

Políbio Ícaro Moro Capo

**DESENVOLVIMENTO DE UMA FERRAMENTA PARA  
PREVISÃO DE CURTO PRAZO DA RADIAÇÃO SOLAR  
UTILIZANDO REDES NEURAS ARTIFICIAIS**

Dissertação submetida ao Programa de Pós-graduação em Energia e Sustentabilidade da Universidade Federal de Santa Catarina para a obtenção do Grau de Mestre em Energia e Sustentabilidade.

Orientador: Prof. Dr. Giuliano Arns Rampinelli

Araranguá  
2018

Ficha de identificação da obra elaborada pelo autor,  
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Capo, Políbio Ícaro Moro  
DESENVOLVIMENTO DE UMA FERRAMENTA PARA PREVISÃO  
DE CURTO PRAZO DA RADIAÇÃO SOLAR UTILIZANDO REDES  
NEURAIS ARTIFICIAIS / Políbio Ícaro Moro Capo ;  
orientador, Giuliano Arns Rampinelli, 2018.  
82 p.

Dissertação (mestrado) - Universidade Federal de  
Santa Catarina, Campus Araranguá, Programa de Pós  
Graduação em Energia e Sustentabilidade, Araranguá,  
2018.

Inclui referências.

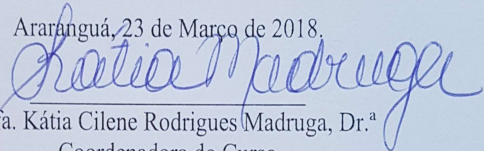
1. Energia e Sustentabilidade. 2. Radiação solar.  
3. Previsão de curto prazo. 4. Redes neurais  
artificiais. I. Rampinelli, Giuliano Arns . II.  
Universidade Federal de Santa Catarina. Programa de  
Pós-Graduação em Energia e Sustentabilidade. III.  
Título.

Políbio Ícaro Moro Capó

**DESENVOLVIMENTO DE UMA FERRAMENTA PARA  
PREVISÃO DE CURTO PRAZO DA RADIAÇÃO SOLAR  
UTILIZANDO REDES NEURAIAS ARTIFICIAIS**

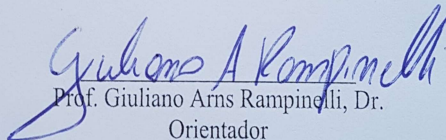
Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Energia e Sustentabilidade” e aprovada em sua forma final pelo Programa de Pós-graduação em Energia e Sustentabilidade.

Araranguá, 23 de Março de 2018.

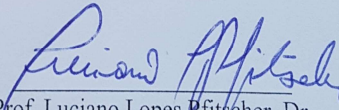


Prof. Kátia Cilene Rodrigues Madruga, Dr.<sup>a</sup>  
Coordenadora do Curso

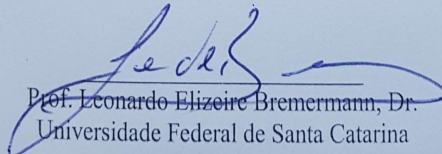
**Banca Examinadora:**



Prof. Giuliano Arns Rampinelli, Dr.  
Orientador  
Universidade Federal de Santa Catarina



Prof. Luciano Lopes Pfitscher, Dr.  
Universidade Federal de Santa Catarina



Prof. Leonardo Elizeire Bremermann, Dr.  
Universidade Federal de Santa Catarina



Prof. Rafael Haag, Dr.  
Universidade Estadual do Rio Grande do Sul



Dedico este trabalho a minha mãe  
Ângela.



## AGRADECIMENTOS

Agradeço a minha mãe Ângela por todo o amor e auxílio durante essa caminhada.

A minha futura esposa Edvana por estar presente em todos os momentos, me dar forças para enfrentar e vencer os desafios pelos quais passei.

A minha família que mesmo distante se fez presente.

Ao meu orientador Giuliano pela sabedoria e dedicação.

A todos os professores pelo esforço e trabalho duro para que o PPGES seja um programa de excelência.

Aos membros do colegiado, o qual tive o privilégio de participar e aprender sobre as importantes decisões para o desenvolvimento do programa.

Aos colaboradores da secretaria integrada de pós-graduação.

Ao pessoal da segurança e do restaurante universitário, pessoas maravilhosas que sempre conversávamos com um prazeroso sorriso no rosto.

Aos colegas de linha de pesquisa, Patrick, Luiz, Júnior, Zedequias, Rafael e ao querido Jorge, por compartilhar bons momentos durante o desenvolvimento do trabalho.

A CAPES pela bolsa concedida.





“É isso aí, você não pode parar. Esperar o tempo ruim vir te abraçar. Acreditar que sonhar sempre é preciso. É o que mantém os irmãos vivos.”

(Racionais MC's – A vida é desafio)



## RESUMO

A energia solar vem ganhando destaque nos últimos anos acompanhando a crescente demanda energética mundial. Atualmente, também pode ser destacado o avanço tecnológico e a competitividade econômica da energia solar fotovoltaica como fatores decisivos para sua inserção na matriz elétrica. Entretanto, a radiação solar que atinge a superfície terrestre varia, principalmente, devido às variações climáticas que ocorrem na atmosfera. Esse fato tem uma grande influência na produção de energia elétrica a partir das tecnologias solares. Portanto, para auxiliar o gerenciamento de operação, principalmente, no caso de usinas fotovoltaicas, entre outros fatores, necessitam-se de estudos que possibilitem conhecer sua disponibilidade regional, variabilidade temporal e previsibilidade. Quando se trata de previsão de curto prazo os modelos preditivos encontram-se em desenvolvimento sendo um grande desafio de engenharia. Dentro desse contexto, o objetivo geral desse trabalho é desenvolver uma ferramenta de previsão de curto prazo da radiação solar, no período de três horas, por meio da utilização de redes neurais artificiais e dados de estações meteorológicas localizadas no município de Araranguá – Santa Catarina. Os resultados demonstram que a ferramenta desenvolvida apresenta boa capacidade de previsão, foram encontrados valores de RMSE (*Root Mean Square Error*) abaixo de 100 W/m<sup>2</sup>, MAE (*Mean Absolute Error*) abaixo de 70 W/m<sup>2</sup> e MBE (*Mean Bias Error*) abaixo de 10 W/m<sup>2</sup> o que garantem que os acertos da previsão foram satisfatórios. Esses permitem que os resultados sejam considerados seguros com erro percentual anual da ordem de 2,38%. Ao final do trabalho, concluiu-se que a ferramenta apresentou, na média, um bom grau de acerto e que esses são importantes para auxiliar na operação e também no planejamento de usinas que utilizem energia solar como fonte.

**Palavras-chave:** Radiação solar, Previsão de curto prazo. Redes neurais artificiais.



## ABSTRACT

The solar energy has been gaining prominence in recent years, following the growing world energy demand. Currently, the technological advance and the economic competitiveness of solar photovoltaic technologies can also be highlighted as decisive factors for its insertion in the energy matrix. However, the solar radiation that reaches the Earth's surface varies, mainly, due to the climatic variations that occur in the atmosphere. This fact has a great influence on the production of electric energy. Therefore, to assist to perform the reliability of the generation systems, especially in the case of photovoltaic plants, among other factors, studies are needed to know its regional availability, temporal variability and predictability. When it comes to short-term forecasting, models are under development being an engineering challenge. In this context, the general objective of this work is to develop a short-term forecasting tool for solar radiation, in the period of three hours ahead, through the use of artificial neural networks and data from meteorological stations located in the city of Araranguá – Santa Catarina – Brazil. The results show that the tool developed has an adequate accuracy of forecast. The RMSE (Root Mean Square Error) values below  $100 \text{ W/m}^2$ , MAE (Mean Absolute Error) below  $70 \text{ W/m}^2$  and MBE (Mean Bias Error) below  $10 \text{ W/m}^2$  were found, which ensure that the capacity of the forecast is satisfactory. These allow the results to be considered safe with an annual percentage error of the order of 2.38%. At the end of the work, it was concluded that the tool presented, on average, a good degree of reliability and that these are important to assist in the management and also in the prospecting for future installations of a solar photovoltaic plant.

**Keywords:** Solar radiation. Short-term forecast. Artificial neural network.



## LISTA DE FIGURAS

Figura 1 – Cenário mundial para o mercado global 2017-2021.....	25
Figura 2 – Componentes da radiação solar.....	30
Figura 3 – Representação esquemática de uma rede neural. ....	36
Figura 4 – Sinais de saída de diferentes funções de ativação: a) função degrau; b) função linear; c) função sigmoidal logística; d) função sigmoidal tangente hiperbólica.....	37
Figura 5 – Rede feedforward com uma única camada de neurônios de saída. ....	38
Figura 6 – Rede <i>feedforward</i> com uma única camada oculta de neurônios..	39
Figura 7 – Rede recorrente com neurônios ocultos. ....	39
Figura 8 – Algoritmo <i>backpropagation</i> .....	41
Figura 9 - Localização do Estado de Santa Catarina. ....	43
Figura 10 - Localização de Araranguá em SC.....	44
Figura 11 – Estação meteorológica NTEEL.....	45
Figura 12 – Estações Automáticas INMET Araranguá.....	45
Figura 13 – Distância entre a estação do INMET e a do NTEEL. ....	45
Figura 14 – Etapas do desenvolvimento.....	46
Figura 15 – Fluxograma de tratamento de dados meteorológicos.....	47
Figura 16 – Fluxograma de tratamento de dados para a RNA. ....	48
Figura 17 – Determinação do número de neurônios da RNA. ....	50
Figura 18 – Etapas de utilização da RNA. ....	51
Figura 19 – Esquema da rede neural desenvolvida. ....	54
Figura 20 – Previsão de curto prazo da radiação solar para janeiro de 2017	59
.....	59
Figura 21 – Previsão de curto prazo da radiação solar para agosto de 2017	60
.....	60





## LISTA DE QUADROS

Quadro 1 – Exemplo de entrada e saída para treinamento da RNA. ....	49
Quadro 2 – Total de dados utilizados para treinamento e previsão.....	53
Quadro 3 – Número de dias utilizados em cada estação meteorológica. .....	54
Quadro 4 – Resultados de métricas mensais. ....	57
Quadro 5 – Erro percentual entre médias reais e previstas.....	61



## LISTA DE TABELAS

Tabela 1 – Prospectos para os maiores mercados 2017-2021.....	26
Tabela 2 – Técnicas de previsão solar. ....	31
Tabela 3 – Valores encontrados para a correlação R.....	55
Tabela 4 – Resultados para as métricas anuais .....	56
Tabela 5 – Score das redes neurais .....	57



## LISTA DE ABREVIATURAS E SIGLAS

EIM – *Energy Imbalance Markets*  
INMET – Instituto Nacional de Meteorologia  
LM - Levenberg-Marquardt *backpropagation*  
MBE – *Mean Bias Error*  
MAE – *Mean Absolute Error*  
NTEEL – Núcleo Tecnológico em Energia Elétrica  
NWP – *Numerical Weather Prediction*  
RMSE – *Root Mean Square Error*  
RNA – Rede Neural Artificial  
SC – Santa Catarina  
SONDA – Sistema de Organização Nacional de Dados Ambientais  
UFSC – Universidade Federal de Santa Catarina



## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO .....</b>	<b>25</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>29</b>
2.1	RECURSO SOLAR .....	29
2.2	MODELOS DE PREVISÃO.....	31
2.3	REDES NEURAIS ARTIFICIAIS .....	35
<b>2.3.1</b>	<b>Neurônios artificiais .....</b>	<b>35</b>
<b>2.3.2</b>	<b>Arquitetura das RNAs .....</b>	<b>37</b>
<b>2.3.3</b>	<b>Treinamento das RNAs.....</b>	<b>40</b>
<b>3</b>	<b>MATERIAIS E MÉTODOS.....</b>	<b>43</b>
3.1	METODOLOGIA PARA TRATAMENTO DAS VARIÁVEIS METEOROLÓGICAS .....	46
3.2	MÉTODOS PARA TRATAMENTO DOS DADOS DE ENTRADA E SAÍDA DA RNA .....	48
3.3	MODELAGEM E DESENVOLVIMENTO DA FERRAMENTA.....	49
3.4	MÉTODO PARA AVALIAÇÃO DAS PREVISÕES .....	51
<b>4</b>	<b>ANÁLISE E DISCUSSÃO DOS RESULTADOS .....</b>	<b>53</b>
<b>5</b>	<b>CONSIDERAÇÕES FINAIS .....</b>	<b>63</b>
	<b>REFERÊNCIAS .....</b>	<b>65</b>
	<b>APÊNDICE A – Previsão de curto prazo da radiação solar para Fevereiro de 2017 .....</b>	<b>73</b>
	<b>APÊNDICE B – Previsão de curto prazo da radiação solar para Março de 2017 .....</b>	<b>74</b>
	<b>APÊNDICE C – Previsão de curto prazo da radiação solar para Abril de 2017.....</b>	<b>75</b>
	<b>APÊNDICE D – Previsão de curto prazo da radiação solar para Maio de 2017.....</b>	<b>76</b>
	<b>APÊNDICE E – Previsão de curto prazo da radiação solar para Junho de 2017 .....</b>	<b>77</b>
	<b>APÊNDICE F – Previsão de curto prazo da radiação solar para Julho de 2017 .....</b>	<b>78</b>

