#)

Fonte: Scopus (2019).

A análise dos títulos forneceu os resultados mais esclarecedores. Nela, o programa computacional levou em consideração termos que ocorreram apenas nos títulos dos artigos. Deste critério, foram recuperados 5.894 termos, dos quais apenas 74 ocorreram pelos menos 10 vezes. Desses 74, os 45 que foram ponderados com os maiores pesos são relatados na Figura 2. Nela é possível ver a correlação entre os termos.

Os termos correlatos foram classificados pelo *software* em 6 grupos, também chamados de *clusters* (do inglês). Os grupos apresentam alguns termos que estão no cerne desta pesquisa, entre eles: *artificial neural network*, *global solar radiation*, *prediction*, *satellite data*, *short term forecasting*, *solar irradiance*, *solar radiation* e *weather forecast*.

Figura 2 – Análise dos termos encontrados nos títulos.

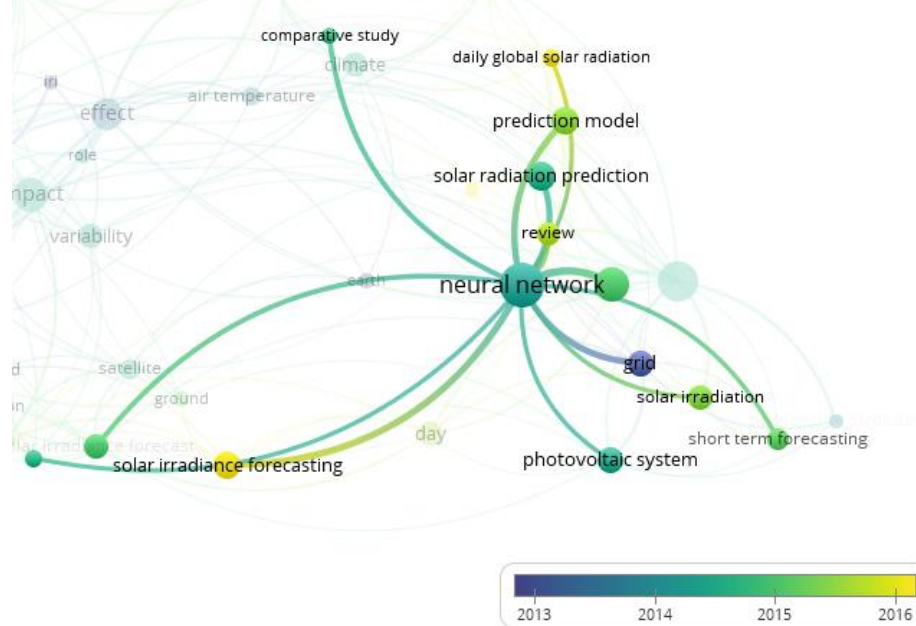


Fonte: Adaptado de VOSviewer (2019).

Interessante notar que o termo *neural network* é o método de previsão que está mais próximo dos termos centrais como *solar radiation prediction*, *solar irradiance*, *short term forecasting* e *photovoltaic system*. Pode-se notar também, que “*solar irradiance forecasting*” é um termo associado à cor amarela, que na escala cronológica, está associada aos termos mais recentes, principalmente a partir de 2016. Isso indica que o conhecimento sobre previsão de irradiância global horizontal não é consolidado e que a ciência ainda está investigando esse tema.

A análise bibliométrica possibilitou notar que nos títulos dos trabalhos publicados, a palavra “*prediction*” é até mais recorrente que a palavra “*forecasting*”. A China está tão associada a esta área de pesquisa que surgiu como termo da área. Uma visão mais detalhada dos termos associados a *neural network* pode ser encontrada na Figura 3.

Figura 3 – Análise temporal das associações ao termo “*neural network*”.

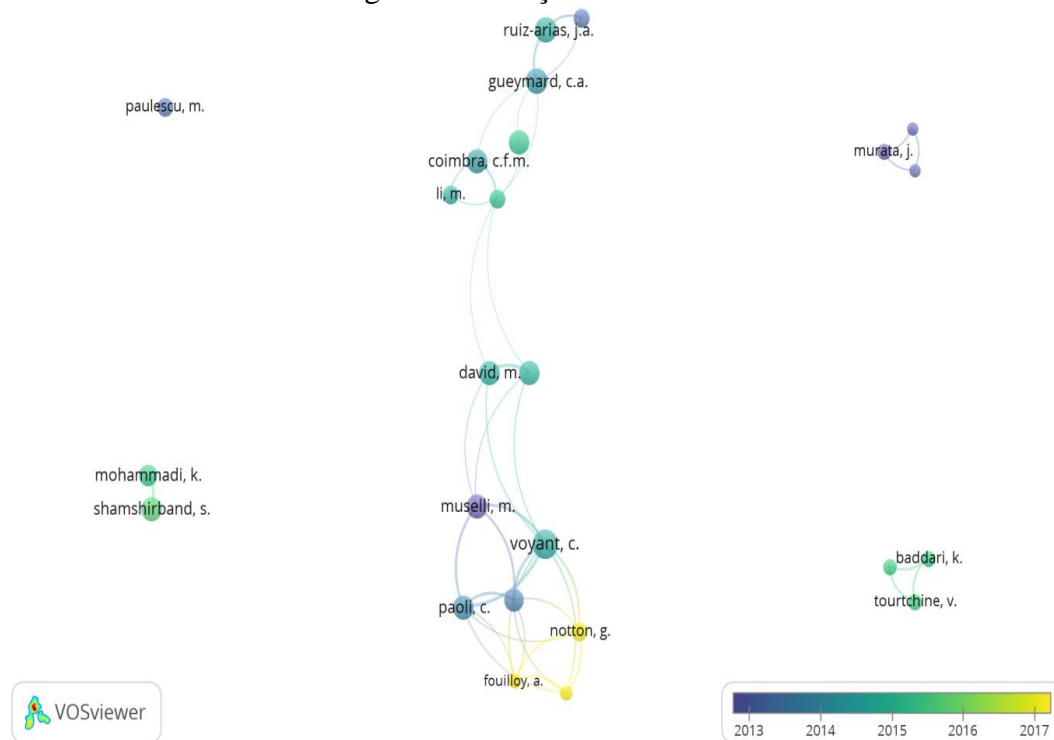


Fonte: Adaptado de VOSviewer (2019).

Verifica-se na Figura 3 que o termo em foco tem sido aplicado de forma muito contemporânea (entre 2013 e 2016) demonstrando que as redes neurais são uma alternativa recente e de uso crescente.

Os autores que mais publicam na área foram identificados pela análise para que pudessem ser recuperados na revisão bibliográfica deste trabalho. Esta correlação demonstra a importância de cada um e de suas publicações. Dos 6.528 autores encontrados, a análise do *software* levou em consideração aqueles que publicaram pelo menos 5 vezes no espaço temporal entre 2008 e 2018, obtendo assim um subgrupo com 161 autores. Desses, os 25 autores ponderados com os maiores pesos podem ser encontrados na Figura 4. Durante os levantamentos deste trabalho, os autores Coimbra, C.F.M.; David, M.; Voyant, C.; Paoli, C. e Notton, G.; foram encontrados e constam nas referências. Interessante notar que na área central da Figura 4 encontram-se os autores cujos temas interagem, de forma que suas pesquisas apresentam certa intertextualidade. Essa conclusão conduziu os levantamentos da revisão de literatura deste trabalho, uma vez que se buscou explorar o tema de uma perspectiva mais usual à literatura.

Figura 4 – Relação de autores.




Fonte: Adaptado de VOSviewer (2019).

Os países atrelados às publicações podem ser constatados na Figura 5. É interessante notar que Estados Unidos, Alemanha e China não possuem publicações muito recentes e as publicações existentes estão associadas ao intervalo 2010 - 2014.

Até 2014, a Alemanha era líder mundial em capacidade instalada de painéis, até que foi superada pela China em 2015 (Brasil, 2017b) e pelo Japão em 2016 (IEA, 2016). Essa transição no *ranking* pode justificar o número de publicações atreladas a esse período. Até 2018, último ano fechado, a China mantém a liderança (176 GW), seguida por EUA (62 GW), Japão (56 GW) e Alemanha (45 GW) (IEA, 2019b). Vale ressaltar que, até 2018, a Alemanha ainda conserva a primeira posição entre os países com maior distribuição de energia fotovoltaica *per capita* (548 Watt/capita), seguida da Austrália (459 Watt/capita) e Japão (442 Watt/capita) (IEA, 2019b).

Figura 5 – Relação de países.



Fonte: Adaptado de VOSviewer (2019).

2.2 MÉTODOS PARA PREVISÃO DE GHI

Em termos de energia renovável, considerando-se a matriz fotovoltaica, é essencial prever a flutuação da irradiância global horizontal incidente, independente se tal flutuação representa decréscimo ou acréscimo na incidência (DIAGNE et al., 2013; VOYANT et al., 2013; ANTONANZAS et al., 2016; VOYANT et al., 2017). As condições estacionárias da irradiância, às quais os painéis fotovoltaicos estão submetidos, fazem parte das questões que precisam ser lidadas para garantir a estabilidade das redes (ANTONANZAS et al., 2016).

Alguns fatores como temperatura ambiente, temperatura de operação, tecnologia e material de fabricação interferem na eficiência de painéis fotovoltaicos. As condições de teste padrão para um painel são definidas como temperatura operacional de 25 °C e radiação solar incidente de 1.000 W/m². Porém, os sistemas raramente funcionam sob condições de teste padrão e normalmente as condições de operação são menos favoráveis (HEIM, 2011).

Consequentemente, sabe-se que a técnica de previsão adotada, dentro do contexto de uma rede de distribuição, depende da fonte de energia convencional e o tempo necessário à inicialização desse sistema (VOYANT et al., 2013). Assim, muitos métodos foram desenvolvidos com esse objetivo e podem ser divididos em grupos, de acordo com os dados disponíveis para a região e o horizonte da previsão. Voyant et al. (2013) dividem em dois grupos: (i) métodos que usam o formalismo matemático de séries temporais; e (ii) modelos de Previsão Numérica do Tempo (*Numerical Weather Prediction – NWP*, do inglês) e imagens meteorológicas de satélite. Por outro lado, Diagne et al. (2013) apresenta uma divisão mais abrangente, em quatro grupos: (i) modelos estatísticos; (ii) modelos baseados em satélites e imagens do céu; (iii) modelos NWP; e (iv) modelos híbridos. Assim, devido à maior abrangência, a divisão de Diagne et al. (2013) é explorada a seguir:

- (i) Modelos estatísticos, baseados em medidas de irradiância *on-line* e aplicados para uma escala de tempo muito curta (a partir de 5 minutos). São exemplos, modelos Autoregressivos (*Autoregressive – AR*, do inglês) como em Bacher, Madsen e Nielsen (2009) e Autoregressivos com Média Móvel (*Autoregressive Moving Average – ARMA*, do inglês), como em Wang et al. (2015) e David et al. (2016). Além disso, Redes Neurais Artificiais (RNA) (*Artificial Neural Network – ANN*, do inglês) podem ser aplicadas para derivar previsões como em Voyant et al. (2013). A metodologia proposta neste trabalho é um modelo estatístico, que utiliza RNA como ferramenta;
- (ii) Modelos baseados em satélites e imagens do céu são aplicados para previsão de curto prazo. Informações sobre desenvolvimento temporal das nuvens, que determinam a radiação solar na superfície, podem ser usadas como base. Previsões baseadas em vetores de movimento de nuvens a partir de imagens de satélite mostram bom desempenho para o intervalo temporal de 30 minutos até 6 horas. Para o intervalo de sub-hora, as informações das nuvens, a partir de imagens do céu, podem ser usadas para derivar previsões de irradiância com maior resolução espacial e temporal em comparação com as previsões baseadas em satélite. Miller et al. (2018) e Ayt e Tandeo (2018), apresentam trabalhos relevantes nesses termos;
- (iii) Os modelos NWP são comumente aplicados para horizontes de previsão mais longos, de cerca de 4 a 6 horas em diante. Esses modelos normalmente

superam aqueles baseados em imagens de satélite. São encontrados, por exemplo, em Voyant et al. (2012) e Tiwari, Sabzehgar e Rasouli (2018);

- (iv) Existem também abordagens que são combinadas a fim de integrar distintos tipos de dados, os quais são utilizados como entrada, visando obter uma previsão otimizada, a depender do horizonte de previsão. Duas abordagens podem ser seguidas, seja pela combinação de duas ou mais técnicas estatísticas (híbrido – estatísticas) ou pela junção de uma técnica estatística a um modelo de desempenho de painéis (físico – híbrido) (ANTONANZAS et al., 2016). Pode-se citar Bouzerdoum, Mellit e Pavan (2013), que desenvolveram uma abordagem híbrida combinando o método da Média Móvel Integrada Autoregressiva Sazonal (*Seasonal Auto-Regressive Integrated Moving Average Method – SARIMA*, do inglês) e o método de Máquinas de Vetores de Suporte (*Support Vector Machines Method – SVM*, do inglês). Ramsami e Oree (2015) que aplicaram uma metodologia baseada em uma combinação de Média Móvel Integrada Auto Regressiva (*Auto-Regressive Integrated Moving Average Method – ARIMA*, do inglês) com RNA, para previsão de irradiância num período 24 horas à frente. Por fim, Vaz et al. (2016) desenvolveram uma metodologia combinando uma RNA não linear Auto Regressiva com Entradas Exógenas (*Nonlinear Autoregressive Neural Network – NARX*, do inglês).

Ressalta-se que, normalmente, a variável prevista é a irradiância ou irradiação global horizontal, embora alguns autores optem por prever o Índice de Clareza (*clearness index – k_t* , do inglês) e depois o convertem em potência (ANTONANZAS et al., 2016). De fato, quando se busca prever GHI, ARMA é o modelo mais clássico e convencional para a modelagem de séries temporais e as RNAs são uma alternativa plausível a essas abordagens (VOYANT et al., 2013).

Como o clima da Terra é dominado por processos não lineares, a RNA é eficaz para prever dias nublados, que afetam severamente os índices de GHI (VOYANT et al., 2013). Redes neurais foram estudadas em muitos locais e os pesquisadores demonstraram a capacidade dessas técnicas de prever, com precisão, as séries temporais descritas por dados meteorológicos (DIAGNE et al., 2013; VOYANT et al., 2013).

2.3 MÉTODOS BASEADOS EM INTELIGÊNCIA ARTIFICIAL PARA PREVISÃO DE SÉRIES TEMPORAIS EM *SMART GRIDS*

Como uma cidade inteligente é um lugar onde as redes e serviços tradicionais são mais flexíveis, eficientes e sustentáveis com o uso de tecnologias de informação, de recursos digitais e de telecomunicações, com o intuito de melhorar as operações em benefício de seus habitantes (MOHANTY; CHOPPALI; KOUGIANOS, 2016) e também do planeta, o emprego da Inteligência Artificial (IA) acontece nas mais diversas interfaces.

Um exemplo de aplicação de IA, em *smart grids*, é a utilização de RNAs com o intuito de gerar as mais diversas previsões, entre elas, a previsão de radiação e índice de céu claro, para geração fotovoltaica; de velocidade e direção dos ventos, para geração eólica; de potência gerada e consumo, para os operadores das redes; entre outras tantas que se fazem necessárias à administração, planejamento e operação dessas redes.

As RNAs foram estudadas em muitas partes do mundo e os investigadores têm demonstrado nas mais diversas localidades, a capacidade que estas técnicas possuem de prever com precisão as séries temporais de dados meteorológicos (DIAGNE et al. 2013; VOYANT et al., 2017). De fato, a arquitetura *Multilayer Perceptron* – MLP, do inglês (ou Perceptron Multicamadas, em português), é usada regularmente devido à sua propriedade de aproximação universal, capaz de realizar regressões não lineares (VOYANT et al., 2017).

Sua aplicabilidade se iniciou em 1999 com o estudo de Kemmoku et al. (1999). Os autores tentavam reduzir o erro médio das previsões da época, que era de cerca de 30%. Para isso, desenvolveram uma RNA em três estágios. Primeiramente, formaram dois bancos de dados chamados de Dados Meteorológicos I (DM I) e Dados Meteorológicos II (DM II), com dados do dia anterior. Nesses bancos constavam coletas de pressão atmosférica, temperatura e índice de clareza, em diferentes horários. Assim, o primeiro estágio da rede, utilizava os dados meteorológicos do DM I como sinais de entrada para prever a pressão atmosférica média no dia seguinte ($d+1$). O segundo estágio, utilizava como entrada a pressão atmosférica média prevista e os mesmos dados do banco DM I, agora com o objetivo de determinar o nível de GHI (baixo, médio ou alto) no dia ($d+1$). Por fim, o terceiro estágio associava o nível de GHI previsto aos dados do banco DM II e estipulava um resultado para a previsão. O estudo aconteceu em 1994 e os autores utilizaram dados meteorológicos de Omaezaki, no Japão, coletados entre os anos de 1988 e 1993. O objetivo foi atingido, sendo que os erros sofreram um decréscimo de 10% (de 30% para 20%).

A aplicabilidade das RNAs na previsão de séries temporais, com enfoque nas que dizem respeito à GHI e temas equivalentes, tem se mostrado válida e seu uso tem sido extenso. Um levantamento dos últimos 5 anos, apresentado na Tabela 1, ratifica tal afirmação e identifica as principais metodologias, os avanços técnicos e as potencialidades ao longo dos anos.

Para composição da referida tabela, o termo de busca “*solar radiation forecast**” foi pesquisado na base de indexação Scopus, utilizando o filtro “*Year*”. O intuito era recuperar artigos que propusessem metodologias de previsão de radiação solar atrelados aos anos de 2014 a 2018. Efetuada a pesquisa, a ferramenta “*Sort on*” foi aplicada para ordenar os artigos. A intenção era obter os artigos “*Cited by (highest)*”, ou seja, os mais citados. Foram obtidos da base os 4 artigos mais citados de cada ano, perfazendo um total de 25 artigos para os 5 anos. Durante a análise do texto, alguns artigos foram descartados, pois abordavam previsão de radiação solar não de forma experimental, mas como revisão da literatura. Ao final, a tabela acabou composta por 17 artigos: 2 de 2014; 4 de 2015; 4 de 2016; 2 de 2017; 2 de 2018 e 3 de 2019.

Vale lembrar que a análise bibliométrica havia antecipado este cenário. Na seção 2.1, Figura 2, o termo “*review*” aparece atrelado ao termo “*solar radiation prediction*” e, na Figura 3, o termo “*review*” está atrelado aos termos “*solar radiation prediction*”, “*prediction model*” e “*daily solar global radiation*”.

Tabela 1 – Revisão da Literatura entre 2014 e 2019.

