ESTIMATIVA DA RADIAÇÃO SOLAR UV HORÁRIA EM BOTUCATU/SP UTILIZANDO RNA.

Érico T. Teramoto[1], João F. Escobedo[2], Cícero M. dos Santos [3], Alexandre Dal Pai [4], Arilson J. Oliveira Júnior[5], Tiago A. Vicentin[6]

[1] Doutor em Energia na Agricultura, Faculdade de Ciências Agronômicas – UNESP, Botucatu-SP, ericoengineer@gmail.com.
[2]Profº Drº, Engenharia Rural, Faculdade de Ciências Agronômicas – UNESP, Botucatu-SP.
[3]Doutorando em Irrigação e Drenagem, Faculdade de Ciências Agronômicas – UNESP, Botucatu-SP.
[4]Profº Drº, Bioprocessos e Biotecnologia, Faculdade de Ciências Agronômicas – UNESP, Botucatu-SP.
[5]Mestrando em Energia na Agricultura, Faculdade de Ciências Agronômicas – UNESP, Botucatu-SP.
[6]Doutorando em Irrigação e Drenagem, Faculdade de Ciências Agronômicas – UNESP, Botucatu-SP.

1 INTRODUÇÃO

Embora radiação UV represente menos de 10% da radiação global (JACOVIDES et al., 2006; HUANG et al., 2011; ESCOBEDO et al., 2012), ela possui notoriedade em relação às faixas espectrais visível e infravermelho devido aos seus efeitos nocivos sobre a biosfera e polímeros sintéticos (DIFFEY, 1991; SAPKOTA et al., 2014). Assim, o estudo dos níveis de incidência da radiação solar UV é essencial para muitas aplicações nas áreas de agricultura, ecologia e ciências médicas.

No Brasil informações sobre os níveis de radiação solar UV ainda são escassos devido ao número pequeno de estações que a monitoram. Por isso, muitos pesquisadores recorrem à diferentes métodos para estimativa da radiação solar UV a partir de outras variáveis meteorológicas. Dentre os vários métodos, os mais utilizados são os modelos estatísticos e as técnicas de aprendizado de máquinas (MLT), que nos últimos anos têm sido extensivamente estudadas e comparadas aos primeiros (FOYO-MORENO et al., 1998; ESCOBEDO et al., 2009; VILLÁN et al., 2010; HUANG et al., 2011). A popularidade dos modelos estatísticos é justificada pela relativa acurácia associada à simplicidade para uso. Dentre as técnicas de aprendizado de máquinas, as mais utilizadas são as Redes Neurais Artificias (RNAs) (ELMINIR et al., 2005; BARBERO et al., 2006; LEAL et al., 2011; JACOVIDES et al., 2013).

O presente trabalho apresenta a estimativa da radiação solar UV em Botucatu/SP utilizando RNA do tipo MLP.

2 MATERIAL E MÉTODOS

2.1 Local estudado e obtenção dos dados

Os dados utilizados neste trabalho foram medidos na estação radiométrica instalada na FCA/UNESP em Botucatu (22,85ºS; 48,43º W; 742 m). Botucatu é considerada uma cidade rural, com área territorial de 1.482,87 km² e população de 127 mil habitantes, e

possui clima classificado como Cfa (Método de Koppen).

Na medição das irradiâncias solar UV (290-400 nm) e global (290-2.800 nm) foram utilizados, respectivamente, um radiômetro CUV3 da Kipp e Zonen e um piranômetro modelo PSP da Eppley. A imprecisão do CUV3 é de ±5% e a do PSP é de ±4% (REDA et al., 2008; HUANG et al., 2011). Ambos os sensores foram calibrados periodicamente pelo método comparativo sugerido pela OMM (FRÖHLICH; LONDON, 1986). Na aquisição dos dados foi utilizando um datalogger CR23X da Campbell operando na frequência de 1 Hz e o armazenamento (média) ocorreu a cada 5 minutos. Os dados médios de 5 minutos passaram por um controle de qualidade no qual os valores espúrios foram eliminados e em seguida foram processados por programas desenvolvidos para o cálculo das irradiações horárias e diárias (CHAVES; ESCOBEDO, 2000). Os dados diários utilizados de coluna total de ozônio (TOC) foram os medidos pelo satélite Earth Probenos anos de 2000 a 2004 e pelo satélite Aura nos anos de 2005 a 2007, disponíveis em hppt://mirador.gsfc.nasa.gov/.O satélite Earth Probe mede o TOC por meio do sensor TOMS (Total Ozone Mapping Spectrometer) e o satélite Aura por meio do sensor OMI (Ozone Monitoring Instrument).