<b>APÊNDICE G – Previsão de curto prazo da radiação solar para Setembro de 2017.....</b>	<b>79</b>
<b>APÊNDICE H – Previsão de curto prazo da radiação solar para Outubro de 2017.....</b>	<b>80</b>
<b>APÊNDICE I – Previsão de curto prazo da radiação solar para Novembro de 2016 .....</b>	<b>81</b>
<b>APÊNDICE J – Previsão de curto prazo da radiação solar para Dezembro de 2016.....</b>	<b>82</b>

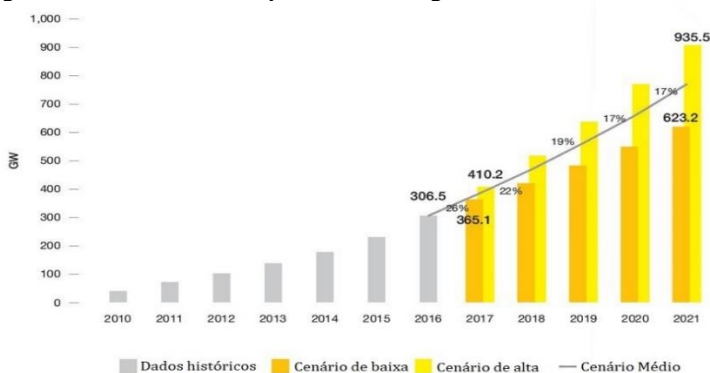


## 1 INTRODUÇÃO

Segundo Lima (2015), a energia solar vem ganhando importância nos últimos anos, acompanhando a crescente demanda energética mundial, as perspectivas de escassez dos combustíveis fósseis e as motivações ambientais ligadas ao aquecimento global. Atualmente, também pode ser destacado o avanço tecnológico e a competitividade econômica da energia solar fotovoltaica como fatores decisivos para sua inserção na matriz elétrica.

O mercado global de energia solar fotovoltaica tem crescido ao longo da última década. Segundo o relatório *Snapshot of Global Photovoltaic Markets* (2015), produzido pela Agência Internacional de Energia (IEA – PVPS - *Photovoltaic Power Systems Programme*), em 2015 o mercado de energia solar fotovoltaica quebrou vários recordes e continuou a sua expansão global. Os dados mostram um crescimento da ordem de 25% de 2016 para 2017. A Figura 1 demonstra uma projeção para os próximos cinco anos (2017-2021). São previstos três cenários, onde a demanda é considerada baixa ou alta e no cenário médio o crescimento deve ser em torno de 17 a 20%.

Figura 1 – Cenário mundial para o mercado global 2017-2021.



Fonte: *SolarPower Europe* (2017), adaptado.

Segundo a organização *SolarPower Europe* (2017), a previsão para o mercado continua em ascensão pelos próximos cinco anos. Todos os vinte primeiros países apresentam uma expectativa, em um cenário conservador, de crescimento na casa de dois dígitos até 2021. O crescimento anual esperado para o Brasil é de cerca de 125% e pode ser visualizado na Tabela 1 que demonstra os nove maiores mercados previstos para 2021.

Tabela 1 – Prospectos para os maiores mercados 2017-2021.

	2016 Capacidade Total (MW)	2021 Capacidade total no cenário médio até 2021 (MW)	2017 - 2021 Nova Capacidade (MW)	2017 - 2021 Taxa Anual de crescimento (%)
<b>China</b>	77.921	197.921	120.000	20%
<b>Estados Unidos</b>	42.362	112.262	69.900	22%
<b>Índia</b>	9548	75.898	66.350	51%
<b>Japão</b>	42.947	72.547	29.600	11%
<b>México</b>	505	10.505	10.000	84%
<b>Austrália</b>	5.843	13.623	7.780	18%
<b>Coréia do Sul</b>	4.921	12.121	7.250	20%
<b>Brasil</b>	112	6.492	6.380	125%
<b>Paquistão</b>	910	5.310	4.400	43%

Fonte: *SolarPower Europe* (2017), adaptado.

Conforme o Balanço Energético Nacional, (EPE, 2017), a energia solar ainda não tem parcela significativa na matriz elétrica e segue em expansão. A capacidade instalada proveniente de energia solar fotovoltaica, sem incluir a geração distribuída, é de 1,1 GW em usinas em operação e deve atingir 2 GW até dezembro de 2018 com a conclusão de projetos que estão em construção. Na geração distribuída, são mais de 27 mil unidades consumidoras em operação, que juntas totalizam mais de 320 MW de capacidade (ABSOLAR, 2018). Em 2018, o Brasil deverá estar entre os 20 países com maior geração de energia solar fotovoltaica, considerando-se a potência já contratada e a escala da expansão dos demais países (BRASIL, MME; 2016).

Ao contrário das centrais ditas convencionais, por exemplo, termelétricas e hidrelétricas com grandes reservatórios, a produção de energia elétrica a partir da energia solar varia de acordo com a disponibilidade do recurso. Pois o recurso está sujeito à variabilidade climática regional e aos ciclos diurno e sazonal.

No caso da radiação solar que atinge a superfície terrestre, esta varia principalmente devido à presença de nuvens na atmosfera, tendo uma grande influência na produção de energia elétrica a partir das tecnologias solares (MELLIT; MASSI PAVAN; LUGHNI, 2014). Portanto, para auxiliar na confiabilidade de operação, principalmente, no caso de usinas fotovoltaicas, entre outros fatores, necessitam-se de estudos que possibilitem conhecer sua disponibilidade regional, variabilidade temporal e previsibilidade (LIMA, 2015).

É importante salientar que na literatura existem modelos consolidados para a previsão de longo prazo. Entretanto, quando se trata de previsão de curto prazo os modelos encontram-se em

desenvolvimento, sendo um grande desafio de engenharia. Segundo Antonanzas et al. (2016), o horizonte de previsão onde a maioria das pesquisas foi feita é para um dia futuro. A razão para esse comportamento é que a maior parte da energia é negociada nos mercados do dia a frente, quando o planejamento e o compromisso de geração ocorrem. À medida que os mercados de energia evoluem, como o caso do EIM (*Energy Imbalance Markets*), o comércio intra-horário se tornará mais importante e, portanto, as pesquisas já se concentram nesse horizonte temporal buscando maior aplicabilidade nos mercados de eletricidade.

Os pressupostos justificam o interesse e a relevância no desenvolvimento de ferramentas de previsão. Com isso, a presente dissertação pretende responder aos seguintes questionamentos:

1. É possível realizar a previsão de curto prazo da radiação solar, em um período de três horas, utilizando dados de estações meteorológicas e redes neurais artificiais?
2. Qual a capacidade de acertos e segurança dos resultados?
3. Os resultados podem auxiliar no gerenciamento de operação de uma usina solar fotovoltaica?

Dentro desse contexto, o objetivo geral desse trabalho é desenvolver uma ferramenta de previsão de curto prazo da radiação solar, no período de três horas, por meio da utilização de redes neurais artificiais e dados de estações meteorológicas localizadas no município de Araranguá – SC. Para tanto, os seguintes objetivos específicos são necessários:

1. Efetuar o tratamento dos dados das estações meteorológicas do Núcleo Tecnológico de Energia Elétrica (NTEEL) - UFSC - Campus Araranguá e do INMET (Instituto Nacional de Meteorologia) durante doze meses, de novembro de 2016 até outubro de 2017.
2. Desenvolver a ferramenta de previsão de radiação solar utilizando redes neurais artificiais em ambiente MATLAB.
3. Avaliar os resultados da ferramenta por meio de previsões com os dados da estação meteorológica do INMET localizada em Araranguá - SC.



## 2 REFERENCIAL TEÓRICO

Na sequência serão descritos os fundamentos teóricos que norteiam esse trabalho.

### 2.1 RECURSO SOLAR

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

A disponibilidade do recurso energético solar e sua variabilidade espacial e temporal estão relacionadas a conceitos astronômicos. Por exemplo, a posição relativa entre o Sol e a Terra. Os fatores astronômicos estabelecem a variabilidade da radiação solar incidente no topo da atmosfera (PEREIRA et al., 2017). No entanto, segundo os autores, a energia solar incidente na superfície do planeta também sofre a influência dos processos físicos que reduzem a intensidade da radiação ao longo do percurso. A transferência radiativa é o mecanismo pelo qual o sistema Terra-Atmosfera interage e atenua a intensidade da radiação solar ao longo de seu percurso até incidir na superfície terrestre.


Segundo Lima (2015), embora a atmosfera seja muito transparente, estima-se que apenas 25% da radiação incidente em seu topo chegam à superfície terrestre, sem sofrer nenhuma interferência dos constituintes atmosféricos. Os 75% restantes são absorvidos, refletidos de volta ao espaço ou espalhados.

Conforme Pereira et al. (2017), geralmente, os processos físicos atenuam a irradiação solar de tal forma que na superfície da Terra atinja seu valor máximo de aproximadamente  $1.000 \text{ W/m}^2$  no meio dia solar (momento do dia em que o Sol está na posição mais elevada de modo que a radiação solar percorre a menor espessura de atmosfera) em condições de céu claro. Valores de até  $1.400 \text{ W/m}^2$  podem ser observados em condições de nebulosidade parcial como consequência de espalhamento por bordas de nuvens ou efeito lente causados pela geometria Sol/Nuvens/Terra (DGS, 2008 apud PEREIRA et al, 2017). Todavia, em pesquisas realizadas no território brasileiro foram observados valores de radiação global horizontal de até  $1822 \text{ W/m}^2$  (RÜTHER et al., 2017 apud PEREIRA et al, 2017).

Considerando a radiação solar que chega à superfície terrestre, incidente sobre uma superfície receptora para geração de energia, tem-se que ela é constituída por uma componente direta e por uma componente difusa. A radiação direta é aquela que provém diretamente da direção do Sol e produz sombras nítidas. A difusa é aquela proveniente de todas as direções e que atinge a superfície após sofrer espalhamento pela atmosfera terrestre (CEPEL - CRESESB, 2014).

Mesmo num dia totalmente sem nuvens, pelo menos 20% da radiação que atinge a superfície é difusa. Já em um dia totalmente nublado, não há radiação direta, e 100% da radiação é difusa. Haverá uma terceira componente refletida pelo ambiente do entorno (solo, vegetação, obstáculos, terrenos rochosos, etc.). O coeficiente de reflexão destas superfícies é denominado de albedo. Parte da radiação é espalhada pela atmosfera, absorvida ou refletida de volta ao espaço. A soma das componentes direta, difusa e albedo é dita radiação global (CEPEL – CRESESB, 2014). As componentes da radiação solar podem ser visualizados na Figura 2.

Figura 2 – Componentes da radiação solar.



Fonte: BADESCU (2008), adaptado.

Dada a sazonalidade da radiação solar, as previsões permitem uma adequada alocação dos recursos energéticos. Além disso, espera-se um melhor funcionamento e confiabilidade de usinas e/ou de sistemas

menores isolados ou conectados à rede. Assim, a capacidade de prever a radiação solar é uma das características que auxiliam na produção de energia em uma usina solar fotovoltaica (DAVID et al., 2016).

## 2.2 MODELOS DE PREVISÃO

Conforme Bacher et al. (2009), duas abordagens são dominantes na previsão da radiação solar. Uma abordagem em duas fases, em que a energia solar (ou radiação) é normalizada com um modelo de céu limpo, de modo a formar uma série temporal. De tal maneira, os métodos clássicos de séries temporais lineares de previsão podem ser utilizados. Outra abordagem utiliza as redes neurais artificiais (RNAs), com diferentes tipos de entrada, para prever a energia solar diretamente.

Os modelos de previsão solares existentes podem ser classificados em método de persistência, dados de satélite / métodos de imagens, métodos de previsão numérica do tempo, método estatístico e método híbrido (HUANG; HUANG; GADH, 2012). Ao analisar o documento “*Photovoltaic and Solar Forecasting: State of the Art*” de 2013, produzido pela Agência Internacional de Energia (IEA - PVPS), encontram-se as principais técnicas, tamanho amostral e o horizonte de previsão, conforme a Tabela 2.

Tabela 2 – Técnicas de previsão solar.

<b>Técnica</b>	<b>Tamanho da amostra</b>	<b>Horizonte de previsão</b>
<b>Persistência</b>	Grande	Minutos
<b>Imagem do céu</b>	30 segundos	Segundos a minutos
<b>Imagem de satélite geoestacionário</b>	15 minutos	5 horas
<b>Previsão numérica do tempo</b>	1 hora	10 dias

Fonte: IEA – PVPS (2013). Adaptado pelo autor.

Antonanzas et al. (2016) afirmam que duas abordagens principais podem ser encontradas na previsão da produção de plantas fotovoltaicas: indireta e direta. As previsões indiretas preveem, em primeiro lugar, a irradiação solar e, em seguida, utilizando um modelo da planta fotovoltaica, obtém-se a potência produzida. Por outro lado, as previsões diretas calculam diretamente a potência da planta. Além disso, segundo os autores, muitos outros estudos se concentram na previsão da irradiação solar, pois é o elemento mais difícil de se modelar e tem outras aplicações

além da previsão da energia solar. Ambas as previsões (potência e irradiação) são abordadas através de técnicas similares.

