

AVALIAÇÃO DE MODELOS DE REGRESSÃO (MR) E REDES NEURAIAS ARTIFICIAIS (RNA) PARA ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL.

Cícero Manoel dos Santos¹, Amaury de Souza², Flávio Aristone³, Maurício Bruno Prado da Silva⁴, Geovani da Silva Santana⁵

RESUMO: A irradiação solar global (Hg) é uma variável de grande importância para diferentes aplicações. Apesar do grande avanço nos últimos, medidas de Hg não estão facilmente disponíveis em muitos lugares do globo devido ao elevado custo de instalação e manutenção dos sensores. O objetivo deste trabalho é avaliar Modelos de Regressão Linear (MR) e Redes Neurais Artificiais (RNAs) para estimar Hg. Seis combinações diferentes de temperatura do ar (T_{\max} , T_{\min} , T_{med} e ΔT) são consideradas. São utilizados dados de 10 anos da região de Campo Grande. Os modelos são avaliados com base nos índices estatísticos: MBE, RMSE, MAPE e ICW. O melhor desempenho dos modelos depende das variáveis utilizadas como entrada. Bom desempenho é encontrado para os modelos de MR, no entanto os índices estatísticos confirmam a melhor precisão para os modelos de RNA.

PALAVRAS-CHAVE: modelos empíricos, temperatura do ar, inteligência artificial.

EVALUATION OF REGRESSION MODELS (RM) AND ARTIFICIAL NEURAL NETWORKS (ANN) TO ESTIMATE OF GLOBAL SOLAR IRRADIATION.

ABSTRACT: Global solar irradiation (Hg) is a very important variable for different applications. Despite major advances in recent years, Hg measurements are not readily available in many parts of the globe due to the high cost of installing and maintaining sensors. The objective of this work is to evaluate Linear Regression Models (RM) and Artificial Neural Networks (ANNs) to estimate Hg. Six different combinations of air temperature (T_{\max} , T_{\min} , T_{med} and ΔT) are considered. Data from 10 years from Campo Grande region

¹Prof. Doutor, Faculdade de Engenharia Agrônômica – UFPA, Altamira, PA.

²Prof. Doutor, Instituto de Física – UFMS, Campo Grande, MS.

³Prof. Doutor, Instituto de Física – UFMS, Campo Grande, MS.

⁴Doutor em Agronomia.

⁵Engenheiro Agrônomo, Altamira, PA.

are used. The models are evaluated based on the statistical indices: MBE, RMSE, MAPE and ICW. The best performance of the models depends on the input variables. Good performance is found for RM models, however statistical indices confirm the best accuracy for ANN models.

KEYWORDS: empirical models, air temperature, artificial intelligence.

INTRODUÇÃO

A irradiação solar global (Hg) desempenha um papel importante em muitos processos da superfície e da atmosfera terrestre: como um dos parâmetros mais significativos na estimativa da evapotranspiração de referência e fotossíntese de plantas (Antonopoulos et al., 2019) e como recurso solar renovável ganha destaque em aplicações para concentradores solares, dimensionamento de células fotovoltaicas e na concepção de fornos solares. Sua variação sazonal e temporal está relacionada ao aquecimento e à mudança climática global (Wang et al., 2017).

Para as aplicações diversas de energia solar, primeiro é necessária a avaliação do recurso solar através da disponibilidade de dados. A disponibilidade de dados de Hg é limitada a poucas estações solarimétricas. Apesar da grande importância e da demanda mundial, não é praticamente possível instalar instrumentos de medição em todos os locais, devido ao custo e dificuldade nas medições (Meenal e Selvakumar, 2018).

Devido à necessidade do conhecimento solar, nas últimas décadas inúmeros métodos foram desenvolvidos e estão sendo usados para estimar Hg. Estes tomam com base os dados meteorológicos comumente disponíveis, como temperatura do ar, duração do brilho solar (n), umidade relativa, e assim por diante. Para os projetistas e fabricantes de equipamentos solares é muito importante ter métodos para estimar indiretamente a Hg com base em outros dados meteorológicos prontamente disponíveis (Antonopoulos et al., 2019). Modelos de regressão, modelos de satélites e outros modelos hídricos são relatados na literatura com mais de um parâmetro de entrada para estimar Hg (Chen et al., 2019).

