

USO DE MODELOS ESTATÍSTICOS E DE MÁQUINA DE VETORES DE SUPORTE NA ESTIMATIVA DA RADIAÇÃO SOLAR GLOBAL DIÁRIA EM IGUAPE, VALE DO RIBEIRA, SÃO PAULO.

Érico Tadao Teramoto, João Francisco Escobedo, Cícero Manoel Santos, Bruno Henrique Dobner Silveira, Eduardo Nardini Gomes, Silvia Helena Modenese Gorla Silva

Recibido 08/08/16, aceptado 09/10/16

RESUMO: Neste trabalho foram ajustados e validados dois modelos empíricos para a estimativa da radiação global (R_G) diária em Iguape/SP/Brasil, os quais foram utilizados como referência na avaliação do desempenho da máquina de vetores de suporte (SVM) estimando a R_G diária. Os dados diários de R_G , precipitação (P) e de temperaturas do ar máxima (T_{max}) e mínima (T_{min}) foram medidos na estação meteorológica do INMET em Iguape no período de 2008 a 2011. Os resultados obtidos apresentaram boa concordância entre os dados medidos e estimados, com R^2 variando entre 0,70 e 0,75. Dentre os modelos empíricos ajustados, o DeJong-Stewart apresentou o melhor desempenho. Como esperado, a SVM apresentou melhor desempenho quando comparada aos modelos empíricos, com MBE variando de -3,16% a 2,18% e RMSE de 26,67% a 28,31%. A SVM utilizando as variáveis de entrada T_{max} , T_{min} , radiação solar extraterrestre e P foi o único método dentre os testados que gerou um conjunto de dados estimados similar estatisticamente aos dados medidos.

Palavras-chave: Hargreaves-Samani; DeJong-Stewart; Temperatura do ar; Chuva.

INTRODUÇÃO

No Estado de São Paulo, o Vale do Ribeira é considerado uma região importante ao abrigar mais de 50% da Mata Atlântica remanescente no Brasil e por sua biodiversidade presente em ecossistemas aquáticos (rio, estuário e mar) e terrestres (duna, mangue, restinga e floresta ombrófila densa) (IBGE, 2015). A porção paulista do Vale do Ribeira abrange 40 municípios, sendo desse total 18 parcialmente inseridos na região, e possui economia baseada na agricultura, com destaque às produções de banana, chá-da-índia e palmito (IBGE, 2016). A pesca, a piscicultura e o turismo são outras atividades de destaques na região do Vale do Ribeira.

Atualmente, um dos grandes desafios para os municípios que compõem o Vale do Ribeira é realizar a expansão e o desenvolvimento sustentável da agricultura e da aquicultura, com aproveitando dos recursos naturais locais de maneira racional e trazendo desenvolvimento social e econômico. E dentro desse contexto há o interesse no aproveitamento de energia solar nos processos de conversão térmica e fotovoltaica aplicados na produção agropecuária.

Para o dimensionamento, planejamento financeiro e simulação de sistemas destinados ao aproveitamento da energia solar torna-se importante o estudo do potencial solar no local de implantação do projeto (Hamed et al., 2014), que pode ser realizado a partir de dados medidos da radiação solar global (R_G , 300-2800 nm). A R_G também é um elemento importante em estudos agrícolas voltados ao manejo de irrigação e de produtividade potencial, pois é um dos principais fatores condicionantes da temperatura do ar, do solo e da Evapotranspiração (Allen, 1998). Porém, em algumas regiões brasileiras, como é o caso do Vale do Ribeira, o monitoramento da R_G em estações meteorológicas ainda permanece escasso. O problema é devido ao elevado custo de aquisição e de manutenção dos sensores para monitoramento e a necessidade de calibração periódica para assegurar a qualidade dos dados medidos. Mesmo nos locais onde há o monitoramento, verifica-se a ocorrência de dias ou mesmo meses em que não houve o registro da

R_G devido à calibração imprópria ou mau funcionamento dos equipamentos de medição empregados.