Segundo David et al., 2016, diversas ferramentas e métodos de previsão da radiação solar foram desenvolvidos para vários horizontes temporais e resoluções espaciais. Para a previsão de um dia a frente, os métodos mais precisos são baseados em previsões numéricas do tempo. Para horizontes de várias horas, os modelos baseados em satélite são os mais adequados. E para horizontes muito curtos, alguns minutos até cerca de 2 h, a literatura é dominada por abordagens estatísticas baseadas em modelos de séries temporais.

Em Ghayekhloo et al., 2015, os autores propõem modelos híbridos com a utilização da teoria dos jogos para realizar a previsão em um período de uma a três horas. A temperatura, a velocidade do vento e os dados de direção do vento estão incluídos nas entradas para as redes neurais bayesianas cujas saídas fornecem as previsões de radiação solar. Os dados históricos de radiação solar são usados para avaliar a precisão da previsão híbrida com o agrupamento proposto.

No trabalho de Sperati et al. 2016, os autores utilizaram cerca de dois anos de dados obtidos de usinas solares, localizadas em regiões da Itália caracterizadas por diferentes condições climáticas. A previsão foi realizada num horizonte de 0-72h. Então, a rede neural foi utilizada para reduzir o erro do modelo e gerar funções de densidade de probabilidade. Em seguida, aplicadas e comparadas técnicas estatísticas para produzir a previsão da irradiação solar.

Na dissertação de Santos (2010) foi desenvolvida uma metodologia de previsão da produção, de muito curto prazo (10 a 30 minutos), de uma central fotovoltaica. O modelo proposto utiliza as redes neurais para simular a evolução temporal da radiação solar na superfície terrestre. Para tal, utiliza informações da presença de nuvens obtidas a partir do solo, extraídas de imagens do céu. Os resultados demonstram que para dias de céu limpo o modelo responde de forma satisfatória. No entanto, para dias nublados, existem maiores dificuldades em prever a variabilidade da radiação solar. A utilização de inteligência artificial para o cálculo da produção da central só foi possível devido à existência de dados históricos de geração em diferentes condições meteorológicas.

No trabalho de Assi, Shamisi e Hejase, 2012, os autores desenvolvem uma interface gráfica de usuário para auxiliar na previsão da radiação solar global em diferentes regiões dos Emirados Árabes Unidos. Os modelos previstos são desenvolvidos utilizando técnicas de rede neural artificial. Os valores mensais de radiação solar global previstos são apresentados em formato gráfico e numérico. Assim, a



ferramenta pode ser usada para a concepção e avaliação de sistemas de aplicação solar.

Os autores Chiteka, Enweremadu, 2016, apresentam a abordagem da RNA para prever a irradiação horizontal global em alguns locais no Zimbábue. A predição da irradiação horizontal global foi realizada com dados geográficos de altitude, latitude e longitude e dados meteorológicos de umidade, pressão, índice de clareza e temperatura média. Uma rede neural com sete entradas, uma camada oculta, uma camada de saída com uma variável de saída como objetivo. Uma rede com 10 neurônios e uma função de transferência *tansig* nas camadas de entrada e saída foi considerada o melhor modelo preditivo de todos os modelos avaliados.

Em Ahmad, Anderson, 2014, os autores utilizam as redes neurais para prever a radiação solar global em toda a Nova Zelândia. Os dados horários para nove variáveis meteorológicas foram registrados em todo o país entre janeiro de 2006 e dezembro de 2012. Os dados foram utilizados para criar, treinar e testar modelos de RNA. Ao fazer isso, foram testados modelos de RNA com diferentes números de neurônios (de 5 a 250) na camada oculta, e seu efeito na precisão de predição foi analisado. Subsequentemente o modelo mais preciso de RNA foi usado para a predição global da radiação solar em dez cidades da Nova Zelândia.

No trabalho de Kashyap et al. (2015), o modelo proposto é iniciado e validado com 10 parâmetros meteorológicos divididos em subcategorias. Os autores utilizam RNAs com atraso e subdividem os modelos em três esquemas de desempenho: tempo de atraso da rede, número de neurônios e função de ativação para determinar a arquitetura da rede neural. Os autores concluem que o fator mais importante para estimar a radiação solar global horária é a seleção das variáveis meteorológicas. Além disso, os resultados mostram flexibilidade em diferentes modelos e na seleção de parâmetros. Os modelos podem alcançar um desempenho satisfatório quando são avaliados os erros estatísticos. Este trabalho autentica a capacidade da RNA de replicar a radiação global horária com precisão.

Devido à recente expansão da geração proveniente de energia solar no Brasil, tem crescido o interesse em relação à previsão da irradiação solar. Pode citar-se como exemplo Guarnieri et al., 2007, que realizaram previsões de radiação solar utilizando modelo de mesoescala e refinamento com redes neurais, realizando comparações entre medidas de radiação solar e previsões do modelo, para estações de medida da rede SONDA localizados em São Martinho da Serra (RS) e Florianópolis (SC). Com o intuito de reduzir os erros de previsão, redes neurais artificiais foram configuradas e treinadas para ambas as estações de coleta de dados.

Os autores Teixeira Júnior et al., 2012, fazem o uso combinado da decomposição *wavelet* com a RNA para gerar previsões de curto prazo da radiação solar direta. O desempenho do método proposto foi avaliado por meio de um experimento computacional, no qual foi considerada a série temporal horária de radiação solar direta média ( $W/m^2$ ) na estação Solarimétrica do Projeto Sonda do INPE/CPTEC localizada na cidade de Cuiabá. A série considerada compreende o período de janeiro até dezembro de 2010.

Autores como, Belúcio et al., 2014, estimaram a radiação solar global em função da insolação na cidade de Macapá (AP) utilizando análise de regressão linear simples e o modelo de Angström-Prescott. Os autores afirmam que tal metodologia pode ser uma abordagem alternativa às estações meteorológicas sem registros de radiação solar global. Os coeficientes de correlação de Pearson (R) mensais analisados revelaram-se satisfatórios entre 0,76 e 0,82.

No trabalho de Lima et al. (2016) os autores realizam a previsão de radiação solar para o Nordeste do Brasil, empregando o modelo WRF (*Weather Research and Forecasting*) ajustado por redes neurais artificiais. A base de dados utilizada no trabalho foi a do INMET, para o período de sete anos de 2005 a 2011. Vários preditores foram testados para ajustar e simular as redes neurais. A melhor arquitetura de RNA foi encontrada e um grupo de 10 preditores foram utilizados para as análises. Houve uma melhoria significativa das previsões do modelo WRF quando ajustadas pelas RNAs, apresentando menor viés e RMSE (*Root Mean Square Error*), e um aumento no coeficiente de correlação.

Em Barth et al., 2016, o objetivo foi desenvolver uma rede neural, capaz de avaliar a irradiação solar na região Noroeste do Estado do Rio Grande do Sul. No caso, a avaliação teve como alvo dados meteorológicos, no período de janeiro a abril de 2015. A rede foi implementada e treinada usando o software MATLAB. Os resultados indicaram que a rede obteve uma precisão alta e que a região é um local suficientemente bom para a produção de energia provinda da irradiação solar.

A literatura é dominada por horizontes de previsão horários ou diários, as RNAs são uma abordagem apropriada para horizontes de curto prazo e NWP (*Numerical Weather Prediction*) são mais adequados para horizontes mais longos (BARBIERI, RAJAKARUNA, CURTIN, 2017).

Segundo Antonanzas et al. (2016), as RNAs são as técnicas de aprendizagem de máquinas mais utilizadas na previsão de energia solar e correspondem a 24% dos trabalhos identificados pelos autores.

Conforme Yang et al. (2018), atualmente, o aprendizado de máquina é a abordagem mais popular na previsão solar. Embora as RNAs permaneçam populares como base para os métodos de aprendizado de máquina na previsão solar, muitas outras abordagens têm sido usadas ultimamente. Entretanto, para um determinado conjunto de dados de entrada, a implementação adequada de qualquer um desses métodos gera habilidades de previsão semelhantes, desde que o *overfitting* seja evitado.

## 2.3 REDES NEURAIS ARTIFICIAIS

Segundo Rosa (2011), a ideia de simular o cérebro humano já era objetivo de muitos trabalhos iniciais em inteligência artificial. O cérebro era visto como uma rede neural, ou seja, um conjunto de neurônios, ou nós, conectados por linhas de comunicação. Em um nível mais simples, o cérebro funciona da seguinte forma: neurônios ativam ou inibem o disparo de outros neurônios. De acordo com Braga et. al (2007), a estrutura individual desses neurônios, a topologia de suas conexões e o comportamento do conjunto desses elementos de processamento naturais formam a base do estudo das RNAs.

Haykin (2001) define uma rede neural sendo um processador paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro em dois aspectos:

1. O conhecimento é adquirido pela rede a partir de seu ambiente através de um processo de aprendizagem.
2. Forças de conexão entre os neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

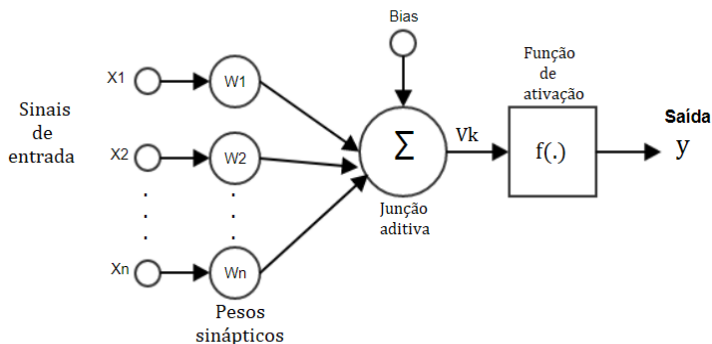
Portanto, uma rede neural extrai seu poder computacional através, primeiro, de sua estrutura paralelamente distribuída e segundo de sua habilidade de aprender e, portanto, de generalizar. A generalização se refere ao fato de a rede neural produzir saídas adequadas para entradas que não estavam presentes durante o treinamento (aprendizagem) (HAYKIN, 2001).

### 2.3.1 Neurônios artificiais

Um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural (HAYKIN, 2001). A

descrição matemática como um modelo de  $n$  terminais de entrada que recebem os valores  $X1, X2 \dots Xn$  (que representam as ativações dos neurônios anteriores) e apenas um terminal de saída  $y$ . Os terminais de entrada do neurônio tem pesos acoplados  $W1, W2 \dots Wn$  cujos valores podem ser positivos ou negativos (BRAGA, CARVALHO, LUDERMIR, 2007). Um somador é utilizado para somar os sinais de entrada, ponderados pelas respectivas sinapses do neurônio. O *bias* tem a função de aumentar ou diminuir a entrada da função de ativação dependendo se ele é positivo ou negativo. E uma função de ativação é usada para restringir a amplitude da saída de um neurônio (HAYKIN, 2001). Uma representação esquemática pode ser vista na Figura 3.


Figura 3 – Representação esquemática de uma rede neural.



Fonte: HAYKIN (2001), adaptado.

A função de ativação,  $f(\cdot)$ , é responsável por gerar a saída  $y$  do neurônio a partir do vetor  $V_k$ , que recebe a contribuição dos vetores de peso  $W=(W1, W2 \dots Wn)$ , de entrada  $X=(X1, X2 \dots Xn)$  e do *bias* associado (BRAGA, CARVALHO, LUDERMIR, 2007). Segundo Haykin, 2001, existem três tipos básicos de funções: função de limiar (ou degrau), linear ou sigmoide. A função do tipo sigmoide é a mais utilizada para construção de redes neurais artificiais de múltiplas camadas. Estas funções podem ser visualizadas na Figura 4.

Figura 4 – Sinais de saída de diferentes funções de ativação: a) função degrau; b) função linear; c) função sigmoidal logística; d) função sigmoidal tangente hiperbólica.



Fonte: LIMA (2015), adaptado.

Segundo Braga, Carvalho, Ludermir, 2007, independentemente da função de ativação escolhida, neurônios individuais possuem capacidade computacional limitada. No entanto, de acordo com a arquitetura de uma rede neural, um conjunto de neurônios conectados é capaz de resolver problemas de complexidade elevada.

A definição da arquitetura de uma RNA é um parâmetro importante na sua concepção, uma vez que ela restringe o tipo de problema que pode ser tratado pela rede. Fazem parte da arquitetura da rede os seguintes parâmetros: o número de camadas; o número de neurônios em cada camada; o tipo de conexão entre os neurônios e a topologia da rede (LIMA, 2015).