Nas últimas décadas técnicas de inteligência artificial estão sendo desenvolvidas e aplicadas para prever Hg. Dentre as técnicas, as Redes Neurais Artificiais (RNAs) têm sido frequentemente usadas para prever com precisão a Hg usando variáveis meteorológicas (Nwokolo e Ogbulezie, 2018), que atua como ferramentas vitais na modelagem, pois são

capazes de computar a classificação de dados, aproximação de funções não-lineares, agrupamento e simulação.

Na Arábia Saudita, Rehman e Mohandes (2008), desenvolveram três modelos de RNA com base no dia do ano, na temperatura do ar e umidade relativa. Fadare (2009) projetou um modelo baseado em RNA para previsão do potencial de energia solar na Nigéria. Benghanem et al., (2009) desenvolveram seis modelos de RNA usando diferentes combinações de variáveis de entradas. Yadav et al., (2014) aplicaram o software Waikato Environment for Knowledge Analysis (WEKA) para encontrar os parâmetros que mais influenciavam a previsão da irradiação solar usando modelos de RNA em 26 locais da Índia.

Estudos mostram a importância das aplicações da RNA para estimativa de Hg. Em muitos locais, modelos de regressão linear (MR) e RNA ainda não foram avaliados para quantificar e qualificar o grau de confiabilidade na estimativa de Hg e na geração de uma base de dados extensa e sólida. Neste trabalho, modelos MR e RNA que estimam Hg, são ajustados e avaliados usando dados de 10 anos (2005 a 2014) para a região de Campo Grande, MS – Brasil. A principal motivação para o desenvolvimento deste trabalho foi avaliar o potencial dos modelos em prever Hg e qual seu desempenho com diferentes combinações de variáveis de entrada (temperatura do ar máxima, mínima e média, amplitude térmica do ar e irradiação solar no topo da atmosfera).

MATERIAL E MÉTODOS

Local e dados

Este estudo foi realizado utilizando dados obtidos entre janeiro de 2005 e de dezembro de 2014, a partir de uma estação meteorológica automática do Instituto Nacional de Meteorologia (INMET) instalada em Campo Grande – MS, Brasil (20°27'S, 54°36'W e altitude 530 m). O clima local é classificado como *Aw* de acordo com Köppen, sendo definido como subtropical, quente e úmido com verão chuvoso e inverno seco. As medidas de temperatura do ar máxima (T_{\max}) e mínima (T_{\min}) e a irradiação solar global (Hg) foram coletadas a cada hora, em seguida foram processados e integrados para partição diária. Devido à grande variabilidade nas medições das variáveis, um critério foi usado para controlar a qualidade dos dados.

Modelos de regressão linear

Foi realizada análise de regressão linear entre as variáveis meteorológicas [irradiação solar global (H_g), temperatura máxima (T_{max}), temperatura mínima (T_{min}), amplitude térmica (ΔT) e temperatura média (T_{med})] e irradiação solar no topo da atmosfera (H_0 , calculada para o local) para geração de modelos. Os modelos de MR desenvolvidos com base na fórmula geral:

$$H_g = \beta_1 + \beta_2 X_1 + \beta_3 X_2 + \beta_4 X_3 \dots + \beta_{n+1} X_n \quad (1)$$

onde $\beta_1, \beta_2, \beta_3, \beta_4$ e β_{n+1} são coeficientes de regressão e X_i são as variáveis meteorológicas de entrada.

