RESSALVA

Atendendo solicitação do(a) autor(a), o texto completo desta tese/dissertação será disponibilizado somente a partir de 29/01/2023.

UNIVERSIDADE ESTADUAL PAULISTA
"JÚLIO DE MESQUITA FILHO"
Campus de Botucatu

FCA
FACULDADE DE CIÊNCIAS AGRONÔMICAS
UNESP | BOTUCATU

ANGÉLICA CASTILHO PAES

ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL PELOS MODELOS HARGREAVES-SAMANI, BRISTOW- CAMPBELL, REGRESSÕES MÚLTIPLAS E TÉCNICAS MVS E RNA NO MUNICÍPIO DE BOTUCATU - SP

Botucatu

2021

ANGÉLICA CASTILHO PAES

ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL PELOS MODELOS HARGREAVES-SAMANI, BRISTOW- CAMPBELL, REGRESSÕES MÚLTIPLAS E TÉCNICAS MVS E RNA NO MUNICÍPIO DE BOTUCATU - SP

Dissertação apresentada à Faculdade de Ciências Agronômicas da Unesp Câmpus de Botucatu, para obtenção do título de Mestre em Energia na Agricultura.

Orientador(a): Prof. Dr. João Francisco Escobedo

Botucatu

2021

P126e

Paes, Angélica Castilho

Estimativa da irradiação solar global pelos modelos Hargreaves-Samani, Bristow-Campbell, regressões múltiplas e técnicas MVS e RNA no município de Botucatu - SP / Angélica Castilho Paes. -- Botucatu, 2021

75 p. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (Unesp), Faculdade de Ciências Agronômicas, Botucatu

Orientador: João Francisco Escobedo

1. radiação solar. 2. modelos estatísticos de estimativa da radiação. 3. regressões múltiplas não lineares. 4. técnicas de aprendizagem de máquinas. I. Título.

Sistema de geração automática de fichas catalográficas da Unesp. Biblioteca da Faculdade de Ciências Agronômicas, Botucatu. Dados fornecidos pelo autor(a).

Essa ficha não pode ser modificada.

UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Botucatu

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL PELOS MODELOS DE HARGREAVES-SAMANI, BRISTOW-CAMPBELL, REGRESSÕES MÚLTIPLAS E TÉCNICAS MVS E RNA NO MUNICÍPIO DE BOTUCATU - SP

AUTORA: ANGÉLICA CASTILHO PAES

ORIENTADOR: JOÃO FRANCISCO ESCOBEDO

Aprovada como parte das exigências para obtenção do Título de Mestra em AGRONOMIA (ENERGIA NA AGRICULTURA), pela Comissão Examinadora:

Prof. Dr. JOÃO FRANCISCO ESCOBEDO (Participação Virtual)
Engenharia Rural e Socioeconomia / Faculdade de Ciências Agronômicas de Botucatu - UNESP

Pesquisador Dr. JOSÉ CARLOS FIGUEIREDO (Participação Virtual)
IPMet – Centro de Meteorologia de Bauru / Faculdade de Ciências de Bauru – UNESP

Prof. Dr. SÉRGIO AUGUSTO RODRIGUES (Participação Virtual)
Bioprocessos e Biotecnologia / Faculdade de Ciências Agronômicas de Botucatu - UNESP

Botucatu, 29 de janeiro de 2021

Aos meus amados pais,

Cleide e Manuel, pelo incentivo constante

dedico

AGRADECIMENTOS

Ao Prof. Dr. João Francisco Escobedo, pela oportunidade, pela orientação e pelos ensinamentos.

A Universidade Estadual Paulista, a Faculdade de Ciências Agronômicas e ao Programa de Pós-Graduação em Energia na Agricultura (UNESP/FCA/BOTUCATU) pela oportunidade e estrutura oferecidas para a conclusão de mais uma etapa no meu desenvolvimento profissional.

Aos professores Dr. José Carlos Figueiredo e Dr. Sérgio Augusto Rodrigues por aceitarem compor a banca avaliadora desta dissertação.

Aos colegas de laboratório Maurício, Edson, Adriano e Taiza, pelos ensinamentos, conselhos e contribuições, diretas ou indiretas, para este trabalho.

A Sulei Barros e Katia Albano, membros da equipe gestora da escola CEEJA – Botucatu, e ao estimado amigo Antonio, que possibilitaram a conciliação entre meus deveres profissionais e meus interesses acadêmicos. Muito obrigada!

“Lembre-se de olhar para as estrelas e não para baixo, para os seus pés. Tente achar sentido no que você vê e pergunte sobre o que faz o Universo existir. Seja curioso”.

Sthephen Hawking

RESUMO

No presente trabalho realizou-se um estudo comparativo entre os modelos de estimativas da irradiação solar global (H_G) diária: Hargreaves-Samani (HS); Bristow e Campbell (BC); uma equação de regressão múltipla não linear (RM) desenvolvida neste trabalho e duas técnicas de Aprendizado de Máquina (Máquinas de Vetores de Suporte - MVS e Redes Neurais Artificiais - RNA). A base de dados usada no trabalho foi medida em Botucatu no período dos anos de 1996-2011. Os modelos foram estimados com a base de dados total, sendo que para validação dos modelos foram usados duas bases de dados, denominados ano típico e ano atípico, criados a partir da base total dos dados. O modelo estatístico HS foi estimado pelo método dos mínimos quadrados, utilizado para ajustes lineares, e os modelos BC e RM foram estimados por algoritmos de regressão não linear que utilizam métodos iterativos para a estimativa dos modelos, enquanto que as técnicas, MVS e RNA, foram treinadas com entradas de 4 variáveis meteorológicas totalizando 4 combinações no programa WEKA. Os resultados obtidos na validação dos modelos mostram que: os modelos estatísticos HS, BC podem estimar H_G com coeficientes de correlação da ordem de r = 0,84 , e os valores de rMBE e rRMSE variando de +/- 3,0% e 20,0% - 25,0% respectivamente para anos típicos e atípicos; o modelo RM pode estimar H_G com valor de r da ordem de 0,960, e valores de rMBE e rRMSE variando de +/- 4,0% e 11,0% - 14,0% respectivamente para anos típicos e atípicos; os indicativos estatísticos obtidos para a combinação 4, a de melhor desempenho, pode estimar H_G com valores de r = 0,965 e r = 0,960 e valores para MVS (rMBE = +/- 0,5 %; rRMSE = 12,0 %) e RNA (rMBE = +/- 1,5; rRMSE = 12,0 % para anos típico e atípico). A comparação entre os desempenhos dos modelos HS, BC, RM e as técnicas RNA e MVS na combinação 4, sugere o uso do modelo de RM, quando os dados de RI e UR estejam disponíveis, por ser um método mais prático que o uso das técnicas de aprendizagem de máquinas.

