



## XIX Congresso Brasileiro de Agrometeorologia

23 a 28 de agosto de 2015

Lavras – MG – Brasil

Agrometeorologia no século 21:

### *O desafio do uso sustentável dos biomas brasileiros*

## **Redes Neurais Artificiais na estimativa da Evapotranspiração de Referência por Penman-Monteith-FAO56**



*Cícero Manoel dos Santos<sup>1</sup>; Maurício Bruno Prado da Silva<sup>2</sup>; José Leonaldo de Souza<sup>3</sup>; Ricardo Araújo Ferreira Junior<sup>4</sup>; Gustavo Bastos Lyra<sup>5</sup>.*

<sup>1</sup>Físico, Doutorando em Irrigação e Drenagem, FCA-UNESP, Fone: (14) – 3880-7585, [ciceromanoel@fca.unesp.br](mailto:ciceromanoel@fca.unesp.br)

<sup>2</sup>Eng. Agrônomo, mestrando em Irrigação e Drenagem, FCA-UNESP

<sup>3</sup>Meteorologista, Doutor em Agronomia, Professor associado, Universidade Federal de Alagoas

<sup>4</sup>Eng. Agrônomo, Doutor em Agronomia, Professor, Universidade Federal de Alagoas

<sup>5</sup>Meteorologista, Doutor em Agronomia, Professor adjunto, Universidade Federal Rural do Rio de Janeiro

**RESUMO:** Valores confiáveis da Evapotranspiração de Referência ( $ET_0$ ) são importantes para o manejo adequado de água em culturas agrícolas. Devido ao custo de aquisição dos sensores e a escassez de informações temporais e espaciais de variáveis meteorológicas, a  $ET_0$  não está disponível em muitos locais. Diferentes modelos têm sido propostos e utilizados para estimar  $ET_0$  e suprir a demanda existente. Objetivou-se neste trabalho estimar a  $ET_0$  pelo método de Penman-Monteith-FAO56 utilizando Redes Neurais Artificiais (RNAs ou ANNs), que é uma técnica de Aprendizado de Máquinas (AMs). São utilizados dados meteorológicos de temperatura do ar, umidade relativa do ar, precipitação, irradiação solar e velocidade do vento, obtidos no período de 2009 a 2011. Os dados utilizados foram obtidos da estação agrometeorológica localizada no Centro de Ciências Agrárias (CECA) da Universidade Federal de Alagoas (UFAL) (09°28'02''S; 35°49'43''W; 127 m de altitude). Dois modelos com diferentes combinações nas variáveis de entrada (ANN1- que utiliza todas variáveis) e (ANN2 – que utiliza todas variáveis, exceto precipitação) são avaliados. O método de Penman-Monteith-FAO (PMF-56) é utilizado como referência. Os índices estatísticos de comparação de modelos foram: MBE, rMBE (%), RMSE, rRMSE (%) e  $d$  de Willmott. As estimativas de  $ET_0$  com ANNs concordam com o  $ET_{0PMF-56}$  e segue a mesma tendência com elevado coeficiente de determinação ( $R^2 = 0,955$  com ANN1 e  $R^2 = 0,954$  com ANN2). O modelo ANN1 teve melhor desempenho (MBE = -0,146 mm dia<sup>-1</sup>, RMSE = 0,286 mm dia<sup>-1</sup> e  $d = 0,984$ ) que o modelo ANN2 (MBE = -0,146 mm dia<sup>-1</sup>, RMSE = 0,293 mm dia<sup>-1</sup> e  $d = 0,984$ ). Em geral, a ANN dá excelente estimativa (rRMSE<10%) e pode ser utilizada na estimativa de  $ET_0$  com boa acurácia.

**PALAVRAS-CHAVE:** Aprendizado de Máquinas, RNAs, Evapotranspiração.

### **ARTIFICIAL NEURAL NETWORKS ON ESTIMATION OF REFERENCE EVAPOTRANSPIRATION BY PENMAN-MONTEITH-FAO56**

**ABSTRACT:** Reliable values of reference evapotranspiration ( $ET_0$ ) are important for the proper management of water in agricultural crops. Due to the acquisition cost of the sensors and the lack of temporal and spatial information of meteorological variables, the  $ET_0$  is not available in many locations. Different models have been proposed and used to estimate  $ET_0$  and meet the existing demand. The objective of this study was to estimate the  $ET_0$  by Penman-Monteith-FAO 56 using Artificial Neural Networks (ANN), which is a Machine Learning technique (ML). Were used meteorological data of air temperature, relative humidity, precipitation, solar irradiation and wind speed, obtained from 2009 to 2011. The data were taken from the agrometeorological station located at the Centro de Ciências Agrárias (CECA) da Universidade Federal de Alagoas (UFAL) (09°28'02 "S, 35°49'43"W; 127m altitude). Two models with different combinations on the input variables (ANN1- using all variables) and (ANN2 - using all variables except precipitation) are evaluated. The Penman-Monteith-FAO (PMF-56) is used as reference. The statistical indices of models comparison were: MBE, rMBE (%), RMSE, rRMSE (%) and  $d$  (index Willmott). Estimates of  $ET_0$  with