No desenvolvimento de MR foram utilizadas seis combinações diferentes de variáveis independentes. A combinação de variáveis de entrada para os modelos de MR sempre mantendo fixo a H_0 e inseridos outras variáveis meteorológicas de entrada. No modelo de regressão 1 (MR1) foi utilizado T_{max} , no MR2 foi apenas a T_{min} , no MR3 a ΔT (diferença entre T_{max} e T_{min} no dia), no MR4 a T_{med} , no MR5 foram utilizados T_{max} e T_{min} , no modelo MR6 foram utilizadas todas as variáveis de entrada, conforme equações:

$$MR1 \Rightarrow H_g = \beta_1 + \beta_2 H_0 + \beta_3 T_{max} \quad (2)$$

$$MR2 \Rightarrow H_g = \beta_1 + \beta_2 H_0 + \beta_3 T_{min} \quad (3)$$

$$MR3 \Rightarrow H_g = \beta_1 + \beta_2 H_0 + \beta_3 \Delta T \quad (4)$$

$$MR4 \Rightarrow H_g = \beta_1 + \beta_2 H_0 + \beta_3 T_{med} \quad (5)$$

$$MR5 \Rightarrow H_g = \beta_1 + \beta_2 H_0 + \beta_3 T_{max} + \beta_4 T_{min} \quad (6)$$

$$MR6 \Rightarrow H_g = \beta_1 + \beta_2 H_0 + \beta_3 T_{max} + \beta_4 T_{min} + \beta_5 \Delta T + \beta_6 T_{med} \quad (7)$$

Onde β_1 (MJm^{-2}), β_2 (sem unidade), β_3 ($^{\circ}C^{-1}$), β_4 ($^{\circ}C^{-1}$), β_5 ($^{\circ}C^{-1}$) e β_6 ($^{\circ}C^{-1}$) são coeficientes empíricos a serem determinados. A irradiação solar no topo da atmosfera (H_0) é um valor teórico e calculado para a localização de interesse conforme (Duffie e Beckman, 2013).

Modelos de Redes Neurais Artificiais

A RNA adotada neste trabalho é a Multilayer Perceptron (MLP) (Santos et al., 2016). A MLP é um sistema de processamento de informações massivamente paralelo e distribuído e aplicado com sucesso a um modelo para muitos problemas não lineares. A estrutura básica do MLP é uma camada de entrada, camada oculta com pesos vinculados e uma camada de saída (eq. 8):

$$y_i = \sum_{j=1}^n w_{i,j} x_{i,j} + \theta_i \quad (8)$$

onde $x_{i,j}$ é o sinal de entrada do j -ésimo neurônio (para a camada de entrada), $w_{i,j}$ é o peso da conexão direta do neurônio j ao neurônio i (na camada oculta) e θ_i é o viés do neurônio i . A saída dos neurônios é calculada pela aplicação de uma função de ativação. A função de ativação utilizada é tipicamente sigmoide padrão (eq. 9).

$$f(x) = \frac{1}{[1 + \exp(-x)]} \quad (9)$$

Existe uma grande variedade de algoritmos disponíveis para treinar RNA e ajustar seus pesos. Neste estudo, a MLP foi treinada usando o algoritmo de treinamento Backpropagation e o termo momentum. Foram utilizadas 20 neurônios para a camada oculta, por considerar o melhor ajuste para os modelos. Outros ensaios foram realizados para o número de neurônios da camada oculta. A Tabela 1 mostra as variáveis de entrada de cada modelo de RNA e na Figura 1 a estrutura típica do modelo de RNA de múltiplas camadas.

Tabela 1. Modelos e variáveis de entrada.

Modelo	Variáveis de entrada
RNA1	H_0, T_{\max}
RNA2	H_0, T_{\min}
RNA3	$H_0, \Delta T$
RNA4	H_0, T_{med}
RNA5	H_0, T_{\max} e T_{\min}
RNA6	$H_0, T_{\max}, T_{\min}, \Delta T$ e T_{med}




Figura 1. Arquitetura da MLP.

Os modelos de RNA foram treinados e validados através do Waikato Environment for Knowledge Analysis (WEKA) (Hall et al., 2009). Para treinamento e validação da RNA foi adotado o termo momento de 0,1 e learnig rate de 0,2. Os dados foram divididos em duas seções, os anos de 2005 a 2011 foram utilizados para ajustar os modelos MR e treinar a RNA, enquanto que os anos de 2012 a 2014 foram utilizados na validação.