(continua)

Autor	Previsão	Abordagem	Local	Horizonte	Variáveis de Entrada	Erro
Voyant et al. (2014)	Irradiância Global Horizontal.	2 arquiteturas de RNA MLP com treinamento Levenberg-Marquardt. Além de abordagens por persistência e ARMA para comparação.	Ajjacio, França	$h+24$	Pressão atmosférica, nebulosidade e precipitação.	$nRMSE = 22,4\%$ (apresentado pela MLP na estação de verão – menor erro alcançado)
Lauret, Diagne e David (2014)	Irradiância Global Horizontal.	Resultados de previsão NWP são pós-processados por uma RNA MLP, treinada para estabelecer uma função de correção por regressão linear (MOS).	Saint Pierre, França	$h+24$	Ângulo de zênite e índice de céu claro.	$RMSE = 155,10 \text{ W/m}^2$ $nRMSE = 28,76\%$ $MAE = 115,74 \text{ W/m}^2$
Cornaro, Pierro e Bucci (2015)	Irradiância Global Horizontal.	RNA MLP de camada única. Foi realizado um teste com dados de entrada selecionados por processamento estatístico e um com dados selecionados por regressão linear (MOS).	Roma, Itália	$h+24$	Temperatura do ar e irradiância global horizontal medidas de minuto em minuto.	$24\% \leq nRMSE \leq 29\%$ (MOS) ST apresentou resultados grosseiros e foi descartado pelos autores como método
Liu et al. (2015)	Potência Fotovoltaica.	RNA MLP utilizando algoritmo de treinamento por retropropagação (<i>backpropagation</i> , do inglês).	Gansu, China	$h+24$	Índice de aerossóis, temperatura, umidade e velocidade do vento.	$MAPE = 7,65\%$ (médio da previsão)

(continuação)

Autor	Previsão	Abordagem	Local	Horizonte	Variáveis de Entrada	Erro
Aguiar et al. (2015)	Irradiância Global Horizontal.	RNA MLP treinada pelo método do gradiente conjugado escalonado.	Pozo Izquierdo e Las Palmas, Espanha	$h+1$ e $h+6$	Irradiância global horizontal, umidade relativa e temperatura.	Pozo Izquierdo: $15,3(h+1) \leq rRMSE(\%) \leq 22,6(h+6)$; Las Palmas: $24,3(h+1) \leq nRMSE(\%) \leq 36,2(h+6)$
Ahmad, Anderson e Lie (2015)	Irradiância Global Horizontal.	RNAs não lineares auto regressivas com entradas exógenas (NARX) e RNA MLP com treinamento <i>backpropagation</i> .	10 cidades da Nova Zelândia	$h+24$	Temperatura, umidade, índices pluviométricos, ângulo de zênite, azimute, pressão atmosférica, velocidade e direção do vento.	$nRMSE = 9,68\%$ (MLP) $nRMSE = 4,95$ (NARX)
Shaddel, Javan e Baghernia (2016)	Irradiância Global Horizontal.	RNA MLP com treinamento <i>backpropagation</i> .	Mashhad, Irã	$h+50$	Ângulo de declinação solar, ângulo de altitude solar, irradiância global horizontal em planos inclinados de 45° e 60° e irradiância global extraterrestre.	$RMSE = 0,055 \text{ MJ/m}^2$ (60°) e $0,0549 \text{ MJ/m}^2$ (45°) $MAE = 0,0284 \text{ MJ/m}^2$ (60°) e $0,0269 \text{ MJ/m}^2$ (45°)
Lima et al. (2016)	Irradiância Global Horizontal.	Modelo NWP combinado com um método de pós-processamento RNA MLP treinada por <i>backpropagation</i> .	Região Nordeste, Brasil	$h+24$	Índice de céu claro e irradiância solar.	$nRMSE = 30,25\%$ (RNA) $nRMSE = 36,27\%$ (NWP)

(continuação)

Autor	Previsão	Abordagem	Local	Horizonte	Variáveis de Entrada	Erro
Jawaid e Nazirjunejo (2016)	Irradiação Média Diária.	RNA MLP treinada por <i>backpropagation</i> foi confrontada com previsões feitas por algoritmos padrão de regressão: k-NN, Regressão Linear e SVM.	Los Angeles, EUA	24h	Temperatura do ar, velocidade do vento, ponto de orvalho, visibilidade, azimute solar e ângulo de zênite.	RMSE = 11,7 Wh/m ² (k-NN); RMSE = 6,5 Wh/m ² (Regressão Linear); RMSE = 12 Wh/m ² (SVM) e RMSE = 1,0 Wh/m ² (RNA)
Aguiar et al. (2016)	Irradiância Global Horizontal.	RNA MLP com treinamento pelo método do gradiente conjugado escalonado.	Pozo Izquierdo e Las Palmas, Espanha	$h+1$ e $h+6$	Irradiância global horizontal, irradiância solar superficial e cobertura total de nuvens extraídas de imagens de satélite.	Pozo Izquierdo: $15,47(h+1) \leq nRMSE(\%) \leq 22,17(h+6)$; Las Palmas: $24,15(h+1) \leq nRMSE(\%) \leq 36,09(h+6)$
Chen e Kartini (2017)	Irradiância Global Horizontal.	Um algoritmo k-NN combinado com uma RNA MLP com treinamento <i>backpropagation</i> para prever radiação solar global em curto prazo.	Taiwan, China	$h+1$	Irradiância global horizontal, temperatura, umidade, velocidade do vento e direção do vento.	RMSE = 242 W/m ² MABE = 42 W/m ²
Romero, Quilumba e Arcos (2017)	Potência fotovoltaica.	RNA MLP com treinamento <i>backpropagation</i> .	Localidade da planta não informada	$h+24$ e $h+48$	Potência, radiação média do dia seguinte e velocidade máxima do vento.	nRMSE = 7,7788% ($h+24$) nRMSE = 7,8618% ($h+48$)

(continuação)

Autor	Previsão	Abordagem	Local	Horizonte	Variáveis de Entrada	Erro
Vanderstar, Musilek e Nassif (2018)	Irradiância Global Horizontal.	RNA MLP com treinamento pelo método do gradiente conjugado escalonado utilizando um algoritmo genético para otimizar os dados de entrada na rede.	Alberta, Canadá	$h+2$	Irradiância global horizontal aferida em intervalos de 30 minutos.	nRMSE = 10,8% MAPE = 7,03%
Crisosto et al. (2018)	Irradiação Global Horizontal.	RNA MLP com treinamento por Levenberg-Marquardt	Hannover, Alemanha	$h+1$	Imagens do céu (para avaliar a cobertura por nuvens) e dados de irradiação global.	$5 \leq \text{MAE}$ (Wh/m ²) ≤ 116 $4 \leq \text{RMSE}$ (Wh/m ²) ≤ 149
Notton et al. (2019)	Irradiação Global Horizontal.	RNA MLP com treinamento por Levenberg-Marquardt	Odeillo, França	$h+1$ e $h+6$	Dados aferidos: Irradiação global horizontal e no plano inclinado (36,8°), temperatura, umidade relativa, velocidade e direção do vento, precipitação, pressão atmosférica, duração do período de sol. Dados calculados: Irradiação horizontal extraterrestre, declinação solar e ângulo de zênite.	RMSE = 101,79 Wh/m ² ($h+1$) e 157,27 Wh/m ² ($h+6$); nRMSE = 22,57% ($h+1$) e 34,85% ($h+6$)

(conclusão)

Autor	Previsão	Abordagem	Local	Horizonte	Variáveis de Entrada	Erro
Benali et al. (2019)	Irradiância Global, Normal e Difusa.	<i>Random Forest</i> e RNA MLP com treinamento <i>backpropagation</i>	Odeillo, França	$h+1, h+2, h+3, h+4, h+5$ e $h+6$	Irradiância global, normal e difusa.	nRMSE para RNA $h+1=22,57\%$; $h+2=28,08\%$; $h+3=31,47\%$; $h+4=33,31\%$; $h+5= 34,31\%$ e $h+6=34,85\%$.
Mghouchi et al. (2019)	Irradiância Global Diária.	511 combinações de entrada em uma RNA MLP com treinamento <i>backpropagation</i>	27 cidades no Marrocos, 2 cidades na Algéria, 2 cidades na Espanha e 2 cidades na Mauritânia	24h	Coordenadas geográficas, declinação do sol, irradiância no topo da atmosfera, duração do dia, índice de clareza, temperatura ambiente mínima, média e máxima, temperatura da diferença, razão de temperatura, umidade relativa e velocidade do vento.	$0,055 \leq nRMSE(\%) \leq 0,091$

Fonte: Elaborado pelo autor (2019).

3 RADIAÇÃO SOLAR E COMPONENTES ASSOCIADAS

A fonte de energia mais primária da Terra é a energia que irradia do Sol, sendo que diferentes comprimentos de luz atingem diferentes partes da atmosfera terrestre (NASA, 2018). Assim, o termo radiação solar é uma maneira geral de se referir a toda radiação eletromagnética emitida pelo Sol (EUA, 2013). A radiação solar pode ser capturada e transformada em outras formas de energia, como calor e eletricidade, porém a viabilidade operacional, técnica e econômica das tecnologias, dependem da quantidade de radiação solar incidente em um local específico (EUA, 2013).

Quando a energia deixa o Sol, o faz na forma de fótons, partículas energéticas e campos magnéticos e cada uma tem um impacto mensurável na Terra ou nas suas dependências espaciais (NASA, 2018). Assim, a radiação solar que incide na atmosfera a todo instante, chamada de Irradiância Extraterrestre (ou *extraterrestrial irradiance* – I_0 , do inglês) tem seu valor estimado em $1,36 \text{ KW/m}^2$ (KOPP, 2011). Deste modo, o cálculo da radiação solar incidente num ambiente sem atmosfera, dependeria apenas da latitude, do dia, da hora e de algum conhecimento em trigonometria (MAGARREIRO; FREITAS; BRITO, 2016). Sabe-se, porém, que os prótons se movem numa trajetória linear entre Sol e a Terra, enquanto os outros tipos de energia seguem caminhos dispersos através da atmosfera do Sol, a heliosfera, e a magnetosfera terrestre, até finalmente atingir a atmosfera da Terra (NASA, 2018).

Assim, este capítulo se propõe explicar, para melhor compreensão, a Irradiância Global Horizontal e os processos naturais estritamente ligados a GHI, que para esclarecimento prévio, serão abordados nas próximas seções. Cabe indicar que as medições de irradiância podem ser tomadas em relação ao tempo, em diferentes unidades, contudo não foi identificado um consenso absoluto, o que pode ser notado através das diferentes unidades que são encontradas em algumas análises no decorrer da pesquisa.

3.1 IRRADIÂNCIA GLOBAL HORIZONTAL

Toda a energia solar que chega ao solo é chamada de Irradiância Global Horizontal (*Global Horizontal Irradiance* – GHI, termo amplamente difundido pela língua inglesa) (BRASIL, 2019b). A GHI é descrita pela soma de duas componentes de I_0 : a Irradiância Normal Direta (DNI) e a Irradiância Horizontal Difusa (DHI) (INMAN; PEDRO; COIMBRA, 2013). Magarreiro, Freitas e Brito (2016) acrescentam também a chamada Irradiância Refletida junto às componentes Direta e Difusa.

De forma sintética, a DNI corresponde aos feixes que atingem de forma perpendicular uma superfície no nível do solo, enquanto a DHI diz respeito à radiação dispersa na atmosfera, mas que ainda chega a alcançar esta superfície (INMAN; PEDRO; COIMBRA, 2013). Sua combinação é dada pela Equação (1), sendo θ o ângulo de zênite, o qual corresponde ao ângulo que o Sol faz uma linha perpendicular à superfície (CRONIN, 2014). A quantidade de radiação solar absorvida ou refletida pela Terra depende do ângulo do zênite, de forma que estimar o clima médio de um planeta em equilíbrio convectivo – radiativo, depende da média global da irradiância solar horizontal (GHI) e da delimitação de um ângulo de zênite solar que seja constante no tempo ou que varie no período diurno, ou seja, o Sol nascendo e se pondo (CRONIN, 2014).

$$GHI = DNI \cdot \cos\theta + DHI \quad (1)$$

Pode-se dizer ainda, que a DNI é a fração da GHI que não sofre nenhum desvio ocasionado pela atmosfera, vindo diretamente do Sol (BRASIL, 2019b) sendo ela que projeta as sombras. Tem valor igual a zero quando o Sol está totalmente encoberto por nuvens (BRASIL, 2019b).

A DHI, por sua vez, é a radiação que alcança a superfície da Terra a partir de todas as direções, após ter sido dispersada pelas moléculas e partículas presentes na atmosfera (BRASIL, 2019b). Quando o céu está encoberto por nuvens, a radiação difusa pode ser observada sob a forma de claridade (BRASIL, 2019b). Painéis fotovoltaicos são capazes de aproveitar e converter esse tipo de radiação, porém sistemas heliotênicos não (BRASIL, 2019b).

A Irradiância Refletida, citada por Magarreiro, Freitas e Brito (2016), é toda aquela resultante da reflexão da radiação solar na superfície. Assim, apresenta relação de dependência com as propriedades ópticas da superfície em questão, sendo também chamada de albedo.

Concerne ainda ao interesse deste trabalho a Irradiância Líquida que também é conhecida pelo termo “balança de radiação”. A Irradiância Líquida é o resultado das trocas de energia na atmosfera condicionadas pelo fluxo de radiação emitida pelo Sol (predominantemente em ondas curtas) e pela radiação terrestre (ondas longas emitidas pela superfície da Terra) (FUNARI; TARIFA, 2017). Esse equilíbrio tem grande importância

devido ao seu uso ambiental: aquecimento do ar e do solo, calor latente de evaporação e processos biológicos (FUNARI; TARIFA, 2017).

As medidas de irradiância podem ser realizadas em função da unidade [W/m^2] no Sistema Internacional de Unidades (SI), pois se referem a uma quantidade de energia instantânea. Alguns autores também utilizam desta forma de energia em função do tempo. Quando a irradiância é integrada no tempo, a literatura costuma associar a terminologia irradiação e a unidade [Wh/m^2]. Contudo, sabe-se ainda que [$1 \text{ W}/\text{m}^2$] é igual a [$1 \text{ J}/\text{m}^2.\text{s}$]. Foram encontradas algumas variações dessas unidades como [Wh/m^2] e [MJ/m^2].

A sigla GHI foi encontrada como referência tanto à Irradiância Global Horizontal (*Global Horizontal Irradiance*, do inglês) como à Irradiação (Global Horizontal e *Global Horizontal Irradiation*, do inglês). Assim, a GHI predita neste trabalho é resultado da radiação global incidindo em uma superfície horizontal em relação ao solo em um dado instante, ou seja, a irradiância.

3.2 EVAPOTRANSPIRAÇÃO (ETO)

A evapotranspiração (Eto) é a combinação de dois processos de perda de água de um ecossistema, sendo eles: (i) a evaporação, que é a perda pela superfície do solo; e (ii) a transpiração, que é a perda pelas superfícies vegetais (ALLEN et al., 1998). A evaporação e a transpiração ocorrem simultaneamente e não há uma maneira fácil de distinguir ambos os processos (ALLEN et al., 1998).

Além da disponibilidade de água superficial, a evaporação é determinada principalmente pela fração da radiação solar que incide sobre a superfície do solo (ALLEN et al., 1998), além de ser influenciada pela temperatura, condições climáticas de forma geral e estar sujeita a própria atividade vital das plantas (PORTO; FILHO; SILVA, 2003). À medida que a vegetação se desenvolve, o dossel da cultura sombreia cada vez mais essa superfície, de forma que em culturas densas a transpiração se torna o processo principal (ALLEN et al., 1998).

Existe ainda a evapotranspiração real (ETR) e a evapotranspiração potencial (ETP). A primeira refere-se ao processo de forma independente às condições da vegetação e da provisão de água. Por sua vez, a segunda diz respeito ao ápice da evapotranspiração que ocorreria em função de um suprimento suficiente de água ao solo e do auge da quantidade de folhagens na plantação (PORTO; FILHO; SILVA, 2003). Enquanto a ETR pode ser estimada apenas por modelagens indiretas (Método do Balanço Hídrico e Método dos Coeficientes de

Cultura) a ETP pode ser estimada por modelagens diretas (lisímetros) e indiretas (Equação de Thorntwaite, Método de Blaney-Cridle. Tanque de Classe A e Método de Penman-Monteith) (PORTO; FILHO; SILVA, 2003).


A Evapotranspiração de referência realizada com o método de Penman-Monteith (EtoPm) ou o Coeficiente do tanque de classe A (ECA) são duas variáveis utilizadas na metodologia deste trabalho e que não são autoexplicativas sendo, por vezes, mais associadas ao cultivo de lavoura.

Penman,-Monteith é recomendado como o principal método para calcular a Eto e incorpora parâmetros fisiológicos e aerodinâmicos. (ALLEN et al., 1998). Em 1948, Penman combinou o balanço de energia com o método de transferência de massa e derivou uma equação para calcular a evaporação de uma superfície de água aberta a partir de registros climatológicos como irradiância do Sol, temperatura, umidade e velocidade do vento (ALLEN et al., 1998). A abordagem de Penman-Monteith é formulada na Equação (2) onde R_n é a radiação líquida, G é o fluxo de calor do solo, $(e_s - e_a)$ representa o déficit de pressão de vapor do ar, ρ_a é a densidade média do ar sob pressão constante, c_p é o calor específico do ar, Δ representa a diferença entre a relação temperatura e pressão de vapor de saturação, γ é a constante psicrométrica, r_s é a resistência aerodinâmica e r_a a resistência superficial (ALLEN et al., 1998). A maioria dos parâmetros é medida ou pode ser facilmente calculada a partir de dados meteorológicos e a equação pode ser utilizada para o cálculo direto da Eto em qualquer cultura, uma vez que as resistências aerodinâmica e de superfície são específicas.

$$EtoPm = \frac{\Delta \cdot (R_n - G) + \rho_a \cdot c_p \cdot \frac{(e_s - e_a)}{r_a}}{\Delta + \gamma \left(1 + \frac{r_s}{r_a}\right)} \quad (2)$$

O Método do Coeficiente do Tanque de Classe A é um método de fácil composição, barato em relação aos equipamentos, muito empregado no Brasil e que demonstra acurácia nos resultados. O experimento é baseado no princípio de que a água contida no interior de um tanque de classe A, Figura 6, não deve oferecer nenhum impedimento ao processo evaporativo.

Figura 6 – Tanque de Classe A.



Fonte: Adaptado de Allen et al. (1998).

Deste modo, a perda de água pelo tanque sempre será maior que a perda efetiva por parte de uma superfície vegetal, mesmo em condições ótimas de suprimento de água. Para converter o resultado obtido com o tanque em E_t , os valores são ponderados com o coeficiente (k_p) relacionado à velocidade do vento, umidade do ar e a características físicas do solo e fisiológicas das plantas (CUNHA, 2011). A Equação (3) descreve a modelagem onde ECA é a E_t potencial em mm/dia calculada pelo método e EP a E_t medida no tanque de Classe A em mm/dia. Os valores aplicáveis de k_p no estado de São Paulo estão dispostos na Tabela 3.

$$ECA = k_p \cdot EP \quad (3)$$

Tabela 2 – Coeficiente k_p do Método do Tanque de Classe A.

Mês	Fator k_p	Mês	Fator k_p
Janeiro	0,74	Julho	0,72
Fevereiro	0,80	Agosto	0,69
Março	0,69	Setembro	0,66
Abril	0,75	Outubro	0,80
Maio	0,63	Novembro	0,79
Junho	0,75	Dezembro	0,87

Fonte: Adaptada de Porto, Filho e Silva (2003).

4 LEVANTAMENTOS DE GHI

Sabe-se que cada região da Terra recebe radiação solar pelo menos por uma parte do ano e a quantidade de radiação que atinge um ponto, depende da localização geográfica, do momento do dia, da estação do ano, do albedo e do clima local (EUA, 2013). Estima-se que aproximadamente 30% da radiação do Sol que incide sobre a Terra é refletida de volta, sendo essa fração conhecida como albedo planetário (VEISSID; PEREIRA, 2000). Quanto menor o albedo, mais energia uma superfície irá acumular.

A radiação solar incide na Terra em diferentes ângulos, variando entre 0° (ligeiramente acima do horizonte) e 90° (no ponto mais alto do céu), sendo que na segunda posição (90°), a superfície terrestre recebe toda a energia possível (EUA, 2013). A inclinação axial, que no eixo de rotação da Terra está na casa de 23,5° resulta em dias mais longos no hemisfério norte, desde o equinócio da primavera até o equinócio de outono e dias mais longos no hemisfério sul durante os outros 6 meses (EUA, 2013).

Assim, ao estudar os países que se destacam no cenário internacional em termos de geração de energia elétrica a partir da matriz fotovoltaica, torna-se necessário avaliar os índices de radiação incidentes nos seus respectivos territórios, visto que esses índices determinam o potencial de geração. Além disso, é necessário entender o histórico e a relação atual desses países com as energias renováveis e com os instrumentos e políticas para incentivar a implantação e o desenvolvimento dessas fontes. Este estudo foi realizado nas próximas seções.

4.1 COMPARATIVO ENTRE ALEMANHA E BRASIL

A Alemanha é um caso de êxito em aplicação de energias renováveis e que conta com um histórico muito consistente de políticas e instrumentos. Em 2018, mantém a primeira posição no *ranking* de geração de energia fotovoltaica *per capita*, com 548 Watt/capita, seguida da Austrália com 459 Watt/capita e do Japão com 442 Watt/capita (IEA, 2019b).

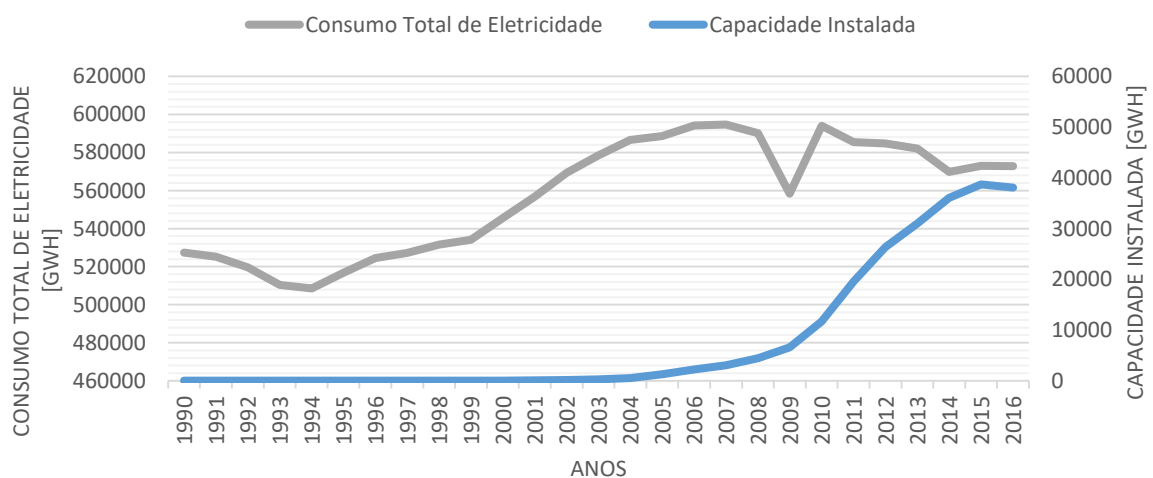
O marco inicial foi em 1990 com a Lei de Fornecimento de Energia (*Stromeinspeisungsgesetz* – StromEinspG, em alemão) que permitiu a entrada de energias renováveis na rede pública de abastecimento. Em 2000, entrou em vigor um sólido programa de apoio às energias renováveis, conhecido como Lei de Energias Renováveis (*Erneuerbare Energien Gesetz* – EEG, em alemão), que possibilitou às residências e às organizações instalarem sistemas fotovoltaicos para fornecer energia elétrica à rede e receberem

compensação financeira acima do valor de mercado por cada kWh produzido, com contratos de fornecimento de 20 anos (INHOFFEN; SIEMROTH; ZAHN, 2019). O sistema de compensação adotado é popularmente conhecido pelo nome inglês *feed-in tariff* (ou FIT) e no caso alemão leva em conta o custo de geração para cada tipo de fonte renovável, o potencial de geração da fonte e a quantidade de kWh gerados no intervalo da última medição (ALEMANHA, 2016).