Na ausência do monitoramento ou para completar séries temporais em locais de interesse, dados de R_G podem ser obtidos utilizando modelos empíricos, imagens de satélite ou técnicas de aprendizado de máquinas (TAM). Dentre os três métodos, devido a facilidade de aplicação e relativa precisão, os mais utilizados são os modelos empíricos, que são baseados na correlação entre a R_G e outras variáveis medidas rotineiramente em estações meteorológicas. As variáveis meteorológicas mais utilizadas são: temperatura do ar, insolação, umidade do ar, precipitação pluviométrica. Um exemplo de modelo empíricos muito conhecido e utilizado é o proposto por Hargreaves (1981), que serviu de base para outros modelos propostos ao longo do tempo e é baseado na relação entre a variação da R_G e a variação da temperatura do ar. Tal relação é explicada devido a parte do saldo de radiação determinar a variação do calor sensível do ar influenciando a diferença entre as temperaturas do ar máxima e mínima (Bristow; Campbell, 1984).

Paralelas aos modelos empíricos, as TAM foram nos últimos vinte anos foco de estudos e tornaram-se métodos alternativos aos modelos convencionais de estimativa (Jian, 2009; Yadav e Chandel, 2013; Raghavendra e Deka, 2014; Mohammadi et al., 2015), processo que ocorreu com o desenvolvimento e popularização dos microcomputadores e a disponibilidade de compilações gratuitas e de fácil utilização (Hall et al., 2009). E como vantagens atribuídas às TAM em relação aos demais métodos utilizados na estimativa de R_G estão: permitem o trabalho com uma quantidade muito maior de variáveis de entrada, melhorando a capacidade de predição; possuem uma boa capacidade de generalização mesmo na presença de dados espúrios (Rumelhart et al., 1986; Yadav e Chandel, 2013).

Dentre as várias TAM disponíveis, as redes neurais artificiais (RNAs) são as mais conhecidas e utilizadas (Ozgoren et al., 2012; Yadav e Chandel, 2013; Amrouche e Pivert, 2014; Jacovides et al., 2015; Kumar et al., 2015). O nome RNAs é uma referência ao cérebro humano devido à habilidade delas de aprender a partir de exemplos, com base na associação de padrões em variáveis (Haykin, 1998). Porém, atualmente, outra TAM tornou-se foco de estudos devido ao seu bom desempenho na estimativa de séries temporais: máquinas de vetores de suporte (SVM). A maioria dos estudos divulgados na literatura verificaram maior precisão da SVM na estimativa da R_G quando comparada aos modelos empíricos ou mesmo às RNA (Chen et al., 2011; Wu; Liu, 2012; Chen et al., 2013; Mohammadi et al., 2015;).

Com base nas informações citadas acima, no presente estudo foram ajustados e validados dois modelos empíricos para estimativa da R_G em Iguape, cidade localizada na porção paulista do Vale do Ribeira. Mantendo os modelos empíricos como referência, avaliou-se o desempenho da SVM na estimativa da R_G . A partir dos resultados será possível selecionar o melhor método de estimar a R_G em Iguape, o qual será utilizado para completar uma série temporal de sete anos para estudos climáticos e aplicações agrícolas.

MATERIAL E MÉTODOS

Local de estudo e obtenção dos dados

Os dados de radiação solar global diária, temperaturas do ar máxima e mínima e precipitação pluvial utilizados neste estudo foram medidos pela estação meteorológica automática pertencente ao Instituto Nacional de Meteorologia (INMET) instalada em Iguape. O período de medição foi de janeiro de 2008 a dezembro de 2011. Tais dados estão disponíveis no endereço eletrônico da própria instituição (<http://www.inmet.gov.br>).

O município de Iguape possui 30390 habitantes, com área territorial total de 1.977.957 Km² (IBGE, 2016), estando localizada no litoral sul paulista, na região do Vale do Ribeira (Figura 1). Integra-se na Bacia Hidrográfica do Ribeira e situa-se no corredor do Mercosul, entre duas importantes capitais: São Paulo e Curitiba. A cidade abriga em seu território aproximadamente 70% de área natural protegida, que inclui a Estação Ecológica dos Chauás e cerca de 85% da Estação Ecológica Juréia-Itatins, além de estar parcialmente em Área de Proteção Ambiental (APA – Cananéia-Iguape-Peruíbe).