2.2 Implementação da RNA

O desempenho da RNA na estimativa da radiação solar UV em Botucatu foi comparada à três dos principais modelos estatísticos encontrados na literatura. Assim, na RNA foram testados três agrupamentos de variáveis de entrada, que são correspondentes às variáveis de entrada de cada um dos modelos estatísticos. Foram considerados os seguintes modelos estatísticos:

Modelo 1) Considera a relação linear entre a variação da KTUV e a variação do KT, utilizando como variáveis de entrada o a radiação UV extraterrestre (UV0) e o KT (Equação 1):

$$UV = bUV_0 K_T \tag{1}$$

onde "b" é um parâmetro calculado a partir da correlação linear entre os dados horários de K_{TUV} e os de K_T. Os valores de K_{TUV} e do índice de claridade K_T foram calculados a partir das Equações 2 e 3 (IQBAL, 1983; HUANG et al., 2010):

$$K_{TUV} = UV / 0{,}057 H_0 \tag{2}$$

$$K_T = G / H_0 \tag{3}$$

onde H_0 é a radiação solar extraterrestre horária, estimada seguindo metodologia divulgada

por Iqbal (1983).

Modelo 2) Considera o efeito do ar seco sobre a radiação solar UV em condições de céu claro, utilizando como variáveis de entrada o K_T e a massa óptica relativa do ar (m_r) (Equação 4):

$$UV = bK_T[y_o + A_1 e^{(-m_r/T_1)} + A_2 e^{(-m_r/T_2)}] \quad (4)$$

onde os coeficientes y_o, A_1, A_2, T_1 e T_2 da foram estimados por meio da correlação entre os dados de irradiação solar UV horária em condições de céu claro e a massa ótica relativa do ar m_r. O critério utilizado para classificação da condição de céu como claro foi o $K_T > 0,65$, conforme proposto por Escobedo et al. (2009) para Botucatu. A massa optica relativa do ar (m_r) foi calculada por meio da Equação 5 (KASTEN; YOUNG, 1989):

$$m_r = 1/[\cos(\theta_z) + 0,050572(96,0795 - \theta_z)^{-1,6364}] \quad (5)$$

onde θ_z é o ângulo zenital.

Modelo 3) Considera o efeito do ar seco e do ozônio sobre a UV em condições de céu claro, utilizando como variáveis de entrada o KT, a m_r e a coluna total de ozônio obliqua (SOC) (Equação 6):

$$UV = bK_T[y_o + A_1 e^{(-m_r/T_1)} + A_2 e^{(-m_r/T_2)} + A_3 e^{(-SOC/T_3)} + A_4 e^{(-SOC/T_4)}] \quad (6)$$

onde o parâmetro coluna total de ozônio obliqua SOC foi calculada a partir Equação 7 (ANTÓN et al., 2008):

$$SOC = TOC/\cos(Z) \quad (7)$$

As RNA foram implementadas utilizando a ferramenta computacional gratuita WEKA 3.7.12 (Waikato Environment for Knowledge Analysis), que consiste num conjunto de algoritmos de aprendizado de máquinas livre, disponível em http://www.cs.waikato.ac.nz/~ml/weka/ (WITTEN; FRANK, 2005).

