

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CÂMPUS BOTUCATU

**ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL PELO
MÉTODO DE ANGSTRÖM-PRESCOTT E TÉCNICAS DE
APRENDIZADO DE MÁQUINAS**

MAURÍCIO BRUNO PRADO DA SILVA

Dissertação apresentada à faculdade de
Ciências Agrônômicas da UNESP –
Campus de Botucatu, para obtenção do
título de Mestre em Agronomia (Irrigação
em Drenagem).

BOTUCATU - SP
FEVEREIRO – 2016

UNIVERSIDADE ESTADUAL PAULISTA “JÚLIO DE MESQUITA FILHO”
FACULDADE DE CIÊNCIAS AGRONÔMICAS
CÂMPUS BOTUCATU

**ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL PELO
MÉTODO DE ANGSTROM-PRESCOTT E TÉCNICAS DE
APRENDIZADO DE MÁQUINAS**

MAURÍCIO BRUNO PRADO DA SILVA

Orientador: Prof. Dr. João Francisco Escobedo

Dissertação apresentada à faculdade de Ciências Agrônômicas da UNESP – Campus de Botucatu, para obtenção do título de Mestre em Agronomia (Irrigação em Drenagem).

BOTUCATU - SP
FEVEREIRO – 2016

FICHA CATALOGRÁFICA ELABORADA PELA SEÇÃO TÉCNICA DE AQUISIÇÃO E TRATAMENTO DA INFORMAÇÃO - DIRETORIA TÉCNICA DE BIBLIOTECA E DOCUMENTAÇÃO - UNESP - FCA - LAGEADO - BOTUCATU (SP)

S586e Silva, Maurício Bruno Prado da, 1988-
Estimativa da irradiação solar global pelo método de Angstrom-Prescott e técnicas de aprendizado de máquinas/
Maurício Bruno Prado da Silva. - Botucatu : [s.n.], 2016
xii, 72 f. : grafs. color., ils., tabs.

Dissertação (Mestrado) - Universidade Estadual Paulista, Faculdade de Ciências Agronômicas, Botucatu, 2016
Orientador: João Francisco Escobedo
Inclui bibliografia

1. Radiação solar. 2. Modelagem gráfica (Estatística). 3. Aprendizado do computador. I. Escobedo, João Francisco. II. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Câmpus de Botucatu). Faculdade de Ciências Agronômicas. III. Título.



UNIVERSIDADE ESTADUAL PAULISTA

Câmpus de Botucatu



CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL PELO MÉTODO DE ANGSTRON-PRESCOTT E TÉCNICAS DE APRENDIZADO DE MÁQUINA.

AUTOR: MAURÍCIO BRUNO PRADO DA SILVA

ORIENTADOR: JOÃO FRANCISCO ESCOBEDO

Aprovado como parte das exigências para obtenção do Título de Mestre em AGRONOMIA (IRRIGAÇÃO E DRENAGEM), pela Comissão Examinadora:

Prof. Dr. JOÃO FRANCISCO ESCOBEDO
Depto Engenharia Rural / Faculdade de Ciências Agrômicas de Botucatu

Prof. Dr. ÉRICO TADAO TERAMOTO
Depto. de Engenharia e Pesca / UNESP - Câmpus Experimental de Registro

Profa. Dra. SILVIA HELENA M GORLA DA SILVA
Depto de Engenharia de Pesca / UNESP - Câmpus Experimental de Registro

Botucatu, 22 de fevereiro de 2016.

OFEREÇO

A toda minha família e amigos.

*“Aguarda as surpresas do tempo, agindo
sem precipitação. Se cada noite é nova
sombra, cada dia é nova luz.”*

Chico Xavier

AGRADECIMENTOS

A minha eterna gratidão ao professor Dr. João Francisco Escobedo pelos ensinamentos, confiança, paciência e amizade.

À Universidade Estadual Paulista “Júlio de Mesquita Filho” (UNESP) – Faculdade de Ciências Agrônômicas (FCA) e ao Programa de Irrigação e Drenagem por oferecer a oportunidade de aprimoramento profissional através dos ensinamentos transmitidos pelo quadro de professores do Departamento de Engenharia Rural.

Aos professores que aceitaram compor a banca avaliadora da dissertação: Érico Tadao Teramoto e Sílvia Helena Modenese Gorla da Silva.

Aos estimados colegas e amigos de departamento: Cícero Santos, Daniel Gomes, Esteban Conde, Bartolomeu Tangune, Lucas Lenz e Taiza Rossi.

Aos companheiros e amigos da República Alagoas: Élvis, David, Jannaylton, Marcos e Thalyson.

Aos demais amigos e colegas pelo companheirismo ao longo desses últimos anos em Botucatu: Cristiane Araújo, Dávila, Fabíola, Henrique Oldoni, Mary, Lucas Holanda, Maria Clara, Natália Soares, entre tantos outros.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de auxílio financeiro.

Muito grato!!!

SUMÁRIO

	Páginas
SUMÁRIO.....	VI
LISTA DE TABELAS	VIII
LISTA DE FIGURAS	IX
LISTA DE ABREVIATURAS E SÍMBOLOS.....	X
1. RESUMO	1
2. ABSTRACT.....	3
3. INTRODUÇÃO	5
4. REVISÃO DE LITERATURA	8
4.1 Radiação solar: importância, medidas e modelagem.....	8
4.2 Modelo de Angstrom-Prescott (A-P).....	9
4.3 Aprendizado de Máquina (AM).....	11
4.3.1 Máquina Vetor de Suporte (MVS).....	12
4.3.2 Rede Neural Artificial (RNA).....	13
5. MATERIAL E MÉTODOS.....	14
5.1 Área de estudo e informações climáticas.....	14
5.2 Instrumentação e medidas.....	16
5.3 Geração de modelos de estimativa de H_G com as técnicas de Aprendizado de Máquina (AM): MVS e RNA	17
5.3.1 Aplicação da Máquina Vetor de Suporte (MVS).....	19
5.3.2 Aplicação da Rede Neural Artificial (RNA).....	19
5.3.3 Software utilizado	21
5.4 Análise sazonal do modelo de A-P	21
5.5 Validação e avaliação dos modelos	22
6. RESULTADOS E DISCUSSÃO	25
6.1 Equação de Angstrom-Prescott: diária (A-P) ^d e mensal (A-P) ^m	25
6.2 Validação dos modelos de Angstrom-Prescott (A-P) ^d e (A-P) ^m e de treinamento das técnicas MVS e RNA.....	32
6.2.1 Validação do modelo de Angstrom-Prescott (A-P) ^d e (A-P) ^m	32
6.3 Validação dos modelos de treinamento das técnicas de AM.....	39
6.3.1 Modelos gerados em partição diária	39
6.3.2 Mensal.....	44
6.4 Comparação dos modelos MVS e RNA (diário e mensal) de Botucatu com resultados da literatura	49

6.5 Comparação do desempenho entre os modelos Angstrom-Prescott (A-P) e as redes MVS e RNA (diário e mensal) em Botucatu e de outros locais	53
7. CONCLUSÃO.....	58
7.1 Dos resultados apresentados e discutidos sobre os modelos de estimativa de H_G , em partição diária, conclui-se:	58
7.2 Dos resultados apresentados e discutidos sobre os modelos de estimativa de H_G , em partição mensal, conclui-se:.....	59
8. REFERÊNCIAS BIBLIOGRÁFICAS	61

LISTA DE TABELAS

Tabela 1. Coeficientes de Angstrom-Prescott (A-P) obtidos por diferentes autores em várias localidades do globo terrestre.	10
Tabela 2. Arquitetura dos Modelos gerados pelas técnicas Máquina Vetor de Suporte (MVS) e Redes Neurais Artificiais (RNA) com diferentes variáveis meteorológicas de entrada.	18
Tabela 3. Ano típico e atípico obtido do banco de dados de 16 anos.....	23
Tabela 4. Coeficientes de Angstrom-Prescott (A-P) obtidos no território nacional por diversos autores.	27
Tabela 5. Equações sazonais desenvolvidos para outras localidades.....	30
Tabela 6. Indicativos estatísticos obtidos para diversas localidades (partição diária).....	36
Tabela 7. Indicativos estatísticos obtidos para diversas localidades (partição mensal).	38
Tabela 8. Índices estatísticos obtidos neste trabalho e comparados aos obtidos por outros autores nas partições diária (d) e mensal (m).	51
Tabela 9. Comparações entre os modelos estatísticos de A-P (partições diária ou mensal) com as técnicas de aprendizado de máquina (AM).	55

LISTA DE FIGURAS

- Figura 1. Séries Climáticas (período: 1970-2008) da Temperatura e Umidade Relativa (a), Nebulosidade (b), Precipitação (c), Relação entre a evolução anual da Profundidade Ótica dos Aerossóis (POA) médias mensais (obtidas do satélite TERRA) no ano de 2001 a 2005. 14
- Figura 2. Correlação entre a transmissividade atmosférica da irradiação global (H_G/H_0) com a razão de insolação (n/N) diária e mensal, usadas para treinamento das técnicas: MVS1 e RNA1. 18
- Figura 3. Diagrama em blocos demonstrando a arquitetura da RNA utilizada (RNA)..... 20
- Figura 4. Comparação do valor da irradiação solar global (H_G^d) média inter-anos com desvio padrão e o valor da irradiação média do ano, para o mês de janeiro da série. 22
- Figura 5. Correlação entre a transmissividade atmosférica da irradiação global (H_G/H_0) e a razão de insolação (n/N) nas partições a) diária, e b) mensal, e as retas obtidas por regressão linear no período de 1996-2011..... 26
- Figura 6. Correlações sazonais: (a) verão; (b) outono; (c) inverno e (d) primavera. 28
- Figura 7. Retas de regressões lineares entre modelo anual de $(A-P)^d$ e os sazonais. 31
- Figura 8. Valores de DL (%) para (a) verão; (b) outono; (c) inverno e (d) primavera..... 32
- Figura 9. Comparação entre os valores estimados por meio de Angstrom-Prescott $(A-P)^d$ e $(A-P)^m$ e medidos de H_G para anos típico e o atípico. 33
- Figura 10. Indicativos estatísticos rMBE, rRMSE e d de Willmott na validação para anos típico e atípico. 34
- Figura 11. Diagramas de dispersão entre os valores estimados pelos modelos de AM, para anos típico e atípico, e os valores medido de H_G 41
- Figura 12. Indicativos estatísticos rMBE (%), rRMSE (%) e d de Willmott na validação para anos típico e atípico. 42
- Figura 13. Diagramas de dispersão entre os valores estimados pelos modelos de AM, para anos típico e atípico, e os valores medido de H_G 46
- Figura 14. Indicativos estatísticos rMBE (%), rRMSE (%) e d de Willmott na validação para anos típico e atípico. 48

LISTA DE ABREVIATURAS E SÍMBOLOS

- (*a*) Coeficiente que expressa a transmissividade mínima atmosférica.
- ("a") Padrão de camadas ocultas do WEKA.
- (*b*) Coeficiente complementar do modelo de A-P.
- a+b* Transmissividade máxima atmosférica.
- (*d*) Índice de concordância de Willmont.
- (AM) Aprendizado de máquina.
- (ANN) Artificial Neural Network.
- (ANFIS) Adaptative Neuro-Fuzzy Inference System.
- (A-P) Modelo de Angstrom-Prescott.
- C* Parâmetro de ajuste da Máquina Vetor de Suporte.
- (DL) Desvio Linear (%).
- (Eo) Fator de correção da excentricidade da órbita da terrestre.
- (*f*) Nebulosidade.
- f* (*x*) Função de ativação utilizada pela Rede Neural Artificial que tipicamente é sigmóide padrão.
- (GP) Genetic Program.
- (*H_d*) Irradiação difusa (MJ m⁻²).
- (*H_B*) Irradiação direta (MJ m⁻²).
- (*H_G*) Irradiação solar global (MJ m⁻²).
- (*H_G^d*) Irradiação solar global em partição diária (MJ m⁻² dia⁻¹).
- (*H_G^m*) Irradiação solar global em partição mensal (MJ m⁻²).
- (*H_O*) Irradiação solar global no topo da atmosfera (MJ m⁻²).
- (*H_G/H_O*) Transmissividade atmosférica (adimensional).
- (*I_G*) Irradiância solar global (W m⁻²).
- (*I_O*) Irradiância solar global no topo da atmosfera (W m⁻²).
- (INMET) Instituto Nacional de Meteorologia.
- (*M*) Número de observações de dados.
- (MBE) Mean Bias Error.
- (MLP) Multilayer Perceptron.
- (MVS) Máquina Vetor de Suporte.

(n)	Brilho solar (h).
(N)	Fotoperíodo (h).
(n/N)	Razão de insolação (adimensional).
(OMM)	Organização Mundial de Meteorologia.
(PEG)	Programa de Expressão do Gene.
(PG)	Programa Genético.
(POA)	Profundidade Ótica dos Aerossóis.
(r)	Coefficiente de correlação.
(R ²)	Coefficiente de determinação.
(RBF)	Radial Basis Function.
(rMBE)	Relative Means Bias Error (%).
(RMSE)	Root Mean Square.
(rRMSE)	Relative Root Mean Square (%).
(Rede Neural Artificial)	(RNA).
(SINF)	Sistema de Inferência Neuro-Fuzzy.
(SMO _{reg})	Sequential Minimal Optimization.
(SVM)	Support Vector Machine.
(SVR)	Support Vector Regression.
(T)	Temperatura do ar (°C).
(UR)	Umidade Relativa (%).
(X_i)	Valores medidos.
(\bar{X})	Valores médios medidos.
(WEKA)	Waikato Environment for Knowledge Analysis.
(Y_i)	Representa os valores estimados.
(\bar{Y}_t)	São valores médios estimados.
(Z)	Ângulo zenital (°, graus).
($x_{i,j}$)	Primeira camada de entrada da RNA.
($w_{i,j}$)	Segunda camada que possui uma ou mais camadas ocultas de nós computacionais com pesos de ligações.
(y_i)	Terceira camada correspondente à saída de nós computacionais.
(ϵ)	Parâmetro de ajuste da MVS.

(γ)	Parâmetro de ajuste da MVS.
(δ)	Declinação solar ($^{\circ}$, graus).
(φ)	Latitude local ($^{\circ}$, graus).
(Γ)	Ângulo dia (rad).
(ω_s)	Ângulo horário solar ($^{\circ}$, graus).

ESTIMATIVA DA IRRADIAÇÃO SOLAR GLOBAL PELO MÉTODO DE ANGSTROM-PRESCOTT E TÉCNICAS DE APRENDIZADO DE MÁQUINAS.

Botucatu, 2016. 72p. Dissertação (Mestrado em Agronomia/Irrigação e Drenagem) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista.

Autor: MAURÍCIO BRUNO PRADO DA SILVA

Orientador: JOÃO FRANCISCO ESCOBEDO

1. RESUMO

No presente trabalho é descrito o estudo comparativo de métodos de estimativas da irradiação solar global (H_G) nas partições diária (H_G^d) e mensal (H_G^m): geradas pela técnica de Angstrom-Prescott (A-P) e duas técnicas de Aprendizado de Máquina (AM), Máquinas de Vetores de Suporte (MVS) e Redes Neurais Artificiais (RNA). A base de dados usada foi medida no período de 1996 a 2011, na Estação Solarimétrica em Botucatu. Por meio da regressão entre a transmissividade atmosférica (H_G/H_0) e razão de insolação (n/N), o modelo estatístico (A-P) foi determinado, obtendo equações lineares que permitem estimar H_G com elevados coeficientes de determinação. As técnicas, MVS e RNA, foram treinadas na mesma arquitetura de A-P (modelo 1). As técnicas MVS e RNA foram treinadas ainda em mais 3 modelos com acréscimos, uma a uma, das variáveis temperatura do ar, precipitação e umidade relativa (modelos 2, 3 e 4). Os modelos foram validados usando uma base de dados de dois anos, denominadas de típico e atípico, por meio de correlações entre os valores estimados e medidos, indicativos estatísticos r_{MBE} , MBE , r_{RMSE} , $RMSE$ e d de Willmott. Os indicativos estatísticos r das correlações mostraram que o modelo (A-P) pode estimar H_G com elevados coeficientes de determinação nas duas condições de validação. Já indicativos estatísticos r_{MBE} , MBE , r_{RMSE} , $RMSE$ e d de Willmott indicam que o modelo (A-P) pode ser utilizado na estimativa de H_G^d com exatidão e precisão. Os indicativos estatísticos obtidos pelos 4 modelos das técnicas MVS^d e RNA^d (diária) e MVS^m e RNA^m (mensal) podem ser utilizadas nas estimativas de H_G^d com elevadas correlações e com precisão e exatidão. Entre os modelos foram selecionadas por comparação entre os indicativo estatísticos as redes $MVS4^d$ e $RNA4^d$ (diária) e $MVS1^m$ e $RNA1^m$ (mensal). A comparação dos indicativos estatísticos r_{MBE} , MBE , r_{RMSE} , $RMSE$, d de Willmott, r e R^2 obtidos na validação entre os modelos (A-P), MVS e RNA mostrou que: a técnica MVS apresentou melhor resultado que o modelo estatístico de (A-P); esta técnica apresentou melhor

resultado que a RNA; o modelo estatístico (A-P), apresentou no geral melhor resultado que a RNA.

Palavras - chave: Radiação solar, Angstrom-Prescott e modelagem estatística.

ESTIMATION OF GLOBAL SOLAR IRRADIATION BY ANGSTROM-PRESCOTT METHOD AND MACHINE LEARNING TECHNIQUES.

Botucatu, 2016.72p. Dissertation (Master in Agronomy/Irrigation and Drainage) – Faculty of Agricultural Sciences, University of São Paulo State.

Author: MAURÍCIO BRUNO PRADO DA SILVA

Advisor: Ph. D. JOÃO FRANCISCO ESCOBEDO

2. ABSTRACT

In this paper describes the comparative study of different methods for estimating global solar irradiation (H_G) in the daily partitions (H_G^d) and monthly (H_G^m): generated by Angstrom-Prescott (AP) and two machine learning techniques (ML), Support Vector Machines (SVM) and Artificial Neural Networks (ANN). The used database was measured from 1996 to 2011, in Solarimetric station in Botucatu. Through regression between atmospheric transmissivity (H_G / H_0) and insolation ratio (n / N), the statistical model (A-P) was determined, obtaining linear equations that allow estimating H_G with high coefficients of determination. The techniques, svm and ANN, were trained on the same architecture of A-P (model 1). The SVM and ANN techniques were further trained on the most models with 3 additions, one by one, the variable air temperature, rainfall and relative humidity (model 2, 3 and 4). The models were validated using a database of two years, called of typical and atypical, with correlation between estimated and measured values, statistical indications: rMBE, MBE, rRMSE, RMSE, and d Willmott. The statistical indicative of correlations coefficient (r) showed that the model (A-P) can be estimated with high H_G determination coefficients in the two validation conditions. The rMBE, MBE, rRMSE, RMSE Willmott and d indicate that the model (A-P) can be used to estimate H_G^D with accuracy and precision. The statistical indicative obtained by the four models of technical SVM^d and ANN^d (daily) and SVM^m and ANN^m (monthly) can be used in the estimates of H_G^D with high correlations and with precision and accuracy. Among the models were selected by comparing the indicative statistical SVM4^d and ANN4^d networks (daily) and SVM1^m and ANN1^m (monthly). The comparison of statistical indicative rMBE, MBE, rRMSE, RMSE, d Willmott, r and R^2 obtained in the validation of the models (A-P), SVM and ANN showed that: the SVM technique showed better results than the statistical model (A-P); this technique showed better results than the ANN; the statistical model (A-P) showed overall better result than ANN.

Key words: Solar radiation; Angstrom-Prescott; Statistical Modeling.

3. INTRODUÇÃO

A radiação solar é a principal fonte de energia para a realização de todos os processos biológicos, físicos e químicos na superfície terrestre. Ao atravessar a atmosfera terrestre, a radiação solar é atenuada por absorção e espalhamento pelos constituintes atmosféricos: gases, vapor de água, nuvens, aerossóis entre outros. A radiação solar total que chega à superfície terrestre é a soma de duas componentes: irradiação difusa (H_d) e irradiação direta (H_B), é chamada de irradiação solar global (H_G). A H_G é de fundamental importância em estudos climáticos, na área de energias renováveis, em projetos de arquitetura e na agricultura (modelos computacionais de crescimento e produtividade de cultura agrícolas e estimativas de evapotranspiração) (SOUZA et al., 2005; ALMOROX et al., 2005; HENG et al., 2009; YANG et al., 2006; BOSCH et al., 2008).

O Brasil, assim como muitos países emergentes, e, devido as suas dimensões continentais, possui enorme escassez da disponibilidade de informações solarimétricas. Atualmente, existem um total de 532 estações automáticas distribuídas em todo território nacional brasileiro sob a responsabilidade do Instituto Nacional de Meteorologia (INMET) (SANTOS et al., 2014). Esse número é baixo, quando leva-se em consideração a extensão do território nacional e as diferentes regiões climáticas do país.

No intuito de suprir a falta de conhecimento de H_G , diversos pesquisadores desenvolvem modelos que permitem estimar valores de H_G por meio de variáveis mais facilmente monitorada nas estações meteorológicas. Em geral, esses modelos utilizados são divididos em classes como: estatísticos (modelos empíricos), físicos e por técnicas de Aprendizado de Máquina (AM) (HARGREAVES; SAMANI, 1982; BRISTOW; CAMPBELL, 1984; LIU et al., 2001; SILVA et al., 2012; ALMOROX et al., 2013; QUEJ et al., 2016). Devido a sua simplicidade e precisão os modelos estatísticos,

normalmente são recomendados para os locais em que os modelos são gerados ou para regiões de clima semelhante. Os modelos físicos (transferência radiativa) são mais complexos que os modelos estatísticos e exigem medidas com precisão de variáveis meteorológicas na superfície e na atmosfera. Os modelos gerados pelas técnicas de AM são capazes de solucionar problemas complexos, gerando estimativas de H_G com maior precisão, utilizando diferentes variáveis de entrada (KUMAR et al., 2015).

O principal modelo estatístico é o de Angstrom-Prescott (A-P), que estima H_G a partir do brilho solar (n). Outros dois modelos utilizados são os de Hargreaves e Samani (1982) e Bristow e Campbell (1984), que usam a temperatura do ar como variável de entrada. Há também outros modelos modificados por outros pesquisadores em diversas localidades que associam a temperatura do ar à outras variáveis de entrada como precipitação, altitude, entre outras (DONATELLI e CAMPBELL, 1998; HANSEN, 1999; HUNT et al., 1998; BECHINI, 2000; ANNANDELE et al., 2002; CHEN et al., 2004; PODESTÁ et al., 2004; WEISS, 2004; ALMOROX et al., 2011; BOJANOWSKI et al., 2013).

Recentemente a técnica de Aprendizado de Máquina (AM) tem ganhado destaque na geração de modelos em diversas áreas do conhecimento científico como: agronomia, economia, engenharia, fisiologia, matemática, meteorologia, neurologia e outros (ZANETTI et al., 2008; ALVAREZ, 2009; KUMAR et al., 2015). E também na geração de modelos de estimativa de H_G com resultados satisfatórios desde os estudos iniciais realizados por Elizondo et al. (1994) e outros posteriormente (BOCCO et al., 2006; LANDERAS et al., 2012; RAMEDANI et al., 2014a; RAMEDANI et al., 2014b; KUMAR et al., 2015; LYRA et al., 2015). Os resultados obtidos das estimativas de H_G , através dos modelos gerados pelo AM, têm sido comparados com os encontrados por modelos estatísticos, onde alguns autores têm relatado em seus trabalhos a superioridade da AM sobre os modelos estatísticos (TYMVIOS et al., 2005; CHEN et al., 2013; PIRI et al., 2015).

As técnicas de AM possuem capacidade computacional adquirida por meio de aprendizado e generalização. Tal habilidade permite, sem a necessidade de conhecer o objeto investigado, modelar um sistema conhecendo apenas os valores de entrada e saída. A maior vantagem do uso de modelos baseados em AM é a sua simplicidade, otimização do tempo e esforço computacional requeridos após a fase de treinamento (SOARES; SILVA, 2011). Entre as diferentes técnicas de AM destacam-se:

Máquina Vetor de Suporte (MVS), Programa Genético (PG), Programa de Expressão do Gene (PEG), Redes Neurais Artificiais (RNA), Sistema de Inferência Neuro-Fuzzy (SINF) e algumas versões híbridas dessas mesmas técnicas (MVS e SINF).