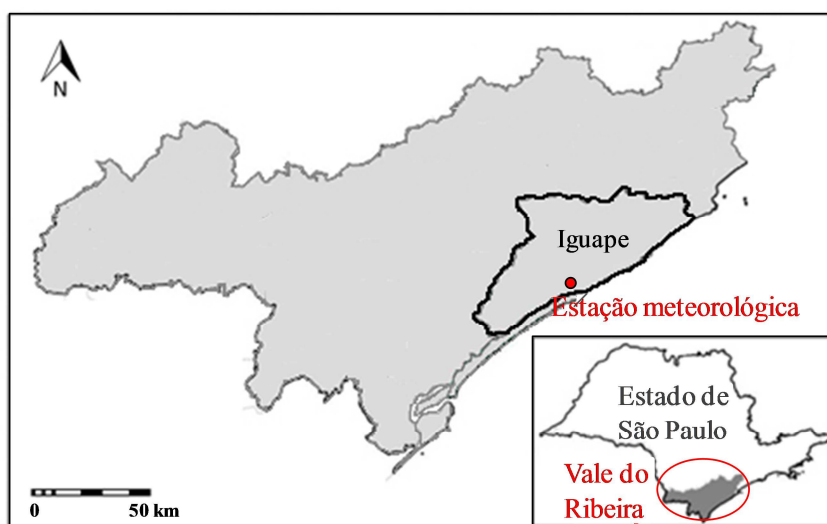


Figura 1: Localização da estação meteorológica.

O clima local foi classificado pelo Centro de Pesquisas Meteorológicas e Climáticas Aplicadas à Agricultura (CEPAGRI), segundo a classificação de Köppen como Af, Clima tropical úmido ou superúmido, sem estação seca. Nos meses mais quentes a temperatura máxima chega a 31°C e nos meses mais frios atinge 14°C, com temperatura média de 26,6°C. A precipitação pluviométrica anual acumulada é de 1900mm (CEPAGRI, 2016).

Com o propósito de desenvolver, testar e validar os modelos (empíricos e SVM), as bases totais de dados foram divididas em duas partes: base de dados de treinamento (75% da base total de dados) e base de dados de validação (25% da base total de dados). Além disto, o desempenho dos modelos avaliados neste trabalho será avaliado por meio dos parâmetros estatísticos amplamente utilizados MBE (erro médio absoluto) e RMSE (raiz quadrada do erro médio) (Escobedo et al., 2011; Jacovides et al., 2015). O MBE será utilizado para avaliar quanto o modelo subestima (MBE < 0) ou superestima (MBE > 0) os valores de radiação (em percentual). A extensão do erro na estimativa é avaliada a partir do RMSE (em percentual). Para verificar se os modelos analisados se diferenciam estatisticamente quando a precisão, utilizou-se o teste t com nível de significância $\alpha = 5\%$ (Stone, 1993). Os parâmetros estatísticos são calculados a partir das seguintes equações:

$$MBE = 100 * \frac{n^{-1} \sum_{i=1}^n (R_{E_i} - R_{M_i})}{\bar{X}} \quad (1)$$

$$RMSE = 100 * \frac{\sqrt{n^{-1} \sum_{i=1}^n (R_{E_i} - R_{M_i})^2}}{\bar{X}} \quad (2)$$

onde R_{E_i} é o valor estimado, R_{M_i} é o valor medido, $\bar{X} = (\sum_{i=1}^n R_{M_i})/n$ é a média dos valores medidos e n é o número de observações.

Modelos empíricos

Foram ajustados dois modelos empíricos, ambos que utilizam variáveis meteorológicas comumente medidas em estações meteorológicas de superfície: Hargreaves-Samani (HS), equação 3 (Hargreaves e Samani, 1982), que utiliza como variáveis de entrada as temperaturas do ar máxima e mínima; DeJong-Stewart (DS), equação 4 (DeJong e Stewart, 1993), que utiliza como variáveis de entrada as temperaturas do ar máxima e mínima e a precipitação pluviométrica.

$$R_G = R_0 a \sqrt{\Delta T} \quad (3)$$

$$R_G = R_0 a \Delta T^b (1 + cP + dP^2) \quad (4)$$

onde R_0 é a radiação solar extraterrestre diárias (que foi calculada segundo metodologia divulgada por Iqbal (1983)), ΔT é a diferença entre a temperatura máxima e mínima do ar (amplitude térmica), expressa em °C; P é a precipitação pluvial diária, expressa em mm; e "a", "b" e "c" são coeficientes a serem ajustados para cada local.