Índices estatísticos de validação

A precisão e o desempenho dos modelos MR e RNA foram avaliados usando vários índices estatísticos. Os indicadores estatísticos utilizados podem ser divididos em dois grupos: indicadores de dispersão (indicadores de erro) e indicadores de desempenho geral (Gueymard, 2014). Os índices de dispersão utilizados neste estudo são: [Mean Bias Error (MBE), Root Mean Square Error (RMSE) e Mean Absolute Percentage Error (MAPE)]. Os indicadores de desempenho geral usados foram: Coeficiente de Determinação (R^2) e Índice de Acordo de Willmott (ICW) (Willmott et al., 2012). Outra análise baseia-se nos coeficientes de regressão linear (tipo $y = ax + b$: onde temos o coeficiente angular “a” e o coeficiente linear “b”).

RESULTADOS E DISCUSSÃO

Ajuste dos coeficientes e validação dos modelos

Os coeficientes das equações de MR foram ajustados e os resultados obtidos foram:

$$Hg = -9,699 + 0,229H_0 + 0,681T_{\max} \quad (10)$$

$$Hg = 7,326 + 0,339H_0 - 0,025T_{\min} \quad (11)$$

$$Hg = -9,417 + 0,483H_0 + 1,081\Delta T \quad (12)$$

$$Hg = -0,529 + 0,227H_0 + 0,469T_{\text{med}} \quad (13)$$

$$Hg = -14,261 + 0,406H_0 + 1,200T_{\max} - 0,878T_{\min} \quad (14)$$

$$Hg = -13,318 + 0,401H_0 - 1,276T_{\max} + 0,585T_{\min} + 1,966\Delta T + 1,022T_{\text{med}} \quad (15)$$

Observa-se maior variação para o coeficiente β_1 . O coeficiente β_2 dos modelos manteve um padrão de gerar sempre valores positivos. Os coeficientes que acompanham as variáveis ΔT e T_{med} , foram positivos para todos os modelos. Para a região de Cañada de Luque na província de Córdoba na Argentina, Almorox et al., (2013), ajustaram e obtiveram para a eq. 14 os coeficientes β_1 (-11,07), β_2 (0,62), β_3 (-0,66) e β_4 (0,62). Estes valores são diferentes dos obtidos localmente.

A Figura 2 (a – f) mostra a comparação entre os valores diários de Hg medidos e estimados para os MR. Os modelos MR2 e MR4 têm a dispersão mais afastada da regressão. Os valores de R^2 dos modelos foram 0,498; 0,257; 0,613; 0,367; 0,629 e 0,617, respectivamente para MR1, MR2, MR3, MR4, MR5 e MR6. A estimativa de Hg com coeficientes distintos resultaram em mudanças nas estimativas.

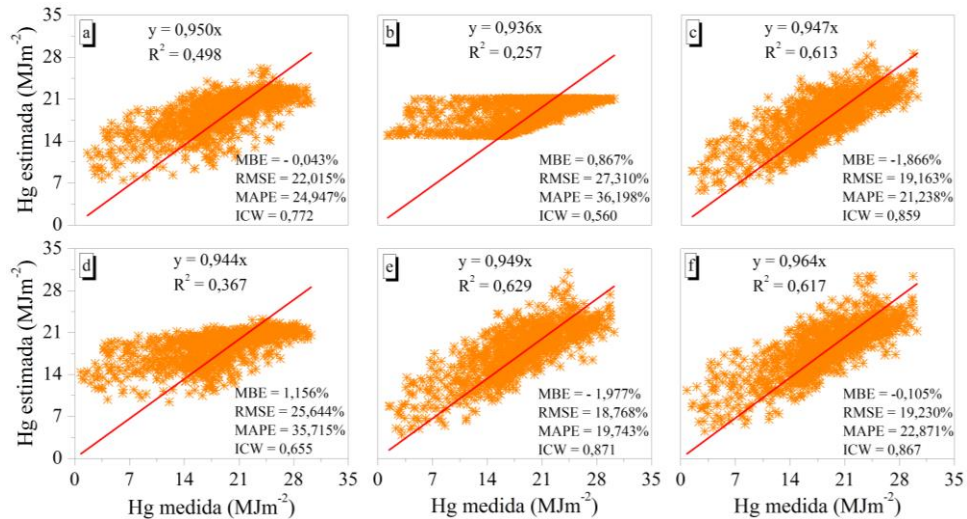


Figura 2. Diagrama de espalhamento entre as medidas e as estimativas com os modelos de regressão linear múltipla. a) MR1, b) MR2, c) MR3, d) MR4, e) MR5 e f) MR6.