No presente trabalho, uma base de dados de irradiação solar global (H_G) do período de 16 anos (1996 a 2011), medido na estação solarimétrica em Botucatu, é utilizada para a obtenção e análise da equação de A-P e de modelos gerados por AM nas partições diária, mensal e sazonal. Foram utilizadas quatro diferentes arquiteturas combinando variáveis meteorológicas de entrada para MVS e RNA: o modelo 1 da MVS e RNA possuem arquitetura do modelo de A-P, ou seja, a razão de insolação (n) e H_0 como variáveis de entrada; e nos modelos seguintes 2, 3 e 4 foram acrescentadas outras variáveis uma a uma como temperatura do ar, precipitação e umidade relativa do ar. Os modelos foram validados por meio de correlação e indicadores estatísticos, por meio dos quais analisou-se e comparou-se o desempenho nas partições diária e mensal. Para a verificação dos resultados obtidos pelo modelo de A-P comparativos aos 4 modelos pela aplicação das técnicas MVS e RNA.

4. REVISÃO DE LITERATURA

4.1 Radiação solar: importância, medidas e modelagem

A radiação solar é principal fonte de energia na terra para os processos biológicos, físicos e químicos, tais como, derretimento da neve, fotossíntese das plantas, evapotranspiração e crescimento das culturas. Sendo também uma variável necessária para modelos biofísicos para avaliar o risco de incêndios florestais, modelos de simulações hidrológicas e modelos matemáticos de processos naturais (MESA; VARAS, 2000; CHEN et al, 2004; ITUEN et al., 2012; SABZIPAVAR et al., 2013; PARK et al., 2015).

Ao atravessar a atmosfera terrestre, a radiação solar é atenuada pelos processos de espalhamento (que ocorrem de duas maneiras distintas e são denominadas espalhamentos de Rayleigh e Mie) e absorção (que normalmente resulta no aquecimento do ar ou na fotodissociação de moléculas) (VIANELLO; ALVES, 2012). Ressalta-se que, o espalhamento da radiação solar pela atmosfera é uma função contínua do comprimento de onda e a absorção é seletiva, onde o vapor d'água (espectro infravermelho) e o ozônio (espectro ultravioleta) são dois dos principais absorvedores da radiação solar. O ozônio absorve a radiação principalmente na estratosfera e o vapor d'água na troposfera (ROBINSON, 1966; VIANELLO; ALVES, 2012). Aproximadamente 51% do total da radiação solar que incidem no topo da atmosfera chegam à superfície terrestre (OMETTO, 1981).

Em decorrência dos efeitos de espalhamento e absorção, por parte dos constituintes atmosféricos, que interferem na disponibilidade total energética da radiação solar que chega à superfície terrestre, duas denominações são dadas às componentes da radiação solar: radiação direta (atinge diretamente a superfície terrestre e

chega num ângulo sólido correspondente ao disco solar, quando visto da Terra) e radiação difusa (chega à superfície devido ao espalhamento da radiação solar pelos constituintes atmosféricos, moléculas, nuvens, aerossóis, entre outros). A Irradiância solar global (I_G) é a energia [joule (J) por unidade de tempo (s) e por unidade de área (m^2) ou ($W m^{-2}$)] total que atinge a superfície da terra instantaneamente (Equação 1).

$$I_G = I_B \cdot \cos Z + I_d \quad (1)$$

Onde I_G é a irradiância solar global, I_B é a irradiação solar global direta, Z é o ângulo zenital ($^\circ$, graus); I_d é a irradiância solar global difusa. I_G é a resultante da contabilização de duas componentes: (I_B) e (I_d).

4.2 Modelo de Angstrom-Prescott (A-P)

O modelo linear de Angstrom-Prescott (A-P) relaciona a transmissividade atmosférica (H_G/H_0) com a razão de insolação (n/N) e é comumente utilizado na estimativa de H_G por ser considerado simples e prático (Equação 2). Esse modelo foi inicialmente proposto por Angstrom (1924) e ajustado por Prescott em 1940.

$$(H_G/H_0) = a + b(n/N) \quad (2)$$

Esse modelo tem como variáveis de entrada: o brilho solar, medido através do heliógrafo (n , hora); irradiação solar global no topo da atmosfera (H_0 , $MJ m^{-2}$), fotoperíodo (N , hora); coeficiente a , correspondente ao valor da transmissividade mínima atmosférica, geralmente alcançado em dias completamente nublados, ajustado a uma determinada localidade; coeficiente b , parâmetro complementar do modelo de A-P que, em dias considerados de céu aberto, pode expressar, junto com o coeficiente a , a transmissividade máxima atmosférica ($a+b$) (MARTINEZ-LOZANO et al. 1984; HINRICHSEN, 1994). Os coeficientes a e b do modelo de A-P são dependentes, sobretudo, do tipo e espessura das nuvens, das características da transmitância atmosférica que são influenciadas pelo conteúdo de vapor d'água (ALMOROX et al., 2008; MANZANO et al., 2015), da latitude, longitude, concentração de aerossóis. O modelo de A-P é suscetível a ajustes locais, com isso pode ser utilizado em qualquer localidade, desde

que haja as devidas calibrações de seus coeficientes. A tabela 1 mostra resultados de trabalhos de Angstrom-Prescott em outros locais. No Brasil, destaca-se o trabalho precursor de Mota et al. (1977), que abrange o território nacional brasileiro.

Tabela 1. Coeficientes de Angstrom-Prescott (A-P) obtidos por diferentes autores em várias localidades do globo terrestre.

Autores	Localidades (N°)	Coeficiente de A-P ^d			R ²
		<i>a</i>	<i>b</i>	<i>a+b</i>	
Mota et al. (1977)	55 (Brasil)	0,17 - 0,31	0,41 - 0,57	0,71 - 0,74	*
Nguyen e Pryor (1996)	12 (Vietnã)	0,15 - 0,26	0,36 - 0,66	0,62 - 0,81	*
Iziomon e Mayer (2001)	2 (Alemanha)	0,19 - 0,20	0,59 - 0,60	0,79 - 0,79	*
Tiba (2001)	34 (Nordeste/Brasil)	0,220 - 0,350	0,310 - 0,580	0,580 - 0,840	0,710 - 0,980
El-Metwally (2005)	6 (Egito)	0,15 - 0,20	0,52 - 0,64	0,72 - 0,79	*
Almorox et al. (2008)	11 (Venezuela)	0,26 - 0,34	0,22 - 0,35	0,51 - 0,69	*
Lam et al. (2008)	40 (China)	0,14 - 0,30	0,47 - 0,64	0,66 - 0,84	0,69 - 0,90
Liu et al. (2009)	31 (China)	0,11 - 0,29	0,50 - 0,69	0,67 - 0,86	0,61 - 0,89
Li et al. (2011)	4 (China)	0,19 - 0,30	0,54 - 0,69	0,84 - 0,92	*
Li et al. (2012)	15 (China)	0,12 - 0,29	0,52 - 0,62	0,65 - 0,83	0,73 - 0,88
Sabzipavar (2013)	15 (Irã)	0,16 - 0,30	0,42 - 0,70	0,68 - 0,86	*
Cotfas et al. (2014)	Brasov (Romênia)	0,16	0,53	0,69	0,98
Quansah et al. (2014)	Kumasi (Gana)	0,22	0,43	0,65	*
Manzano et al. (2015)	25 (Espanha)	0,23 - 0,30	0,44 - 0,56	0,74 - 0,79	0,80 - 0,92
Onyango e Ongoma (2015)	Nairobi (Quênia)	0,18	0,71	0,89	*
Park et al. (2015)	22 (Coréia do Sul)	0,17 - 0,21	0,50 - 0,62	0,69 - 0,80	0,72 - 0,97
Souza e Andrews (2015)	Trinidad e Tobago	0,21	0,38	0,59	*
Souza et al. (2016)	3 (Alagoas/Brasil)	0,24 - 0,34	0,38 - 0,48	0,72 - 0,73	*

Posteriormente à divulgação do modelo de A-P, diversas modificações foram realizadas com o intuito de ajustar as estimativas de H_G . Assim, diversos autores investigaram e publicaram estudos sobre o aumento nos graus do polinômio (AMPRATWUM; DORVLO, 1999; ERTEKIN; YALDIZ, 2000; MANZANO et al., 2015; SOUZA et al., 2016), acréscimo de algumas variáveis meteorológicas ou até mesmo a incorporação de dados de aerossóis medidos para ajuste do modelo (PODESTÁ et al., 2004; ZHAO et al., 2013). Embora, Iziomon e Mayer (2001) destaquem que as modificações realizadas no modelo de A-P não cheguem a resultar em melhorias muito significativas na estimativa de H_G . Assim, verifica-se que o modelo linear de A-P pode ser perfeitamente utilizado mundialmente (ELAGIB et al., 1999; CARVALHO et al., 2011;

ANDRADE JÚNIOR et al., 2012; LI et al., 2012; SABZIPARVAR et al., 2013; PARK et al., 2015; BELÚCIO et al., 2014; MANZANO et al., 2015; SOUZA et al., 2016).

Os modelos modificados de A-P podem, atualmente, ser classificados por: lineares (com seus respectivos coeficientes empíricos *a* e *b* obtidos mediante interpolação linear), polinomiais (mediante acréscimo da ordem polinomial da equação), angulares (modelos modificados de A-P) e os especiais (modelos exponenciais, logarítmicos, entre outros). Na revisão de literatura elaborada por Martinez-Lozano (1984), são destacados alguns trabalhos como os de Black et al. (1954) e Glover e MacCulloch (1958), que investigaram a variação dos coeficientes *a* e *b* através da latitude. Aumento nos graus dos polinômios em relação à razão de insolação (n/N) no modelo de A-P podem se encontrados em alguns trabalhos dispostos na literatura (ERTEKIN; YALDIZ, 2000; BAKIRCI, 2009b; MANZANO et al., 2015). Diferentes maneiras do modelo de A-P se apresentar, em virtude de suas modificações, são classificados da seguinte maneira: lineares (com seus respectivos coeficientes empíricos *a* e *b* obtidos mediante interpolação linear), polinomiais (mediante acréscimo do acréscimo da ordem polinomial da equação), angulares (modelos modificados de A-P tais como o desenvolvido por Glover e McCulloch (1958) e os modelos especiais (exponenciais, logarítmicos e não lineares) [BAKIRCI, 2009b].

4.3 Aprendizado de Máquina (AM)

As técnicas de Aprendizado de Máquina (AM) empregam um princípio de inferência denominado de indução. Em que as conclusões gerais são obtidas a partir de um determinado conjunto de exemplos. A aprendizagem supervisionada é uma das principais abordagens da indução (LORENA et al., 2011). Nesta abordagem o conhecimento sobre o problema que está sendo modelado é apresentado por conjuntos de dados composto por pares: dados de entrada e saída (MITCHELL, 1997). O algoritmo reconhece o padrão dos dados de entrada, para que produzam resultados coerentes para os de saída (LORENA et al., 2011).

Dentre as diferentes técnicas empregadas atualmente na modelagem estatística, destacam-se as: Máquina Vetor de Suporte (MVS), Programa Genético (PG), Programa de Expressão do Gene (PEG), Redes Neurais Artificiais (RNA),

Sistema de Inferência Neuro-Fuzzy (SINF), entre outras. Além de algumas versões híbridas dessas mesmas técnicas (MVS e SINF).

4.3.1 Máquina Vetor de Suporte (MVS)

Máquina Vetor de Suporte (MVS) é uma técnica derivada da teoria de aprendizagem estatística e foi primeiramente introduzida por Vapnik em 1995 (TABARI et al., 2012). A MVS é baseada no princípio da minimização do risco estrutural, que tenta minimizar um limite superior de erro de generalização em vez de minimizar o erro de treinamento local (CHEN et al., 2015). A MSV é amplamente utilizada em problemas de classificação e regressão. O princípio fundamental da MVS é fazer a correlação por meio do mapeamento não-linear dos conjuntos de dados de entradas para um espaço de alta dimensão, usando um conjunto de funções de *Kernel* (VAPNIK, 1995; VAPNIK, 1998; CHEN et al., 2011).

A MVS é robusta diante de dados de grande dimensão e superior a outras técnicas. Em virtude de haver a convexidade o problema da otimização formulado em seu treinamento, que implica na existência de um único mínimo global (SHRESTHA; SHUKLA, 2015). Assim, isso se torna uma grande vantagem da MVS, por exemplo, sobre a RNA do tipo *Multilayer Perceptron (MLP)*, em que há mínimos locais na função objetivo minimizada (BRAGA; LUDERMIR, 2007; LORENA et al, 2011).

Na literatura há diversos exemplos de aplicações da MVS em diferentes áreas de investigação, tais como: modelagem da evapotranspiração de referência e de cultura (KISI; ÇIMEN, 2009; TABARI et al., 2012; SHRESTHA; SHUKLA, 2015); previsão dos níveis de concentração de ozônio troposférico (FENG et al., 2011; LUNA et al., 2014); qualidade do papel utilizando eucalipto (GARCÍA NIETO et al., 2012); investigação da proliferação de algas em água doce (LOU et al., 2015); avaliação do tempo de sono de bezerros em sistemas de produção de gado (HOKKANEN et al., 2011); previsões diárias e mensais de vazões em reservatórios nos Estados Unidos (LIU et al., 2014); modelagem da distribuição potencial de espécies através de condições bióticas e abióticas onde o conhecimento das espécies pode ocorrer (LORENA et al., 2011); teste com sucesso de modelos gerados com dados de entrada de temperatura do ar para modelar H_G (CHEN et al., 2011). Assim, a utilização desta técnica ainda é considerada recente em estudos relacionados à modelagem solar. Como consequência disso, escassos são as

publicações utilizando esta técnica no Brasil e, especificamente, na região Sudeste do Brasil.

4.3.2 Rede Neural Artificial (RNA)

O conceito iniciais de redes neurais foi estudado em 1943 McCulloch e Pitts (1943), mas somente agora nos últimos 20 anos que aplicações com softwares de aplicação têm sido desenvolvidos para lidar com problemas práticos (KUMAR et al., 2015). Rede Neural Artificial (RNA) são sistemas paralelos distribuídos, compostos de unidades simples de processamento, que calculam determinadas funções matemáticas e consistem num grupo interconectado de neurônios artificiais (HAYKIN, 1998; ZANETTI et al., 2008). A RNA é capaz de realizar análise preditiva de dados, armazenando o conhecimento e solucionando problemas de complexa relação não-linear entre os dados de entrada e saída (BEHRANG et al., 2010; MARTÍ; GASQUE, 2011). São estruturadas em três camadas distintas: camada de entrada que apresenta os dados selecionados para o modelo, uma ou mais camadas ocultas que processam os dados e a camada de saída que produz os resultados (LORENA et al., 2011). Entre os diferentes tipos de RNA existente, destaca-se a do tipo *Multilayer Perceptron* (MLP).

A RNA é usada com sucesso na resolução de problemas complexos que incluem o reconhecimento de padrões, identificação, classificação e regressão (HASNI et al., 2012). Sua estrutural não-linear consegue captar características mais complexas dos dados, o que nem sempre é possível com a utilização das técnicas estatísticas tradicionais (ZANETTI et al., 2008).

A RNA têm sido aplicadas com sucesso na modelagem de relações envolvendo séries temporais complexas em várias áreas do conhecimento. Entre essas aplicações, são exemplificadas algumas situações: evapotranspiração (ZANETTI et al., 2008; HUO et al., 2012; DEO; SAHIM, 2015); previsão de safras de importantes culturas agrícolas (KAUL et al., 2005; ALVAREZ, 2009; KHOSHNEVISAN et al., 2013; EMAMGHLIZADEH et al., 2015); geoestatística (DAI et al., 2014); engenharia de pesca (YU et al., 2006); radiação solar (H_G) (ELIZONDO et al., 1994; SOARES et al., 2004; BOCCO et al., 2006; BOSCH et al., 2008; FORTIN et al., 2008; LANDERAS et al., 2012; WAEWASAK et al., 2014; LYRA et al., 2015).

5. MATERIAL E MÉTODOS

5.1 Área de estudo e informações climáticas

O município de Botucatu ($22,85^{\circ}$ S; $48,43^{\circ}$ W) está localizado na região Centro-Sul do Estado de São Paulo, possui grande gradiente de altitude, entre 400 a 500 m na região mais baixa (depressão periférica) e entre 700 a 900 na região serrana (Planalto Ocidental), esta diferença provoca variações na temperatura do ar. O clima local é classificado como Cwa (CEPAGRI, 2012), temperado quente (mesotérmico), o verão é quente e úmido e o inverno é seco. A Figura 1 (a, b, c, d) mostra as séries climáticas da temperatura, umidade relativa, precipitação e nebulosidade, do período de 1970 a 2008 em Botucatu.

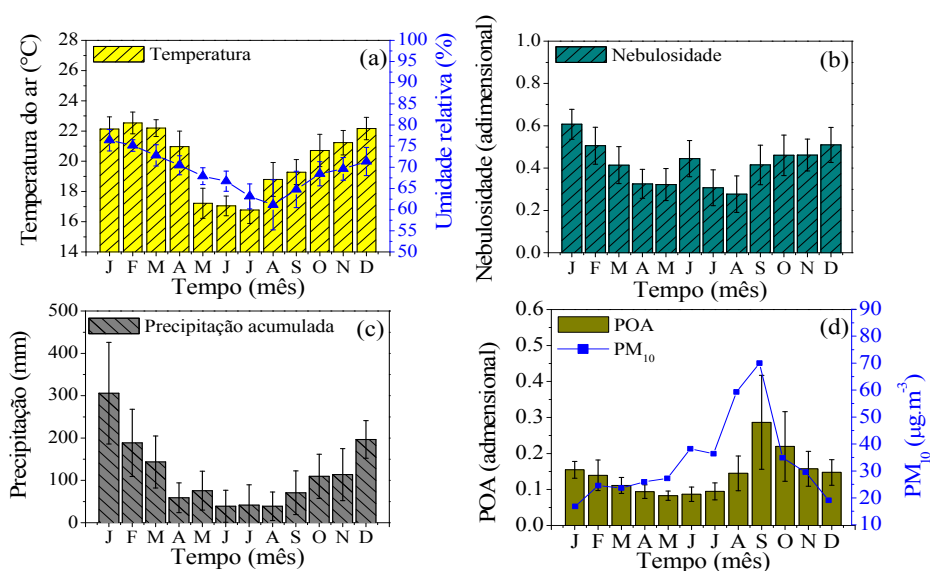


Figura 1. Séries Climáticas (período: 1970-2008) da Temperatura e Umidade Relativa (a), Nebulosidade (b), Precipitação (c), Relação entre a evolução anual da Profundidade Ótica dos Aerossóis (POA) médias mensais (obtidas do satélite TERRA) no ano de 2001 a 2005.

A evolução anual da temperatura e umidade relativa (Figura 1 a) mostra que fevereiro é o mês mais quente e julho é o mais frio do ano, com temperaturas médias de 22,5°C e 16,8°C, respectivamente. Os meses de janeiro e agosto são mais e o menos úmidos, com percentuais de 76,5% e 61,20% respectivamente.

A nebulosidade (f), calculada pela expressão $f = 1 - (n/N)$, expressa a fração do número de horas em que o sol fica encoberto por nuvens no dia, onde (n/N) é a razão de insolação, n é o número de horas de brilho solar (em horas) e N é o fotoperíodo (em horas). A nebulosidade (Figura 1 b) é mais elevada nos meses de janeiro ($f = 0,61$) e menor em agosto ($f = 0,28$). Por outro lado, os meses de maior e menor número de horas de brilho solar ocorrem em agosto e fevereiro com totais de 229 h e 175,28 h, respectivamente.

A evolução anual da precipitação (Figura 1 c) segue a evolução da nebulosidade, e é constituído de dois períodos distintos: chuvoso e seco, onde o limite entre os períodos é o valor da precipitação de 100 mm, aproximadamente. No período chuvoso, de outubro a março (primavera e verão), a precipitação é de natureza microclimática originada do processo de convecção livre e macro-climáticas originadas dos eventos meteorológicos como a Zona de Convergência do Atlântico Sul (ZCAS) e Sistemas Frontais do Atlântico Sul. O ZCAS atua desde a Bacia Amazônica até o oceano Atlântico Sul, como resultado da convergência de massas de ar quente e úmido oriundas da Bacia Amazônica e do oceano Atlântico Sul. O ZCAS gera aumento da nebulosidade e ocorrência de chuvas intensas e persistentes entre a primavera e verão (CARVALHO et al., 2004). A frequência de ocorrência é de duas a quatro vezes ao ano, com duração média de 8 dias e de intensidade variável (NOGUÉS-PAEGLE; MO, 1997). A maior precipitação ocorre no mês de janeiro com total de 304 mm e a menor em junho e agosto com 38,8 mm. No período seco, de abril a setembro (outono e inverno), a precipitação é do tipo frontal originada do encontro das massas frias e secas vindas da Região Sul com as massas quentes e úmidas, da Região Sudeste. A distribuição da chuva frontal gera aumento na nebulosidade com ocorrência de chuvas generalizadas na região. A intensidade da precipitação é fraca a moderada, dependendo do tipo de frente fria, e a duração é de média a longa (horas ou dias), dependendo da velocidade de deslocamento da frente. (SATYAMURTY et al., 1998). Para Lemos e Calbete (1996), ocorrem em média 5 eventos

de sistemas frontais por mês no Estado de São Paulo. A menor precipitação no período seco ocorre em agosto com 38,2 mm.

Ainda nos meses de seca, de junho à novembro, a atmosfera local apresenta elevada concentração de materiais particulados provenientes das queimadas da cana de açúcar no local, e queimadas e/ou incêndios de outras regiões do Brasil (TERAMOTO 2013). A evolução anual das médias mensais da POA (profundidade ótica de aerossóis) obtidas pelo satélite TERRA, do período de 2000 a 2005, mostra que no início das queimadas da cana de açúcar em julho, a concentração de aerossóis mensal aumenta consideravelmente em setembro e outubro, passando por um valor máximo de $POA = 0,45$ em setembro, o que é equivalente à concentração PM_{10} de $70.0 \mu g.m^{-3}$ (Figura 1 d) (CODATO et al., 2008).

5.2 Instrumentação e medidas

Os dados de irradiação solar global utilizados neste trabalho foram obtidos da estação de radiometria solar medidas no período 1996-2011 na unidade da Faculdade de Ciências Agrárias (FCA) da Universidade Estadual Paulista (UNESP). As medidas de irradiância solar global (I_G , $W m^{-2}$), foram monitoradas por um piranômetro Eppley PSP com erro 4,1% (REDA et al., 2008); brilho solar (n , horas), obtido por um heliógrafo *Campbell-Stokes*; precipitação (P , mm) medidos através de um pluviógrafo da marca *Ota Keiki Seisakusho*; temperaturas máxima e mínima (T , °C) medidos por termômetro de bulbo de mercúrio e álcool; e umidade relativa do ar (% , UR) medidos através de um higrômetro (seguindo as recomendações sugeridas pela Organização Mundial de Meteorologia - OMM). A irradiação solar global no topo da atmosfera (H_0 , $MJ m^{-2}$), Equação 3 (IQBAL, 1983), foi obtida como função do fator de correção da excentricidade da órbita terrestre (E_0), Equação 4; ângulo horário solar (ω_s , °), Equação 5; declinação solar (δ , °), Equação 6; latitude local (φ , °); dia Juliano (DJ); ângulo dia (Γ , rad), Equação 7; fotoperíodo (N), Equação 8.

$$H_0 = 1367 (24/\pi) E_0 [(\pi/180) \omega_s \text{sen}(\varphi) \text{sen}(\delta) + \cos(\varphi) \cos(\delta) \text{sem}(\omega_s)] \quad (3)$$

$$E_0 = 1,000 + 0,034 \cos \Gamma + 0,0013 \text{sen}(\Gamma) + 0,000719 \cos 2 \Gamma + 0,000077 \cos 2 \Gamma \quad (4)$$

$$\omega_s = \cos^{-1}[-\text{tg}(\phi) \cdot \text{tg}(\delta)] \quad (5)$$

$$\delta = 23,45 \text{ sen} [(360/365)(\text{DJ} + 284)] \quad (6)$$

$$\Gamma: 2\pi(\text{DJ} - 1)/366 \quad (7)$$

$$N = (2\omega_s/15) \quad (8)$$

Para aquisição dos dados de H_G da estação radiométrica foi utilizado um datalogger CR 23X da Campbell Scientific operando na frequência de 1 Hz e armazenando médias a cada 5 minutos. Estes dados passaram por um rigoroso controle de qualidade (para eliminação de valores errôneos ou inconsistentes) através de programas desenvolvidos na plataforma “Microcal™ Origin 6.0®” para cálculo das irradiações (MICROCAL SOFTWARE, INC., 1999; CHAVES; ESCOBEDO, 2000), que, posteriormente, foram integrados na hora, dia e mês.