Máquinas de vetores de suporte

A SVM foi originalmente desenvolvida por Vapnik (1998), com base na Teoria do Aprendizado Estatístico, e é amplamente utilizado para resolver problemas de classificação, regressão e previsão (Chen e Li, 2013; Raghavendra e Deka, 2014; Mohammadi et al., 2015; Shamshirband et al., 2015). No caso da estimativa de séries temporais, a SVM apresenta elevado desempenho que é atribuído à dois fatores (Cao, 2003): (1) resistência ao "overfitting"; (2) a solução para a função f obtida durante o treinamento é sempre única e globalmente otimizada.

O desempenho e capacidade de aprendizado da SVM na regressão são atribuídos ao uso de um conjunto de funções de Kernel, que diagramam as informações para um espaço de dimensões maiores (Vapnik, 1998). A SVM possui 4 tipos básicos de funções de Kernel, que incluem sigmoidal, linear, polinomial e de base radial. A função de Kernel mais utilizada é a função de base radial (RBF) (Mohammadi et al., 2015). Para permitir maior flexibilidade na aplicação da RBF, é necessário o ajuste adequado dos parâmetros C (custo), γ (gamma) e ϵ (epsilon) (Raghavendra e Deka, 2014). Maiores detalhes sobre a teoria e evolução da SVM podem ser obtidos em Vapnik (1998).

No presente trabalho os modelos utilizando a SVM serão implementados utilizando o software gratuito WEKA (Waikato Environment for Knowledge Analysis) (Hall et al., 2009; Witten et al., 2011). O WEKA é um conjunto de TAM para mineração de dados, que está disponível em <http://www.cs.waikato.ac.nz/~ml/weka/>. Baseado nos modelos empíricos HS e DS, os modelos SVM utilizarão como variáveis de entrada a radiação solar no topo da atmosfera (R_0), a temperaturas máxima (T_{max}) e mínima (T_{min}) do ar e a precipitação pluvial (P).

Nesse caso serão avaliados dois modelos SVM (Tabela 1), que serão simbolizados como SVM(x), onde o x indica as variáveis de entrada utilizadas: (1) R_0, T_{\max} e T_{\min} - similar ao HS; (2) R_0, T_{\max}, T_{\min} e P - similar ao DS. Devido à eficiência computacional, no presente estudo será utilizada a função de Kernel de Base Radial (RBF). Os valores selecionados para os parâmetros da RBF são: $C = 300$, $\gamma = 0,3$ e $\varepsilon = 0,005$.

Modelo	Variáveis de entrada
SVM(1)	R_0, T_{\max} e T_{\min}
SVM(2)	R_0, T_{\max}, T_{\min} e P

Tabela 1: Variáveis de entrada para os modelos SVM.

RESULTADOS E DISCUSSÃO

Abaixo são apresentados os modelos Hargreaves-Samani (HS, equação 5) e DeJong-Stewart (DS, equação 6) com os coeficientes ajustados para Iguape utilizando os dados medidos no período de janeiro de 2008 a dezembro de 2009.

$$R_G = 0,1728R_0\sqrt{\Delta T_1} \quad (5)$$

$$R_G = 0,1559R_0\Delta T_1^{0,5637} (1 - 0,0113P + 6 \times 10^{-5} P^2) \quad (6)$$

No modelo HS, o coeficiente "a" ajustado está próximo do recomendado por Allen et al. (1998) para um local situado no litoral, que é $a = 0,19$. No modelo DS, o coeficiente "a" foi maior e o "b" menor em relação aos obtidos por Silva et al. (2012) para 11 cidades do Estado de Minas Gerais, Brasil ($a: 0,053-0,103$; $b: 0,692-1,028$).

Os valores de MBE, RMSE e t calculados na validação de cada um dos modelos testados e SVM treinada são apresentados na Tabela 2 abaixo. Quanto mais próximo de zero são os valores de MBE e RMSE melhor é o desempenho do modelo analisado. A validação foi realizada utilizando os dados medidos no ano de 2010, com $n = 364$. Pelo teste t, considerou-se a existência de diferença estatisticamente significativa entre os dados de R_G medidos e os estimados quando o t-calculado foi maior que 1,96. Os valores estimados por cada modelo são apresentados na Figura 2 abaixo na forma de gráfico de dispersão (estimado x medido) para comparação visual. As regressões lineares entre os valores medidos e os estimados estão também apresentados na Figura 2 de forma algébrica e geométrica (reta vermelha); e a linha azul representa a reta 1:1.