Para a avaliação dos modelos estatísticos e da RNA na estimativa da radiação solar UV horária foram utilizados os indicativos estatísticos MBE (Mean Bias Error), RMSE (Root Mean Square Error), e d de Willmott (WILMOTT, 1981; IQBAL, 1983):

$$MBE = [\sum(Y_c - Y_m)]/N \quad (8)$$

$$RMSE = \sqrt{[\sum(Y_c - Y_m)^2]/N} \quad (9)$$

$$d = 1 - [\sum_{i=1}^{N}(Y_c - Y_m)^2] / [\sum_{i=1}^{N}(|Y_c'i| + |Y_m'i|)^2] \quad (10)$$

onde N é o número de observações realizadas, Y_c são os valores de irradiação horária calculados, Y_m os medidos e $\overline{Y}$ a média dos valores medidos no intervalo horário considerado. No caso do índice d, $|Y_c'i|$ é o valor absoluto da diferença $Y_c - \overline{Y}_m$ e $|Y_m'i|$ é o valor absoluto da diferença $Y_m - \overline{Y}_m$.

3 RESULTADOS E DISCUSSÕES

Nas Tabela 1 abaixo são apresentados os indicativos estatísticos (R^2, MBE, RMSE e d) que permitem avaliar o desempenho dos modelos estatísticos e da RNA na estimativa da radiação solar UV horária. O MBE indica a tendência do modelo utilizado em superestimar (valores positivos) ou subestimar (valores negativos) e o RMSE dá uma noção do espalhamento na correlação entre os dados medidos e os estimados. Quanto menores forem os valores de MBE e RMSE melhor é o desempenho do modelo avaliado. Diferentes intervalos de RMSE são definidos para avaliar a acurácia dos modelos (HEINEMANN et al., 2012). O desempenho é considerado excelente se RMSE < 10%; bom se 10% ≤ RMSE ≤ 20%; Aceitável se 20% ≤ RMSE ≤ 30%; e pobre se RMSE ≥ 30%. O índice "d", que varia entre 0 e 1, representa o total de discordância ou concordância perfeita, respectivamente, entre os valores medidos e os estimados (WILLMOTT, 1981).

Tabela 1. Indicativos estatísticos dos modelos estatísticos e RNA na estimativa da radiação solar UV horária.

		R^2	MBE (%)	RMSE (%)	d (%)
Modelo (1)	Estatístico	0,984	-5,943	12,875	0,988
	RNA	0,984	-11,754	15,396	0,968
Modelo (2)	Estatístico	0,973	0,829	12,231	0,991
	RNA	0,987	-0,774	7,167	0,996
Modelo (3)	Estatístico	0,971	0,921	12,245	0,990
	RNA	0,988	1,292	7,044	0,996

Verifica-se que dentre os modelos estatísticos, o modelo que apresentou melhor desempenho foi o Modelo 2 (menores valores de MBE e RMSE e maiores de d). Ao contrário, o Modelo 1 apresentou o pior desempenho, apresentando nível de imprecisão superior ao do sensor utilizado na medição da radiação solar UV (±5%). Verifica-se que com

o aumento número das variáveis de entrada do modelo, melhor é o desempenho observado na estimativa da radiação UV. No caso, o desempenho inferior do Modelo 3 em relação ao Modelo 2 é justificado pela imprecisão na medição dos dados de ozônio medidos pelo satélite (MCPETERS et al., 2008).

A RNA apresentou melhor desempenho quando comparada aos modelos estatísticos que utilizam as mesmas variáveis de entrada. O resultado observado está de acordo com o divulgado por outros autores na literatura (BARBERO et al., 2006; FEISTER et al., 2008; LEAL et al., 2011). Verifica-se que em relação ao agrupamento de variáveis de entrada, a RNA apresentou melhor desempenho na estimativa da radiação solar UV quando são utilizados o K_T e a massa óptica relativa do ar.

4 CONCLUSÕES

Dos três modelos estatísticos validados, apenas o Modelo 1 (linear) apresentou nível de imprecisão superior ao dos sensores de medição da UV (±5%). Os modelos estatísticos 2 e 3 apresentaram desempenho similares Foyo-Moreno et al. (1999). Comparado aos modelos estatísticos que utilizam as mesmas variáveis de entrada, a RNA apresentou resultados superiores, sendo observado no caso dos modelos 2 e 3, com MBE entre -0,774 e 1,292, RMSE < 7,167% e d igual a 0,996.