### 2.3.2 Arquitetura das RNAs

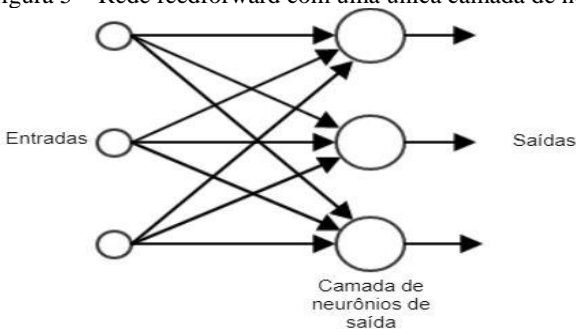
Haykin, 2001, afirma que a maneira como os neurônios de uma rede estão estruturados está intimamente ligada com o algoritmo de aprendizagem utilizado para treinar a rede. Existem duas classificações para as RNAs: recorrentes (*feedback*) e não-recorrentes (*feedforward*). A RNA não recorrente pode conter uma única camada ou múltiplas camadas sendo que esta última possui as chamadas camadas ocultas (*hidden layers*). As RNAs com mais de uma camada oculta são denominadas *Perceptrons* de Múltiplas Camadas (*multilayer perceptron – MLP*) (LIMA, 2015). Portanto, de maneira geral, os três principais tipos de

arquitecturas de rede fundamentalmente diferentes, conforme Haykin (2001), são:

### 1. Redes alimentadas adiante com camada única

Nesse tipo de rede, Figura 5, os neurônios estão organizados na forma de camadas, na forma mais simples, existe uma camada de entrada que se projeta sobre uma camada de saída de neurônios. Esta rede é estritamente do tipo alimentada adiante (*feedforward*).

Figura 5 – Rede feedforward com uma única camada de neurônios de saída.




Fonte: HAYKIN (2001), adaptado.

### 2. Redes alimentadas diretamente com múltiplas camadas (*feedforward MLP*)

Essa classe de rede neural, Figura 6, se distingue pela presença de uma ou mais camadas ocultas. Adicionando-se uma ou mais camadas ocultas, a rede é capaz de extrair estatísticas de ordem elevada. Esta habilidade é particularmente valiosa quando o tamanho da camada de entrada é grande.

Figura 6 – Rede *feedforward* com uma única camada oculta de neurônios..




Fonte: HAYKIN (2001), adaptado.

### 3. Redes recorrentes

Uma rede neural recorrente, Figura 7, se distingue de uma rede neural alimentada adiante por ter pelo menos um laço de realimentação. Essa rede pode ter ou não neurônios ocultos.

Figura 7 – Rede recorrente com neurônios ocultos.



Fonte: HAYKIN (2001), adaptado.

Existe uma grande quantidade de topologias, mas como demonstrado, a classificação pelo número de camadas ocultas (*perceptron* simples ou multicamadas) é a principal. Das diferentes RNAs, a *Multi-Layer Perceptron* é a mais utilizada, e pode ser considerada universal por demonstrar ampla aplicabilidade (ANTONANZAS, 2016).

Conforme Braga, Carvalho, Ludermir, 2007, além da arquitetura, uma das características mais importantes das RNAs é a sua capacidade de

aprender por meio de exemplos. A etapa de aprendizado consiste em um processo iterativo de ajuste de parâmetros da rede, os pesos das conexões, que guardam, ao final do processo, o conhecimento que a rede adquiriu.

### 2.3.3 Treinamento das RNAs


O ajuste dos pesos sinápticos é chamado de algoritmo de treinamento, sendo que esse pode ser classificado como treinamento supervisionado e treinamento não-supervisionado (BRAGA, CARVALHO, LUDERMIR, 2007). Os autores afirmam que durante o treinamento não-supervisionado somente padrões de entrada estão disponíveis para a rede, ao contrário do aprendizado supervisionado, cujo conjunto de treinamento possui dados de entrada e saída.

No treinamento supervisionado, um sinal de entrada e um valor alvo são apresentados à rede. A partir da entrada a rede calcula a saída e a compara com o alvo. Esse procedimento é repetido até a RNA atingir o melhor resultado ajustando os pesos sinápticos (LIMA, 2015). Os algoritmos mais conhecidos para aprendizado supervisionado são a regra delta e a sua generalização para redes de múltiplas camadas, o algoritmo *backpropagation* (BRAGA, CARVALHO, LUDERMIR, 2007).

Segundo Haykin (2001), o algoritmo *backpropagation* utiliza pares de entrada e saída para ajustar os pesos da rede por meio de um mecanismo de correção de erros. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Essas duas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entrada. A fase *backward* utiliza a saída desejada e a saída fornecida pela rede para atualizar os pesos de suas conexões. O esquema de funcionamento pode ser visto na Figura 8.



Figura 8 – Algoritmo *backpropagation*.



Fonte: TEIXEIRA JÚNIOR et al. (2012).

Vários algoritmos foram desenvolvidos para treinar as redes, como gradiente conjugado, *Quasi-Newton*, *Levenberg-Marquardt* (LM), propagação reversa de taxa de aprendizado variável, dentro outros (MELLIT et al. 2014). Esses algoritmos de aprendizado têm como base o algoritmo *backpropagation* e são usados para acelerar a convergência (MANTZARI, MANTZARIS, 2013).

No trabalho de Neelamegam, Amirthamb (2016), os autores investigaram o melhor algoritmo e modelo de RNA para previsão da radiação solar. Eles verificaram com base no erro médio mínimo, erro quadrático médio mínimo e coeficiente de regressão linear máximo. Assim, o *backpropagation* de *Levenberg-Marquardt* provou ser o melhor algoritmo de treinamento e teste. O algoritmo de LM tem sido utilizado para fins de treinamento porque é muito rápido em comparação com a descida de gradiente e descida de gradiente com momento (KUMAR, KAUR, 2016).

O algoritmo de LM é uma aproximação do método de Newton. Ele melhora o método de Gauss-Newton por meio de uma taxa de aprendizado variável. Portanto, o algoritmo de treinamento LM é uma técnica de otimização numérica. Os detalhes matemáticos e implementação computacional fogem ao escopo deste trabalho, entretanto, o equacionamento pode ser visto com mais detalhes em Braga, Carvalho e Ludermir (2007) e Haykin (2001).

Resumidamente, segundo Badescu (2008), o treinamento de uma rede de *backpropagation*, normalmente, começa com pesos aleatórios. Após esse fato, a rede é exposta a um conjunto de treinamento de dados de entrada. A saída da rede é comparada ao exemplo (treinamento supervisionado) e o procedimento de aprendizagem altera as interconexões de rede (pesos). As conexões são ajustadas para que as entradas sejam associadas à resposta esperada. À medida que o treinamento prossegue, a resposta da rede aos dados de entrada fica melhor. O treinamento é repetido para um conjunto de dados até que a rede aprenda a produzir resultados precisos. Uma vez que a rede é treinada usando as entradas e saídas pré-selecionadas, todos os pesos sinápticos são fixados e a rede está pronta para ser testada com novas informações de entrada (simulação).

### 3 MATERIAIS E MÉTODOS

A análise efetuada nesse trabalho foi realizada no município de Araranguá, Figura 9, localizada no estado de Santa Catarina (SC), região Sul do Brasil.

Figura 9 - Localização do Estado de Santa Catarina.



Fonte: GOOGLE MAPS (2018).

A cidade fica localizada no extremo sul do Estado de Santa Catarina, latitude -28.9484101 e longitude -49.4982562. Sua localização pode ser vista na Figura 10.

Figura 10 - Localização de Araranguá em SC.



Fonte: GOOGLE MAPS (2018).

Para o desenvolvimento do trabalho utilizaram-se dados de duas estações meteorológicas, a estação do Núcleo Tecnológico em Energia Elétrica (NTEEL) da Universidade Federal de Santa Catarina, Figura 11, e a estação do Instituto Nacional de Meteorologia (INMET), Figura 12.

Figura 11 – Estação meteorológica NTEEL.



Fonte: Elaborado pelo autor (2017).

Figura 12 – Estações Automáticas INMET Araranguá.



Fonte: INMET (2017).

As estações estão distantes por um raio de aproximadamente 2 km, Figura 13, a estação meteorológica do NTEEL fica localizada no ponto A e a estação do INMET está situada no ponto B.


Figura 13 – Distância entre a estação do INMET e a do NTEEL.



Fonte: GOOGLE MAPS (2017).

É importante salientar que as estações operam com equipamentos diferentes e sistemas de unidades distintos. Portanto, houve a necessidade de padronização dos dados. Desse modo, optou-se por separar o processo em etapas conforme a Figura 14. Esse procedimento foi adotado com intuito de simplificar os algoritmos de tratamento de dados.

Figura 14 – Etapas do desenvolvimento.



Fonte: Elaborado pelo autor (2017).

O processo foi iniciado com a etapa de tratamento das variáveis meteorológicas, em seguida o desenvolvimento da RNA e, por fim, os resultados foram obtidos por meio da avaliação da capacidade de previsão da ferramenta.

### 3.1 METODOLOGIA PARA TRATAMENTO DAS VARIÁVEIS METEOROLÓGICAS

A base de dados corresponde ao período de doze meses, compreendendo os meses de novembro de 2016 até outubro de 2017. O intervalo de coleta foi de cinco minutos, provenientes da estação meteorológica operada pelo NTEEL. A estação do INMET fornece dados com intervalos de uma hora.

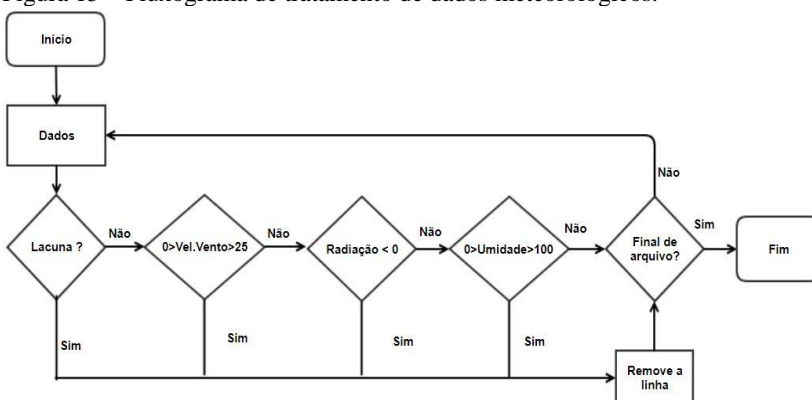
As variáveis utilizadas são: a hora do dia [minutos], temperatura [°C], umidade externa [%], velocidade do vento [m/s], e a radiação solar global no plano horizontal [W/m<sup>2</sup>]. Em Kumar e Kaur (2016), os autores concluem que o modelo utilizando mais variáveis meteorológicas promove uma previsão mais precisa. Entretanto, assim como os autores, salienta-se a necessidade, em trabalhos futuros, de verificar quais as variáveis possuem maior impacto para a previsão da radiação solar.

O tratamento dos dados foi efetuado seguindo uma adaptação do modelo utilizado pelo Sistema de Organização Nacional de Dados Ambientais (SONDA). A rede SONDA, antes de disponibilizar os dados de suas estações, submete-os a um processo de validação que objetiva identificar os dados suspeitos. Por exemplo, vários fatores afetam a

confiabilidade dos dados medidos, relâmpagos e mau funcionamento podem alterar as medições tornando-as incorretas. Em seus procedimentos de controle de qualidade, um dado será sinalizado como correto quando atender aos limites especificados conforme visto no sítio *web* (<http://sonda.ccst.inpe.br/infos/validacao.html>).

A adaptação realizada foi que os dados inconsistentes foram removidos, pois afetariam o funcionamento da rede neural alimentando-a com informações incorretas. Com isso, o fluxograma adotado para o tratamento das variáveis meteorológicas encontra-se na Figura 15.

Figura 15 – Fluxograma de tratamento de dados meteorológicos.



Fonte: Elaborado pelo autor (2017).

Nesse trabalho desenvolveu-se um *software* com base no fluxograma e os códigos foram implementados em Matlab. Com isso, foi possível verificar se houve alguma falha nos sensores. Esse fato acarretaria na presença de lacunas no arquivo de dados. Portanto, removeram-se as linhas que não apresentassem valores e na sequência efetuou-se a verificação das variáveis atmosféricas. Os filtros empregados são:

- Se a velocidade do vento apresenta valores menores que zero ou maiores que 25 m/s.
- Se a radiação apresenta valor menor do que zero.
- Se a umidade externa é menor que zero ou maior que 100%.

Em caso afirmativo, a linha de dados correspondente é removida e o algoritmo continua sua execução. As verificações são realizadas até o final do arquivo de cada estação meteorológica.

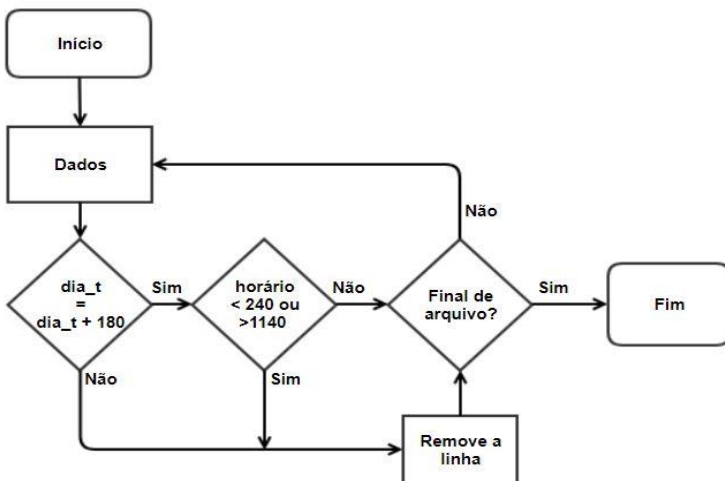
Além da filtragem dos dados, efetuou-se o cálculo das médias e desvio padrão de cada variável. Identificaram-se os limites inferiores e superiores para verificar a existência valores fisicamente impossíveis, por exemplo, se um dado de radiação solar extrapolasse o comumente verificado em determinado horário.

