

# Comparação da Acurácia de Modelos de Redes Neurais Artificiais na Predição da Irradiância Solar e Geração de Energia Fotovoltaica

Carlos Alejandro Urzagasti  
Universidade Federal da Integração  
Latino Americana (UNILA)  
Foz do Iguaçu, Paraná, Brasil  
carlos.urzagasti@aluno.unila.edu.br

Joylan Nunes Maciel  
Universidade Federal da Integração  
Latino Americana (UNILA)  
Foz do Iguaçu, Paraná, Brasil  
joylan.maciel@unila.edu.br

Victor Hugo Wentz  
Universidade Federal da Integração  
Latino Americana (UNILA)  
Foz do Iguaçu, Paraná, Brasil  
victor.wentz@aluno.unila.edu.br

Jorge Javier Gimenez Ledesma  
Universidade Federal da Integração  
Latino Americana (UNILA)  
Foz do Iguaçu, Paraná, Brasil  
jorge.ledesma@unila.edu.br

Oswaldo Hideo Ando Junior  
Universidade Federal da Integração  
Latino Americana (UNILA)  
Foz do Iguaçu, Paraná, Brasil  
oswaldo.junior@unila.edu.br

**Abstract**— One of the ways to supply the growing consumption of electricity with the use of clean and renewable energy sources, such as solar photovoltaics. However, this type of generation has intermittenencies that increase the instability and insecurity of the electric system. One of the solutions to this problem is the study of methods for Prediction of Solar Photovoltaic Energy Generation (PGESF). In this context, the present study compared the prediction accuracy of Artificial Neural Network (ANN) models, published in [14], from two distinct databases (datasets) and three different short-term loss horizons. The results suggest that the use of different meteorological variables and the size of the dataset significantly influence ( $p\text{-value}<0.001$ ) the models's accuracy. Furthermore, the model's prediction accuracy decreases as the prediction horizon increases.

**Resumo**— Uma das maneiras de suprir o crescente consumo de energia elétrica com o uso de fontes de energia limpa e renovável, tal como a solar fotovoltaica. No entanto, este tipo de geração possui intermitências que aumentam a instabilidade e a insegurança da rede energética. Uma das soluções para este problema consiste no estudo de métodos para a Predição da Geração de Energia Solar Fotovoltaica (PGESF). Neste contexto, o presente estudo comparou a acurácia de predição de modelos de Redes Neurais Artificiais (RNA), publicado em [14], a partir de duas bases de dados (*datasets*) distintas e três diferentes horizontes de predição de curto prazo. Os resultados sugerem que o uso de diferentes variáveis meteorológicas e o tamanho do *dataset* influenciam significativamente ( $p\text{-valor}<0,001$ ) na acurácia dos modelos. Além disso, a acurácia de predição dos modelos diminuiu conforme o horizonte de predição aumentou.

**Palavras-chave**— predição de energia solar fotovoltaica; irradiância solar; Redes Neurais Artificiais.

## I. INTRODUÇÃO

A diversificação da matriz energética brasileira com o uso de fontes renováveis é uma das principais estratégias para suprir o crescimento do consumo energético que vem ocorrendo no país [1], contribuindo ainda a sustentabilidade

energética do setor elétrico [2]. Duas das principais formas de geração de energia sustentável são a energia eólica e a solar, com destaque para o acentuado aumento da geração solar por meio de células [3].

A geração de energia a partir do sol, por meio de painéis de células solares fotovoltaicas, possui características importantes, e não controláveis, relativas as condições climáticas, movimentos, altura e espessura das nuvens, temperatura, intensidade e duração da radiação solar, humidade do ar, entre outros [4]. Estas características ocasionam intermitências na geração da energia solar fotovoltaica, e isto aumenta a instabilidade e a insegurança da rede energética [5], [6]. Estas intermitências na geração solar fotovoltaica são estudadas e podem ser preditas a partir de métodos para a Predição da Geração de Energia Solar Fotovoltaica (PGESF), os quais permitem também a comercialização antecipada da produção de energia elétrica a partir da fonte solar [7].