5.3 Geração de modelos de estimativa de H_G com as técnicas de Aprendizado de Máquina (AM): MVS e RNA

A Figura 2 (a, b) mostra a correlação entre a transmissividade atmosférica da irradiação solar global (H_G/H_0) com a razão de insolação (n/N), diária e mensal, para a base de dados medida no período de 1996-2011 em, Botucatu, SP, as quais serviram para a obtenção do modelo estatístico de A-P para estimativas de (H_G/H_0) em função de (n/N), diária e mensal, bem como para o treinamento das redes MVS1 e RNA1, respectivamente.

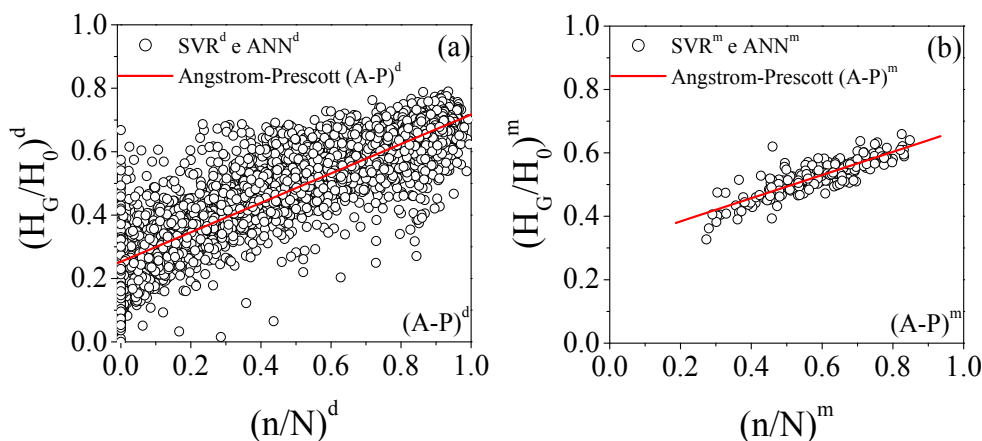


Figura 2. Correlação entre a transmissividade atmosférica da irradiação global (H_G/H_0) com a razão de insolação (n/N) diária e mensal, usadas para treinamento das técnicas: MVS1 e RNA1.

Na Tabela 2 é apresentada a arquitetura dos modelos gerados com as variáveis meteorológicas utilizadas como entrada em cada um dos modelos desenvolvidos pelas técnicas de AM:

Modelo 1 - irradiação solar global no topo da atmosfera - H_0 ($\text{MJ m}^{-2} \text{ dia}^{-1}$); razão de insolação - n/N (adimensional);

Modelo 2- irradiação solar global no topo da atmosfera - H_0 ($\text{MJ m}^{-2} \text{ dia}^{-1}$); razão de insolação - n/N (adimensional); temperaturas - T ($^{\circ}\text{C}$) [máx e mín];

Modelo 3- irradiação solar global no topo da atmosfera - H_0 ($\text{MJ m}^{-2} \text{ dia}^{-1}$); razão de insolação - n/N (adimensional) e precipitação- P (mm);

Modelo 4 - irradiação solar global no topo da atmosfera - H_0 ($\text{MJ m}^{-2} \text{ dia}^{-1}$); razão de insolação - n/N (adimensional) e precipitação- P (mm) e umidade relativa do ar - UR (%).

Tabela 2. Arquitetura dos Modelos gerados pelas técnicas Máquina Vetor de Suporte (MVS) e Redes Neurais Artificiais (RNA) com diferentes variáveis meteorológicas de entrada.

Modelos		Variáveis meteorológicas de entrada
SVR-RBF	ANN-MLP	
MVS1	RNA1	$H_0, n/N$
MVS2	RNA2	$H_0, T_{\text{máx}}, T_{\text{mín}}, n/N$
MVS3	RNA3	$H_0, T_{\text{máx}}, T_{\text{mín}}, P, n/N$
MVS4	RNA4	$H_0, UR, T_{\text{máx}}, T_{\text{mín}}, P, n/N$

5.3.1 Aplicação da Máquina Vetor de Suporte (MVS)

A MVS é uma técnica interessante pela precisão na estimativa. Existem diferentes algoritmos de aprendizado de máquinas (AM), neste trabalho o *Sequential Minimal Optimization* (SMO_{reg}) é utilizado para regressão. SMO_{reg} é um algoritmo simples que rapidamente soluciona e resolve o problema de menor otimização possível com dois multiplicadores de Lagrange (PLATT, 1998; SMOLA; SCHÖLKOPF, 1998; SHEVADE et al., 2000).

A flexibilidade do SMO na regressão é atribuída ao uso do conjunto de funções de *Kernel*. A escolha adequada da função de *Kernel* é determinante para os dados modelados e são essencialmente funções de similaridade com determinadas propriedades matemáticas. Pela eficiência computacional, simplicidade e adaptação para otimização de problemas mais complexos, neste estudo a *Radial Basis Function* (RBF) de *Kernel* é utilizada para regressão. A RBF é utilizada e recomendada pela simplicidade, quando comparada, por exemplo, com a função polinomial (DONG et al., 2005).

Na aplicação da RBF é necessário ajustar adequadamente os parâmetros C (custo), γ (gamma) e ϵ (épsilon). Os parâmetros C e γ são mutuamente dependentes entre si, baixos valores de C produzem um aprendizado de máquina com má aproximação e, valores muito altos, geram um aprendizado de máquina mais complexo (RAGHAVENDRA; DEKA, 2014). Os valores de C e γ são testados e aqueles com a melhor precisão na validação-cruzada são escolhidos. Os modelos gerados com o algoritmo SMO foram com base na função de radial basis function (RBF). Foram testados empiricamente diferentes combinações para os parâmetros da RBF, depois de inúmeros testes os parâmetros utilizados da RBF foram ($C = 100$, $\gamma = 0,3$ e $\epsilon = 0,001$), valores encontrados na literatura (MOHAMMADI et al., 2015a; RAMEDANI et al., 2014a; RAMEDANI et al., 2014b).

5.3.2 Aplicação da Rede Neural Artificial (RNA)

A RNA utilizada foi a *Multilayer perceptron* (MLP). Essa rede é amplamente utilizada em modelagem para resolução de problemas complexos e consiste de um conjunto de unidades sensoriais (nós de fonte) com três ou mais camadas interligadas. Na Figura 3 é demonstrada a estrutura de uma MLP, onde a primeira camada

é a entrada ($x_{i,j}$), a segunda possui uma ou mais camadas ocultas de nós computacionais com pesos de ligações ($w_{i,j}$) e a terceira camada corresponde à saída de nós computacionais (y_i), (BOSCH et al., 2008; ZANETTI et al., 2008; LYRA et al., 2015).

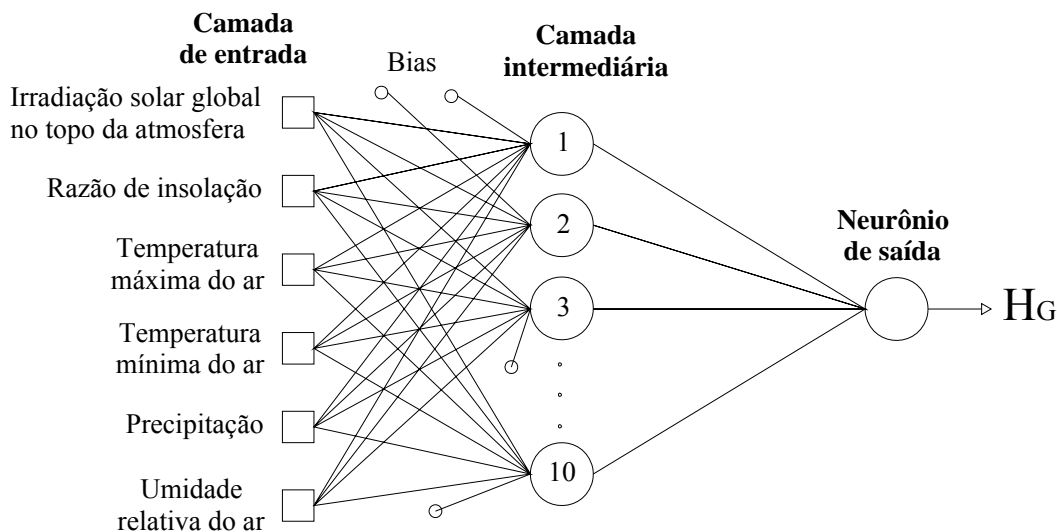


Figura 3. Diagrama em blocos demonstrando a arquitetura da RNA utilizada (RNA).

Adaptado de Haykin (1998) e Zanetti et al. (2008).

A saída da rede (y_i) pode ser modelada conforme (LAM et al., 2008), equação 9:

$$y_i = \sum_{j=1}^n w_{i,j} x_{i,j} + \theta_i \quad (9)$$

Onde $x_{i,j}$ é o sinal de entrada a partir de neurônios de ordem j (para a camada de entrada), $w_{i,j}$ é o peso da ligação direta do neurônio j para neurônio i (na camada oculta) e θ_i é a bias do neurônio i . Na MLP o sinal de entrada se propaga para frente através da rede, camada por camada. Dentro de cada camada há vários neurônios (nós), que estão ligados aos nodos na camada adjacente com pesos diferentes. Cada entrada é multiplicada por um peso de ligação. Após o treinamento os pesos terão informações importantes, antes eles são aleatórios e não têm nenhum significado. A saída dos neurônios é calculada pela aplicação de uma função de ativação, Equação 10, que é tipicamente sigmóide padrão (REHMAN; MOHANDÉS, 2008).

$$f(x) = \frac{1}{(1+\exp(-x))} \quad (10)$$

Existem muitos algoritmos de aprendizado específicos para determinado modelos de redes neurais. Neste trabalho a MLP foi treinada usando o algoritmo de aprendizagem *backpropagation*. Este algoritmo baseia-se na regra de aprendizagem por correção de erros e consiste em duas passagens pelas diferentes camadas das redes: um passe para frente, a propagação e um passe para trás, a retropropagação. No passo para frente, um padrão de atividade é aplicado aos nós sensoriais da rede e os seus efeitos se propagam através da rede camada por camada (RUMELHART et al., 1986).

5.3.3 Software utilizado

A MVS e a RNA foram avaliadas através da WEKA (*Waikato Environment for Knowledge Analysis*), que consiste num conjunto de algoritmos de AM, disponível em <http://www.cs.waikato.ac.nz/~ml/weka/>. A WEKA contém ferramentas para pré-processamento de dados, classificação, regressão, clustering, regras de associação e visualização (WITTEN et al., 2011). Nos modelos de RNA foram considerados os valores: taxa de aprendizado = 0,3; momentum = 0,2 e numero de interações = 500. As camadas ocultas (*hiddenlayers*) foram testadas variando de 1 – 10, porém o valor padrão do WEKA foi adotado pelo melhor ajuste encontrado. Na WEKA o padrão das camadas ocultas é definido como “a” = [(variáveis de entrada + classes)/2]. As técnicas de AM foram propostas para estimar a irradiação solar global (H_G). Os modelos gerados com estas duas técnicas foram comparados entre si.

5.4 Análise sazonal do modelo de A-P

Para análise sazonal da equação de estimativas anual de A-P, em relação às sazonais obtidas, calculou-se Desvio Linear percentual (DL, %), por meio da Equação (11), entre os valores de $(H_G/H_O)_a^d$, da equação anual (a_a), e das equações sazonais em função da razão de insolação $(n/N)^d$, variando de 0 a 1, em intervalos crescentes com escala de 0 a 1. DL (%) expressa a capacidade de $(H_G/H_O)_a^d$ anual de superestimar ou subestimar $(H_G/H_O)_s^d$ sazonal.

$$DL (\%) = 100[H_G/H_O)_a^d - (H_G/H_O)_s^d] / (H_G/H_O)_a^d \quad (11)$$

5.5 Validação e avaliação dos modelos

Na validação dos modelos estatísticos gerados neste trabalho foi utilizada uma base dados de 2 anos, denominadas de ano típico e atípico, a partir da base de dados total de 16 anos. A seleção dos anos típico e atípico, foi efetuada através de análises estatísticas onde se comparou o valor da irradiação solar global (H_G) média inter-anos com desvio padrão de cada mês e o valor da irradiação média de cada mês por ano. Exemplo de aplicação desta metodologia pode ser verificada na Figura 4, onde a linha horizontal com os alteres representa a irradiação media inter-anos com desvio padrão e as colunas representa a irradiação média de cada ano.

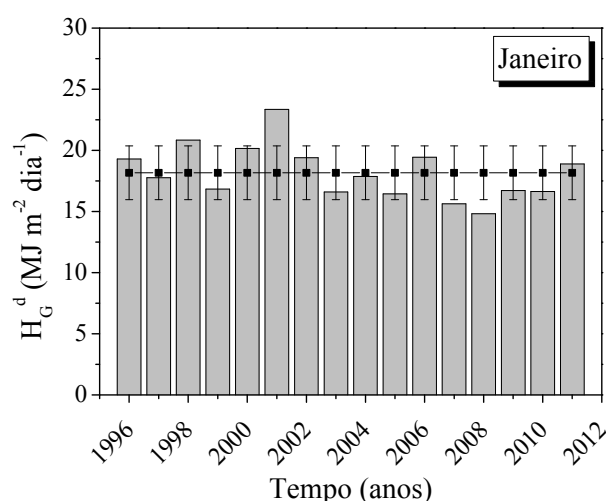


Figura 4. Comparação do valor da irradiação solar global (H_G^d) média inter-anos com desvio padrão e o valor da irradiação média do ano, para o mês de janeiro da série.

O critério de seleção do ano típico é semelhante ao processo de seleção do Ano Meteorológico Típico divulgado pela Organização Mundial de Meteorologia (OMM) em 1981. Para o mês de janeiro, o ano típico foi 2004, enquanto que 2001 foi atípico. Os resultados encontrados para os demais meses estão representados na Tabela 3, a qual mostra a constituição mensal dos anos típico e atípico do banco de dados total de 16 anos.

Tabela 3. Ano típico e atípico obtido do banco de dados de 16 anos.

		Meses											
Meses		Jan.	Fev.	Mar.	Abr.	Mai.	Jun.	Jul.	Ago.	Set.	Out.	Nov.	Dez.
Ano	Típico	2004	2000	2008	2005	2005	2005	2002	2003	2000	2003	2003	2005
	Atípico	2001	2005	2011	2008	2003	1997	2009	1998	2009	2001	1998	2011

Os indicativos estatísticos *Mean Bias Error (MBE)*, *Relative Mean Bias Error (rMBE)*, *Root Mean Square Error (RMSE)*, *Relative Root Mean Square Error (rRMSE)*, *Relative Root Mean Square Error (rRMSE)*, Coeficiente de correlação (r), Coeficiente de determinação (R^2), e o Índice de Concordância de Willmont (d), desenvolvido por esse autor em 1981, foram utilizados para a avaliação da performance dos modelos gerados:

$$MBE = \frac{\sum_{i=1}^M (Y_i - X_i)}{M} \quad (12)$$

$$rMBE (\%) = 100 \cdot \frac{\left(\frac{\sum_{i=1}^M (Y_i - X_i)}{M} \right)}{\bar{X}} \quad (13)$$

$$RMSE = \left[\frac{\sum_{i=1}^M (Y_i - X_i)^2}{M} \right]^{\frac{1}{2}} \quad (14)$$

$$rRMSE (\%) = 100 \cdot \left[\frac{\sum_{i=1}^M (Y_i - X_i)^2}{\bar{X}} \right]^{\frac{1}{2}} \quad (15)$$

$$r = \frac{\sum_{i=1}^M (Y_i - \bar{Y}_i)(X_i - \bar{X}_i)}{\sqrt{\sum_{i=1}^M (Y_i - \bar{Y}_i) \sum_{i=1}^M (X_i - \bar{X}_i)}} \quad (16)$$

$$R^2 = \frac{[\sum_{i=1}^M (Y_i - \bar{Y}_i)(X_i - \bar{X}_i)]^2}{\sum_{i=1}^M (Y_i - \bar{Y}_i) \sum_{i=1}^M (X_i - \bar{X}_i)} \quad (17)$$

$$d = 1 - \frac{\sum_{i=1}^M (Y_i - X_i)^2}{\sum_{i=1}^M (|Y_i - \bar{X}| + |X_i - \bar{X}|)} \quad (18)$$

Onde: Y_i representa os valores estimados, \bar{Y}_i são os valores médios estimados, X_i são os valores medidos, \bar{X} são os valores médios medidos e M é o número de observações.

Na utilização desses índices estatísticos, a unidade da variável de saída é a mesma da variável testada (H_G , MJ m⁻²) ou pode ser a porcentagem (%). Estes índices estatísticos permitem fazer algumas avaliações como: subestimativa ou superestimativa no ajustamento dos modelos. Além de espalhamento, correlação (entro os valores observados e estimados) e tendência sistemática. Com isso, é possível realizar comparações entre os diferentes modelos e verificar os de melhor ajuste.

Alguns autores em seus trabalhos destacam uma escala classificatória para os diferentes intervalos de rRMSE para avaliar a acurácia dos modelos (JAMIESON et al., 1991; HEINEMANN et al., 2012; LI et al. 2013):

Excelente se $rRMSE < 10\%$;

Bom se $10\% \leq rRMSE < 20\%$;

Aceitável se $20\% \leq rRMSE < 30\%$;

Pobre se $rRMSE \geq 30$.

Os índices estatísticos obtidos para o presente trabalho foram realizados com o desenvolvimento de um script para ser processado no software MicrocalTMOrigin 6.0[®].

6. RESULTADOS E DISCUSSÃO

6.1 Equação de Angstrom-Prescott: diária (A-P)^d e mensal (A-P)^m

A Figura 5 (a, b) mostra a correlação entre a transmissividade atmosférica (H_G/H_0) com a razão de insolação (n/N) nas partições diária e mensal, $(H_G/H_0)^d \times (n/N)^d$ e $(H_G/H_0)^m \times (n/N)^m$, para a base de dados medida no período de 1996-2011 em Botucatu, SP. As correlações são lineares em todo intervalo de variação de n/N entre 0 e 1. O espalhamento dos pontos experimentais em ambas as correlações são similares a maioria dos trabalhos da obtenção da equação de Angstrom-Prescott no mundo (MARTINEZ-LOZANO et al., 1984). O espalhamento na primeira correlação (Figura 5 a) é bastante elevado ($r = 0,898 \pm 0,071$), no qual para cada valor de (n/N) há um largo intervalo de variação nos valores $(H_G/H_0)^d$. De maneira similar, o espalhamento na segunda correlação (Figura 5 b) é também considerado bastante elevado ($r = 0,845 \pm 0,030$). Esse efeito ocorre porque existe uma grande variabilidade das concentrações de nuvens, vapor de água e aerossóis na atmosfera nos períodos úmido e seco, que absorvem e espalham a radiação global diferentemente nos dois tipos de atmosfera para mesmos valores de n/N .

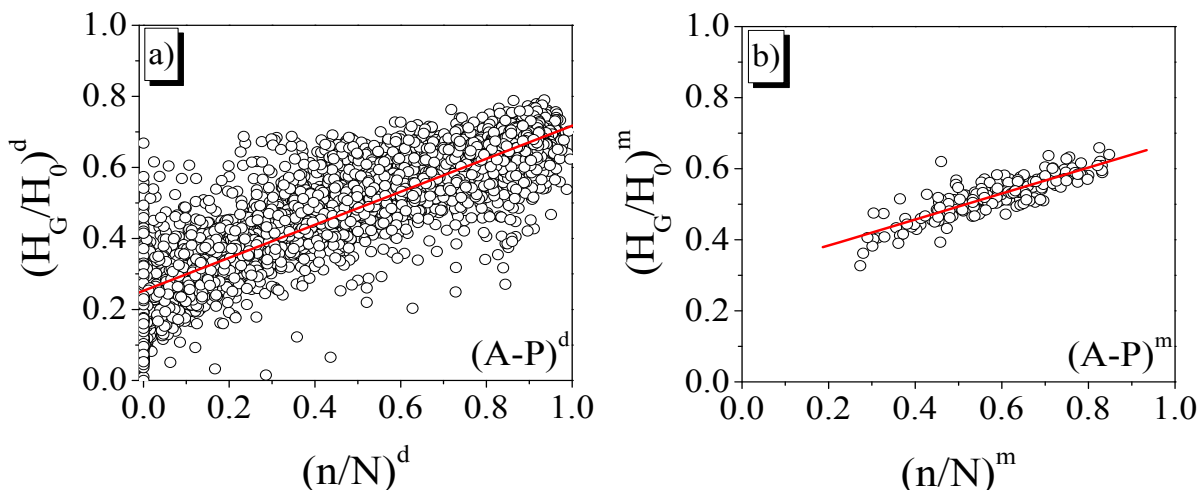


Figura 5. Correlação entre a transmissividade atmosférica da irradiação global (H_G/H_0) e a razão de insolação (n/N) nas partições a) diária, e b) mensal, e as retas obtidas por regressão linear no período de 1996-2011.

As Equações (19) e (20) obtidas nas correlações das Figuras 5 (a, b) por meio de regressão linear:

$$(H_G/H_0)^d = 0,253 + 0,465(n/N)^d \quad (19)$$

$$(H_G/H_0)^m = 0,311 + 0,366(n/N)^m \quad (20)$$

Os valores encontrados para o coeficiente de determinação $R^2 = 0,806$ e $R^2 = 0,715$ são similares aos valores obtidos em muitas cidades no Brasil, e estão dentro do intervalo de variação de R^2 cuja média é de $0,770 \pm 0,146$ (Tabela 4). O limite na razão de insolação $(n/N)^d$ tendendo a 0, condição de cobertura de céu totalmente nebulosa, a Equação (19) define a transmissividade atmosférica mínima da radiação global em Botucatu $(H_G/H_0)^d = 0,253$ como sendo igual a 25,3%. Por outro lado, para a razão de insolação $(n/N)^d$ tendendo a 1, condição de cobertura de céu totalmente aberto ou sem nuvens, a Equação (19) define a transmissividade atmosférica máxima da radiação global $(H_G/H_0)^d = 0,253 + 0,465 = 0,718$ como sendo igual a 71,8%. O resultado encontrado é próximo ao sugerido por Allen et al. (1998) através do Boletim FAO-56 que é $a = 0,25$ e $b = 0,50$ para ser uma equação universal que atende locais onde não existem medidas da radiação global. Os valores de $a = 25,3\%$ para a transmissividade mínima e $b = 71,8\%$ para a transmissividade máxima.

Os coeficientes a e b da equação anual de Angstrom-Prescott obtido para Botucatu $a = 0,253$ e $b = 0,465$ são comparáveis aos valores de a e b da equação de Angstrom-Prescott determinados no País desde a década de 1960 como mostra a Tabela 4.

Tabela 4. Coeficientes de Angstrom-Prescott (A-P) obtidos no território nacional por diversos autores.