Modelo	MBE (%)	RMSE (%)	t-calculado
HS	5,074	30,635	3,416*
DS	3,696	27,319	2,591*
SVM(1)	-3,159	28,317	2,142*
SVM(2)	-2,186	26,672	1,567

Tabela 2: Índices estatísticos MBE, RMSE e t-calculado para a validação dos modelos estatísticos e SVM. * Valores de R_G estimados diferentes estatisticamente das medições ($\alpha = 5$; $n = 364$; t-crítico = 1,96).

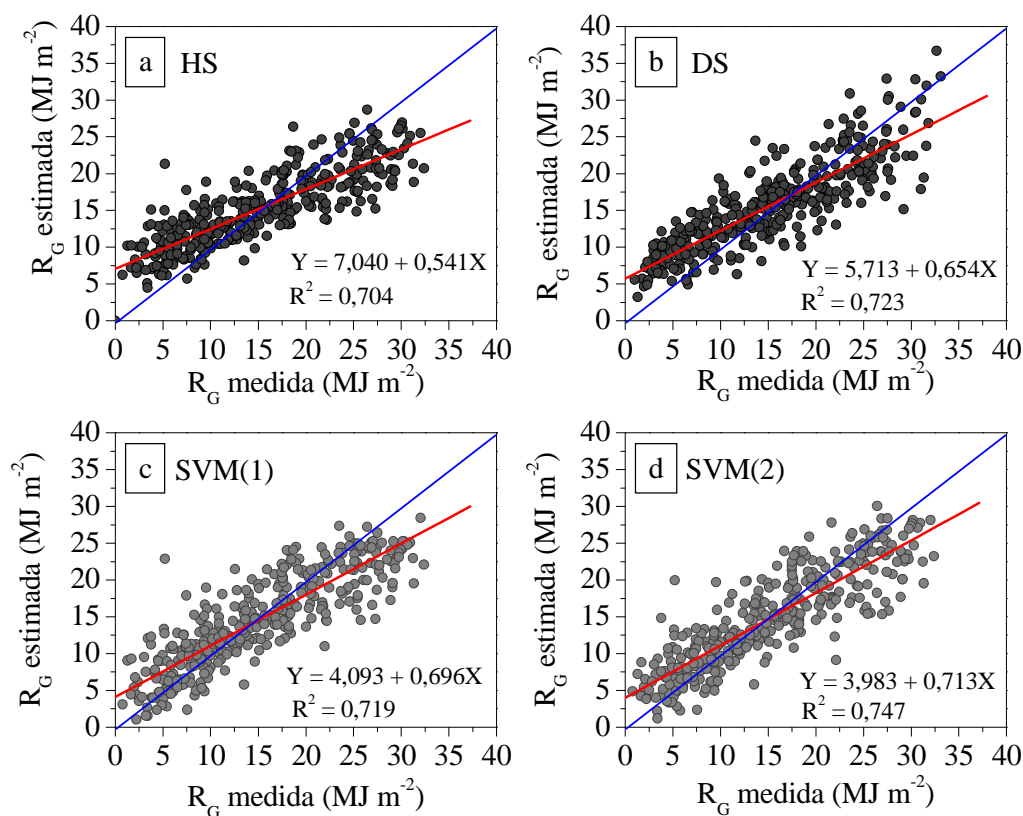


Figura 2: Valores estimados por cada modelo apresentados na forma de gráfico de dispersão: (a) Hargreaves-Samani; (b) DeJong-Stewart; (c) SVM(1); (d) SVM(2).