Os diagramas de dispersão mostram que os modelos MR3, MR5 e MR6 foram os que mais correlacionaram com as medidas. Para os modelos de MR, os valores de MBE variam de -1,977 (-0,359 MJm^{-2}) a 1,156 % (0,210 MJm^{-2}). Os valores de RMSE e MAPE dos modelos de MRL variaram entre 18,768 (3,412) a 27,310% (4,966 MJm^{-2}) e 19,743 a 35,715%, respectivamente. O ICW teve valores entre 0,560 a 0,871. Com base na métrica dos índices estatísticos de validação de modelos, destaca-se que MR2 e MR4 com tiveram desempenho inferiores aos demais modelos. A curva de dispersão e os critérios estatísticos mostram que o modelo MR5 descreve com relativa precisão o Hg, seguido dos modelos MR6 e MR3.

Os resultados obtidos com os modelos de MR são semelhantes com os resultados obtidos por Antonopoulos et al., (2019) para dois locais no norte da Grécia que encontraram RMSE variando de 3,344 a 4,297 MJm^{-2} . Almorox et al., (2013) encontraram para o MR5 valores dos índices estatísticos diferentes dos obtidos localmente. Os resultados são consistentes com os resultados de Zhang et al., (2017) na avaliação de modelos empíricos com diferentes variáveis de entrada, os valores de RMSE de modelos variaram de 2,05 a 4,70 MJm^{-2} .

Avaliação do desempenho da RNA para estimar Hg

Nas Figs. 3 (a – f) são comparadas a evolução e nas Figs 3 (g – i) a dispersão da Hg medida e estimada pelos modelos de RNA. Observa-se que os valores previstos seguem os valores medidos relativamente bem, com a sazonalidade e a magnitude da discordância entre os dados medidos e estimados é pequena. Assim, o efeito das variáveis de entrada para a estimativa de Hg pode observado nos modelos ao observar o R^2 com grandes variações. O desempenho inferior dos modelos RNA2 e RNA4 na estimativa são mostrados visualmente.

Os valores de MBE, RMSE, MAPE e ICW são mostrados na Figura 4 (a – d). De acordo com os valores de MBE, todos os modelos subestimaram as medidas (Figura 4a). Os modelos RNA2, RNA3 e RNA6 têm valores absolutos de MBE maiores que 6%, com maior valor para RNA2 (MBE = -11,177%). Para os modelos RNA1, RNA4 e RNA5 os valores de MBE foram os menores absolutos, com destaque para RNA1 (MBE = -3,756%) e RNA5 (MBE = -4,021%). O valor médio de MBE ($-6,222 \pm 2,744\%$) é impulsionado pelo modelo RNA2. Para os modelos RNA1 a RNA6 os valores de RMSE variaram de 17,141 a 27,235 %, com menor valor para RNA5 e maior para RNA2. Os valores encontrados para o MAPE seguem a mesma tendência dos observados com RMSE, os modelos RNA2 (MAPE = 28,097%) e RNA4 (MAPE = 27,264%) têm os maiores índices (Figura 4c). Os modelos RNA3, RNA5 e RNA6 estimam com MAPE igual a 17,223; 16,817 e 16,404%, respectivamente. Considerando o ICW, os modelos RNA2 e RNA4 apresentaram os menores valores (Figura 4d). Já os modelos RNA3, RNA5 e RNA6 possuem valores de ICW próximo de 0,90. Os indicadores estatísticos mostraram que os valores previstos pelos modelos RNA2 e RNA4 têm baixa precisão. As diferentes estruturas das variáveis de entrada mostram que o modelo RNA5 apresenta melhor desempenho que os demais modelos.