Autores	Localidades (N°)	Coeficientes de (A-P)			
		a	b	$a+b$	R^2
Belúcio et al. (2014)	Macapá (AP)	0,270	0,430	0,700	0,820
Mota et al. (1977)	55 (Brasil)	0,170 - 0,310	0,410 - 0,570	0,710 - 0,740	*
Pacheco e Bastos (2002)	Capitão Poço (PA)	0,298	0,341	0,639	0,702
Tiba (2001)	34 (Nordeste)	0,220 - 0,350	0,310 - 0,580	0,580 - 0,840	0,710 - 0,980
Ribeiro et al. (1982)	Manaus (AM)	0,260	0,480	0,740	0,688
Andrade Júnior et al. (2012)	Parnaíba (PI)	0,321	0,460	0,781	0,629
Azevedo et al. (1981)	Fortaleza (CE)	0,270	0,360	0,630	0,740
Teixeira et al. (2002)	Juazeiro (BA)	0,260	0,320	0,580	0,810
Nicácio et al. (2001)	Maceió (AL)	0,320	0,370	0,690	0,757
Souza et al. (2016)	3 (AL)	0,244 - 0,339	0,375 - 0,481	0,714 - 0,730	*
Martim et al (2014)	Sinop (MT)	0,268	0,473	0,741	0,863
Pereira et al. (2010)	Pedra Azul (MG)	0,265	0,325	0,590	0,570
Torres et al. (2010)	Canavieiras (BA)	0,367	0,267	0,634	0,993
Dornelas et al. (2006)	Brasília (DF)	0,282	0,490	0,772	0,810
Santos et al. (2003)	Ilha Solteira (SP)	0,261	0,471	0,732	0,808
Dantas et al. (2003)	Lavras (MG)	0,230	0,490	0,720	0,792
Tarifa (1972)	Presidente Prudente (SP)	0,190	0,390	0,580	*
Pilau et al. (2007)	Araras (SP)	0,243	0,455	0,698	0,715
Cervellini et al. (1966)	2 (SP)	0,190 - 0,230	0,560 - 0,610	0,790 - 0,800	*
Blanco e Sentelhas (2002)	Piracicaba (SP)	0,231	0,500	0,731	0,844
Carvalho et al. (2011)	Seropédica (RJ)	0,282	0,433	0,715	0,820
Modelo proposto (2016)	Botucatu (SP)	0,253	0,465	0,718	0,806
Araújo et al. (2001)	São Paulo (SP)	0,290	0,360	0,650	*
Dallacort et al. (2004)	Palotina (PR)	0,206	0,391	0,597	0,839
Beruski et al. (2015)	Ponta Grossa (PR)	0,143	0,475	0,618	*
Fontana e Oliveira (1996)	20 (RS)	0,150 - 0,270	0,320 - 0,620	0,590 - 0,790	0,430 - 0,770
Back (2005)	Urussanga (SC)	0,226	0,485	0,711	0,720

Similarmente, para (A-P)^m, equação 20, os valores de $a = 31,1\%$ é a transmissividade mínima e $b = 67,7\%$ a transmissividade máxima. O coeficiente de determinação (R^2) = 0,715 obtido pra Botucatu é da mesma ordem de grandeza de valores

de (R^2) encontrados através do modelo de (A-P)^m nos trabalhos de outros pesquisadores como: Manzano et al. (2015) em Tortosa ($R^2 = 0,70$) e Valência ($R^2 = 0,73$) na Espanha; Liu et al. (2009) em Geermu ($R^2 = 0,71$), Jinan ($R^2 = 0,73$) e Xian ($R^2 = 0,73$), localizadas na região da Bacia do Rio Amarelo (China); Li et al. (2012) em Chengdu ($R^2 = 0,73$) e Hangzhou ($R^2 = 0,72$), localizadas na Bacia do Rio Yangtze (China). Em contraste foi inferior ao trabalho de Mohammadi et al. (2015a) que encontrou valor de $R^2 = 0,962$ em Isfahan no Irã.

Para análise da sazonalidade da equação (A-P)^d, similarmente a correlação total entre a transmissividade atmosférica da irradiação solar global (H_G/H_0)^d com a razão de insolação (n/N)^d para a base de dados medida no período de 1996-2011, em Botucatu, foram efetuados igualmente os cálculos para as quatro estações do ano com seus respectivos coeficientes de correlação (r) e determinação (R^2) em intervalo de variação de n/N entre 0 a 1 (Figura 6).

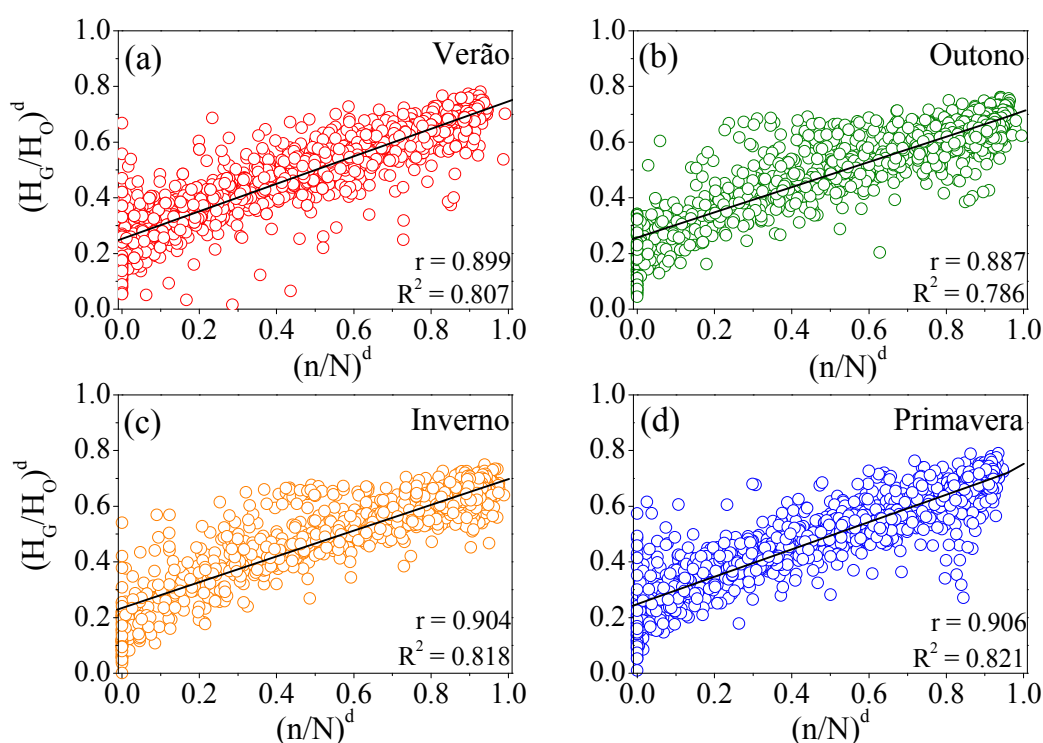


Figura 6. Correlações sazonais: (a) verão; (b) outono; (c) inverno e (d) primavera.

As equações obtidas das correlações por meio de regressão linear com respectivo coeficiente de determinação (R^2) estão apresentados abaixo:

$$\text{Verão} \quad (H_G/H_O)^d = 0,252 + 0,493(n/N)^d \quad (21)$$

$$\text{Outono} \quad (H_G/H_O)^d = 0,257 + 0,453(n/N)^d \quad (22)$$

$$\text{Inverno} \quad (H_G/H_O)^d = 0,234 + 0,462(n/N)^d \quad (23)$$

$$\text{Primavera} \quad (H_G/H_O)^d = 0,248 + 0,491(n/N)^d \quad (24)$$

A transmissividade mínima de $(H_G/H_O)^d$ é menor, sequencialmente para inverno (23,4%), primavera (24,8%), verão (25,2%) e outono (25,7), enquanto que a transmissividade máxima é maior, em seqüência, para verão (74,5%), primavera (73,9%), outono (71,0%) e inverno (69,6%). Fatores climáticos como tipo e espessuras de nuvens, concentrações de vapor de água e aerossóis na atmosfera são os responsáveis pelas variações de a e $a+b$ em cada estação do ano.

Os elevados coeficientes de determinação (R^2), próximos a 80,0% mostram que $(H_G/H_O)^d$ e $(n/N)^d$ estão também bem ajustados estatisticamente nas quatro estações do ano, com melhores resultados em seqüência para primavera, verão, inverno e outono. Os valores encontrados de (R^2) para as equações sazonais são bastante similares aos obtidos em outras localidades brasileiras por outros autores como mostram os trabalhos de Blanco e Sentelhas (2002), Pilau et al. (2007), Pereira et al (2007) e Martim et al. (2014) cujos valores estão no intervalo de variação de (R^2) e com média de $0,821 \pm 0,099$ (Tabela 5).

Tabela 5. Equações sazonais desenvolvidos para outras localidades.

Autores	Localidades	Estação	<i>a</i>	<i>b</i>	<i>a+b</i>	<i>R</i> ²
Laperuta Filho (1996)	Botucatu	Verão	0,230	0,420	0,650	0,810
		Outono	0,230	0,470	0,700	0,830
		Inverno	0,210	0,510	0,720	0,860
		Primavera	0,210	0,450	0,660	0,850
Blanco e Sentelhas (2002)	Piracicaba	Verão	0,259	0,477	0,736	0,843
		Outono	0,239	0,502	0,741	0,874
		Inverno	0,214	0,496	0,710	0,758
		Primavera	0,203	0,547	0,750	0,901
Valiati e Ricieri (2005)	Cascavel	Verão	0,190	0,340	0,530	0,840
		Outono	0,160	0,400	0,560	0,870
		Inverno	0,150	0,430	0,580	0,880
		Primavera	0,160	0,390	0,550	0,880
Pilau et al. (2007)	Araras	Verão	0,262	0,366	0,628	0,570
		Outono	0,286	0,417	0,703	0,647
		Inverno	0,258	0,466	0,724	0,675
		Primavera	0,243	0,439	0,682	0,755
Pereira et al. (2010)	Pedra Azul	Verão	0,272	0,398	0,670	0,917
		Outono	0,220	0,286	0,506	0,866
		Inverno	0,233	0,293	0,526	0,956
		Primavera	0,303	0,392	0,695	0,989
Martim et al. (2014)	Sinop	Verão	0,273	0,402	0,675	0,675
		Outono	0,286	0,440	0,726	0,839
		Inverno	0,255	0,507	0,762	0,833
		Primavera	0,285	0,442	0,727	0,795

A Figura 7 mostra as curvas de regressão linear entre a transmissividade atmosférica da irradiação global $(H_G/H_0)^d$ e a razão de insolação $(n/N)^d$, respectivamente, para as estimativas anual, verão, outono, inverno e primavera. Essas equações não são do tipo $(y = ax)$, portanto, a sazonalidade não pode ser analisada apenas pelo coeficiente angular. Como os valores de *a* e *b* das equações anual e sazonais diferem entre si estatisticamente, os valores de $(H_G/H_0)^d$ dependem dos valores da razão de insolação $(n/N)^d$.

A Figura 8 apresenta os valores de DL (%) calculados para cada estação do ano. Os resultados mostram que a capacidade da equação anual superestimar ou

subestimar as equações sazonais nas estimativas depende da razão de insolação, e também de cada estação do ano.




Figura 7. Retas de regressões lineares entre modelo anual de $(A-P)^d$ e os sazonais.

No verão, a reta da equação anual é inferior a da sazonal, portanto os desvios DL (%) negativos indicam que a equação anual subestima a sazonal em todo intervalo de variação de $(n/N)^d$. O valor de DL (%) é crescente da cobertura de céu nebulosa $(n/N)^d = 0,1$ com DL (%) = 1,0%, até cobertura de céu totalmente aberta $n = N$ com DL (%) = 4,0%.

No outono, a reta da equação anual cruza com a da sazonal no meio do intervalo de $(n/N)^d$. No intervalo de $(n/N)^d < 0,5$, a reta anual é inferior a sazonal, portanto, os desvios DL (%) negativos indicam que a equação anual subestima a sazonal no intervalo de variação de $(n/N)^d$ entre 0,1 a 0,5. O valor de DL (%) é decrescente da cobertura de céu nebulosa $(n/N)^d = 0,1$, com DL (%) = 1,3%, até cobertura de céu parcialmente nublada $(n/N)^d = 0,5$, com DL (%) = 0,1%. No intervalo de $(n/N)^d > 0,5$, a reta anual é superior a sazonal, portanto, os desvios DL (%) positivos indicam que a equação anual superestima a sazonal no intervalo de variação de $(n/N)^d$ entre 0,5 a 1,0. O valor de DL (%) é crescente para a cobertura de céu parcialmente nebulosa $(n/N)^d > 0,5$, com DL (%) = 0,1%, até cobertura de céu aberto $(n/N)^d = 1,0$, com DL (%) = 0,8%.




Figura 8. Valores de DL (%) para (a) verão; (b) outono; (c) inverno e (d) primavera.

Ao contrário do verão, no inverno, a reta da equação anual é superior a da sazonal, portanto os desvios DL (%) positivos indicam que a equação anual superestima a sazonal em todo intervalo de variação de $(n/N)^d$. O valor de DL (%) é decrescente da cobertura de céu nebulosa $(n/N)^d = 0,1$, com DL (%) = 6,1%, até cobertura de céu totalmente aberta $n = N$ com DL (%) = 2,8%.

Similarmente ao verão, na primavera, a menos do primeiro intervalo $(n/N)^d = 0,1$, a reta da equação anual é superior a da sazonal, portanto os desvios DL (%) positivos indicam que a equação anual superestima a sazonal em quase todo intervalo de variação de $(n/N)^d$. O valor de DL (%) é crescente da cobertura de céu nebulosa $(n/N)^d = 0,2$, com DL (%) = 0,4%, até cobertura de céu totalmente aberta, $n = N$, com DL (%) = 3,2%. No intervalo $(n/N)^d = 0,1$, a equação anual subestimou a sazonal, em DL (%) = 4,3%.

6.2 Validação dos modelos de Angstrom-Prescott $(A-P)^d$ e $(A-P)^m$ e de treinamento das técnicas MVS e RNA

6.2.1 Validação do modelo de Angstrom-Prescott $(A-P)^d$ e $(A-P)^m$

6.2.1.1 Correlações entre os valores estimados de H_G^d e H_G^m por meio de $(A-P)^d$ e $(A-P)^m$ e medidos para anos típico e o atípico

A Figura 9 mostra as correlações obtidas na validação entre estimativas de H_G e as medidas de H_G diárias e mensais, para as bases de dados anuais típico e o atípico. As distribuições dos valores estimados por meio de Angstrom-Prescott $(A-P)^d$ e $(A-P)^m$ e medidos nas duas condições de validações estão em concordância linear com as curvas ideais de 45° nos ajustes.

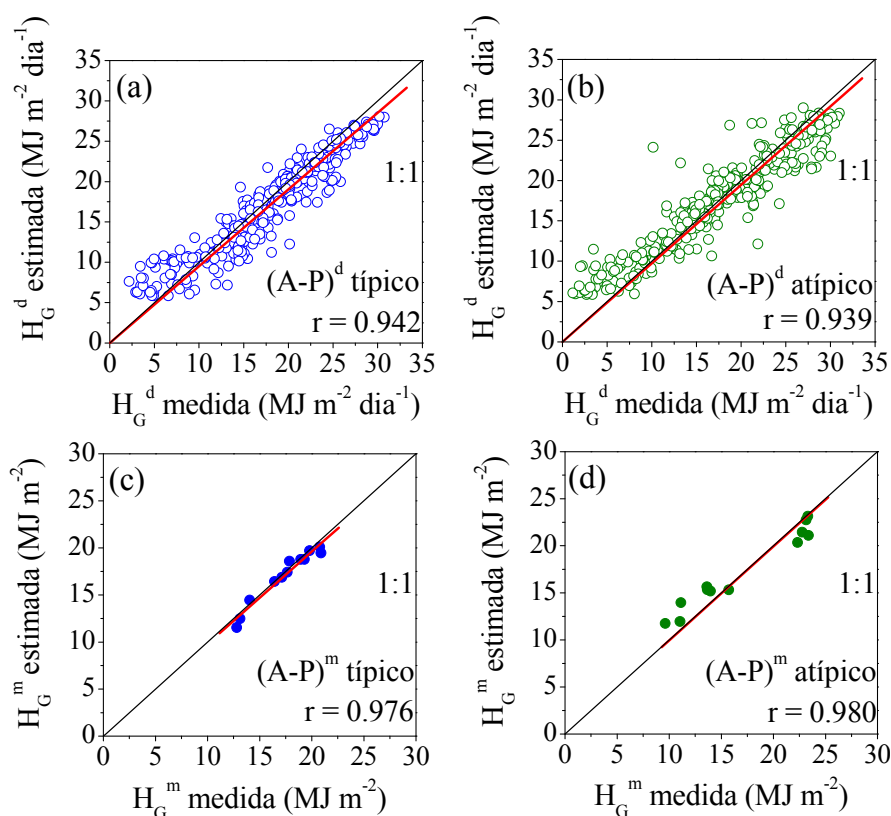


Figura 9. Comparação entre os valores estimados por meio de Angstrom-Prescott $(A-P)^d$ e $(A-P)^m$ e medidos de H_G para anos típico e o atípico.

As equações de regressão linear entre H_G^d estimada e H_G^d medida, com os coeficientes de correlação $r = 0,942$, para validação com ano típico e $r = 0,939$ para ano atípico, mostram que o modelo $(A-P)^d$ pode estimar H_G com elevados coeficientes de determinação, próximos dos 100%, com $R^2 = 88,7\%$ para o ano típico e com $R^2 = 88,0\%$ para o atípico. Similarmente, as equações de regressão linear entre H_G^m estimada por $(A-P)^m$ e H_G^m medida, com os coeficientes de correlação $r = 0,976$ para validação com ano típico e $r = 0,980$ para o ano atípico, mostram que o modelo de $A-P^m$ (Equação 20) pode

estimar H_G^m com elevados coeficientes de determinação $R^2 = 95,3\%$ para o ano típico e com $R^2 = 96,0\%$ para o atípico.

6.2.1.2 Indicativos estatísticos rMBE, rRMSE e d de Willmott na validação dos valores estimados de H_G^d e H_G^m para anos típico e atípico

Os indicativos estatísticos rMBE, rRMSE e d de Willmott, obtidos da validação dos valores estimados de H_G^d e H_G^m pelas Equações 19 e 20, os valores medidos de H_G^d e H_G^m , respectivamente (Figura 9), para os anos típico e atípico, são representados graficamente na Figura 10 (a, b e c).

O resultado obtido para rMBE (Figura 10 a) mostra que a equação 19 subestima a medida em 3,0% ($0,52 \text{ MJ m}^{-2} \text{ dia}^{-1}$) no ano típico, e superestima em 1,1% ($0,19 \text{ MJ m}^{-2} \text{ dia}^{-1}$) no ano atípico. Similarmente, o valor obtido para rMBE (Figura 10 a) mostra que a equação 20 subestima a medida em 2,0% ($0,35 \text{ MJ m}^{-2}$) no ano típico, e superestima em 2,1% ($0,36 \text{ MJ m}^{-2}$) no ano atípico.

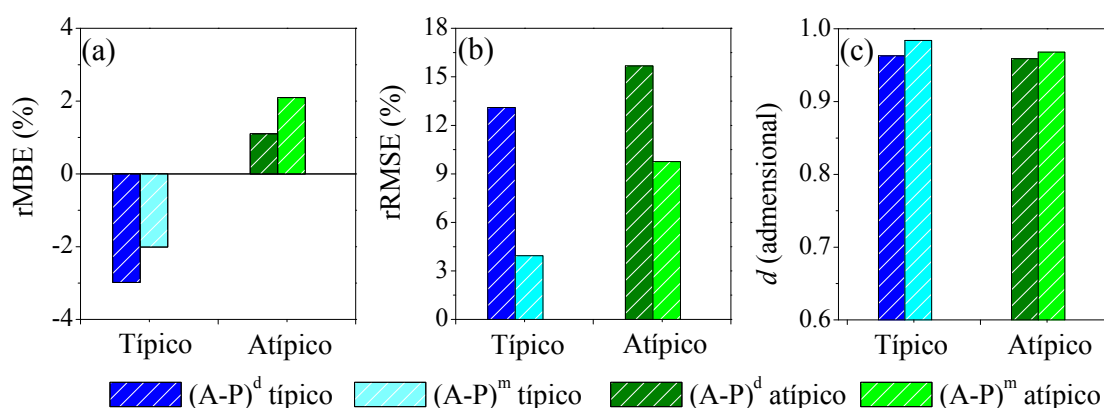


Figura 10. Indicativos estatísticos rMBE, rRMSE e d de Willmott na validação para anos típico e atípico.

Os resultados obtidos para rRMSE (Figura 10 b) mostram que o espalhamento com a equação 19 é menor para ano típico: rRMSE = 13,1% ($2,3 \text{ MJ m}^{-2} \text{ dia}^{-1}$) e maior para o atípico com rRMSE = 15,7% ($2,7 \text{ MJ m}^{-2} \text{ dia}^{-1}$). Semelhantemente, os resultados obtidos para rRMSE (Figura 10 b) mostram que o espalhamento com a Equação 20 é também menor com ano típico: rRMSE = 3,9% ($0,69 \text{ MJ m}^{-2}$), e maior para o atípico com RMSE = 9,7% ($1,6 \text{ MJ m}^{-2}$). O índice de concordância (d) de Willmott (Figura 10 c),

obtido da Equação 19, foi superior numericamente em seqüência para os anos típico (0,963) e atípico (0,959), similarmente valor d (Figura 10 c) para a Equação 20 seguiu a mesma tendência para os anos típico (0,984) e atípico (0,968).

A comparação entre os indicativos estatísticos rMBE, rRMSE e d de Willmott, bem como de r e R^2 , na validação para anos típico e atípico, por meio das estimativas das equações 19 e 20, mostram que o modelo de Angstrom-Prescott (A-P)^m possui melhor desempenho que (A-P)^d.

6.2.1.3 Comparação com a Literatura dos Indicativos estatísticos rMBE, MBE, rRMSE, RMSE e r na validação, nas partições diária e mensal

A Tabela 6 mostra uma comparação dos indicativos estatísticos MBE, rMBE, RMSE, rRMSE e r em percentagem e em unidades de energia por dia, obtidos na validação entre medida e estimativa do modelo (A-P)^d na partição diária em várias localidades do Brasil e do mundo.

Os erros ou valores de MBE e rMBE obtidos neste trabalho são maiores (3,0%) ou (-0,52 MJ m⁻² dia⁻¹) para validação com ano típico e menor 1,1% ou (0,19 MJ m⁻² dia⁻¹) para ano atípico. Ambos considerados resultados dentro do aceitável, visto que ambos estão dentro do erro experimental do equipamento de medida da radiação global, que é de 4,1% (REDA et al., 2008). Comparando os valores de MBE e rMBE em outros locais, com os obtidos em Botucatu (-0,52 MJ m⁻² dia⁻¹ e 0,19 MJ m⁻² dia⁻¹, respectivamente), tem-se que: os resultados de outros locais são superiores aos valores de (0,03 MJ m⁻² dia⁻¹) encontrados por Nicácio et al. (2001); ao valor de (- 0,02 MJ m⁻² dia⁻¹) obtido por Martim et al.(2014); aos valores de (-0,15) - 0,07 MJ m⁻² dia⁻¹ encontrados por Sabziparvar et al. (2013); aos valores de (-0,04) - 0,09 a MJ m⁻² dia⁻¹ obtidos por Zhao et al. (2013) e aos valores de 0 - 0,02 MJ m⁻² dia⁻¹ encontrados por Iziomon e Mayer (2001). Por outro lado, os resultados obtidos em Botucatu foram inferiores: ao valor de (1,58 MJ m⁻² dia⁻¹) encontrado por Beruski et al. (2015); aos valores de (-2,88) - 1,84 MJ m⁻² dia⁻¹ obtidos por Lam et al. (2008); aos valores de 3,00 - 2,04 MJ m⁻² dia⁻¹ encontrados por Wan et al. (2008); aos valores de 0,57 - 1,25 MJ m⁻² dia⁻¹ obtidos por Li et al. (2011). Os resultados obtidos por Manzano et al. (2015), (-1,32) – 0,30 MJ m⁻² dia⁻¹, alternam valores superiores e inferiores aos resultados de Botucatu.

Tabela 6. Indicativos estatísticos obtidos para diversas localidades (partição diária).

Autores	Localidades (N°)	MBE (MJ m⁻² dia⁻¹)	rMBE (%)	RMSE (MJ m⁻² dia⁻¹)	rRMSE (%)	r
Iziomon e Mayer (2001)	2 (Alemanha)	0 a -0,02	-	0,03 - 0,07	-	-
Nicácio et al. (2001)	Maceió (Brasil)	0,03	-	1,73	-	0,87
Lam et al. (2008)	40 (China)	(-2,88) - 1,84	(-14,9) - 18,7	1,19 a 3,61	7,6 a 32,6	-
Liu et al. (2009) ^a	31 (China)	-	-	1,39 a 3,08	-	-
Wan et al. (2008)	41 (China)	(-3,00) - 2,04	(-16,2) - 18,8	1,22 a 3,74	7,4 a 31,3	-
Li et al. (2011) ^b	4 (China)	0,57 - 1,25	-	1,12 a 1,64	-	0,89 a 0,98
Pereira et al. (2010)	Pedra Azul (Brasil)	-	-	2,83	-	-
Torres et al. (2010)	Canavieiras (Brasil)	-	-	1,72	-	-
Andrade Júnior et al. (2012)	Parnaíba (Brasil)	-	-	0,08	-	-
Li et al. (2012) ^c	15 (China)	-	-	1,81 a 3,39	-	-
Chen et al. (2013)	3 (China)	-	-	1,99 a 2,28	14,9 a 19,4	-
Sabziparvar et al. (2013)	15 (Irã)	(-0,15) - 0,07	-	1,66 a 3,25	-	-
Zhao et al. (2013)	9 (China)	(-0,04) - 0,09	-	1,72 a 5,24	-	-
Martim et al. (2014)	Sinop (Brasil)	-0,020	-	1,85	-	-
Beruski et al. (2015)	Ponta Grossa (Brasil)	1,58	-	1,64	-	-
Manzano et al. (2015)	25 (Espanha)	(-1,32) - 0,30	-	1,11 a 3,37	-	-
Mohammadi et al. (2015a)	Isfahan (Irã)	-	-	2,67	13,9	-
Park et al. (2015)	22 (Coréia do Sul)	-	-	0,47 a 2,73	-	-
Modelo proposto (2015)^d	Botucatu (Brasil)	-0,52	-3,0	2,28	13,1	0,94
Modelo proposto (2015)^e	Botucatu (Brasil)	0,19	1,1	2,69	15,7	0,94

- Não informado pelos autores

a = Bacia do Rio Amarelo, b = Comunidade autônoma do Tibete, c = Bacia do Rio Yangtze, d = Modelo desenvolvido para ano típico em Botucatu, e = Modelo desenvolvido para ano atípico em Botucatu.