Existem diversos métodos [8] e diferentes horizontes temporais de predição [9] que são estudados há mais de 10 anos na literatura científica da PGESF, havendo também um crescente aumento de publicações desde 2017 [10]. Ressalta-se que não existe um consenso literário exato sobre a definição única dos horizontes de predição e das classes de métodos utilizados nesta área de pesquisa [7]. Em relação ao métodos baseados em Inteligência Artificial, especificamente de *Machine Learning* (ML) são os que apresentam as melhores precisão nas predições [9], assim como as Redes Neurais Artificiais (RNA) são os modelos mais utilizados na PGESF [10].

Um recente estudo do Grupo de Pesquisa em Energia e Sustentabilidade Energética (GPEnSE) da Universidade Federal da Integração Latino Americana (UNILA) observou que existem poucas pesquisa sobre a PGESF no Brasil e América-Latina [10]. Além disso, neste mesmo estudo constatou-se que, em geral, os métodos de PGESF são

desenvolvidos e avaliados individualmente por meio de métricas de erros, não sendo observadas pesquisas de comparações entre determinado método de PGESF a partir de distintas bases de dados (*datasets*).

Em um destes estudos [11] utilizou-se informações da cidade de Fortaleza no Brasil, onde formularam uma RNA para estimar a irradiação global semanal e mensal. Os resultados demonstraram níveis de acurácia parecidos a pesquisas semelhantes, com menor erro para a predição de média mensal da irradiação global [11]. Outra pesquisa sobre PGESF empregou uma RNA para previsão das 24 horas futuras de irradiação solar com dados de um sistema fotovoltaico na cidade de Trieste, na Itália [12]. A RNA apresentou resultados satisfatórios e coeficientes de correlação de 98-99% para dias ensolarados e de 94-96% para dias com nuvens [12]. Recentemente, uma análise comparativa dos modelos de [11] e [12] constatou que a estrutura de camadas das RNAs, os distintos horizontes de predição e o tipo da irradiância solar influenciam na precisão dos modelos [13]. Este estudo motivou a realização de uma análise das variáveis meteorológicas, estruturas das RNAs, irradiância solar e horizontes de predição de curto prazo na PGESF considerando uma única base de dados [14].

Neste contexto, o objetivo principal desta pesquisa é comparar a precisão de predição dos modelos de RNAs empregados em [14], a partir de uma nova base de dados (*dataset*) de geração de energia solar fotovoltaica localizada na cidade de Florianópolis, Santa Catarina, Brasil [15]. Com esta análise pretende-se contribuir para o desenvolvimento de novos métodos e modelos de PGESF no Brasil e América Latina, fomentando e ampliando os estudos nesta relevante área pesquisa. Portanto, os objetivos específicos deste estudo contemplam: (i) comparar a acurácia do modelo de RNA avaliado em [14] a partir de duas bases de dados distintas: o *dataset* FOLSOM [16] e *dataset* USFC [15]; (ii) analisar a influência das distintas variáveis de entradas das RNAs no desempenho dos modelos e; (iii) analisar a acurácia dos modelos em relação distintos horizontes de predição de curto prazo. Para isto, as próximas seções apresentam os materiais e método, os resultados, discussões e conclusões.

## II. MATERIAIS E MÉTODO

### A. Delineamento Metodológico

Conforme mencionado anteriormente, o método mais empregado nas pesquisas sobre a PGESF são as RNAs [9]. A Figura 1 (a) apresenta, esquematicamente, um neurônio artificial, onde  $x_1, x_2, \dots, x_n$  correspondem às entradas. Para cada entrada  $x_i$  existe um peso correspondente  $w_i$  a soma das entradas  $x_i$ , ponderadas pelos pesos  $w_i$ , é a saída linear  $u$ , em que  $u = \sum_i w_i x_i$ . A saída  $y$  do neurônio, denominada saída de ativação, é obtida pela aplicação de uma função  $f()$  à saída linear  $u$ , indicada por  $y = f(u)$ . A função  $f()$  é chamada de função de ativação e pode assumir várias formas, geralmente não-lineares [17].

A Figura 1(b) representa uma RNA simples que possui cinco entradas ( $x_1, x_2, \dots, x_5$ ), quatro neurônios na camada

intermediária e duas saídas ( $y_1$  e  $y_2$ ). A RNA é, portanto, formada por diversos elementos processadores que tem a capacidade de resolução de problemas complexos [18].