Dentre os dois modelos estatísticos ajustados, o modelo DS apresentou o melhor desempenho, com uma tendência de superestimar de $\sim 3,70\%$ e um erro médio de $\sim 27,32\%$. Porém, ressalta-se que uma das grandes desvantagens na utilização do MBE é a superestimativa de uma observação individual ser passiva de ser anulada por uma subestimativa em outra observação (Stone, 1993). O uso do RMSE para avaliar a extensão do erro apresenta como desvantagem a identificação de valores dos erros médios elevados na presença de casos individuais de erros muito elevados (Willmott e Matssura, 2005). Devido à tais desvantagens, quando são utilizados apenas os índices estatísticos MBE e RMSE para mensurar a precisão de modelos de estimativa, em determinados casos um modelo pode ser considerado insatisfatório com base em apenas um dos índices, porém satisfatório por outro índice. Por isso, no presente trabalho o teste t foi utilizado (Stone, 1993). Por meio do teste t verificou-se que ambos os modelos empíricos ajustados localmente geraram o conjunto de dado estimados diferente estatisticamente do conjunto de valores medidos.

Como esperado, a SVM apresentou melhor desempenho quando comparada aos modelos estatísticos, com MBE variando de $-3,16\%$ a $2,18\%$ e RMSE de $26,67\%$ a $28,31\%$. Dentre os dois agrupamentos de dados de entrada testados na SVM, o similar ao do modelo DS apresentou o melhor desempenho. O conjunto de dados de R_G estimados pela SVM(2) não se diferenciou estatisticamente dos dados medidos. Tal resultado está associado não só à capacidade da SVM de generalizar exemplos, mas também ao uso de um número maior de variáveis de entrada que apresentam correlação com R_G (Cao, 2003; Koca et al., 2011). A adição da precipitação no conjunto de variáveis de entrada permitiu à SVM relacionar a variação da R_G com a variação da concentração de vapor de água na atmosfera e nebulosidade. Ambas as variáveis atmosféricas citadas são consideradas determinantes na transmissividade atmosférica da radiação solar, especialmente em regiões úmidas e próximas do litoral.

CONCLUSÃO

O uso da SVM na estimativa da radiação solar global diária utilizando dados de temperatura do ar e de precipitação pluvial foram reportadas. Os resultados da validação e do estudo comparativo indicaram que a SVM apresenta maior acurácia na estimativa da radiação solar global quando comparada aos modelos empíricos clássicos avaliados. Recomenda-se no treinamento da SVM em Iguape para estimativa da radiação solar global as seguintes variáveis meteorológicas: temperaturas do ar máxima e mínima, radiação solar extraterrestre da atmosfera e precipitação.

REFERÊNCIAS

- Allen, R. G.; Pereira, L. S.; Raes, D.; Smith, M. Crop evapotranspiration: guidelines for computing crop water requirements. Rome: FAO, 1998, 300 p. Irrigation and Drainage Paper, 56.
- Amrouche, B.; Le Pivert, X. Artificial neural network based daily local forecasting for global solar radiation. *Applied Energy*, v. 130, p. 333–341, 2014.
- 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, p. 159-166, 1984.
- Cao, L. Support vector machine experts for time series forecasting. *Neurocomputing*, v. 51, p. 321-339, 2003.
- 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.
- CEPAGRI. Clima dos municípios paulistas. Disponível em: <http://www.cpa.unicamp.br/outras-informacoes/clima_muni_234.html> Acesso em: 05 mar. 2016.
- de Jong, R.; Stewart, D. W. Estimating global solar radiation from common meteorological observations in western Canada. *Canadian Journal of Plant Science*, v. 73, p. 50-518, 1993.
- Escobedo, J. F.; Gomes, E. N.; Oliveira, A. P.; Soares, J. Ratios of UV, PAR and NIR components to global solar radiation measured at Botucatu site in Brazil. *Renewable Energy*, v. 36, p. 169-178, 2011.
- Hall, M. et al.. The WEKA Data Mining Software: An Update; *SIGKDD Explorations*, v. 11, n. 1, 2009.
- Hamed, M. et al.. Parametric sensitivity studies on the performance of a flat plate solar collector in transient behavior. *Energy Conversion and Management*, v. 78, p. 938-947, 2014.
- Haykin, S. *Neural networks: A comprehensive foundation*. 2nd ed. Hamilton: Prentice Hall, 1998, 897p.
- Heargreaves, G. H. Responding to tropical climates. In: *The 1980-81 Food and climate review, the food and climate forum*. Boulder: Aspen Institute for Humanistic Studies, 1981. p. 29-32.
- Heargreaves, G. H.; Samani, Z. A. Estimating potential evapotranspiration. *Journal of Irrigation and Drainage Engineering*, v. 108, p. 225-230, 1982.
- IBGE. Perfil dos Estados e dos Municípios Brasileiros 2014. Disponível em: <<http://www.ibge.gov.br/home/estatistica/economia/perfilmunic/2014/>>. Acesso em: 05 mar. 2016.
- Jacovides, C. P.; Tymvios, F. S.; Boland, J.; Tsitouri, M. Artificial Neural Network models for estimating daily solar global UV, PAR and broadband radiant fluxes in a eastern Mediterranean site. *Atmospheric Research*, 2015.
- Jian, Y. Computation of monthly mean daily global solar radiation in China using artificial neural networks and comparison with other empirical models. *Energy*, v. 34, p.1276-1283, 2009.
- Koga, A.; Oztop, H. F.; Varol, Y.; Koca, G. O. Estimation of solar radiation using artificial neural networks with different input parameters for Mediterranean region of Anatolia in Turkey. *Expert Systems with Applications*, 38, 8756–8762, 2011.
- Kumar, R. et al.. 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.