5 REFERÊNCIAS

BARBERO, F. J.; LÓPEZ, G.; BATLLES, F. J. Determination of daily solar ultraviolet radiation using statistical models and artificial neural networks. Ann. Geophys., v. 24, p. 2105-2114, 2006.

BOEGER, M. R. T.; POULSON, M. Efeitos da radiação ultravioleta-B sobre a morfologia foliar de Arabidopsisthaliana (L.) Heynh (Brassicaceae). Acta Botânica Brasileira, v. 20, n. 2, p. 329-338, 2006.

DIFFEY, B. L. Solar ultraviolet radiation effects on biological system. Physc.Med. Bio., v. 36, p. 299-329, 1991.

ELMINIR, H. K.; AREED, F. F.; ELSAYED, T. S. Estimation of solar radiation components incident on Helwan site using neural network. Solar Energy, v. 79, p. 270-279, 2005.

ESCOBEDO, J. F. et al. Irradiações UV, PAR e IV médias mensais em Botucatu/SP/Brasil. Avances en EnergíasRenovables y MedioAmbiente, v. 16, p. 85-92, 2012.

ESCOBEDO, J. F. et al. Modeling hourly and daily fractions of UV, PAR and NIR to global solar radiation under various sky conditions at Botucatu, Brazil. Applied Energy, v. 86, p. 299-309, 2009.

FEISTER, U.; JUNK, J.; WOLDT, M. Long-term solar UV radiation reconstructed by Artificial Neural Networks (ANN). Atmospheric Chemistry and Physics Discussions, v. 8, p. 453-488, 2008.

HEINEMANN, A. B.; VAN OORT, P. A. J.; FERNANDES, D. S.; MAIA, A. H. N. Sensivity of APSIM/ORYZA model due to estimation errors in solar radation. Bragantia, v. 71, n. 4, p. 572-582, 2012.

HUANG, M.; JIANG, H.; JU, W.; XIAO, Z. Ultraviolet radiation over two lakes in the Middle and lower reaches of the Yangtze River, China: an innovative model for UV estimation. Terrestrial, Atmospheric and Oceanic Sciences, v. 22, n. 5, p. 491-506, 2011.

IQBAL, M. An introduction to solar radiation. London: Academic Press, 1983. 390p

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, 2013.

JACOVIDES, C.P. et al. Solar global UV (280–380 nm) radiation and its relationship with solar global radiation measured on the island of Cyprus. Energy, v. 31, p. 2728–2738, 2006.

LEAL, S. S., TIBA C., PIACENTINI, R. Daily UV radiation modeling with the usage of statistical correlations and artificial neural networks. Renewable Energy, v. 36, p.3337-3344, 2011.

MCPETERS, R. et al. VEEFKIND, J. P.; BHARTIA, P. K.; LEVELT, P. F. Validation of the Aura ozone monitoring instrument total column ozone product. Journal of Geophysical Research, v. 113, p. 1-9, 2008.

REDA, I. M.; MYERS, D. R.; STOFFEL, T. L. Uncertainty Estimate for the Outdoor Calibration of Solar Pyranometers: A Metrologist Perspective. NCSLI Measure. The Journal of Measurement Science, v. 3, p. 58-66, 2008.

SAPKOTA, S. B.; FISCHER, M.; ZIMMERMANN, B.; WÜRFEL, U. Analysis of the degradation mechanism of ITO-free organics olar cells under UV radiation. Solar Energy Materials & Solar Cells, v. 121, p. 43–48, 2014.

VILLÁN, M. D., CASTRILLO, A. M., SANTOS, J. B. Empirical models of UV total radiation and cloud effect study. International Journal of Climatolology, v. 30, p.1407-1415, 2010.

WITTEN, I. H.; FRANK, E. Data Mining: Practical machine learning tools and techniques (2nd ed.). San Francisco: Morgan Kaufman, 2005.

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.

AGRADECIMENTOS

Os autores agradecem o suporte financeiro fornecido pelo CNPq, CAPES e FAPESP. Nós também agradecemos à NASA e ao CPTEC/INPE, por fornecerem dados de variáveis meteorológicas.