Os desvios do erro ou os valores de RMSE e rRMSE, obtidos no trabalho, são menores no espalhamento para a condição de validação do ano típico (2,28 MJ m⁻² dia⁻¹) ou 13,0% e maior para o ano atípico (2,69 MJ m⁻² dia⁻¹) ou 15,7%, também foram considerados bons resultados segundo os critérios estabelecidos por Jamieson et al. (1991) e (Heinemann et al., 2012). Em geral, os resultados de RMSE e rRMSE são próximos aos valores de outras localidades (Tabela 6).

Os valores de RMSE local foram superiores aos valores de: (0,03 - 0,07 MJ m⁻² dia⁻¹) encontrados por Iziomon e Mayer (2001); (1,73 MJ m⁻² dia⁻¹) por Nicácio et al. (2001); (1,12 a 1,64 MJ m⁻² dia⁻¹) por Li et al. (2011)^b; (1,72 MJ m⁻² dia⁻¹) por Torres et al. (2010); (0,08 MJ m⁻² dia⁻¹) por Andrade Júnior et al. (2012); (1,85 MJ m⁻² dia⁻¹) por Martim et al. (2014) e (1,64 MJ m⁻² dia⁻¹) por Beruski et al. (2015). Os resultados de RMSE local alternam ainda valores aos obtidos por: Lam et al. (2008) com valores

variando de (1,19 - 3,61 MJ m⁻² dia⁻¹); Liu et al. (2009)^a com valores variando de (1,39 - 3,08 MJ m⁻² dia⁻¹); Li et al. (2012)^b de (1,12 - 1,64 MJ m⁻² dia⁻¹); Wan et al. (2008) de (1,22 a 3,74 MJ m⁻² dia⁻¹); Li et al. (2012)^c de (1,81 a 3,39 MJ m⁻² dia⁻¹); por Chen et al. (2013) de (1,99 a 2,28 MJ m⁻² dia⁻¹); por Zhao et al. (2013) de (1,72 a 5,24 MJ m⁻² dia⁻¹); por Mohammadi et al. (2015) de (2,67 MJ m⁻² dia⁻¹). Similarmente, por Sabziparvar et al. (2013) variando de (1,66 a 3,25 MJ m⁻² dia⁻¹); por Manzano et al. (2015) de (1,11 a 3,37 MJ m⁻² dia⁻¹) e por Park et al. (2015) de (0,47 a 2,73 MJ m⁻² dia⁻¹). Os valores de RMSE local foram inferiores aos valores (2,83 MJ m⁻² dia⁻¹) encontrados por Pereira (2010).

Os coeficientes de correlação linear (r) obtido neste trabalho, r = 0,942, para validação com ano típico e r = 0,939, para o ano atípico, foram superiores ao valor de r = 0,87, obtido por Nicácio et al. (2001), e são da mesma ordem de grandeza aos valores de r = 0,89 a 0,98 determinados por Li et al. (2011)^b.

A Tabela 7 mostra uma comparação dos indicativos estatísticos MBE, rMBE, RMSE, rRMSE e r em percentagem e em unidades de energia por dia, obtidos na validação entre medida e estimativa dos modelos de Angstrom-Prescott (A-P)^m em diversas localidades.

Comparado os valores de MBE de outras localidades com os obtidos em Botucatu (-0,35 MJ m⁻² e 0,36 MJ m⁻², respectivamente) tem-se que: os resultados locais são superiores aos valores de (0,0 MJ m⁻²) encontrados por Elagib et al. (1999); aos valores de (0,03 a 0,25 MJ m⁻²) encontrados por Tadros (2000); aos valores de (-0,01 a -0,003) obtidos por Iziomon e Mayer (2001); aos valores de encontrados por Almorox et al. (2011); aos valores de (0,0 MJ m⁻²) encontrados por Duzen e Aydin (2012); ao valor de (-0,004 MJ m⁻²) obtido por Ituen et al. (2012); ao valor de (0,04 MJ m⁻²) encontrado por Onyango e Ongoma (2015); aos valores de (-0,01 a 0,02) por Souza e Andrews (2015)^f. Porém, os resultados encontrados para Botucatu foram inferiores: aos valores de (0,54 a 1,20 MJ m⁻²) obtidos por Li et al. (2011). Valores que alternaram entre inferiores e superiores aos resultados de Botucatu foram: os de (-3,47 a 2,24 MJ m⁻²) por Bakirci (2009a); de (-1,13 a 0,120 MJ m⁻²) por Manzano et al. (2015); de (-0,19 a 0,65 MJ m⁻²) por Souza e Andrews (2015)^e.

Tabela 7. Indicativos estatísticos obtidos para diversas localidades (partição mensal).

Autores	Localidades (N°)	MBE (MJ m⁻² dia⁻¹)	rMBE (%)	RMSE (MJ m⁻² dia⁻¹)	rRMSE (%)	r
Hussain (1990)	4 (Índia)	-	-	-	1,8 a 2,9	0,78 a 0,98
Nguyen e Pryor (1996)	12 (Vietnã)	-	(-8,7) - 17,0	-	2,9 a 20,6	0,73 a 0,99
Elagib et al. (1999)	16 (Sudão)	0,0	-	0,01 a 0,03	-	0,69 a 0,99
Tadros (2000)	8 (Egito)	0,03 - 0,25	-	0,59 a 1,01	-	-
Iziomon e Mayer (2001)	2 (Alemanha)	(-0,01 - 0,003)	-	0,01 a 0,05	-	-
Tymvios et al. (2005)	Nicósia (Chipre)	-	6,3	-	13,4	-
Almorox et al. (2008)	11 (Venezuela)	0,0	-	0,03 a 0,05	-	-
Bakirci (2009a)	18 (Turquia)	(-3,47) - 2,24	-	0,31 a 3,65	-	0,82 a 0,99
Liu et al. (2009) ^a	31 (China)	-	-	0,30 a 2,53	-	-
Li et al. (2011) ^b	4 (China)	0,54 - 1,20	-	0,72 a 1,26	-	0,94 a 0,99
Duzen e Aydin (2012) ^c	7 (Turquia)	0,0	-	0,02 a 0,03	-	0,67 a 0,95
Ituen et al. (2012)	Uyo (Nigéria)	(-0,004)	-	0,001	-	0,81
Li et al. (2012) ^d	15 (China)	-	-	0,71 a 1,97	-	-
Cotfas et al. (2014)	Brasov (Romênia)	-	-	0,01	-	-
Manzano et al. (2015)	25 (Espanha)	(-1,13) - 0,120	-	0,36 a 1,43	-	-
Mohammadi et al. (2015a)	Isfahan (Irã)	-	-	1,16	6,0	-
Onyango e Ongoma (2015)	Nairobi (Quênia)	0,04	-	0,07	-	-
Souza e Andrews (2015) ^e	Trinidade e Tobago	(-0,19) - 0,65	-	0,54 a 0,92	-	0,80 a 0,96
Souza e Andrews (2015) ^e	Trinidade e Tobago	(-0,01) - 0,02	-	0,43 a 0,81	-	0,82 a 0,97
Modelo proposto (2015)^g	Botucatu (Brasil)	-0,35	-2,0	0,69	3,9	0,97
Modelo proposto (2015)^h	Botucatu (Brasil)	0,36	2,1	1,66	9,8	0,98

- Não informado pelos autores

a = Bacia do Rio Amarelo, b = Comunidade autônoma do Tibete, c = Região do Lago Van, d = Bacia do Rio Yangtze, e = 5 anos de modelos anuais testados em Trinidade e Tobago, f = 10 anos modelos anuais testados em Trinidad e Tobago, g = Modelo desenvolvido para ano típico em Botucatu, h = Modelo desenvolvido para ano atípico em Botucatu.

Os valores de RMSE local foram superiores aos valores de: (0,01 a 0,03 MJ m⁻²) obtidos por Elagib et al. (1999); de (0,01 a 0,05 MJ m⁻²) obtidos por Iziomon e Mayer (2001); de (0,03 a 0,05 MJ m⁻²) encontrado por Almorox et al. (2008); de (0,02 a 0,03 MJ m⁻²) encontrado por Duzen e Aydin (2012); de (0,001 MJ m⁻²) obtido por Ituen et al. (2012); de (0,01 MJ m⁻²) obtido por Cotfas et al. (2014); de (1,16 MJ m⁻²) encontrado por Mohammadi et al. (2015a) e (0,07 MJ m⁻²) encontrado por Onyango e Ongoma (2015). Os resultados obtidos em Botucatu alternam valores inferiores e superiores aos obtidos por Tadros (2000) com valores variando de (0,59 a 1,01 MJ m⁻²); aos obtidos por Barkici (2009a) de (0,31 a 3,65 MJ m⁻²); por Liu et al. (2009)^a com valores variando de (0,30 a

2,53 MJ m⁻²); por Li et al. (2012)^b com valores variando de (0,72 a 1,26 MJ m⁻²); Li et al. (2009)^c com valores variando de (0,71 a 1,97 MJ m⁻²); por Manzano et al. (2015) com valores variando de (0,36 a 1,43 MJ m⁻²); por Mohammadi et al. (2015) com valor de (1,16 MJ m⁻²); por Souza e Andrews (2015)^e com valores variando (0,54 a 0,92 MJ m⁻²) e (0,43 a 0,81 MJ m⁻²) para as partições de 5 e 10 anos de dados de H_G, respectivamente.

Os coeficientes de correlação (r) entre H_G^m estimada e H_G^m medida, obtidos neste trabalho r = 0,976 para validação com ano típico e r = 0,980 para validação com ano atípico, foram numericamente superiores aos valores (0,67 a 0,95) obtido por Duzen e Aydin (2012)^c e (0,81) por Ituen et al. (2012). Contudo, são da mesma ordem de grandeza aos valores de: (0,78 a 0,98) determinados por Hussain (1990); (0,73 a 0,99) por Nguyen e Pryor (1996); (0,69 a 0,99) por Elagib et al. (1999); (0,82 a 0,99) por Bakirci (2009a); (0,94 a 0,99) por Li et al. (2012); (0,80 a 0,96) e (0,82 a 0,97) por Souza e Andrews (2015) em Trinidad e Tobago com banco de dados de H_G de 5 e 10 anos, respectivamente.

6.3 Validação dos modelos de treinamento das técnicas de AM

6.3.1 Modelos gerados em partição diária

6.3.1.1 Correlações entre estimativas e medidas das MVS e RNA

A Figura 11 de a - h, mostram diagramas de dispersão entre os valores estimados de H_G, pelos modelos gerados pelas MVS e RNA, respectivamente, e as medidas, com as retas obtidas por regressão linear para os anos típico e atípico.

Os valores estimados pelos modelos MVS1^d e RNA1^d respectivamente, estão em concordância linear com as medidas (Figura 11 a, b): as retas de correlações (r) estão muito próximas da reta ideal (45°) com r = 1 no ajuste. Para a rede SVR1^d, o coeficiente de correlação obtido de r = 0,962 e r = 0,947 para o ano típico e atípico, respectivamente, mostram que a medida de H_G^d e a estimativa de H_G^d estão bem correlacionadas estatisticamente. Similarmente, para a rede RNA1^d, os valores obtidos de r = 0,924 e r = 0,932, para os anos típico e atípico respectivamente, mostram que a medida de H_G^d e a estimativa de H_G^d pela rede RNA1^d, também estão bem correlacionadas

estatisticamente. A comparação dos valores de r mostram que a técnica MVS1^d teve maior valor de correlação do que a rede RNA1^d nas duas condições de validações.

Os valores estimados pelos modelos MVS2^d e RNA2^d, respectivamente, e os valores medidos (Figura 11 c, d) também apresentaram as retas de correlações (r) muito próximas da reta ideal (45°) no ajuste. Para os modelos MVS2^d e RNA2^d os valores de r próximos dos 100% para o ano típico: $r = 0,966$ e $r = 0,951$ e atípico de $r = 0,965$ e $r = 0,951$ respectivamente, mostram que a medida de H_G^d e a estimativa de H_G^d apresentam alto coeficiente de correlação. A inserção das temperaturas (T , $T_{\text{máx}}$ e $T_{\text{mín}}$) no treinamento das técnicas de AM do modelo1 (H_O e n/N) aumentaram os valores dos coeficientes de correlações para os dois modelos MVS2^d e RNA2^d. A combinação das variáveis H_O , n/N , $T_{\text{máx}}$ e $T_{\text{mín}}$, nos modelos MVS2^d e RNA2^d, representam a junção de todas as variáveis das equações de Angstrom-Prescott (A-P), Hargreaves-Samani e Bristow-Campbell. Essas duas últimas equações usam as variáveis $T_{\text{máx}}$ e $T_{\text{mín}}$ na estimativa de H_G com altos valores de r (HARGREAVES; SAMANI, 1982; BRISTOW; CAMPBELL, 1984). Esses resultados foram considerados importantes, porque os valores de r aumentaram em relação a MVS1^d e RNA1^d. O maior aumento do valor de r foi obtido com RNA2^d, que apresentou uma maior amplitude de variação, o valor de $r = 0,932$ aumentou para $r = 0,965$ para o ano típico, $r = 0,932$ para $r = 0,951$ no atípico. A comparação nos valores de r mostra que a rede MVS2^d possui melhor desempenho que a rede RNA2^d nas duas condições de validações.

Os valores estimados com os modelos de MVS3^d e RNA3^d (modelo 3) e as medidas (Figura 11 e, f) também apresentaram as retas de correlações (r) muito próximas da reta ideal (45°) no ajuste. Para as redes SVR3^d e ANN3^d os coeficientes de correlação obtido para os típico e atípico de $r = 0,969$ e $r = 0,955$, e de $r = 0,964$ e $r = 0,952$ respectivamente, mostram que a medida de H_G^d a estimativa de H_G^d pela rede SVR3^d e ANN3^d apresentam também elevadas correlações, nas duas condições de validação. A introdução da precipitação no modelo 3 aumentaram ligeiramente os valores dos coeficientes de correlação (r) dos modelos MVS3^d e RNA3^d. O ganho mais significativo foi obtido com o modelo MVS3 visto que o valor de $r = 0,966$ aumentou para $r = 0,969$ para o ano típico, $r = 0,951$ para $r = 0,955$ no atípico.

Os valores estimados pelas MVS4^d e RNA4^d respectivamente (modelo 4) e as medidas (Figura 11 g, h) também apresentaram as retas de correlações (r) muito próximas da reta ideal (45°) no ajuste. Para MVS4^d e RNA4^d os coeficientes de

correlação $r = 0,970$ e $r = 0,963$, e de $r = 0,958$ e $r = 0,951$ para os típico e atípico respectivamente, mostram que a medida de H_G^d a estimativa de H_G^d pela MVS4^d e RNA4^d apresentam também elevadas correlações estatísticas. A introdução da umidade relativa (%) no modelo 3 (MVS3^d e RNA3^d) manteve os valores de r , aproximadamente iguais nas duas condições de validações, na MVS4^d o valor de $r = 0,969$ aumentou para $r = 0,970$ para o ano típico, $r = 0,955$ para $r = 0,958$ no atípico, enquanto que em RNA4^d o valor de $r = 0,964$ diminuiu para $r = 0,963$ para o ano típico, $r = 0,952$ para $r = 0,951$ no atípico.

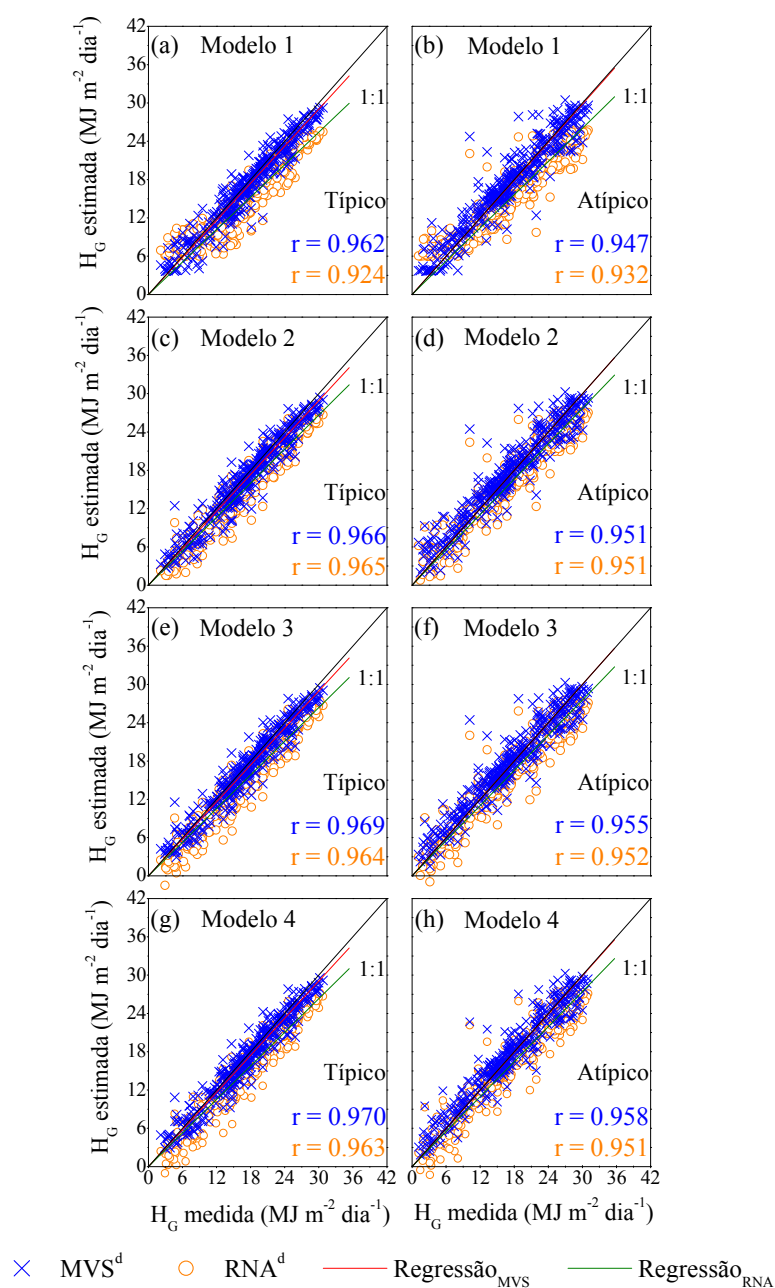


Figura 11. Diagramas de dispersão entre os valores estimados pelos modelos de AM, para anos típico e atípico, e os valores medido de H_G .

6.3.1.2 Indicativos estatísticos $rMBE$, $rRMSE$ e d de Willmott, entre estimativas e medidas das redes MVS^d e RNA^d

Os indicativos estatísticos $rMBE$, $rRMSE$ e d de Willmott, obtidos da comparação dos valores estimados, pelos 8 modelos gerados com as técnicas de AM, e medidos de H_G^d respectivamente para os anos típico e atípico, são mostrados na Figura (12).




Figura 12. Indicativos estatísticos $rMBE$ (%), $rRMSE$ (%) e d de Willmott na validação para anos típico e atípico.

Para o modelo 1, os valores de rMBE (Figura 12 a, b) mostram que MVS1^d subestima a medida em 2,6% (-0,46 MJ m⁻² dia⁻¹) no ano típico, e superestima em 1,6% (0,27 MJ m⁻² dia⁻¹) no ano atípico. A rede RNA1^d subestima a medida em 14,1% (-2,45 MJ m⁻² dia⁻¹) no ano típico, e também subestima em 10,7% (-1,83 MJ m⁻² dia⁻¹) no ano atípico. Os valores obtidos para rRMSE (Figura 12 b) mostram que o espalhamento com MVS1^d é menor para ano típico: rRMSE = 10,5% (1,83 MJ m⁻² dia⁻¹) e maior para o ano atípico com rRMSE = 13,9% (2,39 MJ m⁻² dia⁻¹). Para RNA1^d, é maior para o ano típico: rRMSE = 20,3% (3,54 MJ m⁻² dia⁻¹), e menor para o atípico com rRMSE = 19,9% (3,41 MJ m⁻² dia⁻¹). O índice de concordância (*d*) de Willmott (Figura 12 c) obtido com MVS1^d foi numericamente superior em seqüência para os anos típico (0,99) e atípico (0,98), do que para RNA1^d anos típico (0,98) e atípico (0,97) respectivamente.

Os valores para rMBE (Figura 12 d) mostram que MVS2^d subestima a medida em 3,3% (-0,58 MJ m⁻² dia⁻¹) no ano típico, e superestima em 2,3% (0,39 MJ m⁻² dia⁻¹) no ano atípico. A rede RNA2^d subestima em 11,6% (-2,02 MJ m⁻² dia⁻¹) no ano típico, e também subestima em 6,3% (-1,08 MJ m⁻² dia⁻¹) no ano atípico. Os valores de rRMSE (Figura 12 e) mostram que o espalhamento com MVS2^d é menor para ano típico: rRMSE = 10,2% (1,77 MJ m⁻² dia⁻¹) e maior para o ano atípico com rRMSE = 13,5% (2,32 MJ m⁻² dia⁻¹). Para a rede RNA2^d, é maior para o ano típico: rRMSE = 15,1% (2,64 MJ m⁻² dia⁻¹), e menor para o atípico com rRMSE = 15,0% (2,56 MJ m⁻² dia⁻¹). O índice de concordância (*d*) de Willmott (Figura 12 f) obtido com MVS2^d foi numericamente superior em seqüência para os anos típico (0,98) e atípico (0,97), do que para RNA2^d, anos atípico (0,97) e típico (0,96) respectivamente.

Os valores para rMBE (Figura 12 g) mostram que MVS3^d subestima a medida em 3,1% (-0,54 MJ m⁻² dia⁻¹) no ano típico, e superestima em 2,2% (0,37 MJ m⁻² dia⁻¹) no ano atípico. A RNA3^d subestima a medida em 13,0% (-2,27 MJ m⁻² dia⁻¹) no ano típico, e também subestima em 7,3% (-1,25 MJ m⁻² dia⁻¹) no ano atípico. Os resultados de rRMSE (Figura 12 h) mostram que o espalhamento com MVS3^d é menor para ano típico: rRMSE = 9,7% (1,68 MJ m⁻² dia⁻¹) e maior para o ano atípico com rRMSE = 13,0% (2,23 MJ m⁻² dia⁻¹). Para RNA3^d, é maior para o ano típico: rRMSE = 16,3% (2,84 MJ m⁻² dia⁻¹), e menor para o atípico com rRMSE = 15,6% (2,68 MJ m⁻²). O índice de concordância (*d*) de Willmott (Figura 12 i) obtido com MVS3^d foram semelhantes estatisticamente em seqüência para os anos típico (0,98) e atípico (0,98), do que para RNA3^d, anos típico (0,95) e atípico (0,97) respectivamente.

Os valores para rMBE (Figura 12 j) mostra que MVS4^d subestima a medida em 2,7% (-0,47 MJ m⁻² dia⁻¹) no ano típico, e superestima em 1,6% (0,28MJ m⁻² dia⁻¹) no ano atípico. RNA4^d subestima a medida em 13,2% (-2,30 MJ m⁻² dia⁻¹) no ano típico, e também subestima em 8,1% (-1,38 MJ m⁻² dia⁻¹) no ano atípico. Os valores de rRMSE (Figura 12 l) mostram que o espalhamento com MVS4^d é menor para ano típico: rRMSE = 9,5% (1,64 MJ m⁻² dia⁻¹) e maior para o ano atípico com rRMSE = 12,5% (2,14 MJ m⁻² dia⁻¹). Para RNA4^d o valor é maior para o ano típico: rRMSE = 16,6% (2,89 MJ m⁻² dia⁻¹), e menor para o atípico com rRMSE = 15,6% (2,68 MJ m⁻² dia⁻¹). O índice de concordância (*d*) de Willmott (Figura 12 m) obtido com a rede MVS4^d foram semelhantes numericamente em seqüência para os anos típico (0,98) e atípico (0,98), o mesmo ocorreu com a rede RNA4^d, nos anos típico (0,95) e atípico (0,96), respectivamente.