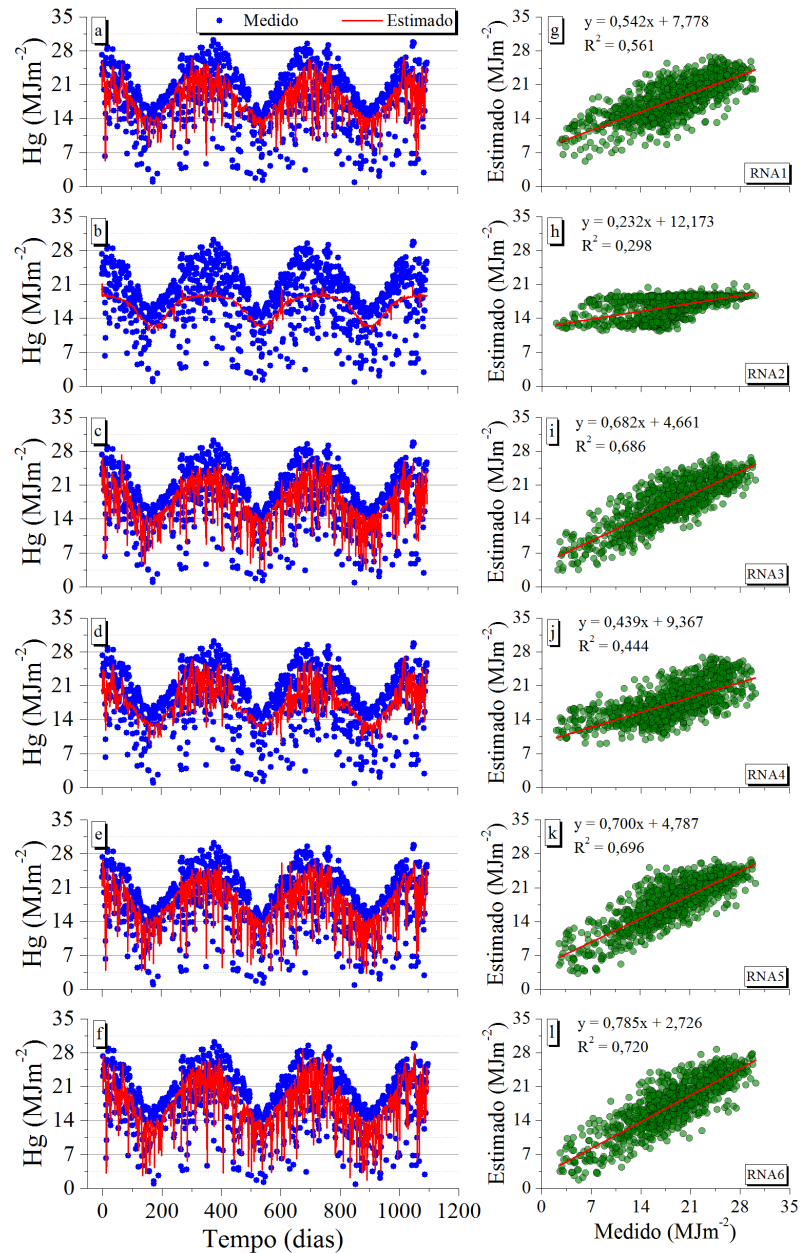


Figura 3. Evolução sazonal entre as medidas e estimativas (a – f) e dispersão (g – l) para os modelos de RNA.




Figura 4. Índices estatísticos de validação. (a) MBE, (b) RMSE, (c) MAPE e (d) ICW.

CONCLUSÕES

Os coeficientes ajustados de MR foram variáveis e não apresentaram nenhum padrão. Os modelos de MR geraram variações, com melhor desempenho para MR5 e pior para MR2 e MR4. Seria interessante investigar as variações temporais destas modelos em outras escalas de tempo, além da escala diária usado neste estudo.

Verifica-se que os valores previstos com as RNAs estão em boa concordância com as medidas, com destaque para RNA5 com melhor desempenho. O presente trabalho confirma a capacidade dos modelos de RNA em aumentar a exatidão das estimativas Hg. Por fim, os resultados obtidos indicaram que o modelo de RNA pode ser usado para prever com precisão a Hg em Campo Grande - Brasil.