Fig. 1. Exemplo de (a) um neurônio e (b) uma RNA.

As RNAs avaliadas neste estudo possuem exatamente a mesma configuração estrutural (número de camadas e neurônios) em relação as RNAs utilizadas em [14]. Esta configuração é exibida na Tabela 1 com o formato  $A \times B \times C \dots \times Y$ . O primeiro valor (A) representa os neurônios (parâmetros) de entrada (*inputs*), B, C e outros, as camadas ocultas e respectivas quantidade de neurônios e, por fim, Y é a camada de saída (*output*) da rede com 1 neurônio. Como exemplo, a RNA-60 possui 6 parâmetros de entrada, uma única camada oculta com 60 neurônios e uma camada de saída com um neurônio.

Tabela 1. Modelos de RNAs desta pesquisa.

Modelo de RNA	Configuração do grupo	Horizontes (minutos)	Saída ( <i>output</i> )
RNA-60	6×60×1	1, 15, 60	GHI
RNA-3030	6×30×30×1	1, 15, 60	GHI

Para possibilitar a comparação dos resultados deste estudo, foram adotados os mesmos horizontes de predição avaliados em [14] (Tabela 1). Além disso, as variáveis existentes no *dataset* UFSC [15] foram utilizadas como parâmetros de entrada (*inputs*) e saída (*output*) nos experimentos deste estudo são detalhado na Tabela 2.

Tabela 2. Parâmetros utilizados nas RNAs.

Parâmetro	Descrição	Tipo
<i>temp_amb</i>	temperatura do ar	<i>input</i>
<i>azimut</i>	ângulo azimutal	<i>input</i>
<i>zenith</i>	Ângulo zenital	<i>input</i>
<i>month, hour, min</i>	mês, hora e minuto	<i>input</i>
<i>solar_irradiation</i>	irradiância solar	<i>output</i>

O desempenho de acurácia (precisão) de uma RNA pode ser mensurado por diversas métricas estatísticas. Com base em [19] foram adotadas as duas principais métricas estatísticas na área da PGESF: o Coeficiente de Determinação ( $R^2$ ) e o *Root Mean Square Error* (RMSE), respectivamente definidas pelas Equações 1 e 2.

$$R^2 = 1 - \frac{\sum_{i=1}^N (p_i - o_i)^2}{\sum_{i=1}^N (p_i + o_i)^2} \quad (1)$$

$$RMSE = \left[ \frac{1}{M} \sum_{i=1}^N (p_i - o_i) \right]^{1/2} \quad (2)$$

Nas métricas acima  $N$  representa a quantidade de pontos da distribuição,  $M$  a média da distribuição observada,  $p_i$  o  $i$ -ésimo ponto predito e  $o_i$  representa o  $i$ -ésimo ponto observado. O  $RMSE$  é o mais utilizado e sensível a grandes erros individuais (contêm valores ao quadrado). O  $R^2$  avalia a precisão do ajuste do modelo aos dados originais, e quanto mais próximo a 1, melhor qualidade tem o modelo previsto em relação aos dados originais.

### B. Banco de Dados (datasets)

Os modelos de RNAs deste estudo foram desenvolvidos e avaliados com o *dataset* UFSC [15]. Desse modo, os resultados de acurácia destes modelos foram então comparados aos resultados de acurácias das RNAs avaliadas [14], que por sua vez empregou o *dataset* FOLSOM [16]. As informações de ambos os *datasets* (UFSC e FOLSOM) e suas variáveis são exibidas na Tabela 3.

Tabela 3. Número de registros por horizonte e as variáveis dos *datasets* empregados neste estudo.

FOLSOM <i>dataset</i> [16]		UFSC <i>dataset</i> [15]		
Horizonte de Predição	Treino 2014-2015 (24 meses)	Teste 2016 (12 meses)	Treino 2018-2019.1 (18 meses)	Teste 2019.2 (6 meses)
1 minutos	1.028.982	261.360	440.775	146.925
15 minutos	68.601	17.424	32.853	10.951
60 minutos	17.152	4.356	8212	2738

FOLSOM <i>dataset</i> [16]		UFSC <i>dataset</i> [15]	
Variáveis de entrada	Temperatura do ar Velocidade do vento* Direção do vento* Mês, hora e minuto	Variáveis de entrada	Temperatura do ar Angulo azimutal* Angulo zenital* Mês, hora e minuto
Variável de saída	Irradiância solar (GHI)	Variável de saída	Irradiância solar (GHI)

\* Variáveis que se diferenciam nos *datasets* FOLSOM e UFSC.