A regulamentação do EEG contém duas premissas: a primeira garante acesso prioritário aos operadores de energias renováveis à rede em relação aos operadores das energias geradas nos moldes convencionais, e a segunda institui propriamente o sistema de compensações (INHOFFEN; SIEMROTH; ZAHN, 2019).

Em um intervalo de 15 anos (2000 – 2015), o Ministério da Economia e Energia (conhecido pela sigla BMWi) em implementar a EEG, fizeram com que as energias renováveis passassem de 6% de representatividade na matriz alemã para 32% (ALEMANHA, 2016). A EEG passou por revisões em 2004, 2009, 2012, 2014 e 2016. A revisão de 2016 incluía alguns fatores limitantes à expansão das energias renováveis, mesmo assim, a lei ainda se mantém fiel ao seu objetivo de promover essas energias e, em 2018, o investimento orçado pelo BMWi em compensações ainda era de 27,7 bilhões de euros (ALEMANHA, 2016). A Figura 7, demonstra a evolução da capacidade instalada de geração fotovoltaica e do consumo de energia elétrica na Alemanha desde a instituição da StromEinspG em 1990 até a EEG em sua última revisão de 2016.

Figura 7 – Consumo total de eletricidade e geração fotovoltaica na Alemanha entre 1990 e 2016.



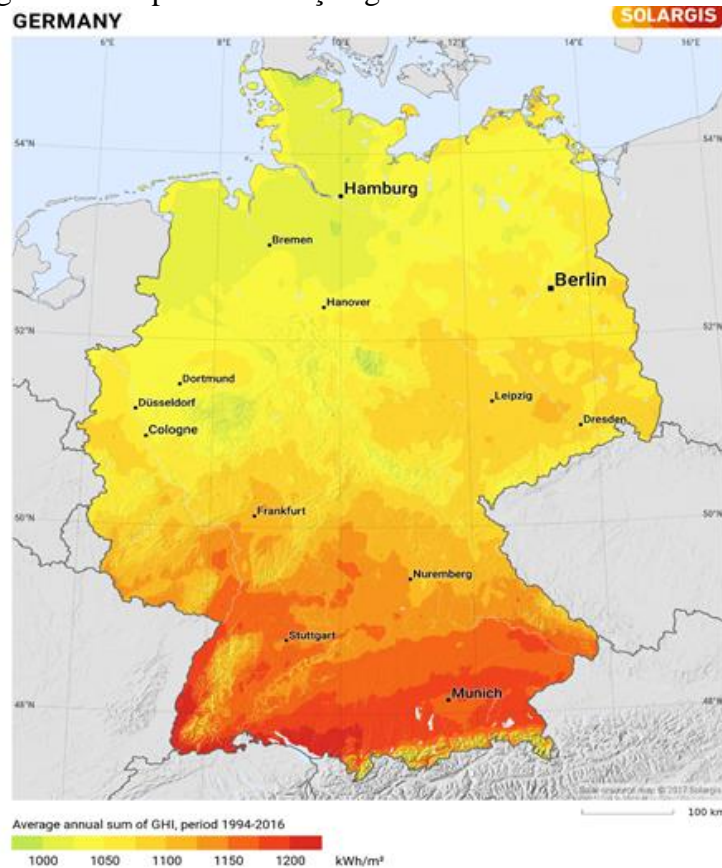
Fonte: Adaptado de IEA (2019b).

O ano de 2016 é marco de queda em quase 2%, em relação a 2015, no que diz respeito à capacidade instalada, fato que pode estar associado à revisão da normativa. Mesmo assim, é possível obter da Figura 7, que, em 2016, a capacidade fotovoltaica representa 6,65% do consumo total de energia elétrica.

Incentivados pelas compensações, sistemas de pequeno e médio porte, que geram até 30 kWp, emergiram rapidamente e como resultado, 70% dos sistemas de geração fotovoltaicos instalados estão conectados às redes de baixa tensão (VON APPEN et al., 2013).

A geração fotovoltaica por si só, é capaz de satisfazer 40% da demanda alemã, durante dias ensolarados e de baixa demanda, e a geração é comumente encontrada nas ensolaradas regiões no sul do país (VON APPEN et al., 2013). A Figura 8 apresenta os índices de irradiação global horizontal (kWh/m²) na Alemanha e confirma a afirmação de Von Appen et al. (2013).

Figura 8 – Mapa de irradiação global horizontal na Alemanha.



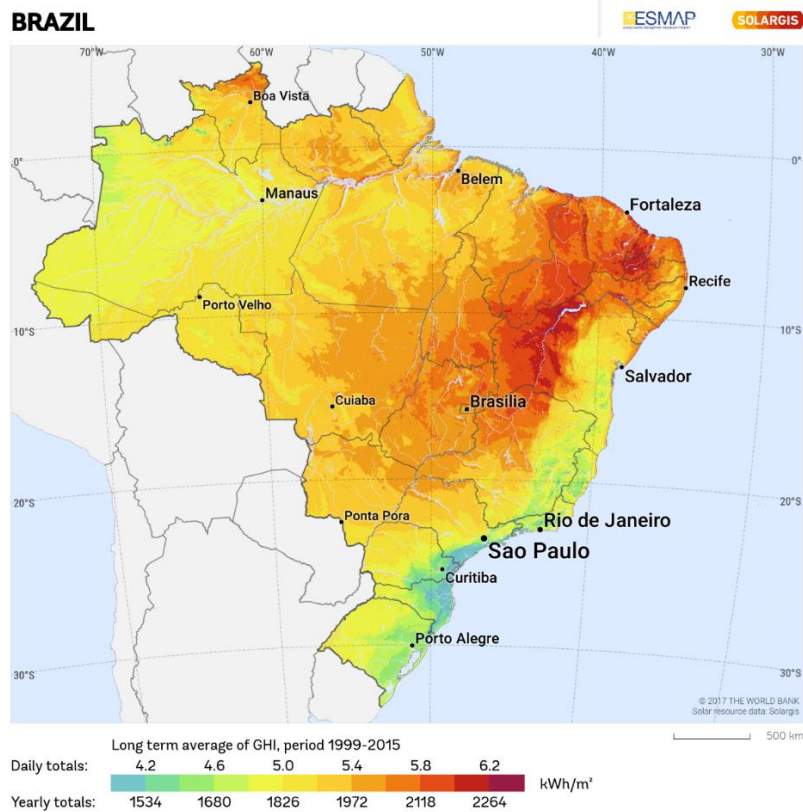
Fonte: Solargis (2017).

O território alemão apesar de suas dimensões não muito extensas, apresenta 3 tipos diferentes de clima distribuídos pela extensão do país (CLIMATE-DATA, 2019a). Nas latitudes mais altas, nas regiões que envolvem Berlin, Hamburg, Munich, Dresden e Leipzig, por exemplo, encontra-se o Clima Continental Quente, conhecido como Dfb na classificação

de Köppen-Geiger (CLIMATE-DATA,2019a). Em Cologne, Frankfurt, Stuttgart e Dortmund, encontra-se o Clima Oceânico, conhecido por Cfb e ainda nos arredores de Tellerhäuser, o Clima Subártico, denominado por Dfc (CLIMATE-DATA, 2019a).

Comparativamente com o Brasil, a Alemanha possui índices de irradiação global horizontal razoavelmente baixos. O espectro de variação de irradiação no território alemão normalmente está entre 1.000 kWh/m² e 1.200 kWh/m². No Brasil, os índices variam entre 1.534 kWh/m² e 2.264 kWh/m², conforme a Figura 9. Assim, o limite inferior no território brasileiro é 22% mais intenso que o limite superior no território alemão. Comparando os dois limites superiores entre si, a irradiação máxima na Alemanha representa apenas 47% da irradiação máxima no Brasil.

Figura 9 – Mapa de irradiação global horizontal no Brasil.



4.2 COMPARATIVO ENTRE CHINA E BRASIL

Apesar do histórico recente da China com a energia fotovoltaica, o governo chinês atingiu um nível aceitável de capacidade total instalada, através da formulação de uma série de leis e políticas, entre elas, as permissões para fabricação de células fotovoltaicas com o intuito de encorajar a energia solar (LIU, 2017). Em 2018, o país ocupava o primeiro lugar no

ranking de geração fotovoltaica com 45,00 GW e capacidade instalada de 176,10 GW (IEA, 2019b).

Os primeiros passos rumo a esses valores foram por volta de 1950, quando o governo chinês aplicou esforços em desenvolver tecnologias de geração fotovoltaica focado nas viagens espaciais. Em 1996, o *Brightness Programme* apoiou energias renováveis com a intenção de atender comunidades isoladas que não podiam ser conectadas à rede. Em meados de 2000, a China alterou suas políticas e incentivou a pesquisa e desenvolvimento dos painéis com a intenção de produzir em quantidade para exportação (NUOSHU; COUTO JUNIOR, 2016).

Em 2006, entrou em vigor a Lei de Energias Renováveis, que guiou o desenvolvimento desse setor e definiu padrões para o apoio governamental (NUOSHU; COUTO JUNIOR, 2016). Em 2007, a tarifa de eletricidade obtida de sistemas solares fotovoltaicos era de cerca de 4,0 Yuan/kWh e após o desenvolvimento e instalação de sistemas solares fotovoltaicos pela Sun Tech Power Co. Ltd. (o maior produtor chinês de células solares), a tarifa foi reduzida para cerca de 1,0 Yuan/kWh (LIU, 2017), despontando assim os primeiros frutos das leis e políticas recentemente instaladas.

Em meados de 2009, a China promoveu o conceito de indústrias emergentes estratégicas e a tecnologia solar foi identificada como um ramo promissor dessas indústrias (ZOU et al., 2017). Desde então, o governo chinês elaborou uma série de políticas de apoio para reduzir as lacunas entre as indústrias fotovoltaicas na China e os países mais avançados (ZOU et al., 2017). O Centro de Economia e Desenvolvimentos Estratégicos do Instituto de Pesquisa Energético da China, afirmou que o país, ao analisar a maneira como as outras nações estavam apoiando energias renováveis, elegeu a Alemanha como exemplo a ser seguido (NUOSHU; COUTO JUNIOR, 2016).

Em julho de 2009, o Ministério das Finanças, o Ministério da Ciência e Tecnologia e a Administração Nacional de Energia, lançaram conjuntamente o “Projeto de Demonstração *Golden Sun*”. Este projeto era pioneiro e marcou a primeira vez que a China subsidiou projetos fotovoltaicos por capacidade instalada (ZOU et al., 2017). O sistema de compensação escolhido foi o FIT (NUOSHU; COUTO JUNIOR, 2016), o mesmo usado na Alemanha.


O sistema FIT contemplava os produtores, levando em conta o investimento inicial e a capacidade instalada do projeto fotovoltaico (ZOU et al., 2017). Ainda assim, nessa época, a maioria das melhorias nas tecnologias fotovoltaicas ocorreu no exterior e o desenvolvimento

do setor na China dependeu, principalmente, da ampliação de processos de produção para fornecer produtos de baixo custo (ZOU et al., 2017).

Desde então, a indústria fotovoltaica da China está passando por uma reestruturação e uma rápida reconfiguração do mercado. Entre 2009 e 2013, o país contribuiu com mais de 50% da produção mundial (ZOU et al., 2017). A recém-instalada capacidade fotovoltaica da China aumentou rapidamente entre 2012 e 2013, alcançando o maior arranjo mundial de instalações fotovoltaicas, com 12,92 GW conectados à rede, seguido pelo Japão com 6,9 GW (ZOU et al., 2017).

Durante o 12º Plano Quinquenal da China, o mercado chinês experimentou rápido desenvolvimento e expansão e em 2014, a capacidade instalada de energia fotovoltaica atingiu 28,05 GW (ZOU et al., 2017). Assim, em 2016, devido à nova política energética do governo chinês para desenvolver sistemas de energia renovável, a capacidade dos sistemas de energia solar instalados na China foi aumentada em 100% (LIU, 2017). A Figura 10, dispõe comparativamente a evolução da capacidade instalada chinesa e o consumo de energia elétrica entre 1990 e 2016.

Figura 10 – Consumo total de eletricidade e geração fotovoltaica na China entre 1990 e 2016.



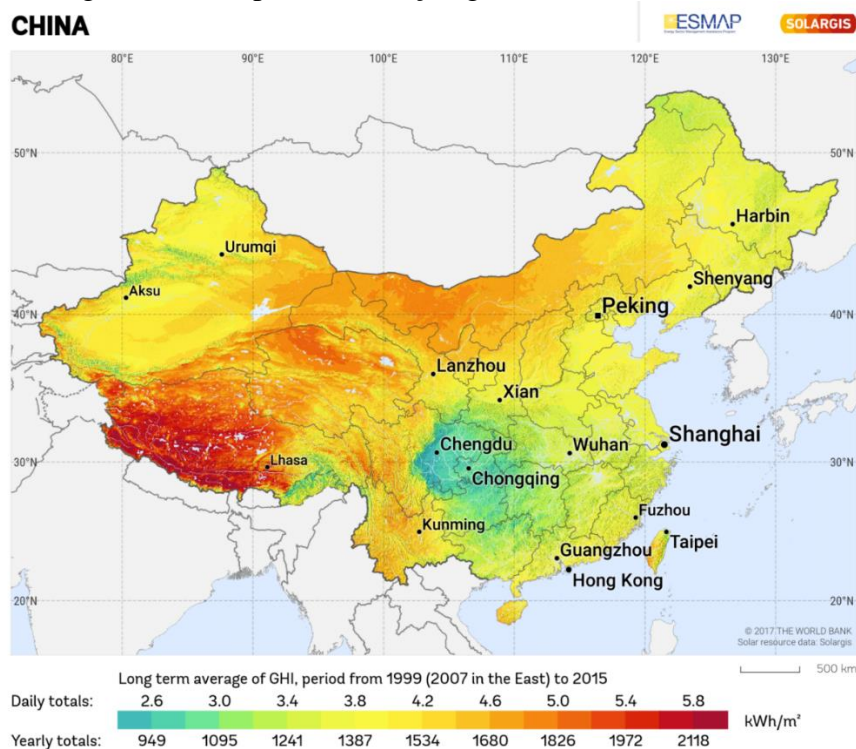
Fonte: Adaptado de IEA (2019b).

A capacidade fotovoltaica chinesa pode ser aprimorada graças aos recursos solares que são abundantes em seu território, sendo que a irradiância anual em um plano horizontal, em média, é 1.492,6 kWh/m². No entanto, a incidência da radiação não é distribuída uniformemente por todo o país, sendo muito maior na porção ocidental do que na porção leste (ZOU et al., 2017), conforme a Figura 11. A área oeste é um vasto território com uma

população escassa, o que representa agravamento das dificuldades em desenvolver uma indústria fotovoltaica. Além disso, a demanda de eletricidade na porção leste é a que continua a aumentar devido à maior densidade populacional e ao crescimento econômico mais rápido dessa região (ZOU et al., 2017).

A China possui 5 tipos diferentes de clima, distribuídos por toda sua extensão territorial (CLIMATE-DATA, 2019b). As regiões de Shanghai, Guangzhou, Shenzhen, e Nanjing têm clima Subtropical Úmido, reconhecido na classificação de Köppen-Geiger pela sigla Cfa (CLIMATE-DATA, 2019b). Beijing, Tianjin, Jinan, Changchun e Harbin apresentam Clima Continental Quente, definido por Dfa (CLIMATE-DATA, 2019b). Beigou, Dahuanggong, Wangqing, Lincang e Dongguan têm Clima Continental Úmido Quente, denominado por Dwb (CLIMATE-DATA, 2019b). Shijiazhuang, Xi'an, Taiyuan, Hohhot e Baotou possuem Clima Semi-árido Frio, definido por Bsk (CLIMATE-DATA, 2019b). Por fim, Longtian, Chengkou, Xiuqi e Qinghua têm Clima Subtropical Úmido, denominado por Cwa (CLIMATE-DATA, 2019b).

Figura 11 – Mapa de irradiação global horizontal na China.



Fonte: Solargis (2017).

Comparativamente ao Brasil, a China possui o limite inferior de seus índices de irradiação mais próximos aos índices alemães e o limite superior bem próximo aos brasileiros. O espectro de variação da irradiação no território chinês normalmente está entre 949 kWh/m²

e 2.118 kWh/m² com média aritmética de 1.533 kWh/m², valor esse bem distribuído pela extensão territorial. O valor da média corrobora a informação de Zou et al. (2017), ao afirmar que a irradiação global horizontal incidente no território chinês é de aproximadamente 1.492 kWh/m². No caso brasileiro, os índices variam entre 1.534 kWh/m² e 2.264 kWh/m², conforme a Figura 9 e no alemão entre 1.000 kWh/m² e 1.200 kWh/m², conforme a Figura 8. Assim, os índices de irradiação superiores que o Brasil se dispõe associados a investimento, tecnologia e pesquisa permitiram ao país atingir níveis de geração fotovoltaica massivamente superiores aos dos países que se destacam atualmente no cenário internacional.

4.3 CARACTERIZAÇÃO DA GERAÇÃO FOTOVOLTAICA EM ARARAS/SP

4.3.1 Caracterização legal

A geração de energia fotovoltaica em todo o território brasileiro de maneira *on-grid*, ou seja, quando a micro/mini geração está conectada à rede de distribuição de baixa tensão, é prevista pela resolução número 687/2015 que altera o texto da resolução 482/2012, ambas da ANEEL (BRASIL, 2015a). Basicamente, a normativa institui um sistema de compensação, como visto na Alemanha e na China, porém em um molde que apresenta suas particularidades.

O sistema brasileiro, Figura 12, prevê a possibilidade de injeção dos excedentes de energia elétrica gerada na rede, contabilizando a quantidade injetada pela unidade kWh. O montante contabilizado fica disponível por 60 meses (5 anos) na forma de créditos para o gerador, sem sofrer nenhum tipo de ponderação. Deste modo, a quantidade de créditos é a mesma quantidade de energia injetada. O gerador, em momento oportuno, pode consumir seus créditos utilizando energia da rede, no mesmo local da planta geradora ou em outro local cadastrado, de forma que, se o consumo for menor ou igual à geração, resta-lhe apenas pagar a taxa mínima.

Figura 12 – Sistema de compensação previsto na resolução nº687/2015 da ANEEL.




Fonte: SolGreen Energia (2019).

Uma possibilidade comum é a de que o gerador injete energia na rede durante o dia, momento propício para que a geração seja maior que o consumo e utilize energia da rede durante a noite, momento em que a geração é interrompida. Neste sistema em que os créditos são acumulados por 60 meses, é possível também que o gerador acumule créditos durante os verões (quando a geração é muito propícia) e consuma-os durante os invernos.

4.3.2 Caracterização geográfica

Distando aproximadamente 180 km da capital do estado e compreendida entre as bacias hidrográficas do Rio Mogi, Ribeirão Itapura e Ribeirão das Araras (BRASIL, 2019c), na porção leste do estado de São Paulo, Brasil, conforme Figura 13, a cidade de Araras localiza-se geograficamente pelas coordenadas 22° 21' 28" Sul e 47° 23' 6" Oeste e possui uma área de unidade territorial de 664,381 km² com elevação de 640 m (IBGE, 2017) e população estimada em aproximadamente 133.000 habitantes para o ano de 2018 (IBGE, 2010c).

Figura 13 – Localização da cidade de Araras no mapa político do estado de São Paulo.



Fonte: IBGE (2017).


4.3.3 Caracterização climática

Araras possui clima quente e temperado, com os índices pluviométricos de verão maiores que os de inverno (CLIMATE-DATA, 2019c). Os verões costumam ser longos abafados e de céu encoberto por nuvens, enquanto os invernos são curtos, amenos e de céu limpo (WEATHER SPARK, 2019). A classificação em Köppen-Geiger é Cwa (CLIMATE-DATA, 2019c), que significa Clima Subtropical Úmido. O mesmo clima foi encontrado na

China. A temperatura varia entre 11 °C e 30 °C, dificilmente atingindo margem inferior a 7 °C e superior a 34 °C (WEATHER SPARK, 2019), com temperatura média de 20,3 °C (CLIMATE-DATA, 2019c).


A duração do dia, momento interessante à geração fotovoltaica, é definida como o instante em que a irradiância ultrapassa 120 W/m² (WORLD METEOROLOGICAL ORGANIZATION, 2008). A duração é variável durante o ano, conforme as Figuras 14 e 15.

Figura 14 – Horas de luz solar e crepúsculo em Araras.



Fonte: Weather Spark (2019).

Figura 15 – Dia solar durante o ano de 2019 em Araras.



Fonte: Weather Spark (2019).


Interessante ressaltar que os dias demarcados na Figura 14 indicam fenômenos associados à incidência de luz solar nos hemisférios. Assim, no hemisfério sul, 20 de março marca o equinócio de outono quando a quantidade de horas ensolaradas e de penumbra é a mesma (na figura, o ponto está na marca 12h); 21 de junho, quando o Sol incide verticalmente sobre o Trópico de Câncer e possibilita o solstício de inverno, marcando os dias mais curtos; em 23 de setembro ocorre o equinócio de primavera e novamente a quantidade de horas

ensolaradas e de penumbra é a mesma; por fim, em 22 de dezembro, acontece o solstício de verão, marcando dias mais longos e noites mais curtas.