***O desafio do uso sustentável dos biomas brasileiros***

ANNs agree with  $ET_{0PMF-56}$  and follows the same trend with a high coefficient of determination ( $R^2 = 0.955$  and  $R^2 = ANN1$  with 0.954 with ANN2). The ANN1 model performed best ( $MBE = -0.146 \text{ mm day}^{-1}$ ,  $RMSE = 0.286 \text{ mm day}^{-1}$  and  $d = 0.984$ ) than the ANN2 model ( $MBE = -0.146 \text{ mm day}^{-1}$ ,  $RMSE = 0.293 \text{ mm day}^{-1}$   $d = 0.984$ ). Usually, the ANN gives excellent estimate ( $rRMSE < 10\%$ ) and can be used in estimating  $ET_0$  with good accuracy.

**KEY WORDS:** Machines Learning, ANNs, Evapotranspiration.

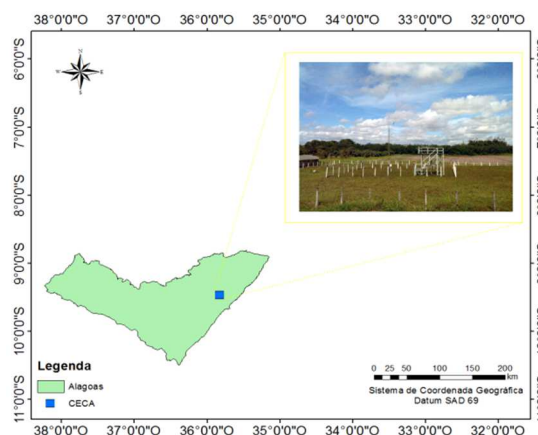
## INTRODUÇÃO

A evapotranspiração (ET) consiste na combinação da transferência de água líquida da superfície do solo para vapor na atmosfera por evaporação do solo e em parte por transpiração da planta (Pereira et al., 2002; Allen et al, 1998). O conhecimento e a quantificação da ET são de grande importância para gestão de recursos hídricos, estudos ambientais e agrícolas, com o gerenciamento dos sistemas de irrigação através da determinação da demanda hídrica das culturas e estudos do balanço hídrico (Allen et al., 2011; Tabari et al., 2012; Adeloje et al., 2012; Huo et al., 2012). A metodologia da FAO-56 (Pereira et al., 2002; Allen et al, 1998) determina a ET de culturas agrícolas pelo conhecimento da ET de referência ( $ET_0$ ), que corresponde a ET de uma cultura de referência (grama ou alfafa) padronizada, sem limitação de água no solo, livre de doenças e pragas.

Devido o alto custo dos sensores e as dificuldades em obter dados confiáveis de ET através de técnicas micrometeorológicas, lisimetria e evaporímetros, diferentes modelos têm sido desenvolvidos e utilizados na estimativa de ET para diferentes condições climáticas e localizações geográficas (Tabari et al., 2012; Allen et al., 1998). Entre estes métodos encontram-se as Redes Neurais Artificiais (RNA's ou em inglês ANNs) (Haykin, 1998), que têm sido amplamente aplicados com sucesso na estimativa da  $ET_0$  em diversos locais e climas diferentes (Chauhan e Shrivastava, 2009; Kişi e Çimen, 2009; Shrestha e Shukla, 2015; Goyalet al., 2014). O objetivo deste estudo é avaliar a ANNs na estimativa da  $ET_0$ , utilizando a metodologia de Penman-Monteith-FAO56MF-56.

## MATERIAIS E MÉTODOS

A área de estudo está localizada na unidade acadêmica do Centro de Ciências Agrárias (CECA) da Universidade Federal de Alagoas (UFAL), no município de Rio Largo (09°28'02''S; 35°49'43''W e alt. 127 m), situado nos Tabuleiros Costeiros do Estado de Alagoas (Figura 1).



**Figura 45.** Localização da área experimental.

***O desafio do uso sustentável dos biomas brasileiros***

O clima da região é caracterizado, pela classificação de Thornthwaite e Mather, como úmido (B1), megatérmico quente (A'), com deficiência de água moderada no verão (s) e grande excesso de água no inverno (w<sub>2</sub>) (Teodoro, 2011). A precipitação média acumulada ao longo do ano é de 1817,6 mm e a temperatura do ar média anual de 25,4 °C.