### C. Ferramentas e Tecnologias

O desenvolvimento desta pesquisa empregou ferramentas e tecnologias de softwares livres (open-source), tais como Linguagem de programação Python e as bibliotecas *Pandas*, *Numpy*, *Matplotlib*, *Sklearn* [20]. Além disso, foi utilizado o ambiente de desenvolvimento *Google Colaboratory* (Colab) [21] e o *dataset* com informações de geração energia solar fotovoltaica da USFC [15]. Nas análises estatísticas foram utilizados os softwares *open-source* Jamovi [22].

## III. RESULTADOS E DISCUSSÃO

Após a execução experimental obteve-se os resultados de acurácias dos modelos utilizando o *dataset* UFSC [15]. O

tempo médio de cada treinamento variou de 10 a 60 minutos no ambiente Colab. A Tabela 4 exhibe o resultado da acurácia de predição dos modelos UFSC gerados neste estudo, assim como os resultados de acurácia dos modelos FOLSOM disponíveis em [14].

Observa-se na Tabela 4 que as acurácias dos modelos em empregando o *dataset* FOLSOM são superiores aos modelos UFSC. Tem-se valores médios de  $R^2 \geq 0,9$  para todos os horizontes de predição nos modelos FOLSOM, enquanto que se obteve os valores de  $R^2 \leq 0,80$  nos modelos utilizando o *dataset* UFSC deste estudo.

Tabela 4. Acurácias dos modelos UFSC e FOLSOM.

Modelos com <i>dataset</i> UFSC [15]			
Estrutura da RNA	Horizonte de predição	$R^2$	$RMSE$
RNA-3030 (6x30x30x1)	1	0,81	0,11
	15	0,78	0,11
	60	0,70	0,11
	Média	0,763	0,11
	Desvio Padrão	0,057	0
RNA-60 (6x60x1)	1	0,79	0,11
	15	0,77	0,12
	60	0,69	0,11
	Média	0,75	0,113
	Desvio Padrão	0,053	0,005

Modelos com <i>dataset</i> FOLSOM [14]			
Estrutura da RNA	Horizonte de predição	$R^2$	$RMSE$
RNA-3030 (6x30x30x1)	1	0,94	0,05
	15	0,93	0,06
	60	0,92	0,07
	Média	0,93	0,06
	Desvio Padrão	0,01	0,01
RNA-60 (6x60x1)	1	0,92	0,05
	15	0,91	0,06
	60	0,91	0,07
	Média	0,913	0,06
	Desvio Padrão	0,005	0,01

Para constatar a existência de diferenças significativas entre os modelos FOLSOM e UFSC (Tabela 4) realizou-se comparações estatísticas das acurácias de predição por meio de testes de hipóteses, os quais permitem rejeitar ou não rejeitar determinada hipótese estatística através da evidência fornecida pela amostra [23], [24]. Nas comparações estatísticas buscou-se verificar a Hipótese Nula ( $H_0$ ) de igualdade da acurácia de predição entre os valores médios de  $R^2$  entre os pares de modelos de predição. Portanto, com base em [23] foi utilizado o teste de *Shapiro Wilk* e constatou-se a não normalidade dos dados ( $p$ -valor < 0,05). Desse modo, foi aplicado o teste de hipótese não-paramétrico *Kruskal Wallis* e o pós-teste *Conover's Post Hoc Comparisons* para se comparar as acurácias entre todos os pares de modelos [25].

A partir dos resultados foram observadas diferenças significativas ( $p\text{-valor} < 0,001$ ), ao nível de 95% [23], entre todas as comparações de modelos utilizando os *datasets* UFSC e FOLSOM, independente do horizonte de predição comparado.