A Figura 15 traz uma visão mais introspectiva da relação entre horas iluminadas e horas de penumbra, durante um dia. Em geral, durante o ano, o momento entre 7h e 19h é marcado pela presença de luz e radiação solar com valores de radiação que devem limiar em torno de 120 W/m². Vale frisar que a descontinuidade nas linhas da Figura 15 marca o início e o término do horário de verão.

A presença ou não de nuvens, Figura 16, tem relação estreita com os índices de radiação global direta e difusa. A radiação difusa pode ser observada quando o céu está encoberto, na forma de claridade e os painéis fotovoltaicos conseguem aproveitar esse tipo de radiação (BRASIL, 2019b). Porém, as nuvens exercem bloqueio à parcela direta – aquela fração que não sofre desvio ocasionado pela atmosfera em sua trajetória, vinda direto do Sol (Brasil, 2019a) – impossibilitando representatividade dessa parcela na geração.

Figura 16 – Categorias de nebulosidade em Araras.




Fonte: Weather Spark (2019).

Nota-se que o período menos encoberto tem início por volta de 2 de abril e término em 6 de outubro, com duração de 6,4 meses (WEATHER SPARK, 2019), caracterizando melhores chances de índices mais altos de GHI. O período mais encoberto dura 5,6 meses e vai de 13 de outubro a 6 de abril (WEATHER SPARK, 2019). O dia 27 de agosto é o menos encoberto do ano, com porcentagens de céu sem nuvens, quase sem nuvens ou parcialmente encoberto de 74% do tempo (WEATHER SPARK, 2019). O dia 16 de janeiro é o mais encoberto do ano, com porcentagens de céu encoberto ou quase encoberto de 75% do tempo (WEATHER SPARK, 2019).

A localização da cidade de Araras no mapa do estado de São Paulo, Figura 17, permite observar que a região pertence a uma faixa de variação de irradiância estipulada entre 1.750 kWh/m² e 1.900 kWh/m² com média aritmética de 1.825 kWh/m². Esses dados ratificam os valores encontrados no enfoque sobre o município, na parte superior da figura, que variam entre 1.850 kWh/m² e 2.000 kWh/m² com média aritmética de 1.925 kWh/m². A discordância entre os limites é pequena e varia em 5,0% para o limite inferior e superior. Tal diferença é aceitável, devido ao fato de que a análise feita sobre o mapa de irradiância estadual é uma projeção em maior escala, na qual o nível de detalhes é diminuído e as informações são generalizadas em função do tamanho do mapa. Vale ressaltar ainda, que o ponto demarcado dentro do município, no enfoque, é a localização da Estação Meteorológica Automática (EMA) no *campus* da UFSCar, a mesma localização fornecida para obtenção da Figura 18.

Figura 17 – Mapa de Irradiação Global Horizontal do estado de São Paulo com enfoque em Araras.



Fonte: Adaptado de The World Bank (2019).

A Figura 18 representa um recorte do relatório disponibilizado pela parceria The World Bank com as empresas Solargis e Esmap. Nele, são fornecidas as coordenadas da Estação Meteorológica Automática (EMA) localizada no *campus* da UFSCar em Araras, a qual será utilizada nesta dissertação. O site retorna um relatório estimando a irradiância global

horizontal e a previsão de energia gerada naquela coordenada em um painel com inclinação ótima de 25° e com a face voltada para o Equador (coordenada 0°). De acordo com o documento, a irradiância global horizontal no ponto demarcado pela coordenada é de 1.901 kWh/m². A informação corrobora o que foi apresentado nos mapas da Figura 17. As divergências são de aproximadamente 8% e 3% em relação limite inferior (estado/município, respectivamente) e 1% e 5% com o limite superior (estado/município, respectivamente).

Figura 18 – Relatório de Irradiação Global Horizontal e previsão de geração fotovoltaica.

GLOBAL SOLAR ATLAS

AN INNOVATION OF THE WORLD BANK GROUP

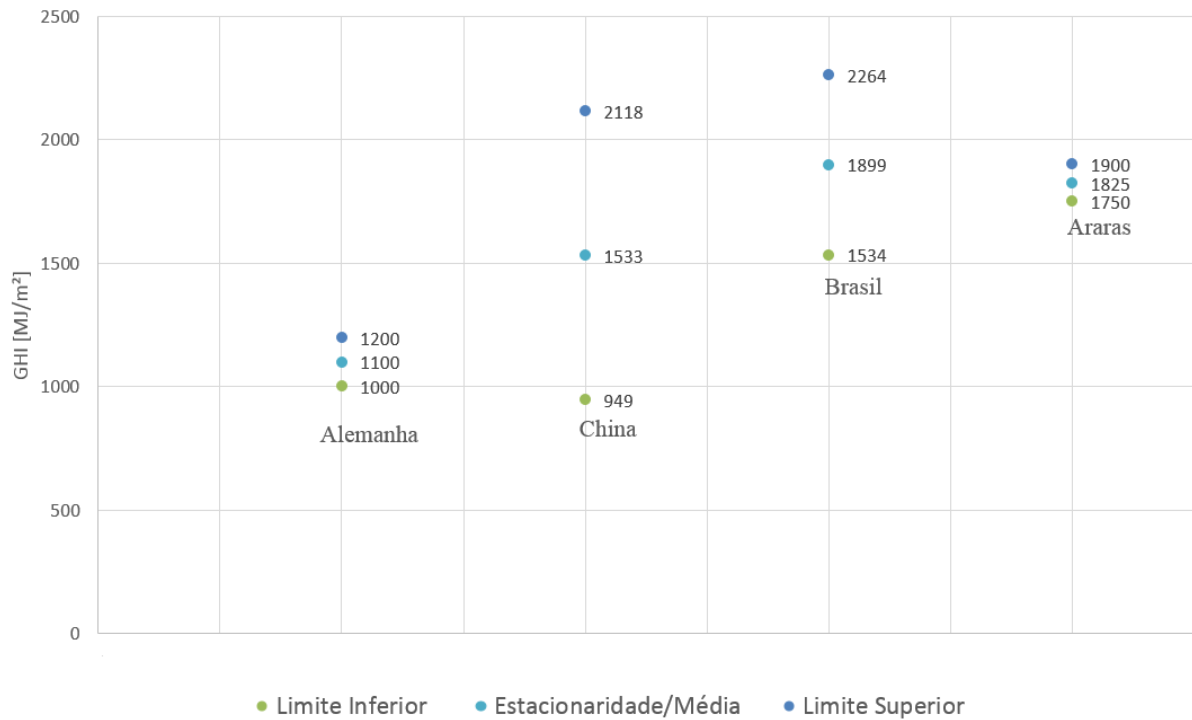


Fonte: Adaptado de The World Bank (2019).

A Figura 19 apresenta uma disposição gráfica comparativa das informações apresentadas pela Figura 8, Figura 9, Figura 11 e Figura 17 em relação à irradiância global horizontal nas localidades estudadas. É notável que a Alemanha possui os menores índices de GHI, mas que são estacionários em torno da média, o que configura uma característica muito favorável à previsão da série temporal. A China apresenta grande lacuna entre seus limites

inferior e superior, o que dificulta a previsão e faz com que os índices médios sejam menores que os do Brasil e da cidade de Araras. Por fim, o índice médio do município ararense é um pouco inferior ao brasileiro, mas ainda maior que o alemão e o chinês, reafirmando a potencialidade da geração fotovoltaica no local.

Figura 19 – Comparativo entre as faixas de GHI contidas nas Figuras 8, 9, 11 e 17.



Fonte: Elaborado pelo autor (2019).

5 TÉCNICAS DE ANÁLISES DE SÉRIES TEMPORAIS

Uma série temporal é uma sequência de observações feitas sequencialmente no tempo. Abundam em áreas como economia, negócios, engenharia, ciências naturais (especialmente geofísica e meteorologia) e ciências sociais. Muitos conjuntos de dados aparecem como séries temporais, por exemplo: uma sequência mensal da quantidade de mercadorias expedidas numa fábrica, uma série semanal do número de acidentes rodoviários, quantidades diárias de chuva, observações horárias feitas no rendimento de um processo químico, entre outros (BOX; JENKINS; REISEL, 2008).

As séries temporais podem ser divididas em duas classes, de acordo com o intervalo da observação (MORETTIN; TOLOI, 2006) a saber:

- Discretas – são aquelas que as observações são feitas em um tempo fixo (t);
- Contínuas – as observações são coletadas em um intervalo de tempo $[0, T]$.

Quando se faz necessário amostrar a série contínua em intervalos de tempo fixos, acaba-se por converter a série contínua observada no intervalo $[0, T]$ em uma série discreta com N pontos, conforme Equação (4).

$$N = \frac{T}{\Delta t} \quad (4)$$

Neste trabalho, as coletas horárias dos dados aconteceram em um tempo fixo ($t, t+1, t+2, \dots, t+23$) e, portanto, caracterizam uma série temporal discreta. Uma característica intrínseca de uma série temporal é que, normalmente, as observações adjacentes são dependentes, sendo tal dependência de considerável interesse prático (BOX; JENKINS; REISEL, 2008), já que um dos objetivos pelos quais se estudam as séries temporais é a necessidade de previsões dos valores futuros da série (MORETTIN; TOLOI, 2006). A previsão, portanto, refere-se à tentativa de associar um valor para um ponto na série, antes desconhecido, em um futuro estipulado (BOX; JENKINS; REISEL, 2008).

O uso de observações disponíveis no tempo $(t-1)$ de uma série temporal, para prever seu valor em algum momento futuro (t) pode fornecer uma base para o planejamento econômico e de negócios, planejamento de produção e controle de estoque, além do controle e a otimização de processos industriais (BOX; JENKINS; REISEL, 2008). Assim, a previsão não constitui um fim em si, mas é apenas um meio de gerar informações para alicerçar uma tomada de decisão, tendo em vista objetivos claros (MORETTIN; TOLOI, 2006).

A previsão da irradiância global horizontal é uma característica fundamental para aumentar a taxa de penetração da energia fotovoltaica nas redes, com efeito, a antecipação das flutuações das energias renováveis permite uma melhor gestão dos meios de produção de eletricidade e uma melhor operação dos sistemas de armazenamento (DAVID et al., 2016).

A supracitada dependência entre os pontos da série requer o desenvolvimento de modelos estocásticos e dinâmicos para análise dos dados no domínio do tempo e/ou das frequências (MORETTIN; TOLOI, 2006).

Modelos estocásticos dizem respeito àqueles que o ambiente após a ação contém alguma incerteza associada, caso contrário, seriam modelos determinísticos. Provavelmente nenhum fenômeno é inteiramente determinístico (BOX; JENKINS; REISEL, 2008). Dito isto, é comum afirmar acerca de séries temporais que elas apresentam alguma estacionaridade, ou seja, variam aleatoriamente ao redor de uma média constante no tempo, apresentando o que se chama de equilíbrio estável (MORETTIN; TOLOI, 2006). Podem ser descritas também, a partir da tendência (mudança sistemática e não periódica) ou da sazonalidade (comportamento que apresenta repetição ao longo do ano).

As séries temporais associadas à irradiância solar são ambientes estocásticos, apresentam estacionaridade dependente do intervalo analisado, além de apresentarem comportamento sazonal regido pelo movimento translacional do planeta.

Assim, além de calcular as previsões, também é necessário especificar sua precisão, para que, por exemplo, os riscos associados às decisões baseadas nessas previsões possam ser calculados (BOX; JENKINS; REISEL, 2008). A precisão pode ser expressa pelo cálculo da probabilidade dos limites de máxima e mínima da previsão, de modo que o valor realizado da série temporal deverá estar dentro desses limites e com probabilidade declarada (BOX; JENKINS; REISEL, 2008).

Os pioneiros modelos paramétricos, aqueles baseados em tratamento estatístico e dos quais fazem parte os modelos AR, ARMA e ARIMA antes amplamente difundidos, agora tem concorrido com os modelos não paramétricos, muitas vezes associados às técnicas de inteligência computacional.

Dentre os motivos, deve-se destacar que os modelos paramétricos são limitados ao lidar com séries temporais que apresentam estocasticidade (PAPAGIANNAKI et al., 2003) e não se adaptam bem à presença de volatilidade, de forma que aplicá-los nessas situações acaba por violar algumas de suas premissas (DUARTE, 2014).

Deste modo, as Redes Neurais Artificiais surgiram como resposta da ciência da computação ao problema da estocasticidade (DUARTE, 2014). Esses modelos não paramétricos apresentam melhor adaptabilidade às mudanças bruscas e potencial de adaptação global (BALIYAN; GAURAV; MISHRA, 2015). Disso, derivam algumas definições que se fazem importantes e necessárias para os modelos de análise e previsão que podem ser observados nas seções seguintes.

5.1 REDES NEURAIAS ARTIFICIAIS

Haykin (2003) define que a “rede neural artificial é um processador maciçamente paralelamente distribuído, constituído de unidades de processamento simples que têm a propensão natural de armazenar conhecimento experimental e torná-lo disponível para o uso”.

Silva, Spatti e Flauzino (2010), propõem ainda de forma bastante técnica, que as redes são como um “conjunto de unidades de processamento, caracterizadas por neurônios artificiais, que são interligados por um grande número de interconexões (sinapses artificiais) sendo as mesmas representadas por matrizes/vetores sinápticos”. Os mesmos autores definem também, de maneira mais análoga ao cérebro, que as redes neurais artificiais são como “modelos computacionais inspirados no sistema nervoso dos seres vivos, dotadas de capacidade de aquisição e manutenção do conhecimento baseado em informações”.

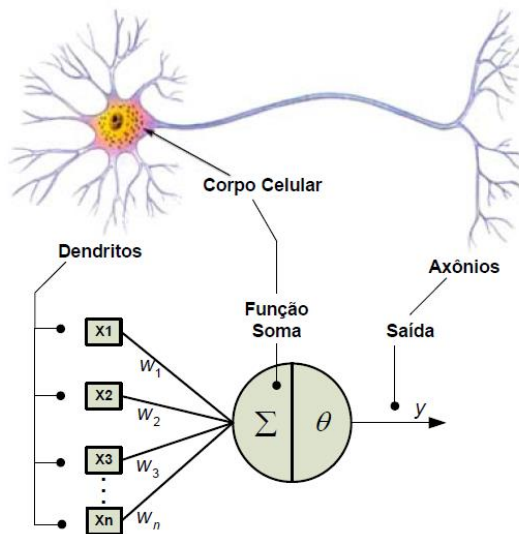
Assim, as redes neurais se assemelham ao cérebro humano de duas formas: (i) o conhecimento é adquirido através de um processo de aprendizado e (ii) os pesos sinápticos, (uma espécie de conexão entre os neurônios), são a maneira que eles se utilizam para armazenar a informação. As redes neurais pertencem a uma área conhecida como inteligência artificial, inteligência computacional e/ou sistemas inteligentes e também podem ser chamadas de redes conexionistas ou neurocomputador (HAYKIN, 2003; SILVA, SPATTI, FLAUZINO, 2010).

As redes neurais possuem um processamento paralelo e distribuído pelos neurônios (ou unidades processadoras), enquanto o cérebro processa a informação de forma complexa, não linear e também paralela. Sua capacidade de aprendizagem está relacionada ao treinamento que permite à rede entender o relacionamento entre as informações e a sua capacidade de generalização. Generalizar o conhecimento adquirido no treinamento permite à rede estimar soluções que antes eram desconhecidas (SILVA; SPATTI; FLAUZINO, 2010).

5.1.1 Neurônio artificial

O cerne das redes neurais foi desenvolvido a partir de unidades processadoras, que ficaram conhecidas como neurônios artificiais. Estas estruturas são fundamentadas no neurônio biológico, que exerce a função de conduzir estímulos no cérebro humano e são unidades básicas de processamento das informações recebidas pelo corpo, conforme a Figura 20.

Figura 20 – Comparativo entre neurônio biológico e artificial.



Fonte: Fernandes (2009).


Os neurônios artificiais, aplicados nas redes neurais, são não lineares, viabilizam saídas contínuas e realizam funções simples (SILVA; SPATTI; FLAUZINO, 2010). A representação dos neurônios proposta por McCulloch e Pitts (1943) é dada na Figura 21. Nela, os neurônios englobam paralelismo e conectividade, características de uma rede neural biológica (SILVA; SPATTI; FLAUZINO, 2010).

Assim, é possível perceber os 7 elementos que compõe o neurônio artificial e são descritos por Silva, Spatti e Flauzino (2010) da seguinte maneira:

- 1) Sinais de entrada (x_1, x_2, \dots, x_n): representam as variáveis;
- 2) Pesos sinápticos (w_1, w_2, \dots, w_n): valores que servem para ponderar as variáveis de entrada da rede. São aprendidos durante o treinamento;
- 3) Combinador linear (Σ): sua função é agregar os sinais que foram ponderados pelos pesos;

- 4) Limiar de ativação (Θ): variável que indica o patamar apropriado para que o resultado produzido pelo combinador linear gere um valor de disparo em direção à saída do neurônio.
- 5) Potencial de ativação (u): Diferença entre os valores da combinação linear e o limiar de ativação. Se $u \geq 0$ é chamado potencial excitatório e se $u < 0$ é chamado potencial inibitório.
- 6) Função de ativação (g): Limita a saída do neurônio dentro de um intervalo razoável;
- 7) Sinal de saída (y): Valor final produzido em relação ao conjunto de sinais de entrada.

Figura 21 – Representação de um neurônio artificial.



Fonte: Elaborado pelo autor (2019).

A expressão que sintetiza a atividade do neurônio artificial é dada pelas Equações (5) e (6).

$$y = g(u) \quad (5)$$

$$\therefore y = g \left(\sum_{i=1}^n w_i \cdot x_i - \theta \right) \quad (6)$$

A disposição dos neurônios, uns em relação aos outros é dada pela arquitetura da RNA (SILVA; SPATTI; FLAUZINO, 2010) e será discutida na próxima seção.

5.1.2 Arquitetura de rede neural artificial

A arquitetura de uma rede neural artificial acaba evidenciando uma simplificação da arquitetura de uma rede neural biológica. Em números, enquanto uma rede neural biológica possui bilhões de neurônios em funcionamento, uma rede artificial possui algumas centenas.

Um dos fatores que influenciam a arquitetura da RNA é o algoritmo de aprendizado, aplicado no treinamento da rede e que interfere também em sua capacidade de resolução de problemas. Existem alguns aspectos que ajudam a cercar a definição de uma arquitetura, são eles o número de camadas, a topologia da rede e o tipo de conexão entre os neurônios.

Silva, Spatti e Flauzino (2010) dividem as camadas em 3 categorias:

- Camada de entrada: É a camada que recebe os sinais do ambiente externo (dados), geralmente normalizados;
- Camadas escondidas: São as camadas intermediárias e que possuem neurônios incumbidos de estabelecer a relação entre os dados e extrair informações associadas aos dados de entrada;
- Camada de saída: Responsável pela produção e apresentação dos resultados. Também são dotadas de neurônios.

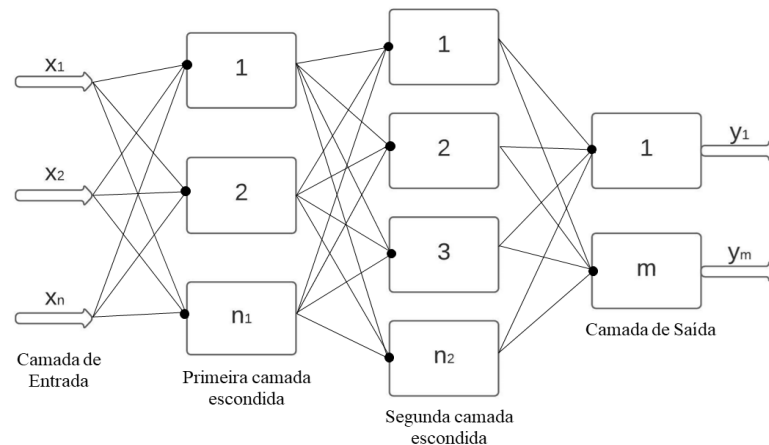
5.1.3 Topologias de redes neurais artificiais

Em relação à topologia da rede, a divisão de Silva, Spatti e Flauzino (2010) acontece em 3 grupos: redes *feedforward*, redes recorrentes e redes em estrutura reticulada.

A topologia *feedforward* pode ser de camada simples e múltiplas camadas. Na topologia de camadas simples, a rede possui apenas uma camada de entrada e uma camada neural de saída. Já a topologia de múltiplas camadas apresenta uma camada de entrada formada por n sinais, as camadas neurais escondidas (no caso de duas camadas, compostas por uma quantidade de n_1 e n_2 neurônios) e a camada neural de saída composta por m neurônios, conforme exemplificada na Figura 22.

Nessa topologia, os neurônios de uma camada são conectados única e exclusivamente a camada imediatamente superior, não existindo outro tipo de conexão. O conhecimento resultante do processamento dos sinais de entrada nas camadas intermediárias é armazenado em forma de pesos sinápticos. As redes de Base Radial e *Multilayer Perceptron* estão entre as principais redes dessa topologia.

Figura 22– Rede *feedforward* com múltiplas camadas.



Fonte: Elaborado pelo autor (2019).