Devido à simplicidade e operabilidade, ainda que com precisão razoável, os MR são extensivamente estudados e aplicados. Nem mesmo a melhor precisão na estimativa de Hg com modelos de RNA, que possuem estrutura mais complexa e em muitos casos maior número de variável de entradas, reduz o uso dos modelos de MR. Os resultados fornecem dimensões futuras para os profissionais da indústria e da pesquisa para estudos adicionais sobre a estimativa do sistema solar e da irradiação solar global. É importante destacar que mais pesquisas usando os modelos e as técnicas sejam realizadas para ampliar a aplicabilidade mundialmente.

REFERÊNCIAS BIBLIOGRÁFICAS

- Almorox, J.; Bocco, M.; Willington, E. Estimation of daily global solar radiation from measured temperatures at Cañada de Luque, Córdoba, Argentina. *Renewable Energy*, v.60, p.382-387, 2013.
- Antonopoulos, V. Z.; Papamichail, D. M.; Aschonitis, V. G.; Antonopoulos, A. V. Solar radiation estimation methods using ANN and empirical models. *Computers and Electronics in Agriculture* v.160 p.160–167, 2019.
- Benghanem, M.; Mellit, A.; Alamari, S. N. ANN based modeling and estimation of daily global radiation data: a case study. *Energy Convers. Manag.* v.50, p.1644-1655, 2009.
- Chen, J-L.; He, L.; Yang, H.; Ma, M.; Chen, Q.; Wu, S-J.; Xia, Z- L. Empirical models for estimating monthly global solar radiation: A most comprehensive review and comparative case study in China. *Renewable and Sustainable Energy Reviews* v.108, p.91–111, 2019.

- Doorga, J. R. S.; Rughooputh, S. D. D. V.; Boojhawon, R. Modelling the global solar radiation climate of Mauritius using regression techniques. *Renewable Energy* v.131, p.861-878, 2019.
- Duffie, J.; Beckman, W. *Solar Engineering of Thermal Processes*, 4th edition, 2013, New Jersey, NJ: John Wiley & Sons, Inc.
- Fadare, D. A. Modeling of solar energy potential in Nigeria using an artificial neural network model. *Applied Energy* v.86, p.1410–1422, 2009.
- Gueymard, C. A. A review of validation methodologies and statistical performance indicators for modeled solar radiation data: Towards a better bankability of solar projects. *Renewable and Sustainable Energy Reviews*, v. 39, p. 1024-1034, 2014.
- Hall M, Frank E, Holmes G, Pfahringer B, Reutemrna P, Witten IH. *The WEKA data mining software: an update; SIGKDD Explorations*, vol. 11, Issue 1; 2009.
- Meenal, R., Selvakumar, A. I. Assessment of SVM, empirical and ANN based solar radiation prediction models with most influencing input parameters. *Renewable Energy*, v.121, p.324-343, 2018.
- Nwokolo, S. C.; Ogbulezie, J. C. A quantitative review and classification of empirical models for predicting global solar radiation in West Africa. *Beni-Suef University Journal of Basic and Applied Sciences* v.7, p.367–396, 2018.
- Rehman, S.; Mohandes. M. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. *Energy policy* v.36, p.571-576, 2008.
- Santos, C. M.; Escobedo, J. F.; Teramoto, E. T.; Silva, S. H. M. G. Assessment of ANN and SVM models for estimating normal direct irradiation (H_b). *Energy Conversion and Management* v.126 p.826–836, 2016.
- Wang L, Kisi O, Zounemat-Kermani M, Zhu Z, Gong W, Niu Z, et al. Prediction of solar radiation in China using different adaptive neuro-fuzzy methods and M5 model tree. *Int J Climatol*, v.37, p.1141–55, 2017.
- Willmott, C. J.; Robeson, S. M.; Matsuura, K. A refined index of model performance. *International Journal of Climatology*, vol. 32, pp. 2088-2094, 2012.
- Yadav, A. K.; Malik, H.; Chandel, S. S. Selection of most relevant input parameters using WEKA for artificial neural network based solar radiation prediction models, *Renew. Sustain. Energy Rev.* v.31, p.509-519, 2014.
- Zhang, J.; Zhao, L.; Deng, S.; Xu, W.; Zhang, Y. A critical review of the models used to estimate solar radiation. *Renew. Sustain. Energy Rev.* v.70, 314–329, 2017.