- Mohammadi, K.; Shamshirband, S.; Anisi, M. H.; Alam, K. A.; Petkovic, D. Support vector regression based prediction of global solar radiation on a horizontal surface. *Energy Conversion and Management*, v.91, p.433–441, 2015.
- Ozgoren, M. et al. Estimation of global solar radiation using ANN over Turkey. *Expert Syst. Appl.* v. 39, n. 5, p. 5043-5051, 2012.
- 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.
- Rumelhart, D. E.; Hinton, G. E., Williams, R. J. Learning representations by back-propagation errors. *Nature*, London, UK, v. 323: p. 533 – 536, 1986.
- Shamshirband, S.; Mohammadi, K.; Chen, H-L.; Samy, G. N.; Petković, D.; MA, C.. Daily global solar radiation prediction from air temperatures using kernel extreme learning machine: A case study for Iran. *Journal of Atmospheric and Solar-Terrestrial Physics*. 134, 109–117, 2015.
- Silva, C. R.; Silva, V. J.; Alves Júnior, J.; Carvalho, H. P. Radiação solar estimada com base na temperatura do ar para três regiões de Minas Gerais. *Revista Brasileira de Engenharia Agrícola e Ambiental*. v. 16, n. 3, p. 281-288, 2012.
- Stone, R. J. Improved statistical procedures for the evaluation of solar radiation estimation models. *Solar Energy*, v. 51, p. 289-291, 1993.
- Vapnik V. N. *Statistical learning theory*. New York: Wiley; 1998.
- Willmott, C. J.; Matsuura, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. *Climate Research*, v. 30, p. 79-82, 2005.
- Witten, I. H.; FRANK, E.. *Data Mining: Practical machine learning tools and techniques*. San Francisco: Morgan Kaufman, 2005.
- Wu, W.; Liu, H. B. Assessment of monthly solar radiation estimates using support vector machines and air temperatures. *International Journal of Climatology*, v. 32, p. 274-285, 2012.
- Yadav, A. K; Chandel, S. S.. Solar radiation prediction using Artificial Neural Network techniques: A review. *Renewable and Sustainable Energy Reviews*, v. 33, p. 772–781, 2013.

Using empirical models and support vector machine for estimating daily global solar radiation in Iguape, Ribeira Valley, São Paulo State

ABSTRACT: In this work were calibrated two empirical models for estimating daily global radiation in Iguape/SP/Brazil, which were used as reference in the assessing of the support vector machine (SVM) estimating daily RG. The daily data of R_G , rainfall (P), air temperature maximal (Tmax) and minimal (Tmin) were measured by the weather station of INMET installed in Iguape during the period from 2008 to 2011. The results showed a good agreement between measured and estimated data, with R^2 ranging between 0.70 and 0.75. Between the adjusted empirical models, the DeJong-Stewart had the best performance. As expected, the performance of SVM was better when compared to the empirical models, with MBE ranging from -3.16% to 2.18% and RMSE of 26.67% to 28.31%. The SVM using the input variables Tmax, Tmin, extraterrestrial solar radiation and P was the only method among the tested that generated a set of estimated data statistically similar to the measured data.

Keywords: Hargreaves-Samani, DeJong-Stewart; Air temperature; rainfall.