### 3.2 MÉTODOS PARA TRATAMENTO DOS DADOS DE ENTRADA E SAÍDA DA RNA

No tratamento de dados da RNA, verificou-se a necessidade de realizar o agrupamento das bases de dados mensais em um arquivo anual. O arquivo passou por um algoritmo que padronizava as cinco variáveis de entrada e uma de saída com o mesmo sistema de unidades.

O fluxograma apresentado na Figura 1 demonstra o algoritmo principal do *software* desenvolvido. A padronização deu-se através da verificação da existência de dados para três horas a frente, ou seja, se os dados correspondem ao mesmo dia, dia\_t (dia atual) e dia\_t+180 (3 horas a frente). Portanto, o treinamento e a previsão ocorreram com todos os dados que estavam completos.

Figura 16 – Fluxograma de tratamento de dados para a RNA.



Fonte: Elaborado pelo autor (2017).



Para a utilização na RNA, têm-se as variáveis de entrada, instante  $t$ , dito instante atual. E na saída o instante  $t+180$ , correspondente às três horas seguintes. Ao analisar a variabilidade do recurso solar no município de estudo, verificou-se que o período de incidência solar, significativa, ocorre entre 7:00h (420 minutos) às 19:00h (1140 minutos). Dada essa característica, os dados foram padronizados com início às 4:00h (240 minutos) para realizar a primeira previsão às 7:00h e a última às 22:00h. O Quadro 1 exemplifica alguns valores utilizados como entrada e saída.

Quadro 1 – Exemplo de entrada e saída para treinamento da RNA.

Entrada $t$						Saída $(t+180)$	
Horário [hora]	Horário [minutos]	Temperatura [°C]	Umidade [%]	Vel. Vento [m/s]	Radiação [W/m <sup>2</sup> ]	Radiação [W/m <sup>2</sup> ]	Horário [hora]
7:35	455	15,3	66	2,2	174	814	10:35
7:40	460	15,6	65	1,8	202	826	10:40

Fonte: Elaborado pelo autor (2017).

Os dados fora do horário de interesse foram excluídos, pois não impactam na previsão da radiação solar e acarretam custo computacional desnecessário durante a modelagem, desenvolvimento e utilização da ferramenta.

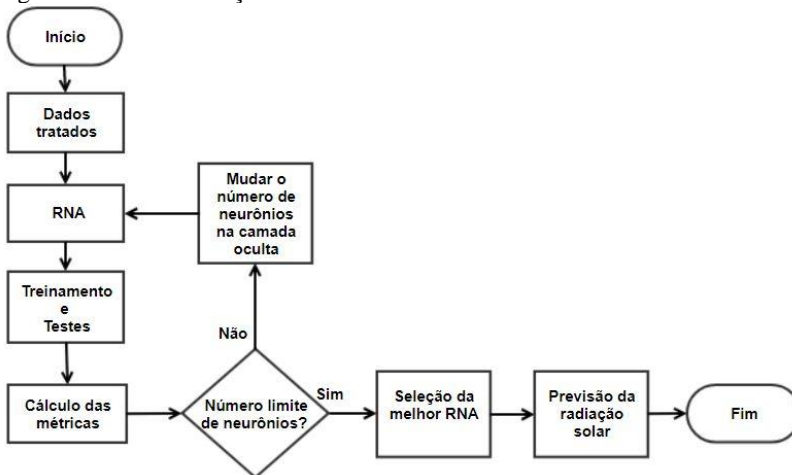
### 3.3 MODELAGEM E DESENVOLVIMENTO DA FERRAMENTA

Diante das características apresentadas, o problema de previsão se caracteriza tipicamente pela estimativa de situações futuras com base nos estados atuais e anteriores do sistema a ser modelado. Portanto, a sua solução envolve tipicamente aprendizado supervisionado em que estados passados, atuais e futuros são apresentados à rede durante o treinamento. Os problemas de previsão podem ser resolvidos, principalmente, com redes neurais do tipo *feedforward MLP* (BRAGA, CARVALHO, LUDERMIR, 2007). Os autores afirmam que, normalmente, as funções de ativação utilizadas para esse tipo de rede são do tipo sigmoidais, tanto para as camadas intermediárias, quanto para a camada de saída.

Segundo Braga, Carvalho e Ludermir (2007), a definição do número de neurônios em cada uma das camadas da rede é de extrema importância para o seu desempenho, principalmente no que se refere a sua capacidade de generalização. Entretanto, não se pode dizer que haja na literatura uma regra geral que determine, de forma precisa, qual deve ser o número de neurônios de uma rede neural para a resolução de determinado problema. O que se sabe é que quanto maior o número de neurônios, maior a complexidade da rede e maior a sua abrangência em termos de soluções possíveis. Há na literatura inúmeras abordagens que visam estimar o tamanho da rede ou avaliar a sua resposta, mas não existe uma abordagem que tenha encontrado, formalmente, uma resposta geral para essa questão fundamental no projeto de redes neurais.

A partir do pressuposto, optou-se pela realização de um conjunto de testes para determinar o número de neurônios da camada oculta da rede. Para tanto, variou-se o número de neurônios entre 5 e 150 a fim de encontrar a rede que obtivesse as melhores métricas anuais, por consequência, a rede que melhor representa o conjunto de dados. A Figura 15, ilustra o fluxograma para determinação desse parâmetro.

Figura 17 – Determinação do número de neurônios da RNA.




Fonte: Elaborado pelo autor (2017).

Os demais aspectos da RNA, função de treinamento de Levenberg-Marquardt *backpropagation* (LM) e a função de ativação (tangente sigmoide), foram utilizados com base na revisão de literatura como explicado na seção 2.

O desenvolvimento da ferramenta foi efetuado utilizando a *toolbox* “nntool” do MATLAB 2014b. O algoritmo de LM é utilizado para o treinamento, teste e validação da rede. O conjunto de dados foi dividido de maneira aleatória e distribuído em 70% para treinamento, 15% para testes e 15% para a validação. Essa é uma configuração padrão do MATLAB e encontrada na literatura como no trabalho de Kashyap et al. (2015). Portanto, optou-se por adotá-la pois não é objetivo do presente trabalho abordar as possíveis combinações entre treinamento, testes e validação. Esse fato poderá ser investigado em trabalhos futuros.

O uso da rede neural deu-se em duas fases, Figura 18, na primeira ocorreram os testes para identificação da melhor rede. E após, o treinamento foi efetuado. Para tanto, utilizaram-se os dados da estação do NTEEL.

Figura 18 – Etapas de utilização da RNA.



Fonte: Elaborado pelo autor (2017).

Na segunda fase, os dados da estação do INMET foram utilizados para realizar a previsão mensal, calcular as métricas e, por fim, avaliar a capacidade de previsão da ferramenta.

### 3.4 MÉTODO PARA AVALIAÇÃO DAS PREVISÕES

Segundo Antonanzas et al. (2016), o desempenho e a precisão de um determinado modelo podem ser avaliados através de várias métricas. Elas permitem a comparação entre diferentes modelos e locais. Na bibliografia, podem ser encontradas diversas métricas, embora existam um grupo delas mais comumente usadas.

Com isso, a Agência Internacional de Energia (IEA, 2013) afirma que as principais métricas são: raiz do erro médio quadrático (RMSE), Equação 1, o erro médio absoluto (MAE), Equação 2, o erro médio (MBE, ou bias), Equação 3.

$$RMSE = \left( \frac{1}{N} \sum_{i=1}^N e_i^2 \right)^{1/2} \quad (1)$$

$$MAE = \frac{1}{N} \sum_{i=1}^N |e_i| \quad (2)$$

$$MBE = \frac{1}{N} \sum_{i=1}^N e_i \quad (3)$$

Sendo  $e_i$  é definido, na Equação 4, como:

$$e_i = y_{i,previsto} - y_{i,observado} \quad (4)$$

Onde  $y_{i,previsto}$  e  $y_{i,observado}$  são os  $i$ -ésimos valores previstos e observados, respectivamente e  $e_i$  é o  $i$ -ésimo erro. Com  $i=1, \dots, N$  através de todo o conjunto de dados até o  $N$ ésimo valor.

Segundo a IEA (2013), o MAE demonstra a magnitude média do erro de previsão, enquanto RMSE fornece mais peso aos maiores erros de previsão. Em Madsen et al. (2005) apud IEA (2013), os autores argumentam que grandes erros são proporcionalmente caros, de modo que o RMSE reflete melhor os custos dos erros de previsão para os operadores do sistema do que o MAE.

Conforme Ahmad, Anderson (2014), o MBE é uma indicação do desvio médio dos valores previstos e pode fornecer informações sobre o desempenho a longo prazo dos modelos. Um valor de MBE positivo indica uma superestimação na radiação solar global predita e um valor negativo demonstra uma subestimação da previsão. Com isso, segundo Zhang et al., 2013, ao compreender a métrica MBE os operadores do sistema de energia conseguem alocar os recursos para compensar erros de previsão no processo de despacho.

Conforme a IEA (2013), ao indicar a precisão da previsão, é importante especificar não apenas qual métrica é usada (RMSE, MAE ou outra), mas também esclarecer se esse valor foi calculado durante períodos completos de 24 horas ou apenas levando em consideração as horas de incidência solar. Portanto, para a construção dos resultados foram utilizadas apenas as horas em que havia incidência solar e as métricas MAE, RMSE e o MBE, vistas nas Equações 1, 2 e 3.

## 4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

As bases de dados utilizadas compreendem o período de doze meses (novembro de 2016 a outubro de 2017), totalizando 85053 dados brutos provenientes da estação do NTEEL e 8485 dados da estação do INMET. Após a utilização dos *softwares* desenvolvidos e explicados na seção 3. Os principais resultados dos tratamentos de dados podem ser visualizados no Quadro 2.

Quadro 2 – Total de dados utilizados para treinamento e previsão.

Mês	NTEEL		INMET	
	Quantidade de dados brutos	Quantidade de dados Tratados	Quantidade de dados brutos	Quantidade de dados Tratados
Novembro	7817	4834	720	540
Dezembro	7789	4860	744	558
Janeiro	7971	4980	744	550
Fevereiro	3793	2349	696	522
Março	8914	5562	744	558
Abril	6861	4275	720	540
Maiο	3907	2455	743	554
Junho	8640	5429	710	507
Julho	8928	5604	456	342
Agosto	8929	5607	744	558
Setembro	5148	3152	720	503
Outubro	6356	3870	744	558
<b>Total</b>	<b>85053</b>	<b>52977</b>	<b>8485</b>	<b>6290</b>

Fonte: Elaborado pelo autor (2018).

Ao verificar os resultados no Quadro 2, nota-se a diminuição da quantidade de dados brutos. Esse fato demonstra que os *softwares* desenvolvidos removeram as inconsistências e que nem todos os meses estavam completos. Assim, conseguiu excluir os dados inconsistentes do treinamento da rede neural. Portanto, no Quadro 3 são apresentados o número de dias completos utilizados em cada mês.

Quadro 3 – Número de dias utilizados em cada estação meteorológica.


	<b>NTEEL</b>	<b>INMET</b>
Mês	Quantidade de dias	Quantidade de dias
Novembro	27	30
Dezembro	27	31
Janeiro	28	31
Fevereiro	13	29
Março	31	31
Abril	24	30
Maio	14	31
Junho	30	29
Julho	31	19
Agosto	31	31
Setembro	18	30
Outubro	22	31
<b>Total</b>	<b>295</b>	<b>353</b>

Fonte: Elaborado pelo autor (2018).

É importante notar que para a obtenção dos resultados de previsão os dados do INMET estavam praticamente completos. Apenas no mês de julho foram 19 dias. Como consequência, a previsão foi considerada completa pois foram utilizados 353 dos 365 dias possíveis. A estação do NTEEL coletou 295 dias de dados completos utilizados para treinamento e escolha da RNA.

A rede neural foi modelada e desenvolvida utilizando o *software* Matlab. O modelo de RNA (arquitetura, função de ativação, etc.), segue o recomendado pela literatura conforme a seção 2.3. O esquema da RNA da ferramenta desenvolvida é apresentado na Figura 19.

Figura 19 – Esquema da rede neural desenvolvida.



Fonte: Elaborado pelo autor (2017).

Os resultados de treinamento mostram que os valores da correlação Pearson  $R$  são bem próximos e variam pouco. Esse fato é identificado na literatura, por exemplo, em Pinheiro, Lovato e R  ther (2017), em Ahmad e Anderson (2014), e por fim em Cornaro et al. (2013).