6.3.2 Mensal

6.3.2.1 Correlações entre estimativas e medidas pelas redes MVS^m e RNA^m

Os diagramas de dispersão ilustrados na Figura 13 (a - h) mostram, para partição mensal, a correlação entre os valores estimados de H_G, pelos modelos gerados, e os valores medidos, com as retas de correlações obtidas por regressão linear com os anos típico e atípico.

Os valores estimados por MVS1^m e RNA1^m (modelo 1) estão em concordância linear com as medidas (Figura 13 a, b): as retas de correlações (*r*) estão muito próximas da reta ideal (45°) com *r* = 1 no ajuste. Para MVS1^m, os valores de *r* = 0,987 e *r* = 0,984 e similarmente, para a rede RNA1^m, os valores de *r* = 0,983 e *r* = 0,989 obtidos para os típico e atípico respectivamente, mostram que a medida de H_G^m a estimativa de H_G^m pelas redes MVS1^m e RNA1^m também estão bem correlacionadas estatisticamente. Melhores resultados para *r* com MVS1^m e RNA1^m para ano atípico é uma consequência estatística da proximidade dos valores médios das radiações que são equalizadas para tempos mais elevados, como o mensal.

Os valores estimados por MVS2^m e RNA2^m (modelo 2), respectivamente, e as medidas (Figura 13 c, d) também apresentaram correlações (*r*) próximas da reta ideal no ajuste. Para MVS2^m e RNA2^m os valores de *r* = 0,977 e *r* = 0,984

e, de $r = 0,977$ e $r = 0,991$ para os anos típico e atípico respectivamente, mostram que a medida de H_G^m a estimativa de H_G^m pelas redes $MVS2^m$ e $RNA2^m$ estão bem correlacionadas estatisticamente. O acréscimo das temperaturas ($T_{máx}$ e $T_{mín}$)^m no treinamento das $MVS1^m$ e $RNA1^m$ não aumentaram os valores de r na mesma proporção dos resultados obtidos com $MVS2^d$ e $RNA2^d$ na partição diária. Ao contrario, diminuíram os coeficientes de correlações para $MVS2^m$ e $RNA2^m$ no ano típico e permaneceu aproximadamente iguais no ano atípico.

Os valores estimados pelo modelo 3 para $MVS3^m$ e $RNA3^m$ e as medidas (Figura 13 e, f) também apresentaram correlações próximas da reta ideal no ajuste. Para $MVS3^m$ e $RNA3^m$ os valores de $r = 0,983$ e $r = 0,985$, e de $r = 0,987$ e $r = 0,992$ para os típico e atípico respectivamente, mostram que a medida de H_G^m a estimativa de H_G^m por $MVS3^m$ e $RNA3^m$ apresentam também elevadas correlações. A introdução da precipitação no modelo 3 aumentaram os valores de r das duas técnicas de AM. O ganho mais significativo com $RNA3^m$ foi obtido principalmente para o ano típico que apresentaram uma maior amplitude de variação, o valor de $r = 0,977$ aumentou para $r = 0,983$ e de $r = 0,977$ para $r = 0,987$ respectivamente.

Os valores estimados pelo modelo 4 para as redes $MVS4^m$ e $RNA4^m$ e as medidas (Figura 13 g, h) também apresentaram correlações próximas da reta ideal (45°) no ajuste e mostram também elevadas correlações entre a medida e a estimativa de H_G^m . A introdução da umidade relativa (%) no modelo 3 ($MVS3^m$ e $RNA3^m$) manteve os valores de r nas mesmas condições obtidas com $MVS1^m$ e $RNA1^m$.

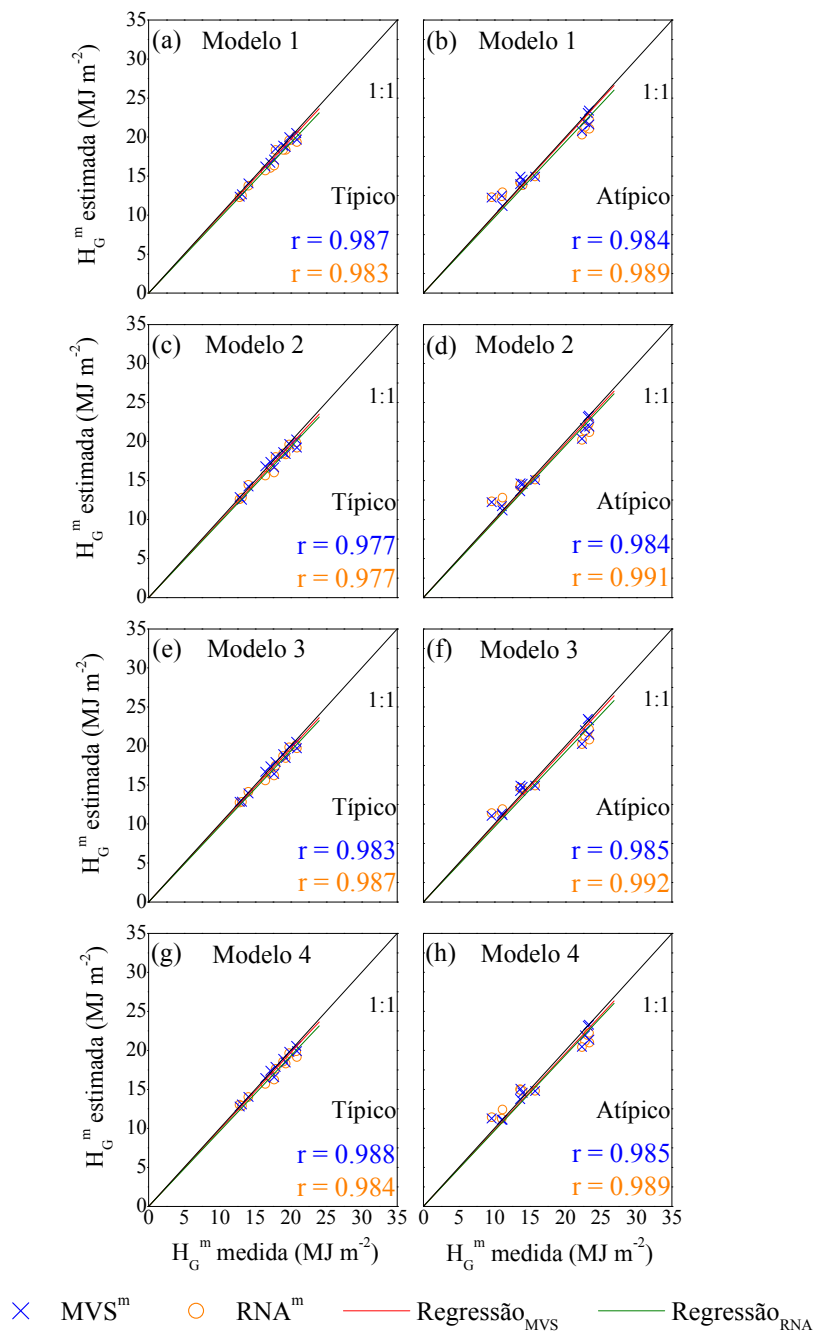


Figura 13. Diagramas de dispersão entre os valores estimados pelos modelos de AM, para anos típico e atípico, e os valores medido de H_G .

6.3.2.2 Indicativos estatísticos rMBE, rRMSE e d de Willmott, entre estimativas e medidas pelas redes MVS^m e RNA^m

Os indicadores estatísticos rMBE, rRMSE e d de Willmott, obtidos da comparação dos valores de H_G^m estimado por MVS^m e RNA^m e medida de H_G^m respectivamente para o ano típico e atípico, são representados na Figura (14 a - m).

Para o modelo 1, os valores de rMBE (Figura 14 a) mostram que a MVS1^m subestima a medida em 1,6% (-0,27 MJ m⁻²) no ano típico, e superestima em 0,7% (0,11 MJ m⁻²) no ano atípico. A rede RNA1^m subestima a medida em 3,8% (-0,66 MJ m⁻²) no ano típico, e superestima em 0,9% (-0,15 MJ m⁻²) no ano atípico. Os valores de rRMSE (Figura 14 b) mostram que o espalhamento com MVS1^m é menor para ano típico: rRMSE = 3,0% (0,51 MJ m⁻²) e maior para o atípico com rRMSE = 7,2% (1,22 MJ m⁻²). Para RNA1^m é maior para o ano típico: rRMSE = 4,7% (0,82 MJ m⁻²), e menor para o atípico com rRMSE = 8,8% (1,5 MJ m⁻²). O índice de concordância (*d*) de Willmott (Figura 14 c) obtido com MVS1^m foi numericamente superior em seqüência para os anos típico (0,99) e atípico (0,98), que para ANN1^m, anos típico (0,98) e atípico (0,97), respectivamente.

Para o modelo 2, os valores de rMBE (Figura 14 d) mostram que MVS2^m subestima a medida em 1,9% (-0,32 MJ m⁻²) no ano típico, e superestima em 0,1% (-0,02 MJ m⁻²) no ano atípico. A RNA2^m subestima a medida em 3,4% (-0,59 MJ m⁻²) no ano típico, e também subestima em 0,5% (-0,08 MJ m⁻²) no ano atípico. Os valores de rRMSE (Figura 14 e) mostram que o espalhamento com MVS2^m é menor para ano típico: rRMSE = 3,9% (0,68 MJ m⁻²) e maior para o ano atípico com rRMSE = 6,8% (1,16 MJ m⁻²). Para RNA2^m é maior para o ano típico: rRMSE = 4,9% (0,85 MJ m⁻²), e menor para o atípico com rRMSE = 8,8% (1,49 MJ m⁻²). O índice de concordância (*d*) de Willmott (Figura 14 f) obtido com MVS2^m foi numericamente superior em seqüência para os anos típico (0,98) e atípico (0,99), do que para RNA2^m anos típico (0,97) e atípico (0,97) respectivamente.

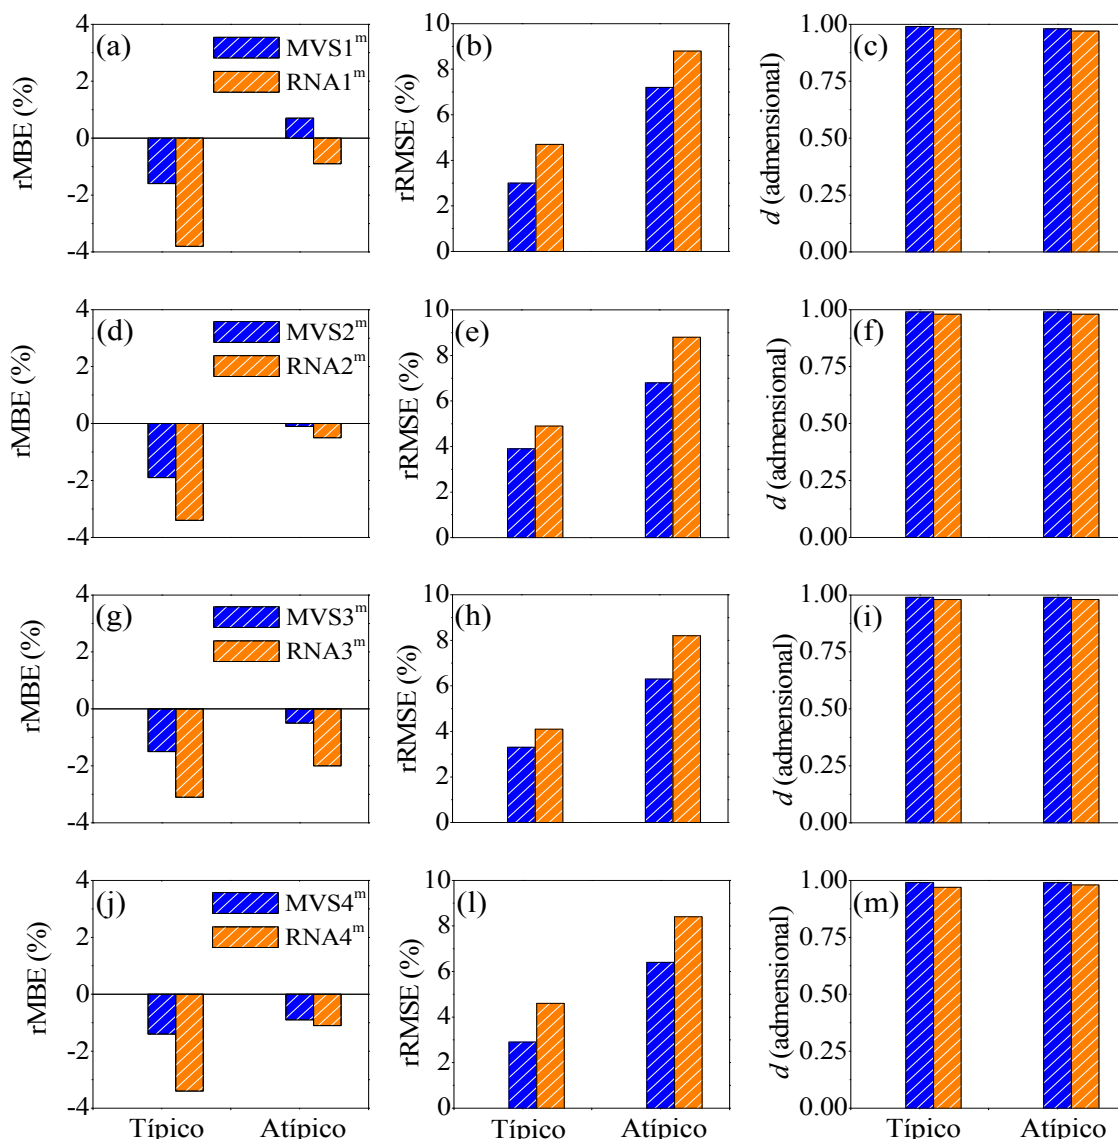


Figura 14. Indicativos estatísticos rMBE (%), rRMSE (%) e *d* de Willmott na validação para anos típico e atípico.

Para o modelo 3, os valores de rMBE (Figura 14 g) mostram que MVS3^m subestima a medida em 1,5% (-0,26 MJ m⁻²) no ano típico, e subestima em 0,08% (-0,5 MJ m⁻²) no ano atípico. A RNA3^m subestima a medida em 3,1% (-0,53 MJ m⁻²) no ano típico, e também subestima em 2,0% (-0,34 MJ m⁻²) no ano atípico. Os valores de rRMSE (Figura 14 h) mostram que o espalhamento com MVS3 é menor para ano típico: rRMSE = 3,3% (0,57 MJ m⁻²) e maior para o ano atípico com rRMSE = 6,3% (1,08 MJ m⁻²). Para RNA3 o valor é maior para o ano atípico: rRMSE = 4,1% (0,71 MJ m⁻²), e menor para o típico com rRMSE = 8,2% (1,39 MJ m⁻²). O índice de concordância (*d*) de Willmott (Figura 14 i) obtido com MVS3^m foi numericamente superior em seqüência para os anos

típico (0,99) e atípico (0,99), do que para RNA3^m anos típico (0,98) e atípico (0,98) respectivamente.

Para o modelo 4, os valores de rMBE (Figura 14 j) mostra que MVS4^m subestima a medida em 1,4% (-0,24 MJ m⁻²) no ano típico, e subestima em 0,9% (-0,15 MJ m⁻²) no ano atípico. A RNA4^m subestima na estimativa em 3,4% (-0,59 MJ m⁻²) no ano típico, e também subestima em 1,1% (-0,18 MJ m⁻²) no ano atípico. Os valores de rRMSE (Figura 14 l) mostram que o espalhamento com MVS4^m é menor para o ano típico: rRMSE = 2,9% (0,50 MJ m⁻²) e maior para o ano atípico com rRMSE = 6,4% (1,08 MJ m⁻²). Para RNA4^m é maior para o ano típico: rRMSE = 8,4% (1,43 MJ m⁻²), e menor para o atípico com rRMSE = 4,6% (0,81 MJ m⁻²). O índice de concordância (*d*) de Willmott (Figura 14 m) obtido com MVS4^m foi numericamente superior em seqüência para os anos típico (0,99) e atípico (0,99), que para RNA4^m nos anos típico (0,97) e atípico (0,98) respectivamente.

6.4 Comparação dos modelos MVS e RNA (diário e mensal) de Botucatu com resultados da literatura

A Tabela (8) mostra uma comparação dos indicativos estatísticos rMBE, MBE, rRMSE, RMSE, *r* ou *R*² em unidades de energia por dia e em percentagem, obtidos nas duas condições de validações, típico e atípico, entre medida e estimativa dos modelos MVS e RNA (diário e mensal) de Botucatu em várias localidades do mundo.

Os valores dos indicativos estatísticos rMBE, MBE, rRMSE, RMSE, *d* de Willmott, *r* e *R*² na comparação entre MVS4 x RNA4 para os anos típico e atípico, mostram que MVS4^d apresenta melhores resultados que RNA4^d nas duas partições, diária e mensal.

A comparação entre MVS4^d x RNA4^d mostra que:

Valores de rMBE_{MVS4^d} = (-2,7%) - 1,6% são inferiores a rMBE_{RNA4^d} = (-13,2%) - (-8,16%); os valores de rRMSE_{MVS4^d} = 9,4% - 12,5% são inferiores a rRMSE_{RNA4^d} = 15,6% - 16,6%; os valores *d* de Willmott *d*_{SVR4^d} = 98,0% - 98,0% são superiores a *d*_{RNA4^d} = 95,0% - 96,0%; os valores de *r*_{MVS4^d} = 96,0% - 97,0% são superiores a *r*_{RNA4^d} = 95,0% - 96,0% e os valores de *R*²_{MVS4^d} = 92,0% - 94,0% são superiores a *R*²_{RNA4^d} = 90,0% - 92,0%.

Similarmente, a comparação entre $MVS1^m$ x $RNA1^m$ mostra que: $rMBE_{MVS1^m} = (-1,6\%) - 0,7\%$ é inferior a $rMBE_{RNA1^m} = (-3,8\%) - (-0,9\%)$; para $rRMSE_{MVS1^m} = 3,0\% - 7,2\%$ é inferior a $rRMSE_{RNA1^m} = 4,7\% - 8,8\%$, para d de Willmott $d_{MVS1^m} = 98,0\% - 99,0\%$ é superior a $d_{RNA1^m} = 97,0\% - 98,0\%$; para a correlação $r_{MVS1^m} = 98,0\% - 99,0\%$ é igual a $r_{RNA1^m} = 98,0\% - 99,0\%$ e para a determinação $R^2_{MVS1^m} = 96,0\% - 98,0\%$ é igual a $R^2_{RNA1^m} = 96,0\% - 98,0\%$.

Há poucas informações do valor de $rMBE$ nos trabalhos com AM (MVS x RNA) citados na Tabela (8), dos quais apenas 3 trabalhos apresentam resultados com RNA e nenhum para MVS (BOSCH et al., 2008; LAM et al., 2008; WAN et al., 2008).

Os valores de $rMBE$ e MBE obtidos neste trabalho com RNA de $(-13,2\%) - (-8,1\%)$ ou $-2,3 \text{ MJ m}^{-2} \text{ dia}^{-1} - 1,38 \text{ MJ m}^{-2} \text{ dia}^{-1}$ para os anos típico e atípico, respectivamente, com o modelo 4 são das mesmas ordem de grandezas dos valores de $rMBE$ dos trabalhos de Lam et al. (2008) e Wan et al. (2008) na China com a mesma da RNA. Resultados similares também são observados nos valores de $rMBE$ dos trabalhos de Bosch et al. (2007) e Linares-Rodriguez et al. (2011) ambos na Espanha. Semelhantemente, os valores de $rMBE$ obtidos por $RNA1^d$ de $-3,8\% - 0,9\%$ ou $-0,66 \text{ MJ m}^{-2} - 0,15 \text{ MJ m}^{-2}$ com o modelo 1 foi superior aos valores de $rMBE$ encontrados por Waewasak et al. (2014) na Tailândia.

Tabela 8. Índices estatísticos obtidos neste trabalho e comparados aos obtidos por outros autores nas partições diária (d) e mensal (m).

Autores	Localidades (N°)	Modelos (Redes neurais)	MBE (MJ m ⁻² dia ⁻¹)	rMBE	RMSE (MJ m ⁻² dia ⁻¹)	rRMSE	r	R ²
			ou (MJ m ⁻²)	(%)	ou (MJ m ⁻²)	(%)		
Chen et al. (2013) ^d	3 (China)	MVS	-	-	1,79 a 2,38	13,4 a 17,4	-	-
Ramedani et al. (2014) ^d	Teerã (Irã)	MVS	-	-	3,30	-	-	0,89
Chen et al. (2015) ^d	32 (China)	MVS	-	-	0,840 a 2,660	-	-	-
Piri et al. (2015) ^d	2 (Irã)	MVS	-	-	1,63 a 2,07	-	-	0,72 a 0,93
Mohammadi et al. (2015a) ^d	Isfahan (Irã)	MVS	-	-	2,01	9,03	-	0,91
Mohammadi et al. (2015a) ^m	Isfahan (Irã)	MVS	-	-	0,45	2,26	-	0,99
Mohammadi et al. (2015b) ^d	Bandar Abbas (Irã)	MVS	-	-	0,66 a 1,85	3,69 a 10,36	-	0,80 a 0,97
Mohammadi et al. (2015b) ^m	Bandar Abbas (Irã)	MVS	-	-	0,662	369	-	0,97
Modelo diário proposto	Botucatu (Brasil)	MVS4^d	-0,47 a 0,28	-2,7 a 1,6	1,64 a 2,14	9,4 a 12,5	0,96 a 0,97	0,92 a 0,94
Modelo mensal proposto	Botucatu (Brasil)	MVS1^m	-0,27 a 0,11	-1,6 a 0,7	0,51 a 1,22	3,0 a 7,2	0,98 a 0,99	0,96 a 0,98
Elizondo et al. (1994) ^d	3 (Estados Unidos)	RNA	-	-	2,92 a 3,64	-	-	0,52 a 0,74
Bocco et al. (2006) ^d	Córdoba (Argentina)	RNA	-	-	3,14 a 3,88	-	0,86 a 0,92	0,96 a 0,99
Bosch et al. (2008) ^d	Granada (Espanha)	RNA	-	-1,2 a 2,1	-	5,0 a 7,5	-	0,98
Lam et al. (2008) ^d	40 (China)	RNA	-2,88 a 1,84	-14,90 a 18,70	1,19 a 3,61	6,9 a 32,6	-	-
Wan et al. (2008) ^d	41 (China)	RNA	-3,08 a 2,14	-16,0 a 18,9	1,27 a 4,00	8,2 a 24,3	-	-
Fortin et al. (2008) ^d	Montreal (Canadá)	RNA	-	-	3,83 a 5,45	-	-	-
Bocco et al. (2010) ^d	Salta (Argentina)	RNA	-	-	1,66 a 2,97	-	-	0,73 a 0,92
Rahimikhoob (2010) ^d	Ahwaz (Irã)	RNA	-	-	2,53	-	-	0,89
Linarez-Rodríguez et al. (2011) ^d	Andaluzia (Espanha)	RNA	-0,470	-	288	16,4	0,94	-
Landeras et al. (2012) ^d	País Basco (Espanha)	RNA	-	-	2,93	-	-	-
Mejdoul et al. (2013) ^d	8 (Marrocos)	RNA	-	-	1,23 a 1,5	-	0,98	-
Waewasak et al. (2014) ^m	Bangckok (Tailândia)	RNA	-0,020 - 0,003	-	0,003 a 0,392	-	-	-
Olatomiwa et al. (2015) ^d	4 (Nigéria)	RNA	-	-	0,55 a 2,98	-	0,37 a 0,86	0,13 a 0,74
Mohammadi et al. (2015b) ^d	Bandar Abbas (Irã)	RNA	-	-	1,81 a 2,05	10,08 a 11,44	-	0,75 a 0,81
Lyra et al. (2015) ^d	Alagoas (Brasil)	RNA	-	-	1,97	10,1	-	0,75
Modelo diário proposto	Botucatu (Brasil)	RNA4^d	-2,30 a - 1,38	-13,2 a -8,1	2,68 a 2,89	15,6 a 16,6	0,95 a 0,96	0,90 a 0,92
Modelo mensal proposto	Botucatu (Brasil)	RNA1^m	-0,66 a -0,15	-3,8 a -0,9	0,82 a 1,50	4,7 a 8,8	0,98 a 0,99	0,96 a 0,98

Os valores de rRMSE obtidos por MVS4^d no intervalo de 9,4% a 12,5% ou em unidades de energia 1,64 MJ m⁻² dia⁻¹ a 2,14 MJ m⁻² dia⁻¹ com o modelo 4 são inferiores aos valores obtidos por Chen et al. (2013) na China e Ramedani et al. (2014) no Irã, e são das mesmas ordem de grandezas dos valores de RMSE dos trabalhos de Piri et al. (2015), Mohammadi et al. (2015a) e Mohammadi et al. (2015b) em Isfahan e Bandar Abbas (Irã).