A topologia Recorrente ou Realimentada diz respeito às redes em que as saídas dos neurônios são utilizadas como sinais de entrada para outros neurônios. Essa característica permite a aplicação dessa topologia em sistemas que variam no tempo, como previsão de séries temporais. Hopfield e *Multilayer Perceptron* são as principais redes desta topologia (SILVA; SPATTI; FLAUZINO, 2010).

Por sua vez, a topologia em estrutura reticulada refere-se à disposição espacial dos neurônios. Nela, a localização do neurônio tem relação direta com o ajuste dos pesos e limiares. Entre as principais aplicações estão os problemas de agrupamento e de reconhecimento de padrões, tendo a rede de Kohonen como principal representante (SILVA; SPATTI; FLAUZINO, 2010).


5.1.4 Funções de ativação

As funções de ativação têm uma singela conexão com a arquitetura das redes e são divididas em dois grupos. As funções parcialmente diferenciáveis, que possuem pontos nos quais a derivada de primeira ordem é inexistente e as funções totalmente diferenciáveis em que todos os pontos possuem derivada de primeira ordem existente e conhecida. As funções de ativação empregadas neste trabalho foram: a função logística (ou sigmoide) nas camadas intermediárias e a função linear na camada de saída.

A Função logística (ou sigmoide) é dada pela Equação (7) e tem seu gráfico dado pela Figura 23. β é uma constante real associada a inclinação da função no ponto de inflexão.

$$y = \frac{1}{1 + e^{-\beta \cdot u}} \stackrel{\text{def}}{=} 0 \leq y \leq 1 \quad (7)$$

Figura 23 – Gráfico da função logística (sigmoide).




Fonte: Adaptado de Fernandes (2009).

Já a Função linear, é dada pela Equação (8) e tem seu gráfico dado pela Figura 24.

$$y = u \quad (8)$$

Figura 24 – Gráfico da função linear.



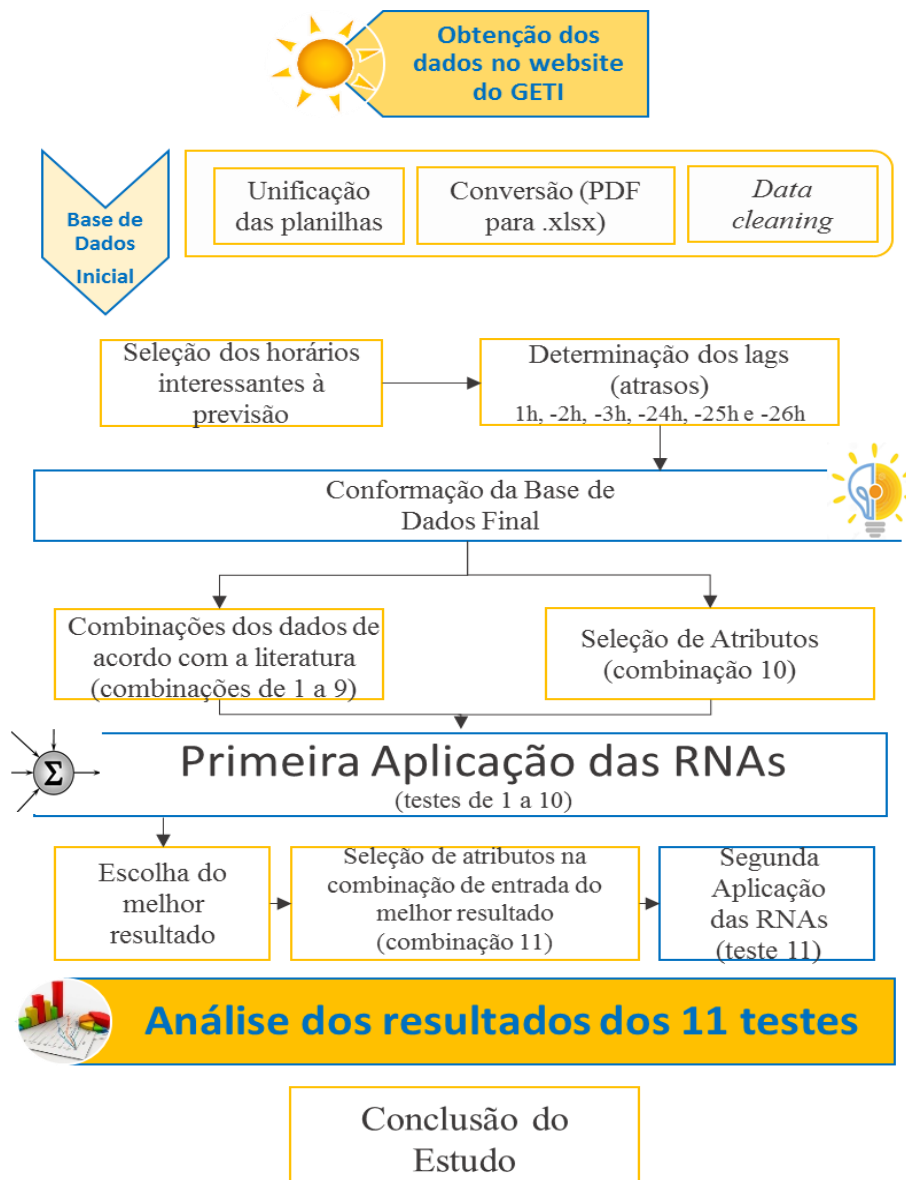
Fonte: Adaptado de Fernandes (2009).

Neste estudo foi aplicada uma topologia *feedforward* com arquitetura MLP treinada pelo algoritmo Levenberg-Marquardt. Esse algoritmo, é um processo otimizado em relação ao tempo, quando comparado com o algoritmo *backpropagation* (HAGAN; MENHAJ, 1994). A otimização é possível graças ao ajuste dos pesos sinápticos que gera uma convergência muito mais rápida (HAGAN; MENHAJ, 1994).

6 METODOLOGIA PROPOSTA

Este capítulo propõe-se a apresentar todas as etapas transcorridas para realização do trabalho. De forma muito sintética e conforme a Figura 25, o trabalho consistiu na obtenção dos dados, conformação de 2 bases (com e sem seleção de atributos), aplicação de RNAs e análise de resultados.

Figura 25 – Visão geral da metodologia proposta.



Fonte: Elaborado pelo autor (2019).

6.1 FORMAÇÃO E PRÉ-PROCESSAMENTO DA BASE DE DADOS INICIAL

O acesso ao *website* do Grupo de Estudos em Tecnologia de Irrigação (GETI), pertencente ao Departamento de Recursos Naturais e Proteção Ambiental do Centro de Ciências Agrárias da Universidade Federal de São Carlos (UFSCar), *campus* Araras/SP possibilita a obtenção de planilhas diárias em formato PDF. As coletas são horárias sob UTC-3. A Figura 26 é uma fotografia da própria estação que realiza a coleta e foi obtida junto ao *website* do GETI. A coleta é realizada por uma Estação Meteorológica Automática (EMA) sob as coordenadas 22° 18' S de latitude e 47° 23' W de longitude, com elevação de 690 m em relação ao nível do mar.

Figura 26 – EMA, UFSCar Araras.



Fonte: GETI (2019).

Cada planilha apresenta medição horária dos seguintes dados climatológicos:

- Irradiância global horizontal (GHI) [MJ/m²];
- Irradiância líquida [MJ/m²];
- Velocidade do vento média e máxima horárias [m/s];
- Umidade relativa mínima, média e máxima horárias [%];
- Temperatura mínima, média e máxima horárias [°C];
- Chuva (precipitação pluviométrica) [mm];
- Coeficiente do tanque de classe A (ECA) [mm];
- Evapotranspiração de referência realizada com o método de Penman-Monteith (EtoPm) [mm].

O *website* está segmentado em períodos de anos, que vão de 2014 a 2019. Cada ano está subdividido em meses. A primeira planilha disponível para download é de abril de 2014. Cada dia de um respectivo ano é disposto na forma de *link* para *download* da planilha.

Foram utilizados quatro anos completos de medições (2015, 2016, 2017 e 2018). É importante ressaltar que devido à manutenção da estação, não existe coleta em dezembro de 2018. Assim, a última medição é de 30/11/2018 às 23 horas.

Terminados os *downloads* de aproximadamente 1.460 planilhas (365 dias * 4 anos), o *software* Adobe Acrobat (versão de avaliação) foi utilizado para reunir todas as planilhas em um único documento, utilizando a sequência cronológica como guia. Assim, a primeira página do documento era referente à planilha de 01/01/2015 e a última referente à coleta de 30/11/2018. Posteriormente, o mesmo *software* converteu essa planilha em um arquivo do tipo .xlsx.

A planilha .xlsx foi aberta no *software* Microsoft Excel, do Pacote Office 2013. Iniciou-se o processo de *data cleaning* com a exclusão das imagens (logotipos do GETI e da UFSCar) e repetições de texto (legendas). Cada dado climatológico foi devidamente alocado em uma coluna da planilha, de forma que cada instância horária ($h, h+1, \dots, h+n$) ocupasse uma linha. Nesse momento do processo de formação da base, foram encontrados alguns dados faltantes, a saber:


- 20/03/2015 – apresentou instâncias sem dados;
- 21/03/2016 a 28/03/2016 – a coleta de 0h estava vazia;
- 08/01/2017 – a tabela deste dia apresentava valores desordenados e não se mostrava confiável;
- 28/06/2017 e 29/06/2017 – a estação estava em manutenção e não houve coleta de dados;
- 01/12/2018 a 31/12/2018 – a estação estava em manutenção e não houve coleta de dados.

As datas que apresentaram problemas tiveram suas linhas excluídas. Diante da grande quantidade de dados – mais de 34 mil coletas – essas poucas exclusões (cerca de 40) não ofereceram efeitos notórios, pois representavam apenas 0,1% do total de coletas. Assim, terminou-se por formar a Base de Dados Inicial deste projeto.

O comportamento da GHI entre 2015 e 2018 pode ser avaliado na Figura 27, gerada por meio do *software* DView, versão sem identificação. Notório que em 2015 o pico não

ultrapassou 4,1 MJ/m². De 2016 em diante, os picos giraram em torno de valores mais altos como 4,2 MJ/m² e 4,3 MJ/m². Esses picos representam também aumento de geração e são úteis no sistema brasileiro de créditos acumulados.

Figura 27 – Comportamento da GHI.



Fonte: Adaptado de DView (2019).

6.2 FORMAÇÃO DA BASE DE DADOS FINAL

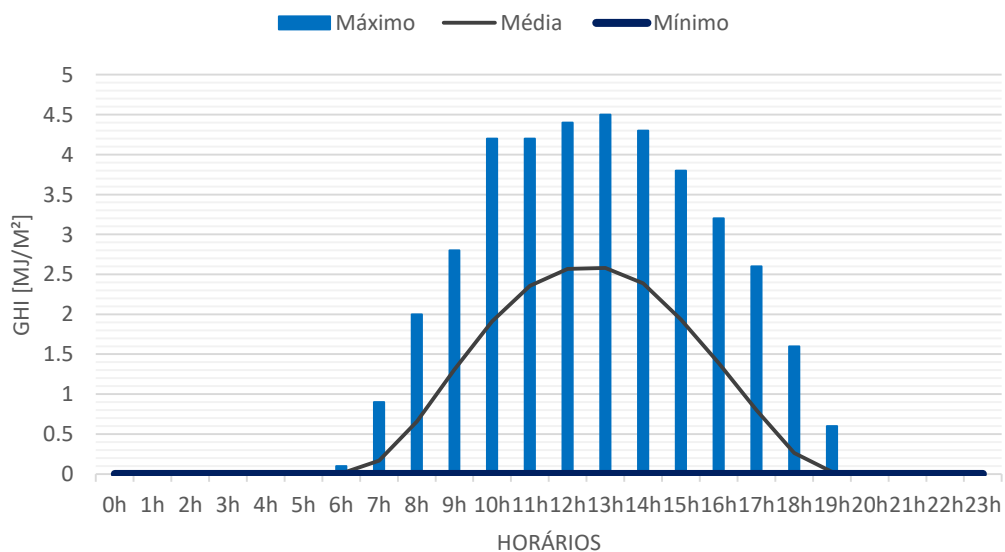
6.2.1 Identificação dos horários de previsão

Como a intenção do trabalho é previsão de irradiância global horizontal, uma segunda base foi construída. Nesta base, o foco era identificar quais os horários apresentavam irradiância considerável e que seriam horários interessantes à previsão.

Alguns períodos, principalmente à noite, apresentam ausência de irradiância solar e a GHI tem valores nulos. Em outros, a presença é insignificante ou inconstante. Na Base de Dados Inicial foi possível identificar a presença de GHI entre os horários das 6h até as 19h, porém alguns horários apresentavam valores muito baixos e intercalados com valores nulos, que não são úteis à geração de forma ordenada, constante e previsível, como necessário à manutenção de um fornecimento de energia sólido.

Deste modo, era necessário identificar o início e o final de uma faixa horária na qual a irradiância seria prevista, bem como, estimar o período em que as RNAs estariam dispensadas de estimar a irradiância, já que os valores seriam majoritariamente iguais a 0,00 MJ/m². Com isso, o trabalho das RNAs é reduzido e consequentemente os erros intrínsecos à predição. A Tabela 3 demonstra o comportamento da irradiância em cada faixa horária (0h até 23h) e a Figura 28 apresenta graficamente os resultados apresentados na Tabela 3.

Figura 28 – Intervalo de variação de GHI para cada hora do dia entre 2015 e 2018.



Fonte: Elaborado pelo autor (2019).

Tabela 3 - Variação de GHI para cada hora do dia entre 2015 e 2018.

Horário da Coleta	Número de Coletas	GHI Média [MJ/m²]	GHI Mínima [MJ/m²]	GHI Máxima [MJ/m²]
00h	1.427 coletas	0	0	0
01h	1.427 coletas	0	0	0
02h	1.427 coletas	0	0	0
03h	1.427 coletas	0	0	0
04h	1.427 coletas	0	0	0
05h	1.427 coletas	0	0	0
06h	1.427 coletas	0,008129	0	0,1
07h	1.427 coletas	0,166223	0	0,9
08h	1.427 coletas	0,656132	0	2
09h	1.427 coletas	1,306657	0	2,8
10h	1.427 coletas	1,911983	0	4,2
11h	1.427 coletas	2,35438	0	4,2
12h	1.427 coletas	2,569166	0	4,4
13h	1.427 coletas	2,579537	0	4,5
14h	1.427 coletas	2,387176	0	4,3
15h	1.427 coletas	1,93616	0	3,8
16h	1.427 coletas	1,389839	0	3,2
17h	1.427 coletas	0,800631	0	2,6
18h	1.427 coletas	0,2637	0	1,6
19h	1.427 coletas	0,025947	0	0,6
20h	1.427 coletas	0	0	0
21h	1.427 coletas	0	0	0
22h	1.427 coletas	0	0	0
23h	1.427 coletas	0	0	0

Fonte: Elaborado pelo autor (2019).

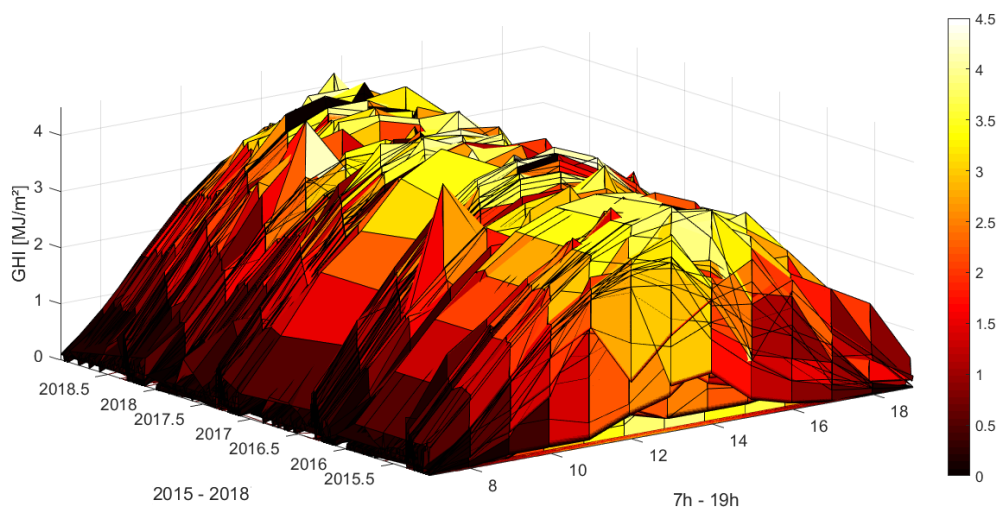
Na Tabela 3 e na Figura 28 é possível identificar o total de coletas e o valor máximo, mínimo e médio de GHI em cada horário. Interessante notar que existem coletas com valor 0,00 MJ/m² em todos os horários, até mesmo nos horários de pico (entre 12h e 13h), fato que pode ser explicado pelo bloqueio exercido pelas nuvens às componentes da GHI. Cabe notar também a diferença entre as médias e os pontos de máximo potencial. No horário de pico, 13 horas, essa diferença chega a 2,00 MJ/m².

O Apêndice A – Comportamento Horário da GHI (2015 – 2018), reúne tabelas e gráficos que possibilitam visualizar com clareza como a GHI se comportou em cada hora do dia, de acordo com as coletas, nos 4 anos observados. Nessas tabelas, o número de instâncias está distribuído em cada faixa de medição de irradiância, desde a mínima 0,00 MJ/m² até a máxima 4,5 MJ/m² com incremento de 0,10 MJ/m² entre cada faixa. Os dados desse apêndice possibilitaram gerar a Tabela 3 o gráfico da Figura 28, que sintetizam toda a informação lá contida.

Cabe explicar ainda, que o horário das 6h não foi considerado interessante à previsão já que das 1.427 coletas realizadas nesse horário aproximadamente 92% – 1.311 coletas – têm valor igual a 0,00 MJ/m² e as 8% restantes – 116 coletas – têm valor menor ou igual a 0,10 MJ/m². Por sua vez, o horário das 19h apresenta valores nulos em 1.148 coletas – 80% – e valores próximos de 0,10 MJ/m² em outras 209 coletas – 15% – mesmo assim foi considerado interessante à previsão, pois não gerou alterações significativas nos erros, além de permitir completar uma faixa horária de 12h de previsão e estar de acordo com a Figura 15.

Por fim, as instâncias de GHI consideradas interessantes à previsão e que tiveram seus dados alocados na Base Final foram aquelas coletadas entre 7h e 19h, perfazendo uma faixa horária de 12 horas, com valores de GHI a serem previstos hora a hora, caracterizando 12 previsões ao dia. Os dados entre 0h e 6h e entre 20h e 23h foram dispensados e a GHI nesses horários foi considerada nula (0,00 MJ/m²). Os dados constantes na Base Final foram fornecidos ao *software* Matlab, onde foi possível obter a Figura 29.

Figura 29 – Representação gráfica da presença de GHI na Base Final.



Fonte: Adaptado de Matlab (2019).

Na Figura 29 é possível avaliar visualmente como a GHI se comportou na faixa horária de interesse à previsão entre os anos de 2015 e 2018, ratificando também as conclusões obtidas a partir das informações da Figura 28 – Intervalo de variação de GHI para cada hora do dia entre 2015 e 2018.

6.2.2 Determinação dos atrasos (*lags*)

Antes de selecionar os atributos, foram definidos os atrasos (ou *lags*, do inglês) da variável a ser prevista e dos dados observados a serem utilizados como entrada nas redes. De forma empírica e tomando o momento da previsão como (*h*), os *lags* instituídos foram de $-1h$, $-2h$, $-3h$, $-24h$, $-25h$ e $-26h$. Essa disposição dos dados terminou de delimitar a Base Final.

6.3 COMBINAÇÃO DE DADOS

Na tentativa de obter resultados promissores e ainda embasados na literatura, algumas combinações de dados da Base Final foram utilizadas como entradas nas RNAs. As combinações não são idênticas às identificadas na literatura, pois dependem da disponibilidade de dados constantes na base. Ao total, foram 9 combinações diferentes. As combinações de variáveis utilizadas em cada teste são apresentadas na Tabela 4.

Tabela 4 – Combinações de variáveis para teste sem seleção de atributos.

Combinação	Variáveis
1	GHI ($-1h$) + temperatura média ($-1h$) + velocidade do vento média ($-1h$)
2	GHI ($-1h$) + temperatura média ($-1h$) + velocidade do vento média ($-1h$) + umidade relativa média ($-1h$)
3	GHI ($-1h$) + temperatura média ($-1h$) + velocidade do vento média ($-1h$) + chuva ($-1h$)
4	GHI ($-1h$) + GHI ($-2h$) + temperatura média ($-1h$) + temperatura média ($-2h$) + velocidade do vento média ($-1h$) + velocidade do vento média ($-2h$)
5	GHI ($-1h$) + GHI ($-2h$) + temperatura média ($-1h$) + temperatura média ($-2h$), velocidade do vento média ($-1h$) + velocidade do vento média ($-2h$) + umidade relativa média ($-1h$) + umidade relativa média ($-2h$)
6	GHI ($-1h$) + GHI ($-2h$) + temperatura média ($-1h$) + temperatura média ($-2h$) + velocidade do vento média ($-1h$) + velocidade do vento média ($-2h$) + chuva ($-1h$) + chuva ($-2h$)
7	Irradiância líquida ($-1h$), EtoPm ($-1h$) e velocidade do vento média ($-1h$)
8	GHI ($-1h$) + GHI ($-2h$) + EtoPm ($-1h$) + EtoPm ($-2h$) + velocidade do vento média ($-1h$) + velocidade do vento média ($-2h$)
9	Todas as instâncias da Base Final

Fonte: Elaborado pelo autor (2019).