A Figura 2 exibe a acurácia de predição geral de todos os modelos UFSC e FOLSOM conjuntamente. A diferença observada pode ser justificada por dois fatores: as variáveis que são utilizadas como entrada em cada modelo diferem-se. No modelo UFSC tem-se o ângulo azimutal e o ângulo zenital, ao passo que nos modelos com *dataset* FOLSOM existem a velocidade e a direção dos ventos. Além disso, a quantidade de dados utilizados no treinamento dos modelos é distinta, o que também prejudica a acurácia das RNAs [17]. Portanto, o uso de uma mesma estrutura de RNA não demonstrou, necessariamente, a mesma acurácia quando se tem variáveis de entrada e tamanhos de *datasets* distintos.

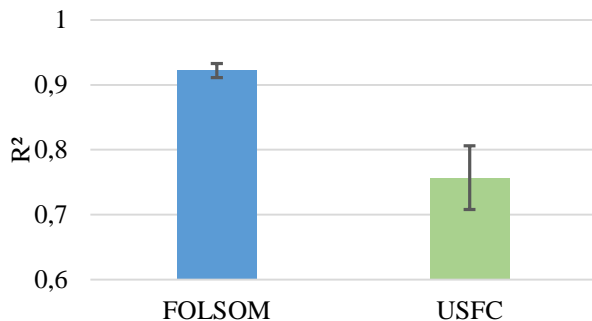


Fig. 2. Comparação da médias e Desvios Padrão de  $R^2$  considerando todas as predições dos modelos com *datasets* FOLSOM e UFSC.

Na Figura 3 é apresentada uma análise comparando as acurácias em relação a métrica de RMSE entre os distintos modelos para cada horizonte de predição avaliado. Nota-se que conforme o horizonte aumenta, o RMSE aumenta para os modelos do *dataset* FOLSOM. Por outro lado, esse resultado não é observado com o *dataset* UFSC, no qual os valores são constantes, com exceção da RNA-3030.

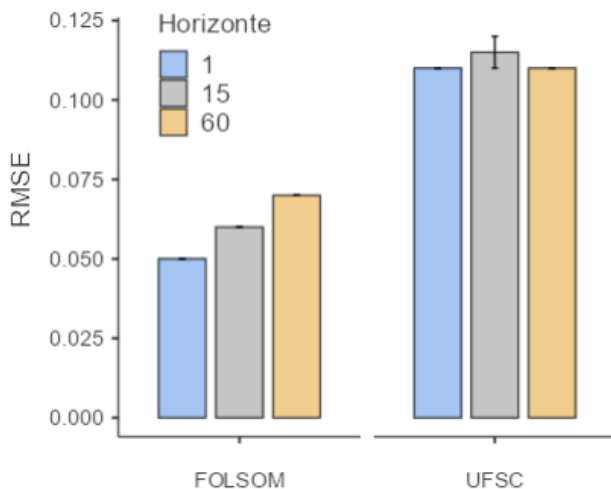


Fig. 3. Valor médio e Desvio Padrão do RMSE por modelos de *datasets* e horizontes de predição.

Portanto, com base na Figura 3, o horizonte de predição influenciou na acurácia dos modelos que utilizaram o *dataset* FOLSOM nos horizontes analisados neste estudo. Em relação aos modelos de RNA aplicados ao *dataset* UFSC, o horizonte de predição não influenciou as acurácias que se mantiveram similares, porém, os valores de RMSE são significativamente maiores do que nos modelos com *dataset* FOLSOM para todos os horizontes de predição de curto prazo avaliados.

#### IV. CONCLUSÃO

O objetivo deste estudo foi comparar a acurácia de dos modelos de RNA, descritos em [14], a partir de um *dataset* distinto (UFSC) que está localizado na cidade de Florianópolis-SC, no Brasil. Foram mantidos as mesmas configurações e estruturas das redes, com exceção de duas variáveis de entrada que são distintas entre os *datasets* UFSC [15] e FOLSOM [14].

A partir dos resultados infere-se que houve diferença estatística significativa (95%) em todas as comparações com distintos *datasets* (modelos UFSC e FOLSOM). Além disso, os horizontes de predição de curto prazo analisados influenciam na precisão dos modelos com o *dataset* FOLSOM, sendo este resultado não observado nos modelos UFSC. Portanto, os resultados demonstram que é necessário avaliar com atenção a seleção da estrutura de RNA e das variáveis de entrada, no contexto da PGESEF, para se buscar modelos com precisão de predição satisfatórios, pois, a quantidade de dados e as variáveis selecionadas como entrada no *datasets* analisados influenciaram a acurácia dos modelos nos distintos horizontes de curto prazo avaliados.