Os valores de rRMSE e RMSE obtidos por RNA4^d de 16,6% - 15,6% ou em unidades de energia 2,89 MJ m⁻² dia⁻¹ - 2,60 MJ m⁻² dia⁻¹ para os anos típico e atípico com o modelo 4 são inferiores aos valores obtidos por: Elizondo et al. (1994) nos Estados Unidos, Bocco et al. (2006) na Argentina, Landeras et al. (2012) na Espanha e Fortin et al. (2008) no Canadá; e são das mesmas ordem de grandezas dos valores de RMSE dos trabalhos de Lam et al. (2008), Wan et al. (2008) ambas em cidades China, Bocco et al. (2010) na Argentina, Rahimikhoob (2010) no Irã, Linarez-Rodríguez et al. (2011) na Espanha. Os valores de Botucatu são superiores aos valores de RMSE dos trabalhos de Bosch et al. (2007) na Espanha e Mejdoul et al. (2013) no Marrocos, Lyra et al. (2015) no Brasil e na mesma ordem de grandeza dos valores RMSE do trabalho de Olatomiwa et al. (2015) na Nigéria. Similarmente, os valores de rRMSE e RMSE obtidos para RNA1^m no intervalo de 4,7% a 8,8% ou em unidades de energia 0,82 a 1,5 MJ m⁻² mês⁻¹ com o modelo 1 são superiores aos valores obtidos por: Waewasak et al. (2014) na Tailândia.

Os valores de r ou R² obtidos para MVS4^d de 96,0% - 97,0% ou de 92,0% - 94,0% para os anos típico e atípico respectivamente com o modelo 4 são superiores aos valores obtidos por: Ramedani et al. (2014) no Teerã (Irã) e Mohammadi et al. (2015a) em Isfahan (Irã); na mesma ordem de grandeza dos trabalhos: Piri et al. (2015) no Irã, Mohammadi et al. (2015b) em Bandar Abbas (Irã). Similarmente, os valores de r ou R² obtidos para a rede MVS1^m no intervalo de 99,0% a 98,0% ou de 98,0% a 97,0% respectivamente com o modelo 1 é da mesma ordem de grandeza do trabalho de Mohammadi et al. (2015b) em Bandar Abbas (Irã).

Os valores obtidos para RNA4^d para r ou R² de 95,0% - 96,0% ou de 90,0% - 92,0% para os anos típico e atípico respectivamente com o modelo 4 são: superiores aos resultados de Elizondo et al. (1994), Rahimikhoob (2010), Bocco et al. (2007), Linarez-Rodríguez et al. (2011), Olatomiwa et al. (2015), Mohammadi et al.

(2015b) e Lyra et al. (2015); da mesma ordem de grandeza aos trabalhos de Bocco et al. (2010) e inferior ao trabalho de Bosch et al. (2007) e Mejdoul et al. (2013).

6.5 Comparação do desempenho entre os modelos Angstrom-Prescott (A-P) e as redes MVS e RNA (diário e mensal) em Botucatu e de outros locais

A Tabela 9 mostra a comparação dos indicativos estatísticos rMBE, MBE, rRMSE, RMSE, em unidades de energia por dia ou mês, e em porcentagem, e também os valores de r e R^2 , obtidos nas duas condições validações, típico e atípico, entre medida e estimativa dos modelos estatístico de Angstrom-Prescott e das AM's MVS e RNA (diário e mensal) em Botucatu, bem como para outros locais no globo terrestre.

Os valores dos indicativos estatísticos MBE, rMBE, RMSE, rRMSE, d de Willmott, r e R^2 do modelo de A-P e das técnicas de AM (MVS e RNA), obtidas em Botucatu (diário e mensal), mostram que os modelos MVS4^d e MVS1^m apresentaram melhores resultados que o modelo estatístico de (A-P)^d e (A-P)^m e os modelos RNA4^d e RNA1^m nas duas condições de validação, respectivamente.

Os indicativos estatísticos rMBE, MBE, rRMSE, RMSE, d de Willmott, r e R^2 mostram ainda que o modelos mensais (A-P)^m e os modelos MVS1^m e RNA1^m apresentam melhores resultados que o modelo diários (A-P)^d e das redes MVS4^d e RNA4^d, respectivamente.

Os valores dos indicativos estatísticos rMBE, MBE, rRMSE, RMSE d de Willmott, r e R^2 na comparação entre MVS4^d x (A-P)^d para os anos típico e atípico, mostram que o modelo MVS4^d apresenta melhores resultados que o modelo (A-P)^d: nas duas partições, diária e mensal. A comparação entre MVS4^d x (A-P)^d mostram que:

Os valores de $rMBE_{MVS4^d} = -2,7\% - 1,6\%$ são inferiores a $rMBE_{(A-P)^d} = -3,0\% - 1,1\%$; os valores de $rRMSE_{MVS4^d} = 9,4\% - 12,5\%$ são inferiores a $rRMSE_{(A-P)^d} = 13,1\% - 15,7\%$, os valores de d de Willmott $d_{MVS4^d} = 98,0\% - 98,0\%$ são superiores a $d_{(A-P)^d} = 95,0\% - 96,0\%$; os valores de $r_{MVS4^d} = 96,0\% - 97,0\%$ são superiores a $r_{(A-P)^d} = 94,0\% - 94,0\%$ e os valores de $R^2_{MVS4^d} = 92,0\% - 94,0\%$ são superiores a $R^2_{(A-P)^d} = 88,0\% - 88,0\%$.

Similarmente, a comparação entre MVS1^m x (A-P)^m mostra que: os valores de $rMBE_{MVS1^m} = -1,6\% - 0,7\%$ são inferiores a $rMBE_{(A-P)^m} = -2,0\% - 2,1\%$; para $rRMSE_{SVRI^m} = 3,0\% - 7,2\%$ são inferiores a $rRMSE_{(A-P)^m} = 3,9\% - 9,8\%$, os valores do d de Willmott $d_{MVS1^m} = 98,0\% - 99,0\%$ são superiores a $d_{(A-P)^m} = 98,0\% - 98,0\%$; os valores

de $r_{MVS1}^m = 98,0\% - 99,0\%$ são superiores a $r_{(A-P)}^m = 97,0\% - 98,0\%$ e os valores de $R^2_{MVS1}^m = 96,0\% - 98,0\%$ é superior a $R^2_{(A-P)}^m = 96,0\% - 96,0\%$.

Tabela 9. Comparações entre os modelos estatísticos de A-P (partições diária ou mensal) com as técnicas de aprendizado de máquina (AM).

Autores	Localidades (N°)	Modelos	MBE (MJ m⁻² dia⁻¹) ou (MJ m⁻²)	rMBE (%)	RMSE (MJ m⁻² dia⁻¹) ou (MJ m⁻²)	rRMSE (%)	r	R²
Chen et al. (2013) ^d	3 (China)	A-P	-	-	1,99 a 2,28	14,9 a 19,4	-	-
Chen et al. (2013) ^d	3 (China)	MVS	-	-	1,79 a 2,38	13,4 a 17,4	-	-
Mohammadi et al. (2015a) ^d	Isfahan (Irã)	A-P	-	-	2,67	13,9	-	0,85
Mohammadi et al. (2015a) ^d	Isfahan (Irã)	MVS	-	-	2,01	9,0	-	0,91
Mohammadi et al. (2015a) ^m	Isfahan (Irã)	A-P	-	-	1,16	6,0	-	0,96
Mohammadi et al. (2015a) ^m	Isfahan (Irã)	MVS	-	-	0,45	2,26	-	0,99
Piri et al. (2015) ^d	2 (Irã)	A-P	-	-	-3,38 a -2,81	-	-	0,78 a 0,79
Piri et al. (2015) ^d	2 (Irã)	MVS	-	-	1,63 a 2,07	-	-	0,72 a 0,93
Lam et al. (2008) ^d	40 (China)	A-P	-2,88 a 1,84	-14,9 a 18,7	1,19 a 3,61	7,6 a 32,6	-	-
Lam et al. (2008) ^d	40 (China)	RNA	-2,88 a 1,84	-14,90 a 18,70	1,19 a 3,61	6,9 a 32,6	-	-
Wan et al. (2008) ^d	41 (China)	A-P	-3,00 a 2,04	-16,2 a 18,8	1,22 a 3,74	7,4 a 31,3	-	-
Wan et al. (2008) ^d	41 (China)	RNA	-3,08 a 2,14	-16,0 a 18,9	1,27 a 4,00	8,2 a 24,3	-	-
Tymvios et al. (2005) ^m	Nicósia (Chipre)	A-P	-	6,30	-	13,36	-	0,85
Tymvios et al. (2005) ^m	Nicósia (Chipre)	RNA	-	-0,68 a 0,78	-	5,67 a 10,15	-	0,74 a 0,91
Modelo diário proposto	Botucatu (Brasil)	A-P^d	-0,52 a 0,19	-2,98 a 1,10	2,28 a 2,69	13,11 a 15,68	0,94 a 0,94	0,88 a 0,88
Modelo diário proposto	Botucatu (Brasil)	MVS^d	-0,47 a 0,28	-2,7 a 1,6	1,64 a 2,14	9,4 a 12,5	0,96 a 0,97	0,92 a 0,94
Modelo diário proposto	Botucatu (Brasil)	RNA^d	-2,30 a -1,38	-13,2 a -8,1	2,68 a 2,89	15,6 a 16,6	0,95 a 0,96	0,90 a 0,92
Modelo mensal proposto	Botucatu (Brasil)	A-P^m	-0,35 a 0,36	-2,01 a 2,10	0,67 a 1,66	3,94 a 9,76	0,98 a 0,98	0,96 a 0,96
Modelo mensal proposto	Botucatu (Brasil)	MVS^m	-0,27 a 0,11	-1,6 a 0,7	0,51 a 1,22	3,0 a 7,2	0,98 a 0,99	0,96 a 0,98
Modelo mensal proposto	Botucatu (Brasil)	RNA^m	-0,66 a -0,15	-3,8 a -0,9	0,82 a 1,50	4,7 a 8,8	0,98 a 0,99	0,96 a 0,98

Os resultados obtidos para o indicativo estístico rRMSE para os modelos MVS4^d e (A-P)^d: $rRMSE_{SVR4^d} = 1,64\%$ a $2,14\%$ e $rRMSE_{(A-P)^d} = 2,28\%$ - $2,69\%$; neste trabalho concordam com os resultados dos trabalhos por Chen et al. (2013) na China, Mohammadi et al. (2015a) no Irã e por Piri et al. (2015) no Irã. Em todos trabalhos citados a MVS possui melhor performance que o modelo (A-P)^d. O valor de rRMSE para Botucatu são inferiores aos resultados obtidos por Chen et al. (2013) na China com $rRMSE_{MVS^d} = 13,4\%$ a $17,4\%$ e $rRMSE_{(A-P)^d} = 14,9\%$ - $19,4\%$; são da mesma ordem de grandeza aos resultados obtidos por Mohammadi et al. (2015a) no Irã com $rRMSE_{MVS^d} = 9,0\%$ e $rRMSE_{(A-P)^d} = 13,9\%$, e dos resultados obtidos por Piri et al. (2015) no Irã $rRMSE_{MVS^d} = (1,63 \text{ MJ m}^{-2} \text{ dia}^{-1} \text{ a } 2,07 \text{ MJ m}^{-2} \text{ dia}^{-1})$ e $rRMSE_{(A-P)^d} = (-3,36 \text{ MJ m}^{-2} \text{ dia}^{-1} \text{ a } 2,0 \text{ MJ m}^{-2} \text{ dia}^{-1})$. Similarmente, os resultados obtidos para o indicativo estístico rRMSE para MVS1^m e (A-P)^m: $rRMSE_{MVS1^m} = 0,51\%$ a $1,2\%$ e $rRMSE_{(A-P)^m} = 0,67\%$ - $1,66\%$ neste trabalho estão de acordo com os resultados dos trabalhos por Mohammadi et al. (2015a) em Isfahan no Irã com $rRMSE_{MVS^m} = 2,3\%$ e $rRMSE_{(A-P)^m} = 6,0\%$ e valores de $R^2_{MVS^m} = 99,0\%$, e $R^2_{(A-P)^m} = 96\%$.

Os valores dos indicativos estatísticos rMBE, MBE, rRMSE, RMSE, d de Willmott, r e R^2 na comparação entre (A-P)^d x RNA4^d para os anos típico e atípico, mostram que o modelo (A-P)^d apresenta no geral melhores resultados que o modelo RNA4^d nas duas partições, diária e mensal. A comparação entre os modelos (A-P)^d x RNA4^d mostra que:

Os valores de $rMBE_{(A-P)^d} = (-2,98,0\%) - 1,10\%$ são inferiores a $rMBE_{RNA4^d} = -13,2\%$ - $8,16\%$; os valores de $rRMSE_{(A-P)^d} = 13,1\%$ - $15,7\%$, são inferiores a $rRMSE_{RNA4^d} = 15,6\%$ - $16,6\%$, os valores de d de Willmott $d_{(A-P)^d} = 95,0\%$ - $96,0\%$; é igual a $d_{RNA4^d} = 95,0\%$ - $96,0\%$; os valores de $r_{(A-P)^d} = 94,0\%$ - $94,0\%$ são inferiores a $r_{RNA4^d} = 95,0\%$ - $96,0\%$ e para a determinação $R^2_{(A-P)^d} = 88,0\%$ - $88,0\%$ são inferiores a $R^2_{RNA4^d} = 90,0\%$ - $92,0\%$.

Similarmente, a comparação entre (A-P)^m x RNA4^m mostra que: os valores de: $rMBE_{(A-P)^m} = -2,0\%$ - $2,1\%$; são inferiores a $rMBE_{RNA4^m} = (-3,8\%) - (-0,9\%)$; os valores de $rRMSE_{(A-P)^m} = 3,0\%$ - $7,2\%$ são inferiores a $rRMSE_{RNA4^m} = 4,7\%$ - $8,8\%$, os valores de d de Willmott $d_{(A-P)^m} = 97,0\%$ - $98,0\%$; é igual a $d_{RNA4^m} = 97,0\%$ - $98,0\%$; os valores de $r_{(A-P)^m} = 97,0\%$ - $98,0\%$ são inferiores a $r_{RNA4^m} = 98,0\%$ - $99,0\%$ e os valores de $R^2_{(A-P)^m} = 88,0\%$ - $88,0\%$ são inferiores a $R^2_{RNA4^m} = 96,0\%$ - $98,0\%$.

Os resultados obtidos para os indicadores estícticos $rMBE_{(A-P)}^d = -3,0\% - 1,1\%$; $rRMSE_{(A-P)}^d = 13\% \text{ a } 15\%$; e $R^2_{(A-P)}^d$ de $88\% \text{ a } 88\%$ e $rMBE_{RNA4}^d = -13,2\% - 8,1\%$; $rRMSE_{RNA4}^d = 15,6\% \text{ a } 16,6\%$; e $R^2_{RNA4}^d$ de $90\% \text{ a } 93\%$ neste trabalho estão de acordo e na mesma ordem de grandeza com os resultados dos trabalhos de Lam et al. (2008) para 40 cidades na China cujos resultados para os indicadores estícticos $rMBE_{(A-P)}^d = -14,9\% \text{ a } 18,7\%$; $rRMSE_{(A-P)}^d = 7,6\% \text{ a } 32,6\%$; e $rMBE_{RNA4}^d = -14,9\% \text{ a } 18,7\%$; $rRMSE_{RNA4}^d = 6,9\% \text{ a } 32,6\%$. Igualmente, os resultados são na mesma ordem de grandeza aos de Wan et al. (2008) para 41 cidades na China cujos resultados para os indicadores estícticos $rMBE_{(A-P)}^d = -16,2 \text{ a } 18,8\%$; $rRMSE_{(A-P)}^d = 7,4\% \text{ a } 31,3\%$; e $rMBE_{RNA4}^d = -16,0 \text{ a } 18,9\%$; $rRMSE_{RNA4}^d = 8,2\% \text{ a } 24,3\%$.

Os resultados obtidos para os indicadores estícticos $rMBE_{(A-P)}^m = -2,0\% - 2,1\%$; $rRMSE_{(A-P)}^m = 3,94\% \text{ a } 9,76\%$; e $R^2_{(A-P)}^m$ de $96\% \text{ a } 96\%$ e $rMBE_{RNA4}^m = -3,8\% - 0,9\%$; $rRMSE_{RNA4}^m = 4,7\% \text{ a } 8,8\%$; e $R^2_{RNA4}^m$ de $96\% \text{ a } 98\%$ são na mesma ordem de grandeza aos de Tymvios et al. (2005) em Nicosia em Chipre cujos resultados para os indicadores estícticos $rMBE_{(A-P)}^m = 6,30\%$; $rRMSE_{(A-P)}^m = 13,36\%$; e $rMBE_{RNA4}^m = -0,68 \text{ a } 0,78\%$; $rRMSE_{RNA4}^m = 5,67\% \text{ a } 10,15\%$.

7. CONCLUSÃO

7.1 Dos resultados apresentados e discutidos sobre os modelos de estimativa de H_G , em partição diária, conclui-se:

A equação de estimativa de H_G^d de Angstrom-Prescott (A-P)^d, obtidas por meio de regressão linear em Botucatu, SP, com coeficientes de determinação $R^2 = 0,806$ é similar aos resultados alcançados em outras localidades.

Os valores obtidos na correlação $r = 0,942$, com ano típico e $r = 0,939$ para o atípico, entre H_G^d estimada e H_G^d medida, indicam que o modelo (A-P)^d pode estimar H_G com elevados coeficientes de determinação: $R^2 = 88,7\%$ e $R^2 = 88,0\%$, respectivamente.

Os indicativos estatísticos rMBE, MBE, rRMSE, rRMSE e d de Willmott, obtidos na validação, realizaram a comparação dos valores estimados de H_G^d pela equação de estimativa (A-P)^d e medida de H_G^d para os anos típico e atípico: $MBE^d = (-0,52 - 0,19 MJ m^{-2} mês^{-1})$ ou $(-2,98 - 1,10\%)$; $RMSE^d = (2,28 - 2,69 MJ m^{-2} mês^{-1})$ ou $(13,11 - 15,68\%)$; d^d de Willmott = $0,95\% - 0,96\%$, indicam que o modelo (A-P)^d pode ser utilizado na estimativa de H_G^d com precisão e exatidão.

Os valores das correlações r próximos de 1, entre os valores medidos e estimados de H_G^d em anos típico e atípico, pelos modelos gerados com entradas de diferentes parâmetros meteorológicos, mostram que as mesmas podem ser utilizadas nas estimativas de H_G^d com elevadas correlações e coeficientes de determinações:

As técnicas MVS1^d e RNA1^d (modelo 1), com as mesmas variáveis de entrada H_0 e (n/N) que o modelo (A-P)^d, mostram, que as mesmas podem estimar H_G na mesma ordem de grandeza que a equação de Angstrom-Prescott clássica.

Os modelos MVS2^d e RNA2^d tiveram aumentos nos valores de r com a inserção das temperaturas (T , $T_{\text{máx}}$ e $T_{\text{mín}}$) nos modelos MVS1^d e RNA1^d. O maior aumento foi obtido com a RNA2^d, na qual o valor de $r = 0,932$ aumentou para $r = 0,965$ para o ano típico, $r = 0,932$ para $r = 0,951$ no atípico.

Os modelos MVS3^d e RNA3^d, bem como MVS4^d e RNA4^d, tiveram melhoras no desempenho com as inclusões da precipitação e umidade relativas nos modelos 3 e 4 respectivamente. A introdução da precipitação aumentou os valores de r nas redes MVS3^d e RNA3^d. O ganho maior foi obtido com MVS3^d. A introdução da umidade relativa manteve os valores de r , aproximadamente iguais nas duas condições de validações em MVS4^d e RNA4^d.

Na comparação entre desempenho para os modelos (A-P)^d, MVS4^d e RNA4^d por meio dos valores dos indicativos estatísticos r_{MBE} , MBE , r_{RMSE} , RMSE , d de Willmott, r e R^2 obtidos da validação mostrou que:

Entre o modelo (A-P)^d e MVS4^d em Botucatu (diário), a MVS4^d apresentou melhor resultado que o modelo estatístico de (A-P)^d;

Entre os modelos MVS4^d e RNA4^d em Botucatu (diário) a MVS4^d apresentou melhor resultado que a rede RNA4^d;

Entre o modelo (A-P)^d e a RNA4^d em Botucatu (diário), o modelo estatístico (A-P)^d apresentou no geral melhor resultado que RNA4^d.

7.2 Dos resultados apresentados e discutidos sobre os modelos de estimativa de H_G , em partição mensal, conclui-se:

A equação de estimativa (A-P)^m, obtidas por meio de regressão linear em Botucatu, SP, com coeficientes de determinação $R^2 = 0,715$ é da mesma ordem de grandeza aos valores de R^2 obtidos por outros pesquisadores e outros locais do globo terrestre.

Os coeficientes de correlação, $r = 0,976$ e $r = 0,980$, para validação com o ano típico e atípico, mostram que o modelo de (A-P)^m pode estimar H_G^m com elevados coeficientes de determinação: $R^2 = 95,3\%$ e $R^2 = 96,0\%$ respectivamente.

Os valores de r próximos de 1, obtidos na validação por meio de regressão linear entre os valores medidos e os estimados de H_G^m respectivamente, em anos típico e atípico, pelos 4 modelos das AM's MVS e RNA com entradas de diferentes,

parâmetros meteorológicos, mostram que as mesmas podem ser utilizadas nas estimativas de H_G^m com elevadas correlações e coeficientes de determinações:

- Para o **modelo 1**, a $MVS1^m$ e a $RNA1^m$ com mesmas variáveis de entrada H_O e n/N que o modelo $(A-P)^m$ com valores de r próximos dos 100% mostram que as redes podem estimar H_G^m na mesma ordem de grandeza que a equação de Angstrom-Prezcott clássica.

- Para o **modelo 2**, o acréscimo das temperaturas ($T_{máx}$ e $T_{mín}$)^m no treinamento da técnica $MVS1^m$ e a rede $RNA1^m$ diminuíram os coeficientes de correlações para as duas técnicas $MVS2^m$ e $RNA2^m$ no ano típico, e permaneceu aproximadamente iguais no ano atípico.

- Para o **modelo 3** o acréscimo da precipitação nas redes $MVS2^m$ e $RNA2^m$ aumentaram os valores de r , nos mesmos valores aos obtidos com o modelo 1 pelas redes $MVS1^m$ e $RNA1^m$.

Para o **modelo 4**, a introdução da umidade relativa (%) nas redes $MVS3^m$ e $RNA3^m$ mantiveram os valores de r nos mesmos valores aos obtidos com o modelo 1 pelas redes $SVR1^m$ e $RNA1^m$.

Na comparação entre desempenho para os modelos $(A-P)^m$, $MVS1^m$ e $RNA1^m$ por meio dos valores dos indicativos estatísticos $rMBE$, MBE , $rRMSE$, $RMSE$, d de Willmott, r e R^2 obtidos da validação mostrou que:

Entre o modelo $(A-P)^m$ e a técnica $MVS1^m$ em Botucatu (mensal), a técnica $MVS1^m$ apresentou melhor resultado que o modelo estatístico de $(A-P)^m$;

Entre os modelos $MVS1^m$ e $RNA1^m$ em Botucatu (mensal) a técnica $MVS1^m$ apresentou melhor resultado do que a rede $RNA1^m$;

Entre o modelo $(A-P)^m$ e a rede $RNA1^m$ em Botucatu (mensal) o modelo estatístico $(A-P)^m$, apresentou no geral melhor resultado do que a rede $RNA1^m$.

8. REFERÊNCIAS

ALLEN, R. G. et al. **Crop evapotranspiration - guidelines for computing crop water requirements**. Roma: Food and Agriculture Organization of the United Nations (FAO) – Irrigation and drainage paper 56, 1998. 300 p.

ALMOROX, J.; BENITO, M.; HONTORIA, C. Estimation of monthly Anström-PreScott equation coefficients from measured daily data in Toledo, Spain. **Renewable Energy**, v. 30, p. 931-936, 2005.

ALMOROX, J.; BENITO, M.; HONTORIA, C. Estimation of global solar radiation in Venezuela. **Comunicaciones Reports Comunicações**, v. 33, 2008.