Palavras-chave: Radiação solar. Modelo de Hargreaves-Samani. Modelo de Bristow e Campbell. Técnicas de aprendizado de máquinas.

ABSTRACT

In this paper is described a comparative study between models for estimating daily global solar radiation (H_G): Hargreavis-Samani (HS), Bristow-Campbell (BC), a non-linear multiple regression equation developed in this work and two learning machine techniques (Support Vector Machine - MVS and Artificial Neural Network - RNA). The database used in this work was measured in Botucatu in the period of years of 1996-2011. The models were generated and trained with the total database, whereas for model validation were used two fictitious years, denominated typical and atypical, created from the total database. The statistical models HS was estimated by the least saqures method, used for linear regressions, and the BC and RM models were estimated by algorithms for non linear regression that, use iteratives methods to estimate, MVS and RNA, were trained with input of four meteorological variables totalizing four combinations on the WEKA software. The results show that: the statistical models HS, BC can estimate H_G with coefficient of correlation of the range of r = 0,84 and the values of rMBE and rRMSE varying from +/- 3,0% and 20,0% - 25,0%, respectively, for typical and atypical years; the multivariate equation can estimate H_G with values of r of the order of 0,960, and values of rMBE and rRMSE varying from +/- 4,0% and 11,0% - 14,0%, respectively, for the typical and atypical years; the statistical indicative obtained for combination 4, the with the best performance, can estimate HG with values of r = 0,965 and r = 0,960 and values for MVS (rMBE = +/- 0,5%, rRMSE = 12,0%), and RNA (rMBE = +/- 1,5%; rRMSE = 12,0%, for typical and atypical years). The comparision between the performance of the HS, BC, RM models and RNA and MVS techniques in the conbination 4, suggest the use of the RM model, when the RI and UR datas are availables, for being a method more pratical than the use of the learning machine techniques.

Keywords: Solar radiation. Hargreaves-Samani model. Bristow-Campbell model. Machine Learning Techniques.

LISTA DE ABREVIATURAS E SIGLAS

AM	Aprendizagem de Máquinas.
ANFIS	Sistema de Inferência Neuro Fuzzy Adaptativo.
GF	Genética Fuzzy
GP	Programação genética.
HS	Hargreaves e Samani.
MLP	Multilayer Perceptron.
MVS	Máquina de Vetor de Suporte.
OMM	Organização Mundial de Meteorologia.
RBF	Função de base radial.
RM	Regressão múltipla não linear.
SMO	Sequential Minimal Optimization.
VCAN	Vórtice Ciclônico em Altos Níveis.
WEKA	Waikato Environment for Knowledge Analysis.

LISTA DE SÍMBOLOS

H_G Irradiação solar global diária (MJ m^{-2} dia^{-1}).

I_G Irradiância solar global (kW m^{-2}).

n Brilho solar (h).

H_0 Irradiação solar no topo da atmosfera (MJ m^{-2} dia^{-1}).

H_d Irradiação solar difusa (MJ m^{-2} dia^{-1}).

H_D Irradiação solar direta (MJ m^{-2} dia^{-1}).

N Fotoperíodo (horas).

RI Razão de insolação (adimensional).

a_{AP}, b_{AP} Coeficientes de calibração do modelo Angström Prescott

a_{HS} Coeficiente de calibração do modelo Hargreaves e Samani.

ΔT_1 Amplitude térmica para o ajuste modelo Hargreaves e Samani (°C).

a_{BC}, b_{BC}, c_{BC} Coeficientes de calibração do modelo Bristow e Campbell.

ΔT_2 Amplitude térmica para o ajuste do modelo Bristow e Campbell.

$T_{m(j)}$ Temperatura mínima do dia j (°C).

$T_{m(j+1)}$ Temperatura mínima do dia subsequente ao dia j (°C)

y Variável dependente da equação de regressão não linear múltipla genérica.

f Função de regressão múltipla que relaciona uma variável dependente a uma ou mais variáveis independente.

x Vetor de variáveis independentes de uma equação regressão não linear múltipla genérica.

θ Coeficientes de uma equação de regressão não linear múltipla genérica.

ε Erro aleatório de uma equação de regressão não linear múltipla genérica.

UR Umidade relativa (%).

H_0	Irradiação solar no topo da atmosfera (MJ m^{-2} dia^{-1}).
I_0	Constante solar (W m^{-2}).
DJ	Dia juliano.
φ	Latitude local (graus).
δ	Declinação solar (graus).
ω_s	Ângulo horário (graus).
a_{SO}, b_{SO}, c_{SO}	Coeficientes da equação de regressão não linear múltipla proposta por Swartman e Ogunlade.
$a_{RM}, b_{RM}, c_{RM}, d_{RM}, e_{RM}$	Coeficiente de calibração do modelo RM.
C, γ	Parâmetros de ajuste da Máquina de Vetor de Suporte.
rRMSE	Raiz quadrada do erro médio relativa (%).
H_m	Valores medidos.
H_e	Valores estimados.
$\bar{H}_m$	Valor médio medido.
m	Número de observação de dados.
x_i	Variáveis inseridas na camada de entrada da RNA.
w_{ij}	Pesos sinápticos entre a camada de entrada e a camada oculta da RNA.
w_0	Limiar de ativação da RNA.
u	Sinal transmitido pela camada de saída da RNA.
u_j	Sinal transmitido para a camada oculta da RNA.
ϕ	Função de ativação da RNA.
μ	Somatória das variáveis de entrada multiplicadas pelos pesos sinápticos.
L	Taxa e aprendizagem da RNA.
M	Momentum da RNA.
MBE	Tendência do erro médio (MJ m^{-2} dia^{-1}).
rMBE	Tendência do erro médio relativa (%).

RMSE Raiz quadrada do erro médio (MJ m^{-2} dia^{-1}).

r Coeficiente de correlação (adimensional).