Entretanto, os autores citados, na maioria dos casos, realizam uma previs  o de pot  ncia gerada e/ou utilizam radia  o hor  ria ou m  dias mensais para diferentes conjuntos de vari  veis de entrada. Portanto, os resultados encontrados devem ser comparados com a literatura utilizando a devida cautela. Os valores encontrados de  $R$ , dispostos na Tabela 3, foram obtidos a partir do treinamento com dados da esta  o meteorol  gica do NTEEL.

Tabela 3 – Valores encontrados para a correla  o  $R$ .

<b>Neur��nios</b>	<b><math>R</math></b>
<b>5</b>	0,849
<b>6</b>	0,848
<b>7</b>	0,849
<b>8</b>	0,854
<b>9</b>	0,855
<b>10</b>	0,853
<b>15</b>	0,857
<b>20</b>	0,863
<b>25</b>	0,866
<b>30</b>	0,867
<b>40</b>	0,869
<b>150</b>	0,882

Fonte: Elaborado pelo autor (2018).

As principais conclus  es obtidas s  o que os valores da correla  o ( $R$ ) est  o diretamente relacionados com as vari  veis de entrada do modelo e com as condi  es clim  ticas locais. Em Kumar e Kaur (2016), os autores concluem que um modelo utilizando mais vari  veis meteorol  gicas promove uma previs  o mais precisa. Em contrapartida, o munic  pio de Ararangu   apresenta grande sazonalidade clim  tica. Salienta-se a necessidade de verificar quais as vari  veis possuem maior impacto para a previs  o da radia  o solar. Prop  e-se que os conjuntos de dados de entrada sejam estudados em detalhes em trabalhos futuros.

Na maioria dos trabalhos revisados, os autores escolhem a melhor rede com base no maior valor da correla  o  $R$  obtida durante o treinamento da RNA. At   o presente momento, n  o se encontram trabalhos com a mesma proposta de previs  o da radia  o solar no per  odo de tr  s horas. Como consequ  ncia, optou-se por calcular as m  tricas

anuais para todas as configurações de rede neural estudadas utilizando os dados da estação do INMET.

Ao calcular as métricas, descritas na seção 3.4, a literatura pressupõe que as redes com maior coeficiente  $R$  apresentariam os melhores resultados de previsão. Esse fato contrasta com os principais valores encontrados para a proposta de três horas. Os mesmos podem ser visualizados na Tabela 4.

Tabela 4 – Resultados para as métricas anuais

Neurônios	R	RMSE [W/m <sup>2</sup> ]	MAE [W/m <sup>2</sup> ]	MBE [W/m <sup>2</sup> ]
<b>5</b>	0,849	122,40	76,08	-11,73
<b>6</b>	0,848	122,73	76,24	-9,39
<b>7</b>	0,849	123,55	77,13	-10,34
<b>8</b>	0,854	125,09	78,10	-9,64
<b>9</b>	0,855	126,56	78,54	-10,16
<b>10</b>	0,853	125,69	77,94	-13,33
<b>15</b>	0,857	126,40	78,10	-6,87
<b>20</b>	0,863	131,75	81,22	-11,09
<b>25</b>	0,866	132,76	81,57	-12,30
<b>30</b>	0,867	136,68	82,70	-9,25
<b>40</b>	0,869	135,40	82,79	-13,86
<b>150</b>	0,882	162,39	92,11	-9,44

Fonte: Elaborado pelo autor (2018).

Conforme o resultado anterior, Tabela 4, optou-se por calcular um ‘*score*’ com base nas métricas anuais. Esse foi definido a partir da Equação 5, onde realizou-se uma média das métricas encontradas.

$$score = \frac{(RMSE+MAE+|MBE|)}{3} \quad (5)$$

Portanto a rede escolhida, com o melhor *score*, foi a rede com seis neurônios na camada oculta, conforme visto na Tabela 5.



Tabela 5 – *Score* das redes neurais

<b>Neurônios</b>	<b>SCORE</b>
5	70,92
<b>6</b>	<b>70,30</b>
7	71,19
8	71,80
9	72,61
10	73,17
15	71,31
20	75,55
25	76,41
30	77,08
40	78,22
150	88,86

Fonte: Elaborado pelo autor (2018).

O *score* foi calculado com a base de dados anual da estação meteorológica do INMET. Com isso, determinou-se a rede com o melhor desempenho. As previsões mensais foram utilizadas para avaliar com mais detalhes a capacidade de previsão da ferramenta. Os resultados mensais estão dispostos no Quadro 4.

Quadro 4 – Resultados de métricas mensais.

<b>Mês</b>	<b>RMSE [W/m<sup>2</sup>]</b>	<b>MAE [W/m<sup>2</sup>]</b>	<b>MBE [W/m<sup>2</sup>]</b>
Novembro	142,10	94,62	-38,66
Dezembro	158,14	105,41	-26,89
<b>Janeiro</b>	<b>159,87</b>	<b>107,48</b>	<b>-36,90</b>
Fevereiro	138,30	89,66	-23,51
Março	130,27	83,62	-30,85
Abril	109,20	68,68	22,98
Maiο	91,98	56,72	11,92
Junho	91,92	52,48	6,82
Julho	81,46	53,42	14,06
<b>Agosto</b>	<b>79,65</b>	<b>51,43</b>	<b>-8,75</b>
Setembro	93,24	55,47	5,66
Outubro	138,95	84,35	1,62
Anual	122,73	76,24	-9,39

Fonte: Elaborado pelo autor (2018).

Ao analisar o Quadro 4, destaca-se os valores de MBE encontrados para os meses de junho, agosto e setembro. Pois, os valores indicam que, quanto mais próximo de zero, melhores são os resultados a longo prazo

do modelo conforme IEA (2013). Nos meses em que o MBE apresentou valores negativos a rede previu de maneira subestimada e em caso positivo sobrestimada. Porém, anualmente a capacidade foi considerada subestimada.

Os valores de MAE representam a magnitude média do erro de previsão. Com isso, destaca-se que dos doze meses, onze obtiveram valores abaixo de  $100 \text{ W/m}^2$ . E o anual em  $76,24 \text{ W/m}^2$ . O que implica que a RNA apresenta uma boa capacidade de previsão.


Os resultados de RMSE fornecem mais peso aos maiores erros de previsão, de modo que o RMSE reflete melhor os custos de despacho pois grandes erros são proporcionalmente caros (Madsen et al. (2005) apud IEA (2013)). Destaca-se os meses de maio a setembro com valores de RMSE abaixo de  $100 \text{ W/m}^2$ . O que demonstra que foram obtidas previsões com pequena discrepância entre o valor real. Contudo, os meses de novembro a março requerem maior atenção quando se trata de despacho de energia.

Através das métricas foi possível quantificar a capacidade de previsão do modelo. Contudo, graficamente pode se verificar onde acontecem os principais erros e acertos de previsão. Toma-se como exemplo o mês de janeiro com o maior RMSE, visualizado na Figura 19.

No mês de janeiro identifica-se que a rede apresenta capacidade subestimada com deficiência na previsão de horários de maior incidência de radiação solar (12:00h às 14:00h). Esse resultado ocorre devido à rede não ser capaz de prever, na maior parte dos meses, valores próximos e/ou superiores a  $1000 \text{ W/m}^2$ . Essa limitação acontece porque no treinamento a rede aprendeu que, na maioria dos casos, a radiação não chega a esse valor, portanto atribuiu um pequeno peso sináptico. Desse modo, o valor de RMSE tende a aumentar.


Em contrapartida, o mês de agosto apresenta o melhor valor de RMSE justamente por apresentar picos na faixa de  $500$  a  $700 \text{ W/m}^2$  e graficamente a previsão pode ser visualizada na Figura 20. Salienta-se que cada curva nos gráficos corresponde a um dia de previsão.

Figura 20 – Previsão de curto prazo da radiação solar para janeiro de 2017



Fonte: Elaborado pelo autor (2018).

Figura 21 – Previsão de curto prazo da radiação solar para agosto de 2017



Fonte: Elaborado pelo autor (2018).

De maneira geral, a rede possui limitação de previsão nos picos de incidência de radiação solar. Esse fato deve ser investigado em trabalhos futuros. Todos os gráficos de previsão podem ser vistos nos Apêndices A até J.

Além do cálculo das métricas, optou-se por analisar as médias reais e a previstas da radiação solar. Efetuou-se o cálculo dos erros percentuais por meio da Equação 6.

$$Erro\% = \left| \frac{média_{real} - média_{prevista}}{média_{real}} \right| \times 100\% \quad (6)$$

Os resultados de erro percentual podem ser vistos no Quadro 5.

Quadro 5 – Erro percentual entre médias reais e previstas

Mês	Média Real [W/m <sup>2</sup> ]	Média Prevista [W/m <sup>2</sup> ]	Erro %
Novembro	363,12	333,16	8,25%
Dezembro	322,72	307,43	4,74%
Janeiro	321,91	296,96	7,75%
Fevereiro	275,3	261,5	5,01%
Março	258,17	232,91	9,78%
<b>Abril</b>	199,07	223,58	<b>12,31%</b>
Maio	143,21	153,4	7,12%
Junho	156,1	147,34	5,61%
Julho	205,82	221,05	7,40%
<b>Agosto</b>	208,24	201,34	<b>3,31%</b>
Setembro	198,75	206,53	3,91%
<b>Outubro</b>	254,85	260,97	<b>2,40%</b>
<b>Anual</b>	244,15	238,33	<b>2,38%</b>

Fonte: Elaborado pelo autor (2018).

Os resultados destacam que na média a previsão é considerada satisfatória, uma vez que sensores de medição apresentam erros da ordem de 5%. Destaca-se os meses de outubro e agosto com 2,4% e 3,31%, respectivamente. O mês de abril foi o único com erro percentual acima de 10%. Na média anual o erro de 2,38% demonstra a boa capacidade de previsão da ferramenta desenvolvida.



## 5 CONSIDERAÇÕES FINAIS

O objetivo geral desse trabalho foi desenvolver uma ferramenta de previsão de curto prazo da radiação solar, no período de três horas, por meio da utilização de redes neurais artificiais e dados de estações meteorológicas localizadas no município de Araranguá – SC.

Sabe-se, que o recurso solar possui oferta intermitente pois está sujeito à variabilidade climática. Tendo em vista que a produção de energia elétrica a partir da energia solar varia de acordo com a disponibilidade do recurso. As variáveis utilizadas foram: a hora do dia [minutos], temperatura [°C], umidade externa [%], velocidade do vento [m/s] e a radiação solar global no plano horizontal [W/m<sup>2</sup>]. Diante do pressuposto, os algoritmos desenvolvidos mostraram-se eficazes e fundamentais para a realização do treinamento e previsão da radiação solar. Verificou-se que a estação meteorológica do INMET apresentou 353 dias de dados completos e a do NTEEL 295 dias.

A metodologia e o *software* desenvolvido para tratamento de dados de entrada e saída da RNA mostraram-se adequados, pois, os dados fora do horário de interesse foram excluídos. Foi possível reduzir as inconsistências dos dados durante a modelagem, desenvolvimento e utilização da ferramenta.

Remetendo aos principais questionamentos que nortearam a pesquisa:

1. É possível realizar a previsão de curto prazo da radiação solar, em um período de três horas, utilizando dados de estações meteorológicas e redes neurais artificiais?
2. Qual a capacidade de acertos e segurança dos resultados?
3. Os resultados podem auxiliar no gerenciamento de operação de uma usina solar fotovoltaica?

Conclui-se que, a partir dos resultados obtidos, a ferramenta desenvolvida possui capacidade de realizar a previsão de curto prazo da radiação solar, em um período de três horas, utilizando dados de estações meteorológicas. Através das métricas foi possível quantificar a capacidade de previsão do modelo. Destaca-se os meses de maio a setembro com valores de RMSE abaixo de 100W/m<sup>2</sup>. O que demonstra que foram obtidas previsões com pequena discrepância entre o valor real. Contudo, os meses de novembro a março requerem maior atenção quando se trata de despacho de energia.

Os valores de MAE representaram que a magnitude média dos erros de previsão, em onze dos doze meses utilizados, ficaram abaixo de 100 W/m<sup>2</sup>. O que implica que a RNA apresenta uma boa capacidade de

previsão. Destaca-se os valores de MBE encontrados para os meses de junho, agosto e setembro. Pois, os valores indicam que, quanto mais próximo de zero, melhores são os resultados a longo prazo do modelo conforme IEA (2013). Nos meses em que o MBE apresentou valores negativos a rede previu de maneira subestimada e em caso positivo sobrestimada. Porém, anualmente a capacidade foi considerada subestimada. Os resultados médios, demonstram que a ferramenta apresentou um bom desempenho nos acertos. Esses permitem concluir que são seguros com erro médio percentual anual da ordem de 2,38%.

À medida que os mercados de energia evoluem, como o caso do EIM (*Energy Imbalance Markets*), o comércio intra-hora se tornará mais importante e, de maneira geral, os resultados encontrados demonstram que a ferramenta desenvolvida pode ser utilizada para auxiliar no gerenciamento de operação de usinas que utilizem energia solar fotovoltaica como fonte.