Ressalta-se que o presente estudo apresenta contribuições para o tema da PGESEF. A primeira é relativa a originalidade desta pesquisa, pois, até o momento não foi identificado na literatura acadêmica uma comparação da acurácia de iguais modelos de RNA a partir de distintos *datasets* e com diferentes horizontes de predição de curto prazo. Neste sentido, uma extensa revisão literária dos diversos modelos de PGESEF pode ser observado em [9], onde foram analisados 1705 estudos sobre a PGESEF.

Adicionalmente, o presente estudo contribui para preencher a lacuna de carência de pesquisas sobre a PGESEF no Brasil e América Latina [10], disponibilizando os códigos-fontes utilizados no material suplementar (Apêndice) deste estudo, e assim, estimulando o desenvolvimento de novos métodos e pesquisas sobre a predição da geração de energia solar fotovoltaica.

#### APÊNDICE

O material suplementar deste estudo está disponível em <http://sites.google.com/site/joylan/supplementary-material>.

#### AGRADECIMENTOS

Os autores agradecem à Universidade Federal Integração Latino-Americana (UNILA/PRPPG), Programa de Pós-

Graduação em Energia e Sustentabilidade (PPGIES), ao Grupo de Pesquisa em Energia e Sustentabilidade Energética (GPEnSE) por disponibilizar a infraestrutura para esta pesquisa. Agradecem também a Fundação Araucária (FAPPR) pela concessão da bolsa de Iniciação em Desenvolvimento Tecnológico e Inovação.