$\overline{H}_e$ Valor médio estimado.

R^2 Coeficiente de determinação (adimensional).

d Índice de concordância de Willmot (adimensional).

SUMÁRIO

1 INTRODUÇÃO..... 23
2 REVISÃO DE LITERATURA..... 26
2.1 Radiação solar..... 26
2.2 Modelos estatísticos..... 27
2.3 Modelos de regressão múltipla..... 29
2.4 Aprendizagem de máquinas..... 31
2.4.1 Rede neural artificial..... 31
2.4.2 Máquina de vetor de suporte..... 32
3 MATERIAIS E MÉTODOS 34
3.1 Local e clima..... 34
3.2 Instrumentos e medidas..... 35
3.3 Modelos estatísticos para a estimativa de H_G..... 36
3.3.1 Hargreaves e Samani..... 37
3.3.2 Bristow e Campbell..... 37
3.4 Regressões múltiplas..... 37
3.5 Aprendizado de máquinas..... 38
3.5.1 Rede neural artificial..... 39
3.5.2 Máquina de vetor de suporte..... 42
3.6 Validação dos modelos..... 43
4 RESULTADOS E DISCUSSÕES..... 46
4.1 Modelos estatísticos..... 46
4.1.1 Obtenção e validação da equação HS..... 46
4.1.2 Obtenção e validação da equação BC..... 50
4.2 Regressão múltipla não linear..... 53
4.3 Aprendizado de máquinas..... 55
4.3.1 Treinamento validação das técnicas de AM..... 55
4.3.2 Comparação do desempenho das técnicas de AM com resultados da literatura..... 60
4.3.3 Comparação do desempenho das técnicas de AM com os modelos estatísticos..... 63
4.3.4 Comparação do desempenho das técnicas de AM com a

equação RM..... 64
5 CONCLUSÃO..... 65
REFERÊNCIAS..... 67

1 INTRODUÇÃO

A irradiação solar global (H_G), principal fonte de energia do planeta, é responsável por diversos processos físicos, biológicos e bioquímicos, participando do balanço de energia, ciclo hidrológico, e afetando diversos parâmetros meteorológicos (PIRI; KISI, 2014). O conhecimento sobre H_G tem importância fundamental no desenvolvimento de sistemas de energia fotovoltaica e estudos na área da agricultura (MEHDIZADEH, 2016).

Em relação ao potencial fotovoltaico, o Brasil apresenta médias anuais de irradiância solar global (I_G) entre 4,53 $kWh.m^{-2}$ (região Sul) e 5,49 $kWh.m^{-2}$ (região Nordeste). Estes valores são maiores do que as médias anuais para países como Espanha, Itália, Alemanha, Portugal e França, onde a tecnologia fotovoltaica está bem estabelecida. Os valores das médias mensais de I_G encontrados na região Nordeste superam os valores encontrados nos países ibéricos, e possuem uma variabilidade menor. A região Sul possui um comportamento similar aos países europeus, em relação ao valor anual e a variabilidade mensal dos valores, devido ao fato de se encontrar em latitudes maiores (INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS, 2017).

O Brasil, país emergente, de dimensões continentais e com diferentes regiões climáticas, possui poucas estações meteorológicas mecânicas e automáticas distribuídas em todo território nacional, medindo continuamente H_G. Por essa razão existem poucas informações de mapas solarimétricos de H_G disponíveis na área de especialização. Para suprir a falta de conhecimento de H_G por meio de medidas, muitos pesquisadores no Brasil e nos demais países com a mesma necessidade, vem desenvolvendo modelos que permitem estimar H_G através de variáveis mais comumente encontradas nas estações meteorológicas. Esses modelos podem ser classificados como de regressão (lineares ou não lineares), físicos e técnicas de Aprendizado de Máquina (AM) (HARGREAVES; SAMANI, 1982; WINSLOW et al., 2001; SHARIFI et al., 2016; LANDERAS et al., 2012, CHEN et al., 2013).

Os modelos estatísticos realizam a estimativa de H_G relacionando esta variável com variáveis meteorológicas locais, restringindo a solução para a região estudada ou para locais de clima semelhante. Os modelos físicos (transferência radiativa) exigem medidas com precisão de variáveis meteorológicas na superfície e na atmosfera, necessitando de dados sobre a quantidade de nuvens e a concentração de aerossóis e outros gases atmosféricos, o que torna estes modelos complexos e menos acessíveis do que os estatísticos (MARTINS et al., 2004). Recentemente as técnicas de AM vêm sendo testadas para a estimativa de H_G a partir de diversas variáveis meteorológicas, apresentando resultados superiores aos modelos estatísticos (KUMAR et al., 2015).

O principal modelo estatístico linear é o de Angstrom-Prescott (1924), o qual estima H_G a partir do brilho solar (n), normalmente monitorado nos postos meteorológicos. Para locais ou estações secundárias onde n não é monitorado, são utilizados os modelos que estimam H_G a partir de dados de temperatura do ar, como os modelos de Hargreaves e Samani (1982) e Bristow e Campbell (1984).

Outros pesquisadores desenvolveram seus modelos ou modificaram modelos já existentes e testaram para diversas localidades, como o modelo desenvolvido por Donatelli e Campbell (1998), que trouxe modificações ao modelo de Bristow e Campbell (1984), introduzindo uma variável para correção de efeitos de sazonalidade; Winslow et al. (2001) também propôs modificações no modelo de Bristow e Campbell (1984), introduzindo as variáveis pressão de vapor de saturação para temperatura mínima e máxima; Annandale et al. (2000) propôs uma modificação no modelo de Hargreaves e Samani (1982), incluindo a altitude local na equação. Outros trabalhos como os desenvolvidos por Ertekin e Yaldiz (1999) e Falayi et al. (2008) testaram regressões múltiplas, utilizando diversas variáveis meteorológicas como: umidade relativa, razão de insolação, temperatura média, entre outras, com resultados similares ou melhores do que os modelos lineares.

As técnicas de Aprendizagem de Máquina (AM) vêm sendo usadas na geração de modelos de estimativa de H_G em função das medidas de diversas variáveis meteorológicas, com bons resultados como mostra os estudos de Elizondo et al.