Comparando as combinações da Tabela 4 com a literatura analisada na Tabela 3, muitas semelhanças são identificadas. As combinações 1, 2 e 4 são muito próximas dos trabalhos de Chen e Kartini (2017); Cornaro, Pierro e Bucci (2015); Aguiar et al. (2015); Liu et al. (2015) e Jawaid e Nazirjunejo (2016). As combinações 3 e 6 são mais semelhantes aos trabalhos de Voyant et al. (2014); Ahmad, Anderson e Lie (2015) e Notton et al. (2016). A combinação 5 tem estreita relação com o trabalho de Chen e Kartini (2017) mas também com Aguiar et al. (2015) e Ahmad, Anderson e Lie (2015). As combinações 7 e 8 são uma tentativa de associar a variável EtoPm às previsões, caracterizando uma combinação menos clássica e mais inovadora. Por fim, a combinação 9 faz uso de todos os dados da Base Final para a previsão da hora a frente.

6.3.1 SELEÇÃO DE ATRIBUTOS

Witten e Frank (2005) definem o atributo como a instância individual e independente, que fornece contribuição para o aprendizado de máquina e é caracterizado por seus valores em um conjunto fixo ou pré-definido de recursos. Assim, Liu e Motoda (1998) definem a seleção como o processo de discriminar o melhor subconjunto de atributos que será encarregado de generalizar a informação contida na base de dados em sintonia com a resposta que se deseja extrair. Dito isto, pode-se afirmar que a seleção de atributos é aplicada quando, diante de um grande número de atributos, é necessário obter os que melhor generalizam a informação.

Neste trabalho, foi empregado o método de correlação CFS (*Correlation-Based Feature Selection*, do inglês) proposto por Hall em 1999. O CFS é capaz de detectar recursos relevantes sob níveis moderados de interação, quando os recursos relevantes são individualmente preditivos da classe, pelo menos em parte do tempo (HALL, 1999). No CFS, quando as últimas cinco iterações retornam o mesmo subconjunto de atributos, é estabelecido o critério de parada, determinando assim o melhor subconjunto.

Para execução do CFS neste trabalho, utilizou-se o *software* Weka versão 3.8. Os atributos selecionados pelo *software* são apresentados na Tabela 5. Foram declarados 78 atributos constantes na Base de Dados Final, sendo eles:

- Irradiância global horizontal (GHI) (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h);
- Irradiância líquida (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h);
- Velocidade do vento média (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h) e máxima (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h) horárias;

- Umidade relativa mínima (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h), média (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h) e máxima (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h) horárias;
- Temperatura mínima (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h), média (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h) e máxima (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h) horárias;
- Chuva (precipitação pluviométrica) (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h);
- Coeficiente do tanque de classe A (ECA), (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h);
- Evapotranspiração de referência realizada com o método de Penman-Monteith (EtoPm) (-1h), (-2h), (-3h), (-24h), (-25h) e (-26h).

Tabela 5 – Seleção de atributos.

Variável predita	GHI (MJ/m ²)
Técnica	CFS
Nº de atributos declarados	78
Nº de atributos selecionados	04
Atributo selecionado 1	GHI (-1h)
Atributo selecionado 2	Chuva (-3h)
Atributo selecionado 3	Irradiância Líquida (-24h)
Atributo selecionado 4	ECA (-25h)

Fonte: Elaborado pelo autor (2019).

Como visto na Tabela 5, dos 78 atributos declarados, apenas 4 deles melhor generalizaram a informação referente à irradiância global horizontal contida. Foram eles: GHI (-1h), Chuva (-3h), Irradiância Líquida (-1h), GHI (-24h) e ECA (-25h). Cabe mencionar que o resultado da seleção de atributos é chamado de combinação 10 e irá servir como entrada para o teste 10.

6.4 APLICAÇÃO DAS REDES NEURAS ARTIFICIAS

As 10 combinações de dados obtidas até esta etapa do trabalho (9 combinações baseadas na literatura e 1 combinação baseada em seleção de atributos) foram fornecidas às Redes Neurais Artificiais para que fosse realizada a previsão da GHI hora à frente com as informações disponíveis. Todas as especificações das RNAs são apresentadas na Tabela 6.

Tabela 6 – Detalhamento das RNAs aplicadas.

Técnica de Previsão	Redes Neurais Artificiais
Arquitetura	<i>Multilayer Percetron</i> (MLP)
Algoritmo de treinamento	Levenberg-Marquardt
Erro quadrático médio	10^{-12}
Máximo de épocas	250
Topologia	1 e 2 camadas neurais escondidas
Função de ativação (camada escondida)	Logística (sigmoide)
Função de ativação (camada de saída)	Linear

Fonte: Elaborado pelo autor (2019).

Em relação às topologias, para as RNAs com 1 camada neural escondida, foram utilizados 3, 6, 9, 12, 15, 18, 21, 24, 27 e 30 neurônios. Já a quantidade de neurônios utilizada nas RNAs com 2 camadas neurais escondidas é exposta na Tabela 7.

Tabela 7 – Quantidade de neurônios nas redes com 2 camadas escondidas.

1ª camada escondida	2ª camada escondida
3	3, 6, 9, 12, 15, 18, 21, 24 e 27
6	3, 6, 9, 12, 15, 18, 21 e 24
9	3, 6, 9, 12, 15, 18 e 21
12	3, 6, 9, 12, 15 e 18
15	3, 6, 9, 12 e 15

Fonte: Elaborado pelo autor (2019).

Para o treinamento das RNAs foram utilizados 70% do conjunto de dados, enquanto para o teste foram utilizados os 30% restantes. Cada topologia foi executada 5 vezes para as RNAs com uma e duas camadas neurais.

Terminada a previsão, os 10 testes tiveram seus resultados comparados entre si com o intuito de identificar qual teste apresentava resultados mais próximos da realidade. A comparação entre eles se deu através das métricas de erro, descritas na próxima seção.

6.5 MÉTRICAS DE AVALIAÇÃO DOS MODELOS PREDITIVOS

Nas últimas décadas, tem havido uma proliferação em número e tipo de modelagens climáticas e ambientais. Assim, cresceu também o interesse na determinação de formulações que produzam estimativas mais precisas e acuradas das variáveis de interesse (WILLMOTT; MATSUURA, 2005).

As chamadas estatísticas ou métricas de erro são usadas para comparar modelos de estimativa com observações independentes e confiáveis (WILLMOTT; MATSUURA, 2005). Como as métricas de erro apresentam diferentes formulações, deve-se esperar que os resultados entre elas também sejam diferentes, de modo que, em muitos casos, várias métricas são necessárias para fornecer uma imagem completa da distribuição de erros (CHAI; DRAXLER, 2014). Neste trabalho foram empregadas algumas métricas que são descritas nesta seção.

O Erro Absoluto Médio – Equação (9) – (*Mean Absolute Error* – MAE, do inglês) afere a significância média dos erros em um grupamento de valores provenientes de métodos de previsão. É uma medida útil e amplamente utilizada em avaliações desse tipo (CHAI; DRAXLER, 2014). Apresenta sua forma percentual através do Erro Percentual Absoluto Médio – Equação (10) – (*Mean Absolute Percentual Error* – MAPE, do inglês). V_i é a instância observada no ambiente e v_i é a instância estimada pelo modelo.

$$MAE = \frac{1}{n} \sum_{i=1}^n |V_i - v_i| \quad (9)$$

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|V_i - v_i|}{V_i} \quad (10)$$

O Erro Quadrático Médio da Raiz – Equação (11) – (*Root Mean Square Error* – RMSE do inglês) pondera de forma quadrática a significância média do erro e tem sido usado como métrica estatística padrão para medir o desempenho de modelos em meteorologia como qualidade do ar e pesquisas de cunho climático (CHAI; DRAXLER, 2014). Caracteriza-se como a diferença entre os valores preditos por um determinado modelo e os valores observados no ambiente em questão. Pode ser normalizado (nRMSE) pelo intervalo ou pela média – Equação (12) – dos dados observados. A normalização é útil quando se deseja compará-lo com os resultados de outros autores. Neste trabalho, aplicou-se a normalização pela média como proposto pela Equação (12). V_i é a instância observada no ambiente, v_i é a instância estimada pelo modelo e \bar{v}_i é a média dos valores estimados.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{(V_i - v_i)^2}{n}} \quad (11)$$

$$nRMSE = \frac{RMSE}{\bar{v}_i} \quad (12)$$

Embora RMSE e MAE venham sendo usados para avaliar o desempenho de modelos há muito tempo, não há consenso sobre a métrica mais apropriada (CHAI; DRAXLER, 2014).

7 RESULTADOS E DISCUSSÃO

Esta seção apresenta os melhores resultados obtidos com o treinamento e validação e a topologia referente. Após analisar os resultados obtidos por cada um dos 10 experimentos (denominados como testes), notou-se que o teste 2 foi o mais acurado. Uma nova seleção de atributos foi aplicada na combinação 2, ou seja, a combinação de dados de entrada do teste 2. Essa aplicação gerou a combinação de dados 11 e, conseqüentemente, o teste 11.

Assim, na Tabela 8 são apresentados os resultados de 5 execuções do teste 2, as quais são definidas por distintas topologias nomeadas pelas letras de A à E. Neste sentido, a topologia A se destaca como melhor resultado através da métrica MAE, enquanto a topologia D é melhor em termos de RMSE e nRMSE.

Tabela 8 – Resultados obtidos no teste 2.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m ²)	0,063750174	0,10649	0,087663	0,07662	0,086471
RMSE (MJ/m ²)	0,100332744	0,14916	0,104627	0,092377	0,130668
nRMSE	0,06826364	0,097432	0,068794	0,059536	0,086024

Fonte: Elaborado pelo autor (2019).

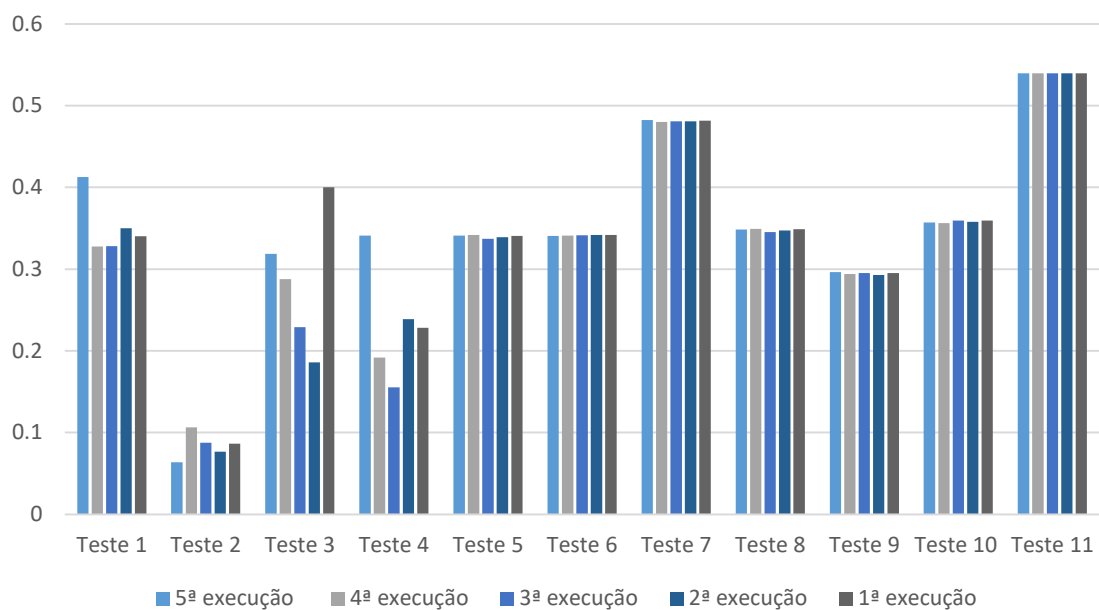
As topologias apresentadas na Tabela 8 são descritas a seguir:

- A. 2 camadas neurais escondidas com 3 e 9 neurônios;
- B. 2 camadas neurais escondidas com 3 e 9 neurônios;
- C. 2 camadas neurais escondidas com 3 e 9 neurônios;
- D. 2 camadas neurais escondidas com 3 e 15 neurônios;
- E. 2 camadas neurais escondidas com 3 e 9 neurônios.

Conforme explicado na Seção 6.3, o teste 2 foi uma tentativa de combinação de dados de entrada, que teve como base os artigos consultados na revisão da literatura e que fortuitamente apresentou erros mais baixos que os outros testes, incluindo aquele com seleção de atributos, teste 10. Ademais, a partir dos atributos que compõem o teste 2, buscou-se realizar a seleção destes atributos, gerando assim o teste 11 que foi composto por apenas a GHI (-1h). Nesse teste, foram utilizados os mesmos parâmetros aplicados no treinamento e teste das RNAs previamente executadas. Os resultados obtidos no teste 11 também não superaram aqueles apresentados pelo teste 2 (Tabela 8).


Com o intuito de sumarizar todos os resultados obtidos pelos testes de 1 a 11, as Figuras de 30 a 32 compara-os em termos das métricas previamente definidas. Os gráficos corroboram a afirmação sobre o teste 2 ser o mais promissor em duas de suas topologias: A (2 camadas neurais escondidas com 3 e 9 neurônios) e D (2 camadas neurais escondidas com 3 e 15 neurônios). Enquanto a melhor solução obtida com seleção de atributos, teste 10 foi dada pela topologia B (2 camadas neurais escondidas com 12 e 9 neurônios). Os resultados dessas topologias justapostos para simples observação são apresentados na Tabela 9 e Figura 33.

Figura 30 – Comparação gráfica através da métrica MAE entre previsões.




Fonte: Elaborado pelo autor (2019).

Figura 31 – Comparação gráfica através da métrica RMSE entre previsões.



Fonte: Elaborado pelo autor (2019).

Figura 32 – Comparação gráfica através da métrica nRMSE entre previsões.



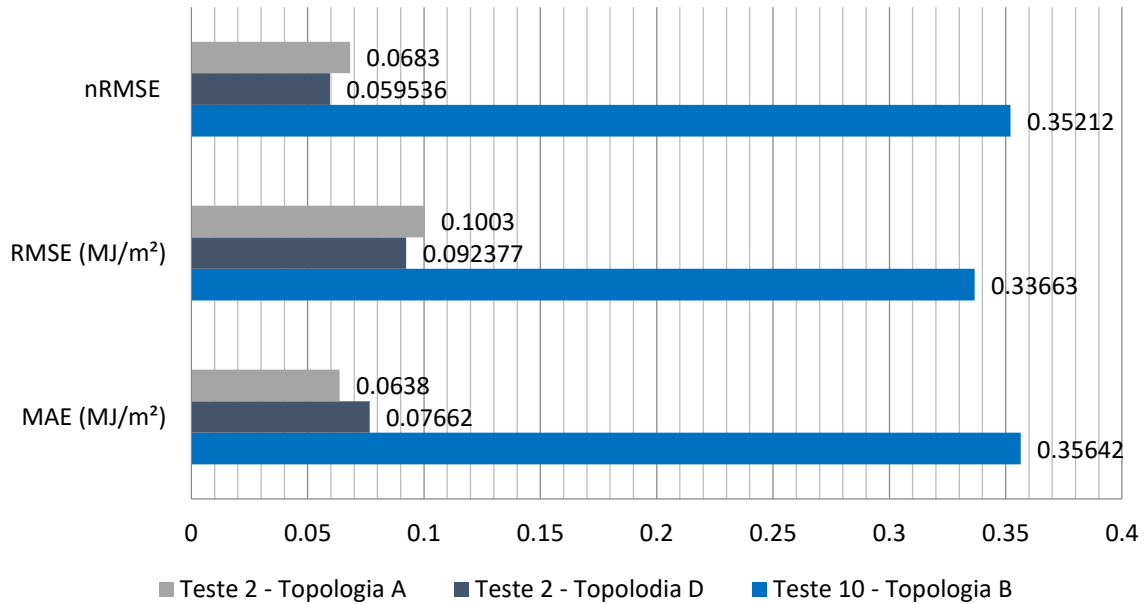
Fonte: Elaborado pelo autor (2019).

Tabela 9 – Comparação entre os resultados dos testes 2 e 10.

Teste	Teste 2 Topologia A	Teste 2 Topologia D	Teste 10 Topologia B
MAE (MJ/m ²)	0,063750174	0,07662	0,35642
RMSE (MJ/m ²)	0,100332744	0,092377	0,33663
nRMSE	0,06826364	0,059536	0,35212

Fonte: Elaborado pelo autor (2019).


Figura 33 – Comparação gráfica entre os resultados dos testes 2 e 10.



Fonte: Elaborado pelo autor (2019).

Por fim, a Figura 34 permite comparar através da métrica nRMSE as publicações consultadas na literatura com os resultados produzidos por este trabalho. As colunas azuis indicam os resultados obtidos nos testes 2 e 10, enquanto as colunas acinzentadas indicam os que foram encontrados na revisão da literatura, Tabela 1.

Figura 34 - Comparação de resultados com a literatura.



Fonte: Elaborado pelo autor (2019).

É possível afirmar a boa acurácia encontrada na predição de GHI através do teste 2, a partir dos resultados alinhados numa escala crescente. Mghouchi et al. (2019) obtiveram $nRMSE = 0,0550$ ou 5,50%, enquanto o teste 2 Topologia D, de forma muito aproximada, obteve $nRMSE = 0,0595$ ou 5,95%.

Contudo, o trabalho dos autores apresentava algumas diferenças. Mghouchi et al. (2019) utilizaram 511 combinações de dados de um banco com 33 localidades diferentes e horizonte de 24 horas à frente. Neste trabalho foram 11 combinações em uma única localidade. O autor também aplicou uma RNA MLP, porém o treinamento era backpropagation, enquanto nesta metodologia o treinamento foi por Levenberg-Marquardt. A combinação de dados dos autores que obteve o melhor resultado foi:

- Índice de céu claro (quociente entre a GHI média diária e a irradiância no topo da atmosfera);
- Temperatura média (em comum com o Teste 2);
- Diferença de temperatura (temperatura máxima diária – temperatura mínima diária);
- GHI mensurada no topo da atmosfera.

Vale ressaltar que a GHI dos autores foi mensurada no topo da atmosfera, enquanto a mesma variável utilizada na metodologia proposta foi mensurada à nível do solo. A literatura é extensa e unânime quando analisa medições de GHI e identifica que as mensurações à nível do solo sofrem severa influência de gases, albedo e particulados provenientes principalmente da queima de combustíveis fósseis e da construção civil. Assim, o resultado obtido com métricas de erro similar a do autor, comprova o potencial da combinação de dados e do método preditivo adotado.

O Apêndice B reúne o melhor resultado obtido em cada uma das execução dos 11 testes, mas que não superam os resultados obtidos no teste 2. O Apêndice B ainda especifica a respectiva topologia de cada uma dessas execuções.

8 CONCLUSÕES

8.1 CONCLUSÕES GERAIS

Este trabalho se propôs a usar dados climáticos diários e horários como sinais de entrada em redes neurais artificiais com o intuito de prever a irradiância global horizontal, mais conhecida pela sigla inglesa GHI. A arquitetura utilizada foi a *Multilayer Perceptron*, que é um modelo clássico quando se trabalha com previsão de variáveis climáticas. Com auxílio da literatura, 11 combinações diferentes de dados foram avaliadas pelos modelos preditivos baseados em redes neurais artificiais, considerando o conjunto de dados com e sem atributos selecionados. Por fim, compararam-se os resultados obtidos com a mesma literatura previamente consultada através da métrica RMSE normalizada.

Percebeu-se que duas topologias, nomeadas pelas letras (A) e (D), ambas do teste 2, se destacaram, obtendo resultados melhores que 8 dos 9 autores comparados pela supracitada métrica. Enquanto Mghouchi et al. (2019) atingiu $nRMSE = 5,50\%$, os resultados obtidos através da metodologia proposta por esse trabalho foram $nRMSE = 5,95\%$ para o teste 2 em sua topologia D.

O teste 10, cujas variáveis de entrada foram escolhidas a partir da seleção de atributos, não demonstrou acurácia, apresentando erros maiores que a maioria dos outros testes. Em termos de $nRMSE$, o melhor resultado obtido para o teste 10 foi de $35,21\%$ que é aproximadamente 7 vezes maior que o erro de $5,95\%$ obtido com o teste 2 – topologia D.

O teste 11, que foi uma segunda tentativa de seleção de atributos, aplicada na combinação de dados do teste 2 foi a menos promissora de toda a pesquisa. Seus índices de erro nas métricas avaliadas são maciçamente mais expressivos que os outros 10 testes.

Por fim, constatou-se que a aplicação de Redes Neurais Artificiais para previsão de GHI à curtíssimo prazo (hora a frente) é uma ferramenta adequada, dado o potencial demonstrado. Ademais, previsões acuradas são de extrema importância aos gerenciadores das redes de energia elétrica e daqueles que formulam políticas nestes termos.