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

ALVAREZ, R. Predicting average regional yield and production of wheat in the Argentine Pampas by an artificial neural network approach. **European Journal Agronomy**, v. 30, p. 70-77, 2009.

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.

AMPRATWUM, D. B.; DORVLO, A. S. S. Estimation of solar radiation from the number of sunshine hours. **Applied Energy**, v. 63, p. 161-167, 1999.

ANDRADE JÚNIOR et al. Coeficientes da equação de Angström-PreScott para Parnaíba, Piauí. **Comunicata Scientiae**, n. 3, v. 1, p. 50-54, 2012.

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

ARAÚJO, C. E.; SANTOS, J. M.; SANSIGOLO, C. A. Radiação solar global nas cidades de São Paulo, Rio de Janeiro e Brasília no período de 1978 - 1987. In: **XII Congresso Brasileiro de Agrometeorologia – Fortaleza, 3 a 6 de 2001**.

AZEVEDO, P. V.; VAREJÃO-SILVA, M. A.; VARGAS, G. A. O. **Zoneamento do Potencial de Energia Solar no Nordeste**. UFPB, Campina Grande, 1981.

BACK, A. J. Determinação dos coeficientes da equação de Angstrom-PreScott para a estimativa da radiação solar global para Urussanga, SC. **Revista Brasileira de Agrometeorologia**, v. 13, n. 3, p. 430-435, 2005.

BAKIRCI, K. Correlations for estimation of daily global solar radiation with hours of bright sun shine in Turkey. **Energy**, v. 34, p.485-501, 2009a.

BAKIRCI, K. Models of radiation with hours of bright sunshine: A review. **Renewable and Sustainable**, v. 13, p. 2580-2588, 2009b.

BELÚCIO et al. Radiação solar global estimada a partir da insolação para Macapá (AP). **Revista Brasileira de Meteorologia**, v. 29, n. 4, p. 494 - 504, 2014.

BERUSKY et al. Desempenho de diferentes modelos de estimativa da radiação solar global em Ponta Grossa, PR. **Revista Brasileira de Meteorologia**, v. 30, n. 2, p. 83 - 91, 2015.

BECHINI et al. Modeling, interpolation and stochastic simulation in space and time of global solar radiation. **Agriculture Ecosystems e Environment**, v. 81, p. 29 - 42, 2000.

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.

BOCCO, M.; OVANDO, G.; SAYAGO, S. Development 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.; ARIAS, M. Comparison of regression and neural networks. **Chilean Journal of Agricultural Research**, v. 70, n. 3, p. 428-435, 2010.

BOJANOWSKI et al. An auto-calibration procedure for empirical solar radiation models. **Environmental Modeling e Software**, v. 49, p. 118 - 128, 2013.

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.

BLANCO, F. F; SENTELHAS, P. C. Coeficientes da equação de Angström-PreScott para estimativa da insolação para Piracicaba, SP. **Revista Brasileira de Agrometeorologia**, v. 10, n.2, p. 295-300, 2002.

BLACK, J. N.; BONYTHON, C. W.; PRESCOTT, J. A. Solar radiation and the duration of sunshine. **Quartely Journal of the Royal Meteorological Society**, p. 80: 231-235, 1954.

BRAGA, A. C. P. L.; LEÓN, A. P.; LUDEMIR, T. B. **Redes Neurais Artificiais: Teoria e Aplicações**. 2. ed. Rio de Janeiro: Livros Técnicos e Científicos Editora S. A. – LTC, 2007.

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, 1984.

CARVALHO, L. M. V.; JONES, C.; LIEBMANN, B. The South Atlantic Convergence Zone: Intensity, Form, Persistence, and Relationships with Intraseasonal to Interannual and Extreme Rainfall. **Journal of Climate**, v. 17, p. 88-108, 2004.

CARVALHO et al. Coeficientes da equação de Angstrom-Prescott e sua influência na evapotranspiração de referência em Seropédica, RJ. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 15, n. 8, p. 838-844, 2011.

CEPAGRI – Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura http://www.cpa.unicamp.br/outras-informacoes/clima_muni_086.html, acesso em 14/09/2012.

CERVellini, A.; SALATI, E. Estimativa da distribuição da energia solar no Estado de São Paulo. **Bragantia**, v. 25, n. 3, 1966.

CODATO et al. Global and diffuse solar irradiances in urban and rural areas in southeast Brazil. **Theoretical and Applied Climatology**, v. 93, p.57 - 73, 2008.

COTFAS et al. Monthly average daily global and diffuse solar radiation based on sunshine duration and clearness index for Brasov, Romania. **Journal of Renewable and Sustainable Energy**, v. 6, n. 053106, p. 1 – 16, 2014.

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

CHEN et al. Validation of five global radiation models with measured daily data in China. **Energy Conversion and Management**, v. 45, p. 1759-1768, 2004.

CHEN et al. Estimation of monthly solar radiation from measured temperatures using support vector machines - A case study. **Renew Energy**, v. 36, p. 413-420, 2011.

CHEN, J. L.; LI, G. S.; WU, S. J. Assessing the potential of support vector machine for estimating daily solar radiation using sunshine duration. **Energy conversion and Management**, v. 75, p. 311-318, 2013.

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.

DAI et al. Spatial prediction of soil organic matter content integrating artificial neural network and ordinary kriging in Tibetan Plateau. **Ecological Indicator**, v. 45, p. 184-194, 2014.

DALLACORT et al. Determinação dos coeficientes da equação de Angstrom para a região de Palotina, Estado do Paraná. **Acta Scientiarum. Agronomy**, v. 26, n. 3, p. 329-336, 2004.

DANTAS, A. A. A.; CARVALHO, L. G.; FERREIRA, E. Estimativa da radiação solar global para a região de Lavras, MG. **Ciência e Agrotecnologia**, v. 27, p. 1260 - 1263, 2003.

DEO, R.; SAHIN, M. Application of the Artificial Neural Network model for prediction of monthly standardized precipitation and evapotranspiration index using hydrometeorological parameters and climate indices in eastern Australia. **Atmospheric research**, v. 161-162, p. 65-81, 2015.

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

DONG, J. X.; DEVROYE, L.; SUEN, C.Y. Fast SVM training algorithm with decomposition on very large data sets. **Pattern Analysis and Machine Intelligence**, v. 27, n.4, p. 603-618, 2005.

DORNELAS, K. D. S.; SILVA, C. L.; OLIVEIRA, C. A. S. Coeficientes médios da equação de Angstrom-Prescott, radiação solar e evapotranspiração de referência em Brasília. **Pesquisa Agropecuária Brasileira**, v. 41, n.8, p. 1213-1219, 2006.

DUZEN, H.; AYDIN, H. Sunshine-based estimation of global solar radiation on horizontal surface at Lake Van region (Turkey). **Energy Conversion and Management**, v. 58, p. 35 - 46, 2012.

ELAGIB, N. A.; ALVI, S. H.; MANSELL, M. G. Correlation between clearness index and relative sunshine duration for Sudan. **Renewable Energy**, v. 17, p. 473 - 498, 1999.

EL-METWALLY, M. Sunshine and global solar radiation estimation at different sites in Egypt. **Journal of atmospheric and solar-terrestrial physics**, v. 67, p. 1331 - 1342, 2005.

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.

EMAMGHOLIZADEH, S.; PARSAEIAM, M.; BARADARAN, M. Seed yield prediction of sesame using artificial neural network. **European Journal of Agronomy**, v. 68, p.89 - 96, 2015.

ERTEKIN, C.; YALDIZ, O. Comparison of some existing models for estimating global solar radiation for Antalya (Turkey). **Energy Conversion and Management**, v. 41, p. 311 - 330, 2000.

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

FONTANA, D. C.; OLIVEIRA, D. Relação entre a radiação solar global e insolação para o Estado do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v. 4, n. 1, p. 87 - 91, 1996.

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

GARCÍA NETO et al. Support vector machines and neural networks used to evaluated paper manufactured using *Eucalyptus globulus*. **Applied Mathematical Modelling**, v. 36, p. 6137-6145, 2012.

GLOVER, J.; MCCULLOCH, J.S.G. The empirical relation between solar radiation and hours of sunshine in high-altitude tropics. **Quarterly Journal of the Royal Meteorological Society**, v. 84, p. 65-60, 1958.

HANSEN, W. W. Stochastic daily solar irradiance for biological modeling applications. **Agricultural and Forest Meteorology**, v. 94, p. 53-63, 1999.

HARGREAVES, G. H.; SAMANI, Z. A. Estimating potential evapotranspiration. **Journal of Irrigation and Drainage Engineering**, v. 108, p. 225-230, 1982.

HASNI, et al. Estimating global solar radiation using artificial neural network and climate data in the south-western region of Algeria. **Energy Procedia**, v.18, p. 531 – 537, 2012.

HAYKIN, S. **Neural networks: A comprehensive foundation**. 2nd ed. Hamilton: Prentice Hall, 1998, 897 p.

HAYKIN, S. **Redes Neurais: Princípios e prática**. Trad. Paulo Martins Engel. – 2. ed. – Porto Alegre: Bookman, 2001, 900 p. [in portuguese].

HENG, L. K et al. AquaCrop – The FAO crop model to simulate yield response to water: III. Parameterization and testing for maize. **Agronomy Journal**, v. 101, p.448-459, 2009.

HEINEMANN et al. Sensitivity of APSIM/ORYZA model due to estimation errors in solar radiation. **Bragantia, Campinas**, v. 71, n. 4, p.572-582, 2012.

HINRICHSEN, K. The Angstrom formula with coefficients having a physical meaning. **Solar Energy**, v. 52, p. 491-495, 1994.

HOKKANEN, A. et al. Predicting sleep and lying time of calves with a support vector machine classifier using accelerometer data. **Applied Animal Behavior Science**, v. 134, p. 10-15, 2011.

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

HUO et al. Artificial neural network models for reference evapotranspiration in an arid area of northwest China. **Journal of Arid Enviroments**, v. 82, p. 81-90, 2012.

HUSSAIN, M. Improved station-independent correlations between global radiation and sunshine duration. **Energy Conversion and Management**, v. 30, n. 2, p. 163-172, 1990.

IQBAL, M. **An introduction to solar radiation**. New York: Academic Press, 1983. 390 p.

ITUEN et al. Prediction of global solar radiation using relative humidity, maximum temperature and sunshine hours in Uyo, in the Niger Delta Region, Nigeria. **Advances in Applied Science Research**, v. 3, n. 4, p. 1923-1937, 2012.

IZIOMON, M. G.; MAYER, H. Performance of solar radiation models – a case study. **Agricultural and forest meteorology**, v. 110, p. 1-11, 2001.

JAMIESON, P. D.; PORTER, J. R.; WILSON, D. R. A test of the computer simulation model ARC - WHEAT1 on wheat crops grown in New Zealand. **Field Crops Research**, v.27, p.337-350, 1991.

KAUL, M.; HILL, R.; WALTHALL, C. Artificial Neural Network for corn and soybean yield prediction. **Agricultural Systems**, v.85, p.1-18, 2005.

KISI, O.; ÇIMEN, M. Evapotranspiration modelling using support vector machines. **Hydrology Science Journal**, v. 54, n. 5, p. 918–928, 2009.

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.

KHOSHNEVISAN, B.; RAFIEE, S.; MOUSAZADEH, H. Enviroment impact assessment of open field and greenhouse strawberry production. **European Journal of Agronomy**, v. 50, p. 29-37, 2013.

LAM et al. Climatic influences on solar modeling in China. **Renewable Energy**, v. 33, p. 1591-1604, 2008.

LANDERAS, G.; LÓPEZ, J. J.; KISI, O.; SHIRI, J. 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.

LAPERUTA FILHO, J. **Modelos de estimativa da radiação solar global diária e horária em Botucatu-SP**. 1996, 124 f. Tese (Doutorado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, 1996.

LEMOS, C.F.; CALBETE, N. O. Sistemas frontais que atuaram no litoral de 1987-1995. **Climanálise**, Edição comemorativa 10 anos, 1996. (INPE-10717-PRE/6178).

LI et al. Global solar radiation estimation with sunshine duration in Tibet, China. **Renewable Energy**, v. 36, p. 3141-3145, 2011.

LI et al. Impact of time interval on the Angstrom-Prescott coefficients and their interchangeability in estimating radiation. **Renewable Energy**, v. 44, p. 431 - 438, 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.

LINARES-RODRÍGUEZ 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 et al. Estimation of solar radiation in Australia from rainfall and temperature observations. **Agricultural Forest and Meteorology**, v. 106, p. 41-59, 2001.

LIU et al. Calibration of the Angström-Prescott coefficients (a , b) under different times scales and their impacts in estimating global solar radiation in the Yellow River Basin. **Agricultural Forest and Meteorology**, v. 149, p. 697-710, 2009.

LIU et al. Evaluating a coupled discrete wavelet transform and support vector regression for daily and monthly streamflow forecasting. **Journal of Hydrology**, v. 519, p. 2822 - 2831, 2014.

LORENA, A. C. et al. Comparing machine learning classifiers in potential distribution modelling. **Expert Systems with Applications**, v.38, p.5268 - 5275, 2011.

LOU et al. Integrating Support Vector Regression with Particle Swarm Optimization for numerical modeling for algal blooms of freshwater. **Applied Mathematical Modelling**, v.39, p. 5907 - 5916, 2015.

LUNA et al. Prediction of ozone concentration in tropospheric levels using artificial neural networks and support vector machine at Rio de Janeiro, Brazil. **Atmospherical Environment**, v. 98, p. 98-104, 2014.

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

MANZANO et al. A single method to estimate the daily global solar radiation from monthly data. **Atmospheric Research**, v. 166, p. 70 - 82, 2015.

McCULLOCH, W. S.; PITTS, W. A Logical Calculus of the Ideas Immanent in Nervous Activity. **Bulletin of Mathematical Biophysics**, New York, US, v. 5: p. 115 - 133, 1943.

MARTÍ, P.; GASQUE, M. Improvement of temperature-based ANN models for solar radiation estimation through exogenous data assistance. **Energy Conversion and Management**, v. 52, p. 990 - 1003, 2011.

MARTIM et al. Coeficientes de Angstrom-Prescott para a Região Norte do Mato Grosso: primeira aproximação. In: **XLII Congresso Brasileiro de Engenharia Agrícola – Campo Grande, 27 a 31 de julho 2014**.

MARTÍNEZ-LOZANO et al. The historical evolution of the Angstrom Formula and its modifications. **Agricultural and Forest Meteorology**, v.33, n.2-3, p. 109 - 128, 1984.

MEJDOUL, R. M. T.; BELOUAGGADIA, N. Artificial neural network based prediction model of daily global solar radiation in Morocco. **Journal of Renewable and Sustainable Energy**, v. 5, p. 063137 1 – 9, 2013.

MESA, 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.

MITCHELL, T. M. **Machine learning**. Boston: McGraw Hill Companies Inc., 1997, 414p.

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

MOHAMMADI et al. A new hybrid support vector machine-wavelet transform approach for estimation of horizontal global solar radiation. **Energy Conversion and Management**, v. 92, p. 162 - 171, 2015b.

MOTA, F. S.; BEIRSDORF, M. I. C.; ACOSTA, M. J. C. Estimates of solar radiation in Brazil. **Agricultural Meteorological**, v. 18, p. 241-254, 1977.

NGUYEN, B. T.; PRYOR, T. L. The relationship between global solar radiation and sunshine duration in Vietnam. **Renewable Energy**, v. 11, p. 47-60, 1997.

NICÁCIO, R. M.; SOUZA, J. L.; BERNARDO, S. O. Estimativa da irradiância solar global para Maceió utilizando o modelo linear de Angstrom-Prescott. In: **XII Congresso Brasileiro de Agrometeorologia – Fortaleza, 3 a 6 de 2001**.

NOGUÉS-PAEGLE, J.; MO, K.C. Alternating wet and dry conditions over South America during summer. **Monthly Weather Review**, v. 125, p 279-291, 1997.

OLATOMIWA et al. A support vector machine-firelyalgorithm-based model for global solar radiation prediction. **Solar Energy**, v. 115, p. 632-644, 2015.

OMETTO, J.C. **Bioclimatologia vegetal**. São Paulo: Ceres, 1981. 425 p.

ONYANGO, O. A.; ONGOMA, V. Estimation of mean monthly global solar radiation using sunshine hours for Nairobi City, Kenya. **Journal of renewable and sustainable energy**, v. 7, n. 053105, p. 1 – 9, 2015.

PARK, J.; DAS, A.; PARK, J. H. A new approach to estimate the spatial distribution of solar radiation using topographic factor and sunshine duration in South Korea. **Energy Conversion and Management**, v. 101, p. 30-39, 2015.

NICÁCIO, R. M.; SOUZA, J. L.; BERNARDO, S. O. Estimativa da irradiância solar global para Maceió utilizando o modelo linear de Angstrom-Prescott. In: **XII Congresso Brasileiro de Agrometeorologia – Fortaleza, 3 a 6 de 2001**.

PACHECO, N. A.; BASTOS, T. X. Estimativa da radiação solar global diária em Capitão Poço, PA através da equação de Angstrom. In: **XII Congresso Brasileiro de Meteorologia – Foz do Iguaçu, 2002**.

PEREIRA et al. Estimativa da radiação solar global para a Região de Pedra Azul. **Enciclopédia Biosfera**, v. 6, n. 11, p. 1 - 9, 2010.

PILAU, F. G., BARBIERI, V., MARIN, F. R. Coeficientes da equação de Angström-Prescott para estimativa da irradiância solar global na região de Araras, SP. **Revista Brasileira de Agrometeorologia**, v. 15, n.1, p. 109-113, 2007.

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

PODESTÁ et al. Estimating daily solar radiation in the Argentine Pampas. **Agricultural and Forest Meteorology**, v. 123, p. 41-53, 2004.

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

PRESCOTT, J. A. Evaporation from a water surface in relation to solar radiation. **Transactions of the Royal Society Science Australian**, Adelaide, v. 64, p. 114 - 118, 1940.

QUANSAH et al. Empirical Models for estimating global solar radiation over the Ashanti Region of Ghana. **Journal of Solar Energy**, Volume 2014, Article ID 897970, 6 pages <http://dx.doi.org/10.1155/2014/897970>.

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

RAHIMIKHOOB, A. Estimating global solar radiation using artificial neural network and air temperature data in a semi-arid environment. **Renewable Energy**, v. 35, p. 2131-2135, 2010.

RAMEDANI et al. Potential of radial basis function based support vector regression for global solar radiation prediction. **Renewable and Sustainable Energy Reviews**, v. 39, p. 1005-1011, 2014.

RAGHAVENDRA, S.; DEKA, P. C. Support vector machine applications in the field of hydrology: A review. **Applied Soft Computing**, v.19, p.372 - 386, 2014.

REDA, I.M.; MYERS, D.R.; STOFFEL, T.L. Uncertainty estimate for the outdoor calibration of solar pyranometers:NCSLI Measure. **The Journal of Measurement Science**, v. 3, n.4, p. 58-66, 2008.

REHMAN, S.; MOHANDRES, M. Artificial neural network estimation of global solar radiation using air temperature and relative humidity. **Energy Policy**, v. 36, p. 571-576, 2008.

RIBEIRO et al. Radiação solar disponível em Manaus (AM) e sua relação com a duração do brilho solar. **Acta Amazonica**, v. 12, n.2, p. 339-346, 1982.

ROBINSON, N. **Solar radiation**. New York: Elsevier, 1966. 347 p.

RUMELHART, D. E.; HINTON, G. E., WILLIAMS, R. J. Learning representations by backpropagation errors. **Nature**, London, UK, v. 323: p. 533 – 536, 1986.

SABZIPAVAR et al. An improved estimation of the Angstrom-Prescott radiation coefficients for the FAO 56 Penman-Monteith evapotranspiration method. **Water Resources Management**, v. 27, p. 2839-2854, 2013.

SANTOS et al. Estimativa da radiação solar global diária em Ilha Solteira, São Paulo. In: **XXXII Congresso Brasileiro de Engenharia Agrícola – 28 de julho a 01 de agosto de 2003**.

SANTOS et al. On modeling global solar irradiation using air temperature for Alagoas State, Northeastern Brazil. **Energy**, v. 71, p. 338 - 398, 2014.

SATYAMURTY, P.; NOBRE, C. A.; SILVA DIAS, P. L. Topics: South America. **Meteorological Monographs**, v.27, n.49, p.119-139, 1998.

SOARES et al. Modeling hourly diffuse solar radiation in the city of São Paulo using a neural-network technique. **Applied Energy**, v. 79, p. 201-214, 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.

SOUZA, J. L., NICÁCIO, R. M., MOURA, M. A. L. Global solar radiation measurements in Maceió, Brasil. **Renewable Energy**, v. 30, p. 1203-1220, 2005.

SOUZA et al. Empirical models of daily and monthly global solar irradiation using sunshine duration for Alagoas State, Northeastern Brazil. **Sustainable Energy Technologies and Assessments**, v. 14, p. 35-45, 2016.

SOUZA, K.; ANDREWS, R. Models for daily global solar radiation for the Caribbean island of Trinidad. **Journal of Renewable and Sustainable Energy**, v. 7, n. 013132, p. 1 – 17, 2015.

SHRESTHA, N. K.; SHUKLA, S. Support vector machine based modeling of evapotranspiration using hydro-climatic variables in a sub-tropical environment. **Agricultural and Forest Meteorology**, v. 200, p. 172 - 184, 2015.

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

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

TABARI et al. SVM, ANFIS, regression and climate based models for reference evapotranspiration modeling using limited climatic data in a semi-arid highland environment. **Journal of Hydrology**, v. 444 - 445, p. 78-89, 2012.

TADROS, M. T. Y. Uses of sunshine duration to estimate the global solar radiation over eight meteorological stations in Egypt. **Renewable Energy**, v. 21, p. 231-246, 2000.

TARIFA, J. R. Estimativa da radiação solar em função da insolação para Presidente Prudente. **Caderno de Ciências da Terra**, n. 22, p. 1-15, 1972.

TERAMOTO, É. T. **Transmissividade atmosférica da radiação solar UV: análise climática e modelos de estimativa**. 2013. 88 f. Tese (Doutorado em Agronomia/Energia na Agricultura) – Faculdade de Ciências Agrônômicas, Universidade Estadual Paulista, 2013.

TEXEIRA et al. Radiação solar global e insolação no município de Juazeiro-BA. In: **XII Congresso Brasileiro de Meteorologia – Foz do Iguaçu, 2002**.

TIBA, C. Solar radiation in the Brazilian Northeast. **Renewable Energy**, v. 22, p. 565-578, 2001.

TORRES et al. Determinação dos coeficientes do modelo de Angstrom-Preseott para a Região de Canavieiras, Estado da Bahia. **Enciclopédia Biosfera**, v. 6, n. 11, 2010.

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.

VALIATI, M. I.; RICIÉRI, R. P. **Estimativa da irradiação solar global com partição mensal e sazonal para a região de Cascavel-PR**. Revista Engenharia Agrícola, Jaboticabal, v. 25, n.1, p. 76-85, 2005.

- VAPNIK, V. N. **The nature of statistical learning theory**. New York: Springer, 1995.
- VAPNIK, V. N. **Statistical learning theory**. New York: Wiley, 1998.
- VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. Viçosa: Editora UFV, 2012. 460 p.
- WAEWSAK, J. et al. Estimation of monthly mean daily global solar radiation over Bangkok, Thailand using artificial neural network. **Energy Procedia**, v. 57, p. 1160-1168, 2014.
- WAN et al. An analysis of thermal and solar zone radiation models using an Angstrom- Prescott equation and artificial neural networks. **Energy**, v. 33, p. 1115-1127, 2008.
- WEISS, A.; HAYS, C. Simulation of daily solar irradiance. **Agricultural and Forest Meteorology**, v. 123, p. 187 - 199, 2004.
- WILLMOTT, C. J. On the validation of models. **Physical Geography**, v.2, p.184 - 194, 1981.
- WITTEN, I. H.; FRANK, E.; HALL, M. A. **Data Mining: Practical Machine Learning Tools and Techniques**. 3 rd ed. 2011, 630 p
- YANG, H. et al. Features, Applications, and limitations of the hybrid-Maize simulation model. **Agronomy Journal**, v.98, p.737-748, 2006.
- YU, P.; CHEN, S.; CHANG, I. Support Vector Regression for real time flood stage forecasting. **Journal of Hidrology**, v.328, p.704-716, 2006.
- ZANETTI et al. Estimativa da evapotranspiração de referência no Estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 12, p. 174-180, 2008.
- ZHAO, N., ZENG, X., HAN, S. Solar radiation estimation using sunshine hour and air pollution index in China. **Energy Conversion and Management**, v. 76, p. 846-851, 2013.