(1994), Bocco et al. (2006); Linarez-Rodríguez et al. (2011), Chen et al. (2013), Chen et al. (2015), Mohammadi et al. (2016), Wan et al. (2008), entre outros. As técnicas de AM são algoritmos computacionais capazes de aprender a partir de dados oferecidos, classificando estes dados e generalizando a solução para classificações futuras, sendo que quanto maior o banco de dados e mais precisos os dados fornecidos, melhor será o aprendizado (MOHRI et al., 2018; KOTSIANTIS, 2007).

Das diversas técnicas disponíveis como rede neural artificial (RNA), programação genética (GP), máquina de vetor de suporte (MVS), sistema de inferência neuro-fuzzy adaptativo (ANFIS), entre outras, a mais utilizada para gerar estimativas de H_G é a RNA, porém estudos apontam que a MVS tem apresentado resultados superiores (MOHAMMADI et al., 2015; AYODELE et al., 2016; CHEN et al., 2013).

Existem poucos estudos comparativos entre modelos AM e modelos estatístico lineares ou não lineares para estimativa de H_G, usando a temperatura como variável meteorológica de entrada nos modelos. Essas pesquisas são de fundamental importância para a maioria das regiões do país onde a radiação solar global não é monitorada, e sim a temperatura. Diante dessa necessidade, o presente trabalho teve o objetivo geral de realizar um estudo comparativo entre diferentes modelos de estimativa da irradiação solar global (H_G) a partir de dados meteorológicos do município de Botucatu. Os objetivos específicos deste trabalho foram: estudar o desempenho dos modelos estatísticos de Hargreaves - Samani (HS) e Bristow - Campbell (BC); estudar o desempenho de duas técnicas de Aprendizagem de Máquinas (AM): Máquina Vetor de Suporte (MVS) e Redes Neurais Artificiais (RNA) para quatro diferentes arquiteturas de variáveis meteorológicas; comparar os resultados das técnicas de AM com os modelos estatísticos; propor e estudar o desempenho de um modelo de regressão não linear múltiplo (RM) e comparar os resultados deste novo modelo com as técnicas de AM.

5 CONCLUSÕES

Dos resultados apresentados e discutidos sobre os modelos de estimativa de H_G diária: estatístico de HS**,** BC e RM, e por técnicas de aprendizado de máquinas RNA e MVS, propostos para a cidade de Botucatu podemos concluir:

O coeficiente da equação de Hargreaves-Samani a_{HS} = 0,170 obtido em Botucatu SP/Brazil, depende do clima, latitude e altitude, e pode der utilizada na estimativa de H_G com restrições devido ao baixo coeficiente de determinação (R^2 = 0,495). Na validação do modelo HS, comparação, entre H_G estimada e H_G medida em Botucatu, os valores obtidos foram: coeficiente de correlação r_t = 0,823 e r_a = 0,831; os indicativos estatísticos $rMBE_t$ = -3,1 % e $rMBE_a$ = 3,2% ; $rRMSE_t$ = 21,9 % e $rRMSE_a$ = 24,7%, para o ano típico e o atípico respectivamente indicam que o modelo HS pode ser utilizado na estimativa de H_G com regular precisão e exatidão.

O coeficiente não linear do modelo de BC obtido a = 0,637 na cidade de Botucatu, SP/Brazil, depende do clima, latitude e altitude e pode der utilizada na estimativa de H_G com restrições devido ao baixo coeficiente de determinação (R^2 = 0,537).

Na validação da equação de BC, os valores obtidos: coeficiente de correlação r_t = 0,846 e r_a = 0,828 ; e os indicativos estatísticos $rMBE_t$ = -7,0 % e $rMBE_a$ = 1,0 %; $rRMSE_t$ = 21,0 % e $rRMSE_a$ = 24,1 % para o ano típico e o atípico, respectivamente, indicando que o modelo BC pode ser utilizado na estimativa de H_G com regular precisão e exatidão.

O modelo de regressão múltipla desenvolvido neste trabalho apresentou indicativos de validação: r_t = 0,960 e r_a = 0,956 ; $rMBE_t$ = - 3,8 % , $rMBE_a$ =2,0 %; rRMSEt = 11,3 %, rRMSEa = 13,6 % para o ano típico e o atípico, respectivamente.

As técnicas MVS e RNA, com as mesmas variáveis de entrada (H_0 e $\Delta T^{0,5}$) que o modelo HS, mostram por meio dos valores dos indicativos estatísticos: MVS ($rMBE_t$ = 0,9% e $rMBE_a$ = 1,6 %; $rRMSE_t$ = 20,0 % e $rRMSE_a$ = 20,2 %) e RNA ($rMBE_t$ = 1,4% e $rMBE_a$ = 1,6 %; $rRMSE_t$ = 19,7 % e $rRMSE_a$ = 20,0 %) para o ano típico e o atípico, respectivamente, e podem estimar H_G com desempenho similar aos modelos estatísticos de HS e BC.

Os valores crescentes dos valores de r com entradas de diferentes variáveis meteorológicas mostram que as técnicas RNA e MVS elevam o desempenho dos modelos AM nas estimativas de H_G.

As técnicas MVS e RNA na combinação 4, com as entradas das variáveis meteorológicas: irradiação solar global no topo da atmosfera (H_0, MJ m-2 dia-1); e temperatura máxima- ($T_{máx}$, °C); temperatura mínima (T_{min}, (°C); razão de insolação (RI) e umidade relativa do ar (UR, %), com valores dos coeficientes de correlações r_t= 0,960 e r_a=0,95, e valores dos indicativos estatísticos: MVS ($rMBE_t$ = 0,1 % e $rMBE_a$ = 0,4 %; $rRMSE_t$ = 11,5 % e $rRMSE_a$ = 11,7 %); e RNA($rMBE_t$ = -1,2 % e $rMBE_a$ = -1,0 %; $rRMSE_t$ = 11,7 % e $rRMSE_a$ = 11,9 %), para o ano típico e o atípico, respectivamente, podem estimar H_G com melhor desempenho que as modelos de HS e BC, e desempenho similar ao modelo RM.

A comparação entre os desempenhos dos modelos HS, BC, RM e as redes MVS e RNA na combinação 4, sugere o uso do modelo RM, quando os dados de RI e UR estejam disponíveis, por ser um método mais prático que o uso das técnicas de aprendizado de máquinas.