Vale salientar o fato de que, até o presente momento, poucas investigações foram realizadas no Brasil para verificar a capacidade de previsão de curto prazo do recurso solar. Portanto, recomenda-se a continuidade da pesquisa a fim de confirmar, ampliar, ou refutar, os resultados apresentados. Portanto, como perspectiva de trabalhos futuros recomenda-se:

- Que sejam investigados os pesos sinápticos e as relações das variáveis de entrada da RNA.
- A análise sobre a utilização de mais ou menos dados e sua relação com a limitação da RNA em prever valores próximos ou superiores a 1000W/m<sup>2</sup>.
- Que sejam utilizados os dados do INMET para o treinamento da RNA e os dados do NTEEL para previsão, para verificar a relação de ambas as estações.
- Que sejam analisados os horários em que a RNA apresenta maior capacidade de acerto e erros. Com isso identificar e mitigar grandes valores de RMSE.
- Que os estudos sejam ampliados utilizando outros municípios do Estado de Santa Catarina e do Brasil.
- Que os resultados sejam analisados em detalhes levando em consideração a geração de potência e despacho de energia.
- Que possam ser realizados estudos vislumbrando o mercado de energia e os impactos financeiros dos erros e acertos das previsões.



## REFERÊNCIAS

ABSOLAR – Associação Brasileira de Energia Solar Fotovoltaica - **BRASIL DEVE ALCANÇAR A MARCA DE 2 GW EM ENERGIA SOLAR INSTALADA EM 2018.**

Disponível em: <http://www.absolar.org.br/noticia/noticias-externas/brasil-deve-alcancar-a-marca-de-2-gw-em-energia-solar-instalada-em-2018.html>>

Acesso em: 09/05/2018

AHMAD, A.; ANDERSON, T.. Global Solar Radiation Prediction using Artificial Neural Network Models for New Zealand. Solar2014: **The 52nd Annual Conference of the Australian Solar Council.** 2014.

Disponível em: <[http://solarexhibition.com.au/wp-content/uploads/Solar\\_2014\\_Scientific-Research-Session\\_FINAL.pdf](http://solarexhibition.com.au/wp-content/uploads/Solar_2014_Scientific-Research-Session_FINAL.pdf)>

Acesso em: 20/07/2016.

ANTONANZAS, J.; OSORIO, N.; ESCOBAR, R.; URRACA, R.; MARTINEZ-DE-PISON, F.J.; ANTONANZAS-TORRES, F.. Review of photovoltaic power forecasting. **Solar Energy** **136** (2016) 78–111.

Disponível em:<<http://dx.doi.org/10.1016/j.solener.2016.06.069>>

Acesso em: 19/07/2017.

ASSI, A. H.; SHAMISI, M. H. Al; HEJASE, H. A. N. MATLAB tool for predicting the global solar radiation in UAE. **2012 International Conference on Renewable Energies for Developing Countries, REDEC 2012.** Disponível em:

<<http://ieeexplore.ieee.org/stamp/stamp.jsp?tp=&arnumber=6416698>>

Acesso em: 15/08/2016.

BACHER, P.; MADSENA, H.; NIELSEN, H. A.; Online short-term solar power forecasting. **Solar Energy** (2009). Volume 83. Pg. 1772–1783.

Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0038092X09001364>>

Acesso em: 22/06/2016.

BADESCU, V.. **Modeling Solar Radiation at the Earth’s Surface: Recent Advances.** Springer-Verlag Berlin Heidelberg 2008. ISBN: 978-3-540-77454-9.

BARBIERI, F.; RAJAKARUNA, S.; CURTIN, A. G.. Very short-term photovoltaic power forecasting with cloud modeling: A review.

**Renewable and Sustainable Energy Reviews** **75** (2017) 242–263.

Disponível em: <<http://dx.doi.org/10.1016/j.rser.2016.10.068>>

Acesso em: 21/07/2017.

BARTH, A.; WOLFER, C.; LOVATO, A.; GRIEBLER, D.. Avaliação da Irradiação Solar como Fonte de Energia Renovável no Noroeste do Estado do Rio Grande do Sul Através de Uma Rede Neural.

**Revista Eletrônica Argentina-Brasil de Tecnologias da Informação e da Comunicação**, [S.l.], v. 1, n. 5, set. 2016. ISSN 2446-7634.

Disponível em: <<http://revistas.setrem.com.br/index.php/reabtic/article/view/160>>.

Acesso em: 16 mar. 2017.

BELÚCIO, L. P.; SILVA, A. P. N.; SOUZA, L. R.; MOURA, G. B. de A.. G Radiação solar global estimada a partir da insolação para Macapá (AP). **Revista Brasileira de Meteorologia**, v.29, n.4, 494 - 504, 2014.

Disponível em: <<http://dx.doi.org/10.1590/0102-778620130079>>

Acesso em: 01/07/2016.

BRAGA, A. de P.; CARVALHO, A. P. de L. F. de; LUDERMIR, T. B..

**Redes neurais artificiais: teoria e aplicações**. 2. ed. Rio de Janeiro:

LTC, 2007.

BRASIL, MME – Ministério de Minas e Energia. **Brasil estará entre os 20 países com maior geração solar em 2018**. Publicado: 03/01/2016.

Disponível em: <<http://www.brasil.gov.br/infraestrutura/2016/01/brasil-estara-entre-os-20-paises-com-maior-geracao-solar-em-2018>>

Acesso em: 04/07/2016.

CEPEL – CRESESB. **Manual de engenharia para sistemas fotovoltaicos. Edição Revisada e Atualizada**. Rio de Janeiro, 2014.

Disponível

em: <<http://www.cresesb.cepel.br/index.php?section=publicacoes&task=livro&cid=481>>

Acesso em: 20/06/2016.

CHITEKA, K.; ENWEREMADU, C. C.; Prediction of global horizontal solar irradiance in Zimbabwe using artificial neural networks. **Journal of Cleaner Production** **135** (2016).

Disponível em: <[http://ac.els-cdn.com/S0959652616308058/1-s2.0-S0959652616308058-main.pdf?\\_tid=f08874f0-040c-11e7-815f-00000aab0f26&acdnat=1488984108\\_2f81d281e1f298680bee17d7f6673958](http://ac.els-cdn.com/S0959652616308058/1-s2.0-S0959652616308058-main.pdf?_tid=f08874f0-040c-11e7-815f-00000aab0f26&acdnat=1488984108_2f81d281e1f298680bee17d7f6673958)>

Acesso em: 19/06/2016.

CORNARO, C.; BUCCI, F.; PIERRO, M.; DEL FRATE, F.; PERONACI, S.; TARAVAT, A.. Solar radiation forecast using neural networks for the prediction of grid connected PV plants energy production (DSP project). **28th European Photovoltaic Solar Energy Conference and Exhibition. (2013).**

Disponível em: <<https://doi.org/10.4229/28theupvsec2013-5bv.4.48>>

Acesso em: 20/09/2017.

DAVID, M.; RAMAHATANA, F.; TROMBE, P.J.; LAURET, P.. Probabilistic forecasting of the solar irradiance with recursive ARMA and GARCH models. **Solar Energy (2016)**. Volume: 133, Publisher: Elsevier Ltd, Pages: 55-72.

Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0038092X16300172>>

Acesso em: 22/06/2016.

DGS - Deutsche Gesellschaft für Sonnenenergie. **Planning & Installing Photovoltaic Systems - A guide for installers, architects and engineers**. Earth-scan, UK, 2008. ISBN 978-1-84407-442-6.

EPE - EMPRESA DE PESQUISA ENERGÉTICA (EPE) - **Balço Energético Nacional – BEN 2017**.

Disponível em: <<https://ben.epe.gov.br/benrelatoriosintese.aspx>>

Acesso em: 16/09/2017.

GHAYEKHLOO, M.; GHOFRANI, M.; MENHAJ, M.B.; AZIMI, R.. A novel clustering approach for short-term solar radiation forecasting. **Solar Energy, 2015**. Volume 122 pg 1371–1383.

Disponível

em: <<http://www.sciencedirect.com/science/article/pii/S0038092X1500609X>>

Acesso em: 22/06/2016.

GUARNIERI, R. A.; PEREIRA, E. B.; MARTINS, F. R.; CHAN, C. S.. Previsões de radiação solar utilizando modelo de mesoescala: refinamento com redes neurais. **I CBENS - I Congresso Brasileiro de Energia Solar**. ABENS - Associação Brasileira de Energia Solar Fortaleza, 2007.

Disponível

em:<[http://ftp.cptec.inpe.br/labren/publ/eventos/CBENS2007\\_RicardoAGuarnieri\\_et al.pdf](http://ftp.cptec.inpe.br/labren/publ/eventos/CBENS2007_RicardoAGuarnieri_et al.pdf)>

Acesso em: 22/06/2016.

GOOGLE MAPS, **Mapa de Araranguá, 2017.**

Disponível em: [maps.google.com](http://maps.google.com)

Acesso em: 23/07/2016.

HAYKIN, S. S. **Redes neurais: princípios e prática. 2ed.** - Porto Alegre: Bookman,2001.

HUANG, R.; HUANG, T.; GADH, R. Solar Generation Prediction using the ARMA Model in a Laboratory-level Micro-grid. **IEEE Third International Conference on Smart Grid Communications (SmartGridComm)**, 2012.

Disponível em:<

<http://ieeexplore.ieee.org/xpl/login.jsp?tp=&arnumber=6486039&url=ht tp%3A%2F%2Fieeexplore.ieee.org%2Fiel7%2F6479749%2F6485945 %2F06486039.pdf%3Farnumber%3D6486039>>

Acesso em: 21/07/2016.

IEA - PVPS - INTERNATIONAL ENERGY AGENCY - PHOTOVOLTAIC POWER SYSTEMS PROGRAMME. **Snapshot of Global Photovoltaic Markets 2015.**

Disponível em: <[http://www.iea-pvps.org/index.php?id=95&eID=dam\\_frontend\\_push&docID=3079](http://www.iea-pvps.org/index.php?id=95&eID=dam_frontend_push&docID=3079)>

Acesso em: 18/07/2016.

IEA - PVPS - INTERNATIONAL ENERGY AGENCY - PHOTOVOLTAIC POWER SYSTEMS PROGRAMME. **Photovoltaic and Solar Forecasting: State of the Art. 2013.** ISBN 978-3-906042-13-8

Disponível em: < [http://www.iea-pvps.org/index.php?id=3&eID=dam\\_frontend\\_push&docID=1690](http://www.iea-pvps.org/index.php?id=3&eID=dam_frontend_push&docID=1690)>

Acesso em: 18/07/2016.

INMET (INSTITUTO NACIONAL DE METEOROLOGIA) - **Estações Automáticas**. Disponível em:

<<http://www.inmet.gov.br/portal/index.php?r=estacoes/estacoesautomaticas>>

Acesso em: 10/03/2017.

KASHYAP, Y.; BANSAL, A.; SAO, A. K.. Solar radiation forecasting with multiple parameters neural networks. **Renewable and Sustainable Energy Reviews** **49** (2015) pg. 825–835 .

Disponível em: <<http://dx.doi.org/10.1016/j.rser.2015.04.077>>

Acesso em: 10/03/2017.

KUMAR, S.; KAUR, T.. Development of ANN Based Model for Solar Potential Assessment Using Various Meteorological Parameters. Energy Procedia 90 ( 2016 ) 587 – 592. **5th International Conference on Advances in Energy Research, ICAER 2015**, 15-17 December 2015, Mumbai, India.

Disponível em:<[10.1016/j.egypro.2016.11.227](http://10.1016/j.egypro.2016.11.227)>

Acesso em:< 15/08/2017.

LIMA, F. J. L. **Previsão de irradiação solar no Nordeste do Brasil empregando o modelo WRF ajustado por redes neurais artificiais (rnas)**. Tese de Doutorado do Curso de Pós- Graduação em Meteorologia,INPE São José dos Campos 2015.

Disponível em:

<[http://ftp.cptec.inpe.br/labren/publ/teses/Tese2015\\_Francisco\\_Lima.pdf](http://ftp.cptec.inpe.br/labren/publ/teses/Tese2015_Francisco_Lima.pdf)>

Acesso em: 11/07/2016.

LIMA, F. J. L.; MARTINS, F. R.; PEREIRA, E. B.; LORENZ, E.; HEINEMANN, D.. Forecast for surface solar irradiance at the Brazilian Northeastern region using NWP model and artificial neural networks. **Renewable Energy** **87** (2016) 807 - 818.

Disponível em: <<http://dx.doi.org/10.1016/j.renene.2015.11.005>>

Acesso em: 10/05/2017.

MADSEN, H.; PINSON, P.; KARINIOTAKIS, G.; NIELSEN, H.A.; NIELSEN, T. S.. Standardizing the performance evaluation of short-term wind power prediction models”. **Wind Eng.** **2005**;29(6):475-89.

MANTZARI, V. H.; MANTZARIS, D. H.. Solar radiation: Cloudiness forecasting using a soft computing approach. **Artificial Intelligence Research**, 2013, Vol. 2, No. 1.