8.2 TRABALHOS FUTUROS

Esta pesquisa ainda apresenta alguns aspectos potenciais que podem ser estudados. Entre eles, sugere-se a obtenção de dados semelhantes aos utilizados por Mghouchi et al. (2019), com o intuito de agregá-los à combinação do teste 2 e, assim, buscar reduzir ainda mais os erros. Por fim, em uma abordagem metodológica diferente da proposta, utilizar outros algoritmos de *machine learning*, como é o caso das redes neurais recorrentes, *extreme*

learning machine e *long short-term machine* além de aplicar outros métodos de seleção de atributo.

REFERÊNCIAS BIBLIOGRÁFICAS

ABRAMO, G.; D'ANGELO, C. A.; VIEL, F. The field-standardized average impact of national research systems compared to world average: the case of Italy. **Scientometrics**, [s.l.], v. 88, n. 2, p.599-615, 2011.

AGUIAR, L. M. et al. Use of satellite data to improve solar radiation forecasting with Bayesian Artificial Neural Networks. **Solar Energy**, [s.l.], v. 122, p.1309-1324, dez. 2015. Elsevier BV.

AGUIAR, L. M. et al. Combining solar irradiance measurements, satellite-derived data and a numerical weather prediction model to improve intra-day solar forecasting. **Renewable Energy**, [s.l.], v. 97, p.599-610, nov. 2016. Elsevier BV.

AHMAD, A.; ANDERSON, T. N.; LIE, T. T. Hourly global solar irradiation forecasting for New Zealand. **Solar Energy**, [s.l.], v. 122, p.1398-1408, dez. 2015. Elsevier BV.

ALEMANHA. BUNDESMINISTERIUM FÜR WIRTSCHAFT UND ENERGIE (BMWi) - MINISTÉRIO DA ECONOMIA E ENERGIA. **Informations Portal Erneuerbare Energien**. 2016. Disponível em: <<https://www.erneuerbare-energien.de/EE/Redaktion/DE/Downloads/zeitreihen-zur-entwicklung-der-erneuerbaren-energien-in-deutschland-1990-2015.pdf>>. Acesso em: 11 jan. 2019.

ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration: guidelines for computing crop water requirements**. Roma: FAO, 1998. 300 p. (Irrigation and Drainage, n.56).

AMAZONAS ENERGIA (Brasil). **Mini usinas fotovoltaicas de comunidades isoladas do interior são reativadas**. 2017. Disponível em: <<http://www.eletronbrasamazonas.com/cms/index.php/mini-usinas-fotovoltaicas-de-comunidades-isoladas-do-interior-sao-reativadas/>>. Acesso em: 26 ago. 2019.

ANTONANZAS, J. et al. Review of photovoltaic power forecasting. **Solar Energy**, [s.l.], v. 136, p.78-111, out. 2016. Elsevier BV.

AYET, A.; TANDEO, P. Nowcasting solar irradiance using an analog method and geostationary satellite images. **Solar Energy**, [s.l.], v. 164, p.301-315, abr. 2018. Elsevier BV.

BACHER, P.; MADSEN, H.; NIELSEN, H. A. Online short-term solar power forecasting. **Solar Energy**, [s.l.], v. 83, n. 10, p.1772-1783, out. 2009. Elsevier BV.

BALIYAN, A.; GAURAV, K.; MISHRA, S. K. A. Review of short term load forecasting using Artificial Neural Network Models. **Procedia Computer Science**, [s.l.], v. 48, p. 121–125, jan. 2015.

BENALI, L. et al. Solar radiation forecasting using artificial neural network and random forest methods: Application to normal beam, horizontal diffuse and global components. **Renewable Energy**, [s.l.], v. 132, p.871-884, mar. 2019. Elsevier BV.

BOUZERDOUM, M.; MELLIT, A.; PAVAN, A. M. A hybrid model (SARIMA–SVM) for short-term power forecasting of a small-scale grid-connected photovoltaic plant. **Solar Energy**, [s.l.], v. 98, p.226-235, dez. 2013. Elsevier BV.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: forecasting and control**. 4. ed. Hoboken, NJ: John Wiley & Sons, Inc., 2008.

BRASIL. Ministério de Minas e Energia (MME). Agência Nacional de Energia Elétrica (ANEEL). **Resolução Normativa nº 687/2015**, de 27 de novembro de 2015. Brasília, DF. 2015a. Disponível em: <<http://www2.aneel.gov.br/cedoc/ren2015687.pdf>>. Acesso em: 11 set. 2019.

BRASIL. Ministério de Minas e Energia (MME). Empresa de Pesquisa Energética (EPE). **Energia renovável representa mais de 42% da matriz energética brasileira**. 2015b. Disponível em: <<http://www.brasil.gov.br/meio-ambiente/2015/11/energia-renovavel-representa-mais-de-42-da-matriz-energetica-brasileira>>. Acesso em: 11 maio 2018.

BRASIL. Ministério de Minas e Energia (MME). Empresa de Pesquisa Energética (EPE). **Plano Decenal de Expansão de Energia 2026**. 2016. Disponível em: <<http://www.mme.gov.br/documents/10584/0/PDE2026.pdf/474c63d5-a6ae-451c-8155-ce2938fbf896>>. Acesso em: 27 de ago. 2019.

BRASIL. Resolução Federal nº 02, de 29 de junho de 2017. Brasília: **DOU - Diário Oficial da União**. Brasília, DF. 2017a. Seção 1, p. 96.

BRASIL. RODRIGO LIMP NASCIMENTO. Consultoria Legislativa da Câmara dos Deputados. **Energia Solar no Brasil: Situação e Perspectiva**. Brasília, DF. 2017b. 46 p.

BRASIL. Governo do Estado de São Paulo. Secretaria de Infraestrutura e Meio Ambiente. **Villa-Lobos é o primeiro parque abastecido por energia solar**. 2017c. Disponível em: <<https://www.infraestruturameioambiente.sp.gov.br/2017/01/villa-lobos-e-o-primeiro-parque-do-brasil-a-ser-totalmente-abastecido-por-energia-solar/>>. Acesso em: 26 ago. 2019.

BRASIL. Ministério de Minas e Energia (MME). Agência Nacional de Energia Elétrica (ANEEL). **Capacidade de Geração do Brasil**. 2019a. Disponível em: <<http://www2.aneel.gov.br/aplicacoes/capacidadebrasil/OperacaoCapacidadeBrasil.cfm>>. Acesso em: 27 ago. 2019.

BRASIL. Ministério da Ciência, Tecnologia, Inovações e Comunicações (MCTIC). Instituto Brasileiro de Informação em Ciência e Tecnologia (IBICT). **Glossário**. 2019b. Disponível em: <<http://energiaheliotermica.gov.br/pt-br/glossario>>. Acesso em: 09 jan. 2019.

BRASIL. PREFEITURA MUNICIPAL DE ARARAS. **Conheça um pouco da História de Araras**. 2019c. Disponível em: <<http://araras.sp.gov.br/historia/>>. Acesso em: 29 jan. 2019.

CHAI, T.; DRAXLER, R. R. Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature. **Geoscientific Model Development**, [s.l.], v. 7, n. 3, p.1247-1250, 30 jun. 2014. Copernicus GmbH.

CHEN, C.; KARTINI, U. K-Nearest Neighbor neural network models for very short-term global solar irradiance forecasting based on meteorological data. **Energies**, [s.l.], v. 10, n. 2, p.186-204, 8 fev. 2017. IEEE.

CHU, Y. et al. Real-time forecasting of solar irradiance ramps with smart image processing. **Solar Energy**, [s.l.], v. 114, p.91-104, abr. 2015. Elsevier BV.

CLIMATE-DATA (Alemanha). **Clima: Alemanha**. 2019a. Elaborado por AM ONLINE PROJECTS - ALEXANDER MERKEL. Disponível em: <<https://pt.climate-data.org/europa/alemanha-232/>>. Acesso em: 30 jan. 2019.

CLIMATE-DATA (Alemanha). **Clima: República Popular da China**. 2019b. Elaborado por AM ONLINE PROJECTS - ALEXANDER MERKEL. Disponível em: <<https://pt.climate-data.org/asia/republica-popular-da-china-110/>> Acesso em: 30 jan. 2019.

CLIMATE-DATA (Alemanha). **Clima: Araras**. 2019c. Elaborado por AM ONLINE PROJECTS - ALEXANDER MERKEL. Disponível em: <<https://pt.climate-data.org/america-do-sul/brasil/sao-paulo/araras-10675/>>. Acesso em: 30 jan. 2019.

CORNARO, C.; PIERRO, M.; BUCCI, F. Master optimization process based on neural networks ensemble for 24-h solar irradiance forecast. **Solar Energy**, [s.l.], v. 111, p.297-312, jan. 2015. Elsevier BV.

CRISOSTO, C. et al. One-hour prediction of the Global Solar Irradiance from all-sky images using Artificial Neural Networks. **Energies**, [s.l.], v. 11, n. 11, p.2906-2922, 25 out. 2018. MDPI AG.

CRONIN, T. W. On the choice of average Solar Zenith Angle. **Journal Of The Atmospheric Sciences**, [s.l.], v. 71, n. 8, p.2994-3003, ago. 2014. American Meteorological Society.

CUNHA, A. R. Coeficiente do tanque Classe A obtido por diferentes métodos em ambiente protegido e no campo. In: SEMINA CIÊNCIAS AGRÁRIAS, 2, 2011, Londrina. **Revista Cultural e Científica**. Londrina: Ed.uel, 2011. p. 451 - 464.

CURRIE, G. et al. Policy options to regulate pv in low voltage grids-australian case with international implications. **Technology and Economics of Smart Grids and Sustainable Energy**, [s.l.], v. 4, n. 1, p.1-10, 26 jun. 2019.

DAVID, M. et al. Probabilistic forecasting of the solar irradiance with recursive ARMA and GARCH models. **Solar Energy**, [s.l.], v. 133, p.55-72, ago. 2016. Elsevier BV.

DIAGNE, M. et al. Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. **Renewable and Sustainable Energy Reviews**, [S.l.], v. 27, p.65-76, nov. 2013. Elsevier BV.

DUARTE, F. M. **Acurácia de previsões para vazão em redes**: Um comparativo entre ARIMA, GARCH e RNA. 2014. 81 f. Dissertação (Mestrado) – Curso de Ciência da Computação, Centro de Informática, Universidade Federal de Pernambuco, Recife, 2014.

ESTADOS UNIDOS DA AMÉRICA (EUA). Office of Energy Efficiency & Renewable Energy. U.S. Department of Energy. **Solar Radiation Basics**. 2013. Disponível em: <<https://www.energy.gov/eere/solar/articles/solar-radiation-basics>>. Acesso em: 08 jan. 2019.

ESTADOS UNIDOS DA AMÉRICA (EUA). Central Intelligence Agency (CIA). **The World Factbook: Country Comparison - Electricity Consumption**. Washington, 2017. Disponível em: <<https://www.cia.gov/library/publications/the-world-factbook/rankorder/2233rank.html>>. Acesso em: 21 mar. 2018.

FAYYAD, U.; PIATETSKY-SHAPIRO, G.; SMYTH, P. knowledge discovery and data mining: Towards a unifying framework. **Proceedings of the Second International Conference on Knowledge Discovery and Data Mining**, p. 82–88, 1996.

FERNANDES, R. A. S. **Identificação de fontes de correntes harmônicas por redes neurais artificiais**. 2009. 105 f. Dissertação (Mestrado) – Curso de Engenharia Elétrica, Universidade de São Paulo, São Carlos, 2009.

FUNARI, F. L.; TARIFA, J. R. Sunshine, global radiation and net radiation in Brazil.

Revista do Instituto Geológico, [s.l.], v. 38, n. 2, p.49-83, 2017. GN1 Genesis Network.

Grupo de Estudos em Tecnologia de Irrigação (GETI). **Dados Meteorológicos**. 2015-2018. Disponível em: <<http://www.meteorologia-ara.ufscar.br/dados-meteorologicos/estacao-meteorologica-automatica-ema/>>. Acesso em: 30 abr. 2019.

GÓMEZ, J. M. R. et al. A irradiância solar: conceitos básicos. **Revista Brasileira de Ensino de Física**, [s.l.], v. 40, n. 3, p.1-12, 26 mar. 2018.

HAGAN, M. T.; MENHAJ, M. B. Training feedforward networks with the Marquardt algorithm. **IEEE Transactions on Neural Networks**, v. 5, n. 6, p. 989–993, 1994.

HALL, M. A. **Correlation-based Feature Selection for Machine Learning**. [s.l.] The University of Waikato, 1999.

HAN, J.; KAMBER, M. **Data Mining: Concepts and Techniques**. 2. ed. [s.l.] Diane Cerra, 2006.

HAYKIN, Simon. **Redes Neurais: Princípios e Prática**. 2. ed. São Paulo: Bookman, 2003. 898 p.

HE, Y.; STOJMENOVIC, I.; GU, Y. Smart City. **International Journal Of Distributed Sensor Networks**, [s.l.], p. 1-2. 29 maio 2014.

HEIM, D. The simultaneous effect of the operating temperature and solar radiation on the efficiency of photovoltaic panels. **Archives of Civil Engineering**, [s.l.], v. 57, n. 3, p.261-274, 1 set. 2011.

IBGE (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA) (Brasil). **População nos censos demográficos, segundo as grandes regiões e as unidades da federação - 1872/2010**. 2010a. Disponível em: <<https://ww2.ibge.gov.br/home/estatistica/populacao/censo2010/default.shtm>>. Acesso em: 20 mar. 2018.

IBGE (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA) (Brasil). **Domicílios particulares permanentes, por existência de energia elétrica, segundo as grandes regiões e unidades da federação - 2010**. 2010b. Disponível em: <<https://censo2010.ibge.gov.br/sinopse/index.php?dados=P13&uf=00>>. Acesso em: 07 jan. 2019.

IBGE (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA) (Brasil). **Panorama Araras**. 2010c. Disponível em: <<https://cidades.ibge.gov.br/brasil/sp/araras/panorama>>. Acesso em: 30 jan. 2019.

IBGE (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA) (Brasil). **Panorama Araras**. 2017. Disponível em: <<https://cidades.ibge.gov.br/brasil/sp/araras/panorama>>. Acesso em: 30 jan. 2019.

INHOFFEN, J.; SIEMROTH, C.; ZAHN, P. Minimum prices and social interactions: Evidence from the German renewable energy program. **Energy Economics**, [s.l.], v. 78, p.350-364, fev. 2019. Elsevier BV.

INMAN, R. H.; PEDRO, H. T. C.; COIMBRA, C. F. M. Solar forecasting methods for renewable energy integration. **Progress In Energy And Combustion Science**, [s.l.], v. 39, n. 6, p.535-576, dez. 2013.

INTERNATIONAL ENERGY AGENCY (IEA) (França). **Snapshot of Global Photovoltaic Markets**. Paris. 2016.

INTERNATIONAL ENERGY AGENCY (IEA) (França). **World Energy Outlook**. Paris, 2017.

INTERNATIONAL ENERGY AGENCY (IEA) (França). **Key Electricity Trends 2017**. Paris, 2018.

INTERNATIONAL ENERGY AGENCY (IEA) (França). **Solar Energy**. Paris. 2019a.

INTERNATIONAL ENERGY AGENCY (IEA) (França). **Snapshot of Global PV Markets**. Paris. 2019b.

JAWAID, F.; NAZIRJUNEJO, K. Predicting daily mean solar power using machine learning regression techniques. **2016 Sixth International Conference On Innovative Computing Technology (INTECH)**, [s.l.], p.355-360, ago. 2016. IEEE.

KANKAL, M. et al. Modeling and forecasting of Turkey's energy consumption using socio-economic and demographic variables. **Applied Energy**, [s.l.], v. 88, n. 5, p.127-1939, maio 2011.

KEMMOKU, Y. et al. Daily insolation forecasting using a multi-stage neural network. **Solar Energy**, [s.l.], v. 66, n. 3, p.193-199, jun. 1999. Elsevier BV.

KOPP, E. Probability and measure. **From Measures To Itô Integrals**, [s.l.], p.1-11, 2011. Cambridge University Press.

LAURET, P.; DIAGNE, M.; DAVID, M. A Neural Network post-processing approach to improving NWP solar radiation forecasts. **Energy Procedia**, [s.l.], v. 57, p.1044-1052, 2014. Elsevier BV.

LIMA, F. J. L. et al. Forecast for surface solar irradiance at the Brazilian Northeastern region using NWP model and artificial neural networks. **Renewable Energy**, [s.l.], v. 87, p.807-818, mar. 2016. Elsevier BV.

LIU, H.; MOTODA, H. **Feature Selection for Knowledge Discovery and Data Mining**. [s.l.]: Springer, 1998. 214 p.

LIU, J. et al. An improved photovoltaic power forecasting model with the assistance of aerosol index data. **IEEE Transactions On Sustainable Energy**, [s.l.], v. 6, n. 2, p.434-442, abr. 2015. Institute of Electrical and Electronics Engineers (IEEE).

LIU, Z. China's strategy for the development of renewable energies. **Energy Sources, Part B: Economics, Planning, and Policy**, [s.l.], v. 12, n. 11, p.971-975, 19 jul. 2017. Informa UK Limited.

MAGARREIRO, C.; FREITAS, S.; BRITO, M. C. Radiação e Energia Solar. **Gazeta de Física**, Lisboa, v. 39, n. 12, p.57-59, jun. 2016. Sociedade Portuguesa de Física (SP Física).

MARX, W. et al. Which early works are cited most frequently in climate change research literature? A bibliometric approach based on reference publication year spectroscopy. **Scientometrics**, v. 110, n. 1, p.335-353, 2016.

MCCANDLESS, T. C.; HAUPT, S. E.; YOUNG, G. S. A regime-dependent artificial neural network technique for short-range solar irradiance forecasting. **Renewable Energy**, [s.l.], v. 89, p.351-359, abr. 2016. Elsevier BV.

MGHOUCHI, Y. E. et al. Assessment of different combinations of meteorological parameters for predicting daily global solar radiation using artificial neural networks. **Building And Environment**, [s.l.], v. 149, p.607-622, fev. 2019. Elsevier BV.

MILLER, S. D. et al. Short-term solar irradiance forecasting via satellite/model coupling. **Solar Energy**, [s.l.], v. 168, p.102-117, jul. 2018. Elsevier BV.

MOHANTY, S. P.; CHOPPALI, U.; KOUGIANOS, E. Everything you wanted to know about smart cities: The Internet of things is the backbone. **IEEE Consumer Electronics Magazine**, [s.l.], v. 5, n. 3, p. 60–70, jul. 2016.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2. ed. São Paulo: Blucher, 2006. 538 p.

NATIONAL AERONAUTICS AND SPACE ADMINISTRATION (NASA) (Estados Unidos da América). **Solar Irradiance**. 2018. Disponível em: <https://www.nasa.gov/mission_pages/sdo/science/solar-irradiance.html>. Acesso em: 08 jan. 2019.

NOTTON, G. et al. Some applications of ANN to solar radiation estimation and forecasting for energy applications. **Applied Sciences**, [s.l.], v. 9, n. 1, p.209-229, 8 jan. 2019. MDPI AG.

NUOSHU, H.; COUTO JUNIOR, F. Brasil pode replicar sucesso da China na indústria solar? 2016. Disponível em: <<https://dialogochino.net/wp/wp-content/uploads/2019/01/DC-Solar-Report-v5-PT.pdf>>. Acesso em> 04 set. 2019.

ÓRIGO ENERGIA (Brasil). **Comunidades isoladas também são beneficiadas pela energia solar**. 2017. Disponível em: <<https://origoenergia.com.br/comunidades-isoladas-tambem-sao-beneficiadas-pela-energia-solar/>>. Acesso em: 26 ago. 2019.

PAOLI, C. et al. Forecasting of preprocessed daily solar radiation time series using neural networks. **Solar Energy**, [s.l.], v. 84, n. 12, p.2146-2160, dez. 2010. Elsevier BV.

PAPAGIANNAKI, K. et al. Long-term forecasting of Internet backbone traffic: observations and initial models. **Ieee Infocom 2003. Twenty-second Annual Joint Conference Of The Ieee Computer And Communications Societies**, [s.l.], p.1178-1188, 2003. IEEE.

PORTO, R. L. L.; Filho, F. P.; Silva, R. M. Evapotranspiração. 2003. 31 p. Notas de Aula. Disciplina PHD – 307 Hidrologia Aplicada. Escola Politécnica da Universidade de São Paulo – USP.

RAMSAMI, P.; OREE, V. A hybrid method for forecasting the energy output of photovoltaic systems. **Energy Conversion And Management**, [s.l.], v. 95, p.406-413, maio 2015. Elsevier BV.

ROMERO, A. F.; QUILUMBA, F. L.; ARCOS, H. N. Short-term active power forecasting of a photovoltaic power plant using an artificial neural network. **2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM)**, [s.l.], v. [s.l.], p.[s.l.], out. 2017. IEEE.

SHADDEL, M.; JAVAN, D. S.; BAGHERNIA, P. Estimation of hourly global solar irradiation on tilted absorbers from horizontal one using Artificial Neural Network for case study of Mashhad. **Renewable And Sustainable Energy Reviews**, [s.l.], v. 53, p.59-67, jan. 2016. Elsevier BV.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber, 2010. 399 p.

SOLARGIS (Eslováquia). **Solar resource maps and GIS data for 200+ countries**. Disponível em: <<https://solargis.com/maps-and-gis-data/overview/>>. Acesso em: 14 jan. 2019.

SOLGREEN ENERGIA (Brasil). **Como funciona: geração de energia fotovoltaica**. 2019. Disponível em: <<https://www.solgreen.com.br/como-funciona/>>. Acesso em: 10 set. 2019.