REFERÊNCIAS

ALLEN, R. G. Self-Calibrating Method for Estimating Solar Radiation from Air Temperature. **Journal of Hidrologic Engineering**, v. 2, n. 2, p. 56 – 67, 1997.

ALMEIDA, W. G. **Avaliação de um modelo físico estimadorde irradiância solar baseado em satélites geoestacionários.** 1998. Dissertação (Mestrado em Engenharia Mecânica) – Universidade Federal de Santa Catarina, Florianópolis, 1998.

ALMOROX, J. Estimating global solar radiation from common meteorological data in Aranjuez, Spain. **Turkish Jornal of Physics**, v. 35, p. 53-64, 2011.

ALMOROX, J.; BENITO, C. H. Models for obtaining daily global solar radiation with measured air temperature data in Madrid (Spain). **Applied Energy**, v. 88, p. 1703-1709, 2011.

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.

ALSINA, E. et al. Artificial neural network optimisation for monthly average daily global solar radiation prediction. **Energy Conversion and Management**, v. 120, p. 320-329, 2016.

ALVARENGA, L. A. Precipitação no sudeste brasileiro e sua relação com a Zona de Convergência do Atlântico Sul. **Revista Agrogeoambiental**, 2012. DOI: http://dx.doi.org/10.18406/2316-1817v4n22012452

ANNANDALE, J. G. et al. Software for missing data error analysis of Penman-Monteith reference evapotranspiration. **Irrigation Science**, 2002. DOI 10.1007/s002710100047.

ANGSTRÖM, A. Solar and terrestrial radiation. **Quartely Journal of the Royal Meteorological Society**, v. 50, p. 121-125, 1924.

ANTONANZAS-TORRES, F. et al. Generation of daily global solar irradiation with support vector machines for regression. **Energy Conversion and Management**, v. 96, p. 277-286, 2015.

AYODELE, T. R.; OGUNJUYIGBE, A. S. O.; MONYEI, C. G. On the global solar radiation predictions methods. **Journal of Renewable and Sustainable Energy**, v. 8, 2016. DOI: 10.1063/1.4944968

BECHINI, L.; DUCCO, G.; DONATTELI, M.; STEIN, A. Modelling, interpolation and stochastic simulation is space and time of global solar radiation. **Agriculture, Ecosystems and Environment**, 2000. https://doi.org/10.1016/S0167-8809(00)00170-5.

BEHRANG et al. The potential of different artificial neural network (ANN) techniques in daily global solar radiation modeling based on meteorological data. **Solar Energy**, v. 84, p.1468 - 1480, 2010.

BELAID, S.; MELLIT, A. Prediction of daily and mean monthly global solar radiation using support vector machine in na arid climate**. Energy Conversion and Management**, v. 118, p. 105 – 118, abril, 2016.

BERRY, W. D.; FELDMAN, S. **Multiple regression in practice:** Series: Quantitative Applications in the Social Sciences. California: Sage Publications, 1985. p. 1-5.

BESHARAT F.; DEHGHAN, A. A.; FAGHIH A. R. Empirical models for estimating global solar radiation: A review and case study. **Renewable and Sustainable Energy Reviews**, v. 21, p. 798-821, 2013.

BILGILI, M.; OZFOREN, M. Daily total global solar radiation modeling from several meteorological data**. Meteorology and Atmospheric Physics**, 2011. DOI 10.1007/s00703-011-0137-9.

BOCCO, M.; OVANDO, G.; SAYAGO, S. Devolopment and evaluation of neural network models to estimate daily solar radiation at Córdoba, Argentina. **Pesquisa Agropecuária Brasileira**, v. 41, p. 179-184, 2006.

BOCCO, M.; WILLINGTON, E.; ARIA, M. Comparison of regression and neural networks models to estimate solar radiation. **Chilean Journal of Agricultural Reseach**, v. 70, n. 3, p. 428-435, 2010.

BOJANOWSKI, J. S.; DONATELLLI, M.; SKIDMORE, A. K.; VRIELING, A. Na auto-calibration procedure for empirical solar radiation models. **Environmental Modelling and Software**, 2013. https://doi.org/10.1016/j.envsoft.2013.08.002.

BONACCORSO, G. **Machine Learning Algorithms**: A reference guide to popular algorithms for data science anda machine learning. Birmingham: Packt Publishing, 2017, cap. 1, p. 8.

BOSCH, J. L.; LÓPEZ, G.; BATLLES, F. J. Daily solar irradiation estimation over a mountainous area using artificial neural networks. **Renewable Energy**, v. 33, p. 1622-1628, 2008.

BRISTOW, K. L.; CAMPBELL, G. S. On the relationship between incoming solar radiation and daily maximum and minimum temperature. **Agricultural and Forest Meteorology**, v. 31, n. 2, p. 159 – 166, maio, 1984.

CHAVES, M. A.; ESCOBEDO, J. F. A software to process daily solar radiation data. **Renewable Energy**, v. 19, p. 339 – 344, 2000.

CHAVES, M. A.; ESCOBEDO, J. F.; TEODORO, S. M. “Horas de brilho solar e índice de insolação: uma comparação entre os valores medidos com heliógrafo e pireliômetro”. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 2, 1999, Florianópolis, SC: **Epagri**, 1999. CD-ROM.

CHEN, R. et al. Validation of five global radiation models with measured daily data in China. **Energy Conversion and Management**, v. 45, p. 1759-1769, 2004.

CHEN, J. L; LI, G. S.; WU, S. J. Assessing the potentical of support vector machine for estimatting daily solar radiation using Sunshine duraction. **Energy Conversion and Management**, v. 75, p. 311-318, 2013.

CHEN, J-L.; LI, G-S. Evaluation of support vector machine for estimation of solar radiation from measured meteorological variables. **Theoretical and Applied Climatology**, v. 115, n. 3 – 4, p. 627 – 638, fevereiro, 2014.

CHEN et al. Assessing the transferability os support vector machine model for estimation of global solar radiation from air temperature. **Energy Conversion and Management**, v. 89, p. 318-329, 2015.

CITAKOGLU, H. Comparison of artificial intelligence techniques via empirical equations for prediction of solar radiation. **Computers and Electronics in Agriculture**, v. 118, p. 28-37, 2015.