Disponível em:<<http://dx.doi.org/10.5430/air.v2n1p69>>

Acesso em: 21/07/2016.

MELLIT, A.; MASSI PAVAN, A.; LUGHI, V. Short-term forecasting of power production in a large-scale photovoltaic plant. **Solar Energy** (2014). Volume 105, Pages 401–413.

Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0038092X14001522>>

Acesso em: 22/06/2016.

NEELAMEGAM, P.; AMIRTHAM, V. A.; Prediction of solar radiation for solar systems by using ANN models with different back propagation algorithms. **Journal of Applied Research and Technology** 14 (2016) 206–214.

Disponível

em:<<http://www.sciencedirect.com/science/article/pii/S1665642316300438>>

Acesso em: 24/05/2017.

PEREIRA, E. B.; MARTINS, F. R.; GONÇALVES, A. R.; COSTA, R. S.; LIMA, F. J. L.; RÜTHER, R.; ABREU, S. L. de; TIEPOLO, G. M.; PEREIRA, S. V.; SOUZA, J. G.s de.. **Atlas Brasileiro de Energia Solar. 2.ed.** LABREN (Laboratório de Modelagem e Estudos de Recursos Renováveis de Energia) / CCST (Centro de Ciência do Sistema Terrestre) / INPE (Instituto Nacional de Pesquisas Espaciais). São José dos Campos - Brasil. INPE, 2017.(E-BOOK)

Disponível em: <[http://labren.ccst.inpe.br/atlas\\_2017.html](http://labren.ccst.inpe.br/atlas_2017.html)>

Acesso em: 15/09/2017

PINHEIRO, E.; LOVATO, A.; RÜTHER, R.. Aplicabilidade de redes neurais artificiais para análise de geração de energia de um sistema fotovoltaico conectado a rede elétrica. **Revista Brasileira de Energias Renováveis** (2017).

Disponível em: <<http://dx.doi.org/10.5380/rber.v6i5.48431>>

Acesso em: 30/01/2018.

ROSA, J. L. G.. **Fundamentos da inteligência artificial**. Rio de Janeiro: LTC, 2011.

RÜTHER, R., NASCIMENTO, L. R., CAMPOS, R. A. Extreme overirradiance events in Brazil: consequences on PV power plant output performance, submitted to **Solar Energy**, 2017.

SANTOS, B. A. de O. **Previsão de produção de centrais solares a muito curto prazo**. Mestrado Integrado em Engenharia Electrotécnica e de Computadores Major Energia. Faculdade de Engenharia da Universidade do Porto. Portugal, 2010.

Disponível em: <<https://repositorio-aberto.up.pt/bitstream/10216/58192/1/000143979.pdf>>

Acesso em: 20/06/2016.

SOLARPOWER EUROPE - **Global Market Outlook for solar power /2017 - 2021**.

Disponível em:

<[http://www.solarpowereurope.org/index.php?id=819&ADMCMDCMD\\_cooluri=1](http://www.solarpowereurope.org/index.php?id=819&ADMCMDCMD_cooluri=1)>

Acesso em: 15/07/2017.

SONDA (Sistema de Organização Nacional de Dados Ambientais) - **VALIDAÇÃO DOS DADOS**.

Disponível em: <<http://sonda.ccst.inpe.br/infos/validacao.html>>

Acesso em: 20/08/2016.

SPERATI, S.; ALESSANDRINI, S.; MONACHE, L. D.. An application of the ECMWF Ensemble Prediction System for short-term solar power forecasting. **Solar Energy**, 2016. Volume 133. Pg 437–450. Disponível

em: <<http://www.sciencedirect.com/science/article/pii/S0038092X1630041X>>

Acesso em: 10/06/2016.

TEIXEIRA JÚNIOR, L. A.; PESSANHA, J. F. M.; MENEZES, M. L. de; CASSIANO, K. M.; SOUZA, R. C.. Redes neurais artificiais e decomposição wavelet na previsão da radiação solar direta. **Congresso Latino-Iberoamericano de Investigación Operativa, Simpósio Brasileiro de Pesquisa Operacional. 2012**, Rio de Janeiro.

Disponível em:

<<http://www.din.uem.br/sbpo/sbpo2012/pdf/arq0282.pdf>>

Acesso em: 15/03/2017.

YANG, D.; KLEISSL, J.; GUEYMARD, C. A.; PEDRO, H. T. C.; COIMBRA, C. F. M.. History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. **Solar Energy. 2018**.

Acesso em: 25/04/2018

Disponível em: < <https://doi.org/10.1016/j.solener.2017.11.023>>

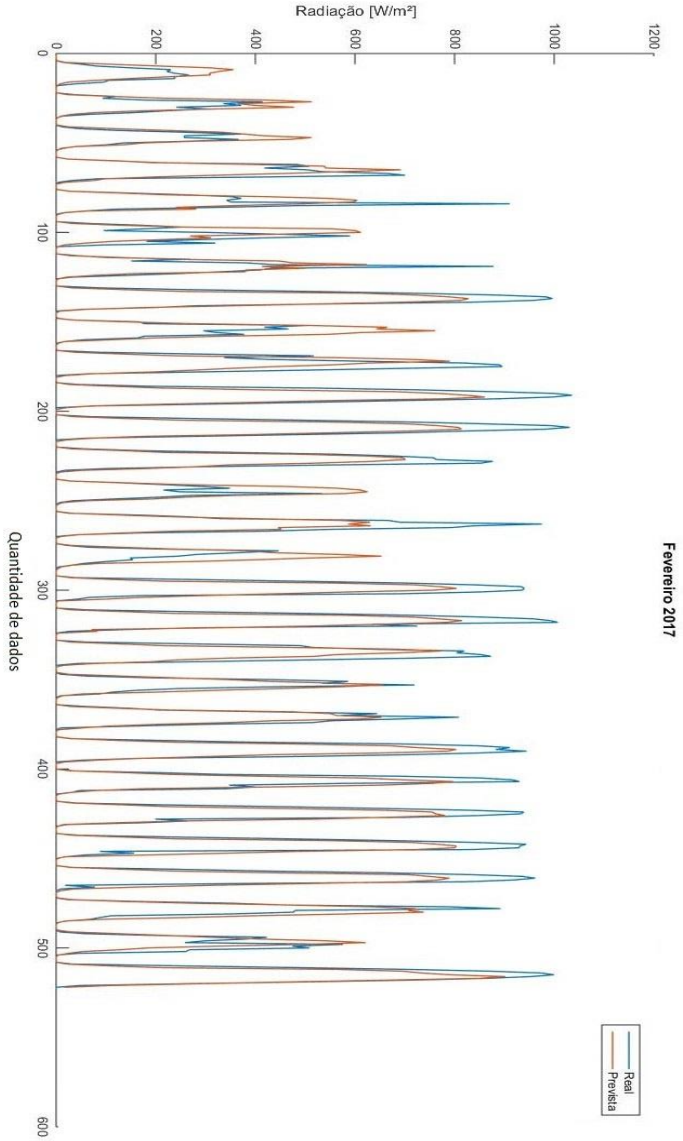
ZHANG, J.; HODGE, B.-M.; FLORITA, A.; LU, S.; HAMANN, H. F.; BANUNARAYANAN, V.. Metrics for Evaluating the Accuracy of Solar Power. **3rd International Workshop on Integration of Solar Power into Power Systems**. London, England, 2013.

Disponível em: < <https://www.nrel.gov/docs/fy14osti/60142.pdf>>


Acesso em: 25/09/2017.




### APÊNDICE A – Previsão de curto prazo da radiação solar para Fevereiro de 2017




### APÊNDICE B – Previsão de curto prazo da radiação solar para Março de 2017




### APÊNDICE C – Previsão de curto prazo da radiação solar para Abril de 2017



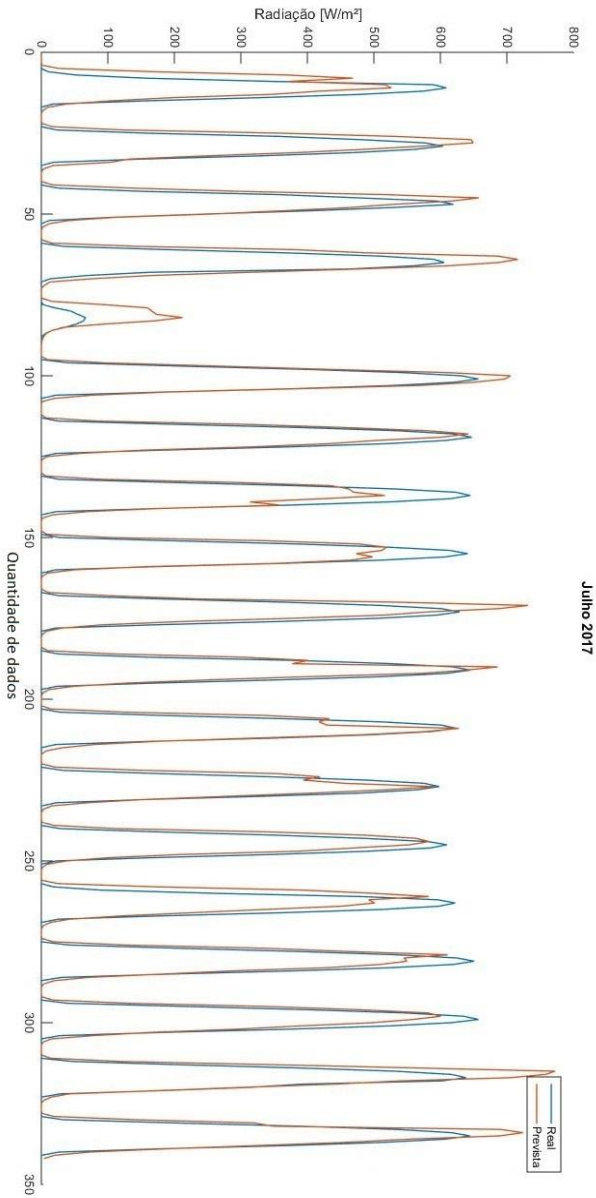
### APÊNDICE D – Previsão de curto prazo da radiação solar para Maio de 2017




### APÊNDICE E – Previsão de curto prazo da radiação solar para Junho de 2017




## APÊNDICE F – Previsão de curto prazo da radiação solar para Julho de 2017



### APÊNDICE G – Previsão de curto prazo da radiação solar para Setembro de 2017

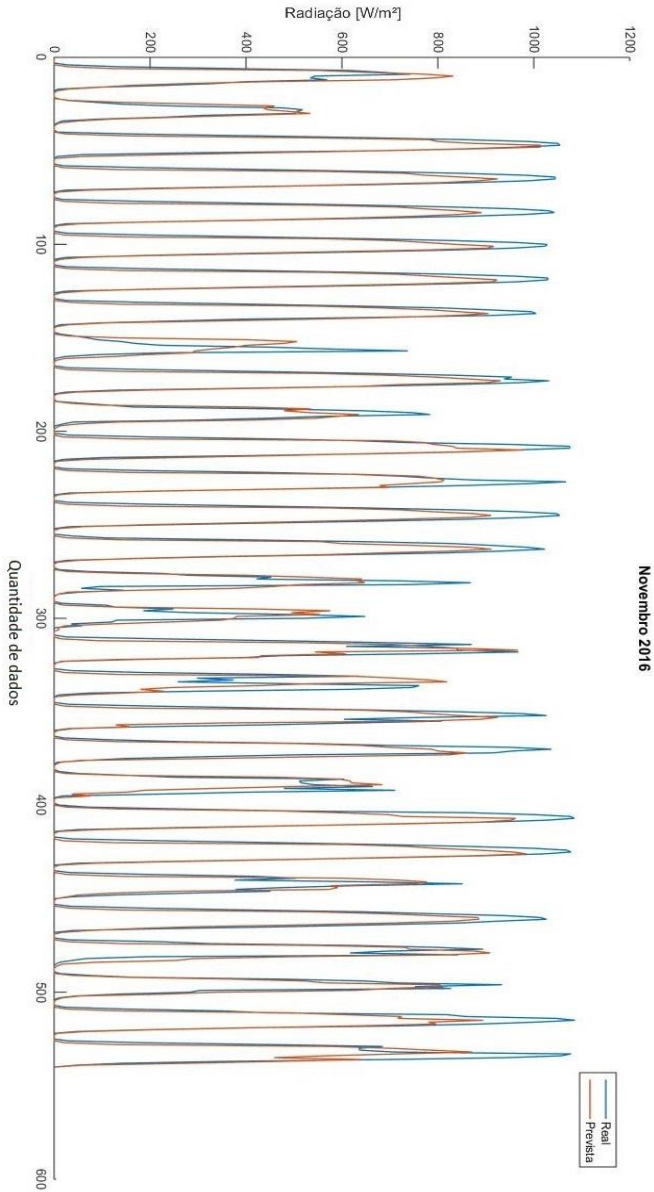


## APÊNDICE H – Previsão de curto prazo da radiação solar para Outubro de 2017





## APÊNDICE I – Previsão de curto prazo da radiação solar para Novembro de 2016



## APÊNDICE J – Previsão de curto prazo da radiação solar para Dezembro de 2016