THE WORLD BANK (Estados Unidos da América). **Global Solar Atlas**. 2019. Disponível em: <<https://globalsolaratlas.info/?c=-21.289374,-47.197266,4&s=-22.3569,-47.3839>>. Acesso em: 15 jan. 2019.

TIWARI, S.; SABZEHGAR, R.; RASOULI, M. Short term solar irradiance forecast using numerical weather prediction (NWP) with gradient boost regression. **2018 9th IEEE International Symposium On Power Electronics For Distributed Generation Systems (PEDG)**, Charlotte, p.01-08, jun. 2018.

ÜÇTUĞ, F. G.; AZAPAGIC, A. Environmental impacts of small-scale hybrid energy systems: Coupling solar photovoltaics and lithium-ion batteries. **Science Of The Total Environment**, [s.l.], v. 643, p.1579-1589, dez. 2018. Elsevier BV.

UNITED NATIONS CLIMATE CHANGE (UNCC) (New York). **The Paris Agreement**. 2018. Disponível em: <<https://unfccc.int/process-and-meetings/the-paris-agreement/the-paris-agreement>>. Acesso em: 07 jan. 2019.

VANDERSTAR, G.; MUSILEK, P.; NASSIF, A. Solar forecasting using remote solar monitoring stations and Artificial Neural Networks. **2018 IEEE Canadian Conference On Electrical & Computer Engineering (CCECE)**, [s.l.], v. [s.l.], p.01-04, maio 2018. IEEE.

VAZ, A. G. R. et al. An artificial neural network to assess the impact of neighbouring photovoltaic systems in power forecasting in Utrecht, the Netherlands. **Renewable Energy**, [s.l.], v. 85, p.631-641, jan. 2016. Elsevier BV.

VEISSID, N.; PEREIRA, E. B. Estimativa do albedo planetário empregando dados do experimento célula solar do satélite brasileiro SCD2. **Brazilian Journal of Geophysics**, São José dos Campos, [s.l.], v. 18, n. 1, p.25-39, 2000.

VON APPEN, J. et al. Time in the Sun: The Challenge of High PV Penetration in the German Electric Grid. **IEEE Power And Energy Magazine**, [s.l.], v. 11, n. 2, p.55-64, mar. 2013. Institute of Electrical and Electronics Engineers (IEEE).

VOYANT, C. et al. Numerical weather prediction (NWP) and hybrid ARMA/ANN model to predict global radiation. **Energy**, [s.l.], v. 39, n. 1, p.341-355, mar. 2012. Elsevier BV.

VOYANT, C. et al. Multi-horizon solar radiation forecasting for Mediterranean locations using time series models. **Renewable And Sustainable Energy Reviews**, [s.l.], v. 28, p.44-52, dez. 2013. Elsevier BV.

VOYANT, C. et al. Twenty four hours ahead global irradiation forecasting using multi-layer perceptron. **Meteorological Applications**, [s.l.], v. 21, n. 3, p.644-655, 03 jul. 2014. Wiley.

VOYANT, C. et al. Machine learning methods for solar radiation forecasting: A review. **Renewable Energy**, [s.l.], v. 105, p.569-582, maio 2017. Elsevier BV.

WANG, J. et al. Forecasting solar radiation using an optimized hybrid model by Cuckoo Search algorithm. **Energy**, [s.l.], v. 81, p.627-644, mar. 2015. Elsevier BV.

WEATHER SPARK (Estados Unidos da América). **Condições Meteorológicas Médias de Araras**. Elaborado por Cedar Lake Ventures, Inc. Disponível em: <<https://pt.weatherspark.com/y/30199/Clima-caracter%C3%ADstico-em-Araras-Brasil-durante-o-ano#Sections-Clouds>>. Acesso em: 31 jan. 2019.

WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, Oldendorf, [s.l.], v. 30, n. 19, p.79-82, dez. 2005.

WITTEN, I. H.; FRANK, E. **Data Mining: Practical Machine Learning Tools and Techniques**. 2. ed. São Francisco: Elsevier, 2005. 524 p.

WORLD METEOROLOGICAL ORGANIZATION (Suíça). **Guide to Meteorological Instruments and Methods of Observation**. 7. ed. Genebra: Chairperson Publications, 2008. 681 p.

ZOU, H. et al. Market dynamics, innovation, and transition in China's solar photovoltaic (PV) industry: A critical review. **Renewable And Sustainable Energy Reviews**, [s.l.], v. 69, p.197-206, mar. 2017. Elsevier BV.

APÊNDICE A – COMPORTAMENTO HORÁRIO DA GHI (2015 – 2018)

As Tabelas de 10 a 12 relacionam o número de coletas em cada horário (0h até 23h) por faixa de medição de GHI (0,0 MJ/m² até 4,5 MJ/m²). Na sequência, as Figuras de 35 a 49, permitem avaliar, por horário, a distribuição do número de coletas no período 2015 – 2018.

Tabela 10 – Número de coletas de GHI por faixa horária para valores entre 0,0 MJ/m² e 1,4 MJ/m².

Horários	Faixas de GHI [MJ/m ²]														
	0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1,0	1,1	1,2	1,3	1,4
00h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
01h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
02h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
03h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
04h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
05h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
06h	1.311	116	0	0	0	0	0	0	0	0	0	0	0	0	0
07h	549	342	180	109	87	54	44	37	23	2	0	0	0	0	0
08h	16	76	123	206	149	117	117	105	102	81	81	50	45	47	30
09h	4	26	22	29	40	47	53	48	65	103	100	79	70	75	80
10h	3	9	7	24	14	21	29	30	23	28	28	37	32	45	55
11h	10	6	9	13	15	11	18	19	18	13	27	23	27	20	16
12h	32	3	7	8	11	10	18	14	17	17	13	14	22	14	19
13h	37	2	11	8	10	7	12	11	14	11	19	16	19	19	14
14h	6	8	10	11	12	16	18	12	10	16	24	19	18	28	24
15h	6	8	20	19	14	34	18	29	25	36	20	31	37	38	46
16h	6	27	37	23	36	49	41	41	58	73	58	74	92	77	94
17h	18	58	75	87	91	136	153	124	106	104	91	87	62	51	33
18h	213	379	262	214	94	78	58	35	38	30	14	6	4	0	0
19h	1.148	209	57	8	3	1	1	0	0	0	0	0	0	0	0
20h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
21h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0
23h	1.427	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Elaborado pelo autor (2019).

Tabela 11 – Número de coletas de GHI por faixa horária para valores entre 1,5 MJ/m² e 3,0 MJ/m².

Horários	Faixas de GHI [MJ/m ²]															
	1,5	1,6	1,7	1,8	1,9	2,0	2,1	2,2	2,3	2,4	2,5	2,6	2,7	2,8	2,9	3,0
00h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
01h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
02h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
03h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
04h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
05h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
06h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
07h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
08h	23	31	20	5	2	1	0	0	0	0	0	0	0	0	0	0
09h	82	82	66	69	59	52	35	33	23	29	28	22	4	2	0	0
10h	81	67	63	60	56	66	61	67	62	69	57	65	59	42	37	28
11h	26	28	34	34	70	58	68	53	46	37	60	60	52	56	68	63
12h	24	24	26	21	26	22	41	64	58	58	46	44	40	49	69	61
13h	22	29	24	17	23	35	40	55	63	66	52	46	36	59	63	50
14h	26	30	34	39	39	67	64	68	51	55	49	46	51	78	53	60
15h	43	65	90	66	62	55	61	48	68	61	62	51	64	58	46	36
16h	65	66	59	76	71	62	43	50	31	20	26	26	18	13	11	2
17h	31	32	28	22	18	14	3	1	0	1	0	1	0	0	0	0
18h	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0	0
19h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
20h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
21h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
23h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Elaborado pelo autor (2019).

Tabela 12 – Número de coletas de GHI por faixa horária para valores entre 3,1 MJ/m² e 4,5 MJ/m².

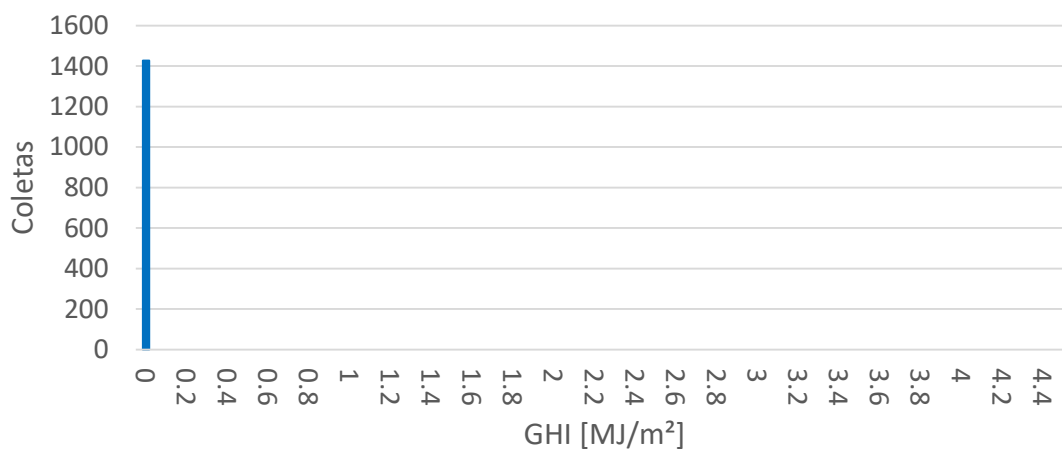
Horários	Faixas de GHI [MJ/m ²]														
	3,1	3,2	3,3	3,4	3,5	3,6	3,7	3,8	3,9	4,0	4,1	4,2	4,3	4,4	4,5
00h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
01h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
02h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
03h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
04h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
05h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
06h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
07h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
08h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
09h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
10h	26	27	27	15	3	3	0	0	0	0	0	1	0	0	0
11h	63	56	57	53	35	18	27	27	20	8	2	3	0	0	0
12h	52	66	55	72	55	51	44	38	21	30	25	18	6	2	0
13h	54	52	62	69	63	48	34	39	40	21	21	19	10	2	3
14h	59	63	65	32	41	44	28	17	17	11	7	0	1	0	0
15h	24	20	25	15	13	5	6	2	0	0	0	0	0	0	0
16h	1	1	0	0	0	0	0	0	0	0	0	0	0	0	0
17h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
18h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
19h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
20h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
21h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
22h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0
23h	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0

Fonte: Elaborado pelo autor (2019).

As coletas aferidas entre 0h e 5h (6 coletas) e entre 20h e 23h (4 coletas), perfazem um total 10 instâncias diárias que foram dispensadas da previsão porque apresentaram valores nulos de GHI em todas as 14.270 coletas realizadas nesses horários (1.427 coletas por horário * 10 horários) entre 2015 e 2018. Isso é devidamente explicado por terem sido realizadas no período da noite, período em que a estação não recebia irradiância. Assim, é possível


representar graficamente todos esses horários com um único gráfico, disposto na Figura 35. Os demais horários são representados separadamente nas Figuras de 36 a 49.

Figura 35 – Número de coletas por faixa de GHI entre 0h e 5h e entre 20h e 23h.




Fonte: Elaborado pelo autor (2019).

Figura 36 – Número de coletas por faixa de GHI às 6h.




Fonte: Elaborado pelo autor (2019).

Figura 37 – Número de coletas por faixa de GHI às 7h.




Fonte: Elaborado pelo autor (2019).

Figura 38 – Número de coletas por faixa de GHI às 8h.




Fonte: Elaborado pelo autor (2019).

Figura 39 – Número de coletas por faixa de GHI às 9h.




Fonte: Elaborado pelo autor (2019).

Figura 40 – Número de coletas por faixa de GHI às 10h.




Fonte: Elaborado pelo autor (2019).

Figura 41 – Número de coletas por faixa de GHI às 11h.




Fonte: Elaborado pelo autor (2019).

Figura 42 – Número de coletas por faixa de GHI às 12h.




Fonte: Elaborado pelo autor (2019).

Figura 43 – Número de coletas por faixa de GHI às 13h.




Fonte: Elaborado pelo autor (2019).

Figura 44 – Número de coletas por faixa de GHI às 14h.




Fonte: Elaborado pelo autor (2019).

Figura 45 – Número de coletas por faixa de GHI às 15h.




Fonte: Elaborado pelo autor (2019).

Figura 46 – Número de coletas por faixa de GHI às 16h.



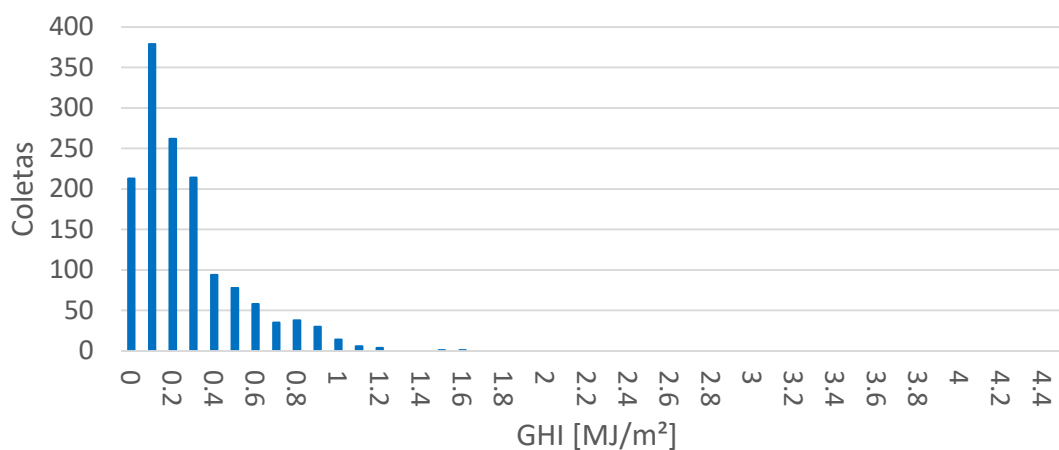
Fonte: Elaborado pelo autor (2019).

Figura 47 – Número de coletas por faixa de GHI às 17h.




Fonte: Elaborado pelo autor (2019).

Figura 48 – Número de coletas por faixa de GHI às 18h.



Fonte: Elaborado pelo autor (2019).

Figura 49 – Número de coletas por faixa de GHI às 19h.



Fonte: Elaborado pelo autor (2019).

APÊNDICE B – RESULTADOS ADICIONAIS

Tabela 13 – Resultados obtidos no Teste 1.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,412568	0,327604	0,327881	0,35008	0,340074
RMSE (MJ/m²)	0,567703	0,391765	0,398018	0,446369	0,407063
nRMSE	0,372559	0,231365	0,224315	0,25508	0,233756

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 13 são descritas a seguir:

- A. 2 camadas neurais escondidas com 3 e 12 neurônios;
- B. 2 camadas neurais escondidas com 3 e 3 neurônios;
- C. 2 camadas neurais escondidas com 6 e 3 neurônios;
- D. 2 camadas neurais escondidas com 3 e 3 neurônios;
- E. 2 camadas neurais escondidas com 3 e 3 neurônios.

Tabela 14 – Resultados obtidos no Teste 2.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,063750174	0,10649	0,087663	0,07662	0,086471
RMSE (MJ/m²)	0,100332744	0,14916	0,104627	0,092377	0,130668
nRMSE	0,06826364	0,097432	0,068794	0,059536	0,086024

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 14 são descritas a seguir:

- A. 2 camadas neurais escondidas com 3 e 9 neurônios;
- B. 2 camadas neurais escondidas com 3 e 9 neurônios;
- C. 2 camadas neurais escondidas com 3 e 9 neurônios;
- D. 2 camadas neurais escondidas com 3 e 15 neurônios;
- E. 2 camadas neurais escondidas com 3 e 9 neurônios.

Tabela 15 – Resultados obtidos no Teste 3.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m ²)	0,318599607	0,287675	0,229056	0,185832	0,400205
RMSE (MJ/m ²)	0,348709183	0,367416	0,442009	0,27203	0,523579
nRMSE	0,201648076	0,20882	0,3193	0,187155	0,354513

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 15 são descritas a seguir:

- A. 2 camadas neurais escondidas com 3 e 3 neurônios;
- B. 2 camadas neurais escondidas com 3 e 27 neurônios;
- C. 1 camada neural escondida com 12 neurônios;
- D. 2 camadas neurais escondidas com 6 e 6 neurônios;
- E. 1 camada neural escondida com 6 neurônios.

Tabela 16 – Resultados obtidos no Teste 4.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m ²)	0,340865589	0,191553	0,155361	0,238787	0,228367
RMSE (MJ/m ²)	0,516661107	0,277615	0,196375	0,276708	0,316603
nRMSE	0,341537957	0,200837	0,133148	0,1898	0,228945

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 16 são descritas a seguir:

- A. 2 camadas neurais escondidas com 3 e 18 neurônios;
- B. 2 camadas neurais escondidas com 3 e 15 neurônios;
- C. 2 camadas neurais escondidas com 3 e 27 neurônios;
- D. 2 camadas neurais escondidas com 3 e 9 neurônios;
- E. 2 camadas neurais escondidas com 3 e 27 neurônios.

Tabela 17 – Resultados obtidos no Teste 5.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,340888896	0,341857	0,337229	0,339055	0,340603
RMSE (MJ/m²)	0,52149955	0,51782	0,517238	0,5162	0,517214
nRMSE	0,341923083	0,338373	0,337908	0,340561	0,33888

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 17 são descritas a seguir:

- A. 2 camadas neurais escondidas com 6 e 6 neurônios;
- B. 2 camadas neurais escondidas com 6 e 15 neurônios;
- C. 2 camadas neurais escondidas com 6 e 15 neurônios;
- D. 2 camadas neurais escondidas com 3 e 15 neurônios;
- E. 2 camadas neurais escondidas com 6 e 6 neurônios.

Tabela 18 – Resultados obtidos no Teste 6.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,340421	0,341007	0,341214	0,341714	0,341735
RMSE (MJ/m²)	0,518418	0,517409	0,518056	0,518221	0,516455
nRMSE	0,341814	0,340151	0,341645	0,341638	0,3414

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 18 são descritas a seguir:

- A. 2 camadas neurais escondidas com 3 e 18 neurônios;
- B. 2 camadas neurais escondidas com 3 e 15 neurônios;
- C. 2 camadas neurais escondidas com 3 e 12 neurônios;
- D. 2 camadas neurais escondidas com 3 e 21 neurônios;
- E. 2 camadas neurais escondidas com 6 e 3 neurônios.

Tabela 19 – Resultados obtidos no Teste 7.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,482312	0,480188	0,480648	0,480896	0,481659
RMSE (MJ/m²)	0,63304	0,631714	0,63322	0,631384	0,633138
nRMSE	0,417025	0,4145	0,411171	0,414748	0,416942

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 19 são descritas a seguir:

- A. 2 camadas neurais escondidas com 6 e 12 neurônios;
- B. 1 camada neural escondida com 18 neurônios;
- C. 2 camadas neurais escondidas com 9 e 18 neurônios;
- D. 2 camadas neurais escondidas com 9 e 3 neurônios;
- E. 2 camadas neurais escondidas com 3 e 15 neurônios.

Tabela 20 – Resultados obtidos no Teste 8.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,348491	0,34903	0,345199	0,347373	0,348632
RMSE (MJ/m²)	0,528531	0,528184	0,524639	0,527324	0,525208
nRMSE	0,344133	0,346337	0,346318	0,34504	0,346075

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 20 são descritas a seguir:

- A. 2 camadas neurais escondidas com 15 e 12 neurônios;
- B. 2 camadas neurais escondidas com 6 e 24 neurônios;
- C. 2 camadas neurais escondidas com 9 e 12 neurônios;
- D. 2 camadas neurais escondidas com 9 e 6 neurônios;
- E. 2 camadas neurais escondidas com 6 e 3 neurônios.

Tabela 21 – Resultados obtidos no Teste 9.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,29647	0,293977	0,295111	0,292879	0,295205
RMSE (MJ/m²)	0,468701	0,462511	0,465663	0,468255	0,470218
nRMSE	0,304665	0,309768	0,304489	0,307519	0,302291

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 21 são descritas a seguir:

- A. 2 camadas neurais escondidas com 9 e 18 neurônios;
- B. 2 camadas neurais escondidas com 9 e 6 neurônios;
- C. 2 camadas neurais escondidas com 6 e 9 neurônios;
- D. 2 camadas neurais escondidas com 9 e 3 neurônios;
- E. 2 camadas neurais escondidas com 15 e 9 neurônios.

Tabela 22 – Resultados obtidos no Teste 10.

	5ª execução	4ª execução	3ª execução	2ª execução	1ª execução
Topologia	A	B	C	D	E
MAE (MJ/m²)	0,539377	0,539485	0,539593	0,539533	0,539713
RMSE (MJ/m²)	0,678916	0,679305	0,679608	0,679208	0,679338
nRMSE	0,449952	0,452058	0,454657	0,453502	0,454566

Fonte: Elaborado pelo autor (2019).

As topologias apresentadas na Tabela 22 são descritas a seguir:

- A. 2 camadas neurais escondidas com 3 e 21 neurônios;
- B. 2 camadas neurais escondidas com 3 e 15 neurônios;
- C. 2 camadas neurais escondidas com 3 e 24 neurônios;
- D. 2 camadas neurais escondidas com 3 e 27 neurônios;
- E. 2 camadas neurais escondidas com 3 e 6 neurônios.