CROTTI, P.; RAMPINELLI, G. A. Estimativa das componentes direta e difusa da radiação solar em superfície horizontal para Araranguá/SC a partir de redes meteorológicas. In: COGRESSO BRASILEIRO DE ENERGIA SOLAR, 7., 2018, Gramado. **Anais** [...]. Gramado, 2018. Disponível em: https://anaiscbens.emnuvens.com.br/cbens/issue/view/1

DONATELLI, M.; CAMPBELL, G. S. A simple model to estimate global solar radiation. **Procedings of the 5th European Sociaty of Agronomy Congress**. Nitra, Slovak Republic; p. 133-134, 1998.

ECHER, E.; SOUZA, M. P.; SCHUCH, N. J. A Lei de Beer Aplicada na Atmosfera Terrestre. **Revista Brasileira de Ensino de Física**, v. 23, n. 3, p. 276-283, 2001.

ELIZONDO, D.; HOOGENBOOM, G.; MCCLENDON, R. W. Development of a neural network model to predict daily solar radiation. **Agricultural and Forest Meteorology**, v. 71, p. 115-132, 1994.

ERTEKIN, C.; YALDIZ, O. Estimation of monthly average daily global radiation on horizontal surfasse for Antalya (Turkey). **Renewable Energy**, v. 17, p. 95-102, 1999.

ESTÉVEZ, J.; PADILLA, F. L. M.; GAVILÁN, P. Evaluation and Regional Calibration of Solar Radiation Prediction Models in Southern Spain. **Journa of Irrigation and Drainage Enginnering**, v. 138, n. 10, p. 868-879, 2012.

FALAYI, E. O.; ADEPITAN, J. O.; RABIU, A. B. Empirical models for the correlation of global solar radiation with meteorological data for Isayin, Nigeria. **International Journal of Physical Sciences**, v. 3, n. 9, p. 210-216, 2008.

FENG, Y. et al. Ozone concentration forecast method based on genetic algorithm optimized back propagation neural networks and support vector machine data classification. **Atmosphere Environment**, v. 45, n. 11, p. 1979 – 1985, abril, 2011.

FERRARI, S. et al. "Computational intelligence models for solar radiation prediction," ***2013 IEEE International Instrumentation and Measurement Technology Conference (I2MTC)***, Minneapolis, MN, 2013, p. 757-762, doi: 10.1109/I2MTC.2013.6555517.

FIORIN, D. V. et al. Aplicações de redes neurais e previsões de disponibilidade de recursos energéticos solares. **Revista Brasileira de Ensino de Física**, v. 33, n. 1, p. 1- 20, 2011.

FORTIN et al. Comparision of empirical daily surface incoming solar radiation models. **Agricultural and Forest Meteorology**, v. 148, 1332-1340, 2008.

GARDNER, M. W.; DORLING, S. R. Artificial Neural Networks (The Multilayer Perceptron) – A Review of Applications in the Atmospheric Sciences. **Atmospheric Environment**, v. 32, n. 14/15, p. 2627 – 2636, junho, 1998.

GARSON, G. D. **Neural Networks**: An Introductory Guide for Social Scientists. Londres: Sage Publications, 1998. cap. 1, p. 2-5.

GOIS, G. et al. Models to estimate incidente solar radiation on Seropédoca, Rio de Janeiro. **Bioscience Journal**, v. 32, n. 2, p. 505-513, 2016.

GOODIN, D. G. et al. Estimating solar irradiance for crop modeling using air temperature data. **Agronomy Journal**, v. 91, n. 5,p. 845-851, 1999.
DOI: 10.2134/agronj1999.915845x

GRILLONE, G.; AGNESE, C. D'ASARO, F. Estimation of Daily Solar Radiation from Measured Air Temperature Extremes in the Mid-Mediterranean Area. **Journal of Irrigation and Drainage Engineering**, v. 138, n. 10, p. 939-947, 2012.

HARGREAVES, G. H.; SAMANI, Z. A. Estimating Potential Evapotranspiration. **Journal of the Irrigation and Drainage Division**, v. 108, n. 3, p. 225 – 230, 1982.

HARGREAVES et al. Irrigation Water Requirements For Senegal River Basin. **Journal of Irrigation and Drainage Engineering**, v. 111, n. 3, p. 265-275, 1985.

HUNT, L. A. et al. Estimation of solar radiation for use crop modeling. **Agricultural Forest Meteorology**, v. 91, p. 293-300, 1998.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS. **Atlas Brasileiro de Energia Solar**. São José dos Campos, 2017, 80 p.

KOTSIANTIS, S. B. Supervised Machine Learning: a Review of Classification Techniques. In: MAGLOGIANNIS, I. et al. **Emerging Artifitial Intelligence: Aplications in Computer Enginneering**. Amsterdã: IOS Press, 2007. p. 3.

KOUSKY, V. E.; GAN, M. A. Upper tropospheric cyclonic vortices in the tropical South Atlantic. **Tellus**, v. 33, n. 6, p. 538-551, 1981.

KULIK, S. D. Neural network model or artificial intelligence for handwriting recognition. Journal of Theoretical and Applied Information Technology, v. 73, n. 2, p. 202-211, 2015.

KUMAR, R. Comparison of regression and artificial neural network models for estimation of global solar radiations. **Renewable and Sustainable Energy Reviews**, v. 52, p. 1294-1299, 2015.

LANDERAS, G. et al. Comparison of Gene Expression Programming with neuro-fuzzy and neural network computing techniques in estimating daily incoming solar radiation in the Basque Country (Northern Spain). **Energy Conversion and Management**, v. 62, p. 1-13, 2012.

LÊDO, E. R. F. et al. Avaliação de modelo de estimativa da radiação solar global (Rs) com base na amplitude térmica. **Conexões Ciência e Tecnologia**, v. 6, n. 1, p. 15-26, 2012.

LI et al. General models for estimating daily global solar radiation for different solar radiation zones in mainland China. **Energy Conversion and Management**, v. 70, p. 139-148, 2013.

LIAKOS, K. G. et al. Machine Learning in Agriculture: a Review. **Sensors in Agriculture**, v. 18, n. 8, 2018. Disponível em: https://doi.org/10.3390/s18082674.

LINARES-RODRÍGUEZ, A. et al. Generation of synthetical daily global solar radiation data based on ERA-Interim reanalysis and artificial neural networks. **Energy**, v. 36, p. 5356-5365, 2011.