## REFERÊNCIAS

- [1] ANEEL, “Sistema de Informações de Geração da ANEEL - SIGA,” *Agência Nacional de Energia Elétrica*, 2020. <https://bit.ly/2IGf4Q0> (accessed Apr. 26, 2020).
- [2] MME, “Plano Decenal de Expansão de Energia 2026 (versão para consulta pública).” Brasília, p. 264, 2017.
- [3] M. G. Villalva, *Energia Solar Fotovoltaica: Conceitos e aplicações*, 2ed ed. São Paulo: Érica, 2015.
- [4] K. Lappalainen and S. Valkealahti, “Photovoltaic mismatch losses caused by moving clouds,” *Sol. Energy*, vol. 158, no. October, pp. 455–461, 2017, doi: 10.1016/j.solener.2017.10.001.
- [5] J. Marcos, O. Storkel, L. Marroyo, M. Garcia, and E. Lorenzo, “Storage requirements for PV power ramp-rate control,” *Sol. Energy*, vol. 99, pp. 28–35, Jan. 2014, doi: 10.1016/j.solener.2013.10.037.
- [6] S. Shivashankar, S. Mekhilef, H. Mokhlis, and M. Karimi, “Mitigating methods of power fluctuation of photovoltaic (PV) sources - A review,” *Renew. Sustain. Energy Rev.*, vol. 59, pp. 1170–1184, 2016, doi: 10.1016/j.rser.2016.01.059.
- [7] J. Antonanzas, N. Osorio, R. Escobar, R. Urraca, F. J. Martinez-de-Pison, and F. Antonanzas-Torres, “Review of photovoltaic power forecasting,” *Sol. Energy*, vol. 136, pp. 78–111, 2016, doi: 10.1016/j.solener.2016.06.069.
- [8] P. Li, K. Zhou, and S. Yang, “Photovoltaic Power Forecasting: Models and Methods,” in *2nd IEEE Conference on Energy Internet and Energy System Integration, EI2 2018 - Proceedings*, Oct. 2018, pp. 1–6, doi: 10.1109/EI2.2018.8582674.
- [9] R. Blaga, A. Sabadus, N. Stefu, C. Dughir, M. Paulescu, and V. Badescu, “A current perspective on the accuracy of incoming solar energy forecasting,” *Prog. Energy Combust. Sci.*, vol. 70, pp. 119–144, 2019, doi: 10.1016/j.pecs.2018.10.003.
- [10] J. N. Maciel, J. Javier Gimenez Ledesma, and O. Hideo Ando Junior, “Forecasting Solar Power Output Generation: A Systematic Review with the Proknow-C,” *IEEE Lat. Am. Trans.*, vol. 19, no. 4, pp. 612–624, Apr. 2021, doi: 10.1109/TLA.2021.9448544.
- [11] P. A. C. Rocha, J. L. Fernandes, A. B. Modolo, R. J. P. Lima, M. E. V. da Silva, and C. A. D. Bezerra, “Estimation of daily, weekly and monthly global solar radiation using ANNs and a long data set: a case study of Fortaleza, in Brazilian Northeast region,” *Int. J. Energy Environ. Eng.*, vol. 10, no. 3, pp. 319–334, 2019, doi: 10.1007/s40095-019-0313-0.
- [12] A. Mellit and A. M. Pavan, “A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy,” *Sol. Energy*, vol. 84, no. 5, pp. 807–821, 2010, doi: 10.1016/j.solener.2010.02.006.
- [13] V. H. Wentz, J. N. Maciel, M. N. Kapp, J. J. G. Ledesma, O. H. Ando Junior, and O. H. A. Junior, “Comparação de Modelos de Redes Neurais Artificiais para a Predição da Irradiância Solar na Geração de Energia Fotovoltaica,” in *Anais do I Congresso Brasileiro Interdisciplinar em Ciência e Tecnologia*, 2020, p. 8, [Online]. Disponível em: <<https://www.even3.com.br/anais/icobicet2020/265096-comparacao-de-modelos-de-redes-neurais-artificiais-para-a-predicao-de-irradiancia-solar-na-geracao-de-energia-foto>>.
- [14] J. N. Maciel, V. H. Wentz, J. J. G. Ledesma, and O. H. Ando Junior, “Analysis of Artificial Neural Networks for Forecasting Photovoltaic Energy Generation with Solar Irradiance,” *Brazilian Arch. Biol. Technol.*, vol. 64, no. spe, 2021, doi: 10.1590/1678-4324-75years-2021210131.
- [15] F. UFSC, “Fotovoltaica - Grupo de Pesquisa Estratégica em Energia Solar Fotovoltaica,” 2021. <https://fotovoltaica.ufsc.br/sistemas/fotov> (accessed Sep. 20, 2021).
- [16] H. T. C. Pedro, D. P. Larson, and C. F. M. Coimbra, “A comprehensive dataset for the accelerated development and benchmarking of solar forecasting methods,” *J. Renew. Sustain. Energy*, vol. 11, no. 3, p. 036102, May 2019, doi: 10.1063/1.5094494.
- [17] S. Russell and P. Norvig, *Artificial Intelligence: A Modern Approach*, 3rd editio. India: Pearson Education India, 2015.
- [18] S. O. Rezende, *Sistemas Inteligentes*, 1st ed., vol. 2013. São Paulo: Manole, 2003.
- [19] C. A. Gueymard, “A review of validation methodologies and statistical performance indicators for modeled solar radiation data: Towards a better bankability of solar projects,” *Renew. Sustain. Energy Rev.*, vol. 39, pp. 1024–1034, 2014, doi: 10.1016/j.rser.2014.07.117.
- [20] E. Mining, *Python Machine Learning: Understand Python Libraries (Keras, NumPy, Scikit-Learn, TensorFlow) for Implementing Machine Learning Models in Order to Build Intelligent Systems*. Amazon Digital Services LLC - KDP Print US, 2019.
- [21] E. Bisong, “Google Colaboratory,” in *Building*

- Machine Learning and Deep Learning Models on Google Cloud Platform*, Berkeley, CA: Apress, 2019, pp. 59–64.
- [22] Jamovi, “The jamovi project (2021),” Computer Software, 2021. .
- [23] P. R. B. Guimarães, Métodos quantitativos estatísticos, 1.ed. rev. Curitiba, PR: IESDE Brasil S.A., 2012.
- [24] P. A. Morettin and W. de O. Bussab, Estatística básica, 9a edição. São Paulo: Saraivauni, 2017.
- [25] J. Hsu, Multiple Comparisons: Theory and Methods, 1st ed. Ohio - USA: Taylor & Francis, 1996.