LIU, X. et al. Evaluation of temperature-based global solar radiation models in China. **Agricultural and Forest Meteorology**, n. 149, p. 1433-1446, 2009.

LYRA et al. Estimation of monthly global solar irradiation using the Hargreaves-Samani model and na artificial neural network for the state of Alagoas in northeastern Brazil. **Theoretical Applied Climatology**, DOI 10.1007/s00704-015-1541-8, 2015.

MACAGNAN, M. H. **Introdução à radiação solar**. São Leopoldo, Universidade do Vale do Rio dos Sinos, 2010, 100p.

MAGHRABI, A. H. Parametrization of a simple model to estimate monthly global solar radiation based on meteorological variables, and evaluation of existing solar radiation for Tabouk, Saudi Arabia. **Energy Conversion and Management**, v. 50, p. 2754-2760, 2009.

MATTOS, T. B. **Modelos Não Lineares e suas Aplicações**. 2013. 59 f. Trabalho de conclusão de curso (Bacharel em Estatística) - Instituto de Ciências Exatas, Universidade Federal de Juiz de Fora, Juiz de Fora, 2013.

MEHDIZADEH, S.; BEHMANESH, J.; KHALILI, K. Comparison of artificial intelligence methods and empirical equations to estimate daily solar radiation. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 146, p. 215 – 227, junho, 2016.

MEJDOUL, R.; TAQI, M.; BELOUAGGADIA, N. Artificial neural network based prediction model of daily global solar radiation in Morocco. **Journal of Renewable and Sustainable Energy,** 2013. DOI: 10.1063/1.4854817.

MEZA, F.;VARAS, E. Estimation of mean monthly solar global radiation as a function of temperature. **Agricultural and Forest Meteorology**, v.100, p. 231-241, 2000.

MICROCAL SOFTWARE, INC. Data analysis and technical graphics software. **Origin Professional Version 6.0**. Northampton, MA: Copyright©, 1999, 772p.

MOHAMMADI, K. et al. Extreme learning machine based prediction of daily dew point temperature. **Computers and Electronics in Agriculture**, v. 117, p. 214-225, 2015.

MOHAMMADI, K. et al. Support vector regression based prediction of global solar radiation on a horizontal surface. **Energy Conversion and Management**, v. 91, p. 433-441, 2015.

MOHAMMADI, K. et al. Temperature-based estimation of global solar radiation using soft computing methodologies. **Theoretical and Applied Climatology**, v. 125, p. 101-112, 2016.

MOHRI, M.; ROSTAMIZADEH, A; TALWALKAR, A. **Foundations of Machine Learning**, 2. ed. Cambridge: MIT Press, 2018. cap. 1, p. 1.

MOOJEN, T. M. B.; CAVALCANTE, R. B. L.; MENDES, C. A. B. Avaliação da radiação solar com base em dados de nebulosidade. **Geografia**, v. 21, n. 3, p. 41-55, 2012.

MORENO, A.; GILABERT, M. A.; MARTÍNEZ, B. Mapping daily global solar irradiation over Spain: A comparative study of selected approaches. **Solar Energy**, v. 85, p. 2072-2084, 2011.

NOGUEIRA, D. H.; SILVA, M. G.; LEDO, E. R. F.; ARAUJO, E. M. Estimativa da radiação solar global (RS) através da amplitude térmica diária. In: INOVAGRI INTERNATIONAL MEETING; WORKSHOP INTERNACIONAL DE INOVAÇÕES TECNOLÓGICAS NA IRRIGAÇÃO, 4., 2012, Fortaleza. Anais... Fortaleza: **INOVAGRI Meeting**, 2012.

PALÁCIOS, R. S. **Interação entre a radiação solar direta e os aerossóis atmosféricos na Amazônia**, 2017. Tese (Doutorado Física Ambiental) – Universidade Federal do Mato Grosso, Cuiabá, 2017

PIRI, J.; KISI, O. Modelling solar radiation reached to the Earth using ANFIS, NN-ARX, and empirical models (Case studies: Zahedan and Bojnurd stations). **Journal of Atmospheric and Solar-Terrestrial Psysics**, v. 123, p. 39 – 47, dezembro, 2014.

PIRI et al. Prediction of the solar radiation on the Earth using support vector regression technique. **Infrared Physics &Tecnology**, v. 68, p. 179-185, 2015.

PLATT, J. Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines. **Redmond: Microsoft Research**, 1998. 21 p. TechReport.

PODESTÁ, G. P.; Núñez, L., VILLANUEVA, C. A., SKANSI, M. A. Estimating daily solar radiation in the Argentine Pampas. **Agricultural and Forest Meteorology**, 2004. https://doi.org/10.1016/j.agrformet.2003.11.002.

QUEJ, V. H.; ALMOROX, J.; IBRAKHIMOV, M.; SAITO, L. Empirical models for estimating daily global solar radiation in Yucatán Peninsula, Mexico. **Energy Conversion and Management**, v. 110, p. 448-456, 2016.

QUEJ, V. et al. ANFIS, SVM and ANN soft-computing techniques to estimate daily global solar radiation in a warm sub-humid environment. **Journal of Atmospheric and Solar–Terrestrial Physics,** v. 155, p. 62 – 70, 2017.

RADHIKA, Y.; SHASHI, M. Atmospheric Temperature Prediction using Support Vector Machines. **International Journal of Computer Theory and Engineering**, v. 1, n. 1, p. 55 – 58, abril, 2009.

RAJASEKARAN, S.; GAYATHRI, S.; LEE, T-L. Support vector regression methodology for storm surge predictions. **Ocean Engineering**, v. 35, n. 16, p. 1578 – 1587, novembro, 2008.

RAHIMIKHOOK, A. Estimating global solar radiation using artificial neural network and air temperature data in a semi-arid environment. **Renewable Energy**, v. 35, p. 2131-3135, 2010.

RAMEDANI, Z.; OMID, M.; KEYHANI, A. A method based on neural networks for generating solar radiation map**. International Journal of Energy and Environment**, v. 3, n. 5, p. 775-786, 2012.

RAMEDANI, Z. et al. (2014). A comparative study between fuzzy linear regression and support vector regressions for global solar radiation prediction in Iran. **Solar Enery**, v. 109, p. 135-143, 2014.

RAMOS, C. M. C. et al. Modelagem da variação horária da temperatura do ar em Petrolina, PE, e Botucatu, SP. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 9, p. 959-965, 2011.

R CORE TEAM. **R: A Language and Environment for Statistical Computing** 3.6.0. Austria: R Foundation for Statistical Computing, 2018. Disponível em: https://www.r-project.org/.

RONDÓN, A.C.B.; DUCATI, J. R.; HAAG, R. ANÁLISE ANUAL DAS COMPONENTES DIRETA, DIFUSA E GLOBAL DA RADIAÇÃO SOLAR EM PORTO ALEGRE, RS. In: Congresso Brasileiro de Energia Solar, 8, 2020, Fortaleza. **Anais** [...]. Fortaleza, 2017. Disponível em: https://anaiscbens.emnuvens.com.br/cbens

SANUSI, Y. K.; ABISYE, S. G.; ABIODUN, A. O. Application of Artificial Neural Networks to Predict Daily Solar Radiation in Sokoto. **International Journal of Current Engineering and Technology**, v. 3, n. 2, p. 647-652, 2013. http://inpressco.com/category/ijcet

SANTOS, C. M**. Modelagem da irradiação direta na incidência normal em Botucatu: aprendizado de máquinas, estatístico e LINKE**. 2016. 131f. Tese (Doutorado em Agronomia/Irrigação e Drenagem) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, 2016.

SHARIF, S. S.; REZAVERDINEJAD, V.; NOURANI, V. Estimation of daily global solar radiation using wavelet regression, ANN, GEP and empirical models: A comparative study of selected temperaturebased approaches. **Journal of Atmospheric and Solar-Terrestrial Physics**, v. 149, p. 131-145, 2016.

SHEVADE et al. Improvement to the SMO Algorithm for SVM Regression. **IEEE Transactions on Neural Networks**, v. 11, n. 5, 2000.

SILVA, C. R. et al. Radiação solar estimada com base na temperatura do ar para três regiões de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 16, n. 3, p. 281-288, 2012.

SILVA, M. B. P. **Estimativa da irradiação solar global pelo método Angström-Prescott e técnicas de aprendizado de máquinas**. 2016. 86 f. Dissertação (Mestrado em Agronomia/Irrigação e Drenagem) - Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, 2016.

SMOLA, A. J.; SCHÖLKOPF, B. A tutorial on support vector regression. **Statistics and Computing**, v.14, p.199-222, 2004.

SOARES, P. L. B.; SILVA, J. P. Aplicação de redes neurais artificiais em conjuntos com o método vetorial da propagação de Feixes na análise de um acoplador direcional baseado em fibra ótica. **Revista Brasileira de Computação Aplicada**, v. 3, n. 2, p. 58-72, 2011.

SONDAK, N. E.; SONDAK, V. K. Neural network and artificial intelligence. In: PROCEEDINGS OF THE 20TH SIGCSE TECHNICAL SYMPOSIUM ON COMPUTER SCIENCE EDUCATION, 1989, p. 241-245.

SWARTMAN, R. K.; OGUNLADE, O. Solar Radiation Estimates from Common Parameters. **Solar Energy**, v. 11, n. 3 – 4, p. 170 – 172, 1967.

TEIXEIRA Jr., L. A.; PESSANHA, J, F. M.; SOUZA, R. C. Análise wavelet e redes neurais artificiais na previsão da velocidade de vento. In: SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 43, 2011, Ubatuba. **Anais:** XLIII Simpósio Brasileiro de Pesquisa Operacional, Ubatuba – Sociedade Brasileira de Pesquisa Operacional, 2011, p. 684 – 695.

TERAMOTO, E. T.; ESCOBEDO, J. F. Análise da frequência anual das condições de céu em Botucatu, São Paulo. **Revista Brasileira de Engenharia Agrícola e Ambiental,** Campina Grande, v. 16, n. 9, p. 985 – 992, 2012.

TORRES, W. L. V.; OLIVEIRA, J. B.; ARRAES, F. D. D.; CORDEIRO, A. Y. P. A. V. G.; ALVES, A.S. Avaliação de Modelos de Estimativa da Radiação Solar na Escala

Mensal em Fortaleza – CE. In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 19, 2015, Lavras. **Anais:** agrometeorologia no século 21 - o desafio do uso sustentável dos biomas brasileiros, Lavras: Universidade Federal de Lavras – Sociedade Brasileira de Agrometeorologia, 2015, p. 73 – 81.

TYMVIOS et al. Comparative study of Angstrom and artificial neural networks' methodologies in estimating global solar radiation. **Solar Energy**, v. 78, p. 752 - 762, 2005.

UGWU, A. I.; UGWUANYI, J. U. Performance assessment of Hargreaves model in estimating solar adiation in Abuja using minimum climatological data. **International Journal of the Physical Sciences**, DOI: 10.5897/IJPS11.1403, 2011.

URRACA, R. et al. Estimation of solar global irradiation in remote areas. Journal of Renewable and Sustainable **Energy**, DOI: 10.1063/1.4919084, 2015.

VIGANÓ, H. H. G. et al. Redes Neurais Artificiais na Previsão de Queimadas e Incêndios no Pantanal. **Revista Brasileira de Geografia Física,** Recife, v. 10, n. 5, 2017.

WAEWSAK, J. et al. Estimation of Monthly Mean Daily Global Solar Radiationover Bangkok, Thailand using Artificial Neural Networks. **Energy Procedia**, v. 57, p. 1160-1168, 2014.

WAN, K. K. W. et al. An analysis of thermal and solar zone radiation models using na Angstrom–Prescott equation and artificial neural networks. **Energy**, v. 33, n. 7, p. 115-1127, 2008.

WEISS, A., HAYS, C. J. Simulation of daily solar irradiance. **Agricultural and Forest Meteorology**, 2004. https://doi.org/10.1016/j.agrformet.2003.12.002

WINSLOW, J. C.; HUNT, E. R. Jr.; PIPER, S. C. A globally applicable model of daily solar irradiance estimated from air temperature and precipitation data. **Ecological Modelling**, v. 143, n. 3, p. 227-243, 2001.

ZANETTI, S. S. et al. Estimação da evapotranspiração de referência no Estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 12, n. 2, p. 174 – 180, 2008.