Os dados das variáveis meteorológicas foram obtidos da estação agrometeorológica automática (aquisição automática - CR1000, Campbell Scientific, Utah). A temperatura e umidade do ar foram medidas por sensor HMP45C, Campbell Scientific, Utah, precipitação por um pluviômetro automático - TB3, Hydrological Services PTY. LTD., Sydney, irradiação solar global por um piranômetro - CM3, KIPP & ZONEN, Netherlands, a velocidade do vento foi obtida por um anemômetro de conchas automático (03101-L, Young, Michigan), situado a uma altura de 2,0 m do solo. As medidas foram realizadas em intervalos de 10 segundos e suas médias armazenadas a cada 10 minutos. Os dados foram medidos no período de janeiro de 2009 a dezembro de 2011.

A Evapotranspiração de Referência (ET<sub>0</sub>) (mm dia<sup>-1</sup>) foi obtida pelo método de Penman-Monteith (Allen et al., 1998), através do Boletim da FAO-56 (PMF-56), conforme eq. 1:

$$ET_0 = \frac{0,408\Delta(R_n - G) + (\gamma \frac{900}{T + 273})u_2(e_s - e)}{\Delta + [\gamma(1 + 0,34u_2)]} \quad (1)$$

em que, R<sub>n</sub>(MJ m<sup>-2</sup> dia<sup>-1</sup>) é o saldo de radiação, G (MJ m<sup>-2</sup> dia<sup>-1</sup>) é o fluxo de calor no solo, o qual é considerado igual a zero em escala diária; U<sub>2</sub> é a velocidade do vento a 2 m de altura (m s<sup>-1</sup>), e é a pressão de saturação de vapor atual (kPa), e<sub>s</sub> é a pressão do vapor d'água do ar (kPa), e T é a temperatura do ar média (°C), Δ = inclinação da curva de pressão de vapor saturado versus temperatura (kPa °C<sup>-1</sup>) e γ = coeficiente psicrométrico (kPa °C<sup>-1</sup>). O saldo de radiação (R<sub>n</sub>) foi obtido como fração da R<sub>g</sub> (R<sub>n</sub> = 0,576 R<sub>g</sub>; com coeficiente de determinação (r<sup>2</sup>) igual a 0,927), realizada pelo Laboratório de Agrometeorologia e Radiometria Solar (LARAS) da UFAL (Ferreira Júnior, 2010).

***Técnicas de Aprendizado de Máquinas para estimativa de ET<sub>0</sub>***

As técnicas de Aprendizado de Máquinas (AMs) empregam um princípio de inferência denominado de indução, onde as conclusões gerais são obtidas a partir de um determinado conjunto de exemplos, sendo a aprendizagem supervisionada 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 compostos por pares: dados de entrada e saída (Mitchell, 1997). O algoritmo utilizado reconhece o padrão dos dados de entrada, para que produzam resultados coerentes para os dados de saída (Lorena et al., 2011). Existem diferentes técnicas de AMs, aqui será considerado e avaliado a Artificial Neural Network (ANN's).

As Artificiais Neurais Networks (ANNs) são sistemas computacionais que se baseiam na estrutura, no método de processamento e na capacidade de aprendizagem do cérebro (Haykin, 1998). Elas são compostas de unidades de processamento simples, que simulam os neurônios biológicos e estão dispostos em uma ou mais camadas (Lorena et al., 2011). Neste trabalho é empregada no treinamento das ANNs a MultilayerPerceptron (MLP), com o algoritmo *backpropagation* (Haykin, 1998) e termo *momentum*.

As ANN's foram testadas e avaliadas através da ferramenta computacional de domínio publico WEKA (*Waikato Environment for Knowledge Analysis*), que consiste num conjunto de algoritmos de AMs livre, disponível em <http://www.cs.waikato.ac.nz/~ml/weka/> (Witten e Frank, 2005). A Tabela 1 apresenta os modelos de ANNs com os símbolos e as variáveis de entrada na modelagem para cada modelo.

**Tabela 31.** Modelos ajustados e parâmetros de entrada.

ANN-MLP	Variáveis de entrada
ANN1	Hg, Tmed, UR, P, Vv
ANN2	Hg, Tmed, UR, Vv

Hg = irradiação solar global, Tmed = temperatura do ar média, UR = umidade relativa do ar, P = precipitação e Vv velocidade do vento.

### Índices estatísticos

Na avaliação do desempenho dos modelos ANN e foram utilizados: MBE (Mean Bias Error), Relative Mean Bias Error (rMBE), Root Mean Square Error (RMSE), Relative Root Mean Square Error (rRMSE) e *d* de Willmott (Escobedo et al., 2011; Santos et al., 2014). Estes índices estatísticos permitem a detecção de subestimativa ou superestimativa, espalhamento ou tendência sistemática e ajustamento dos modelos.

$$MBE = \frac{\sum_{i=1}^{N'} (P_i - O_i)}{N'} \quad rMBE (\%) = 100 \times \frac{\frac{\sum_{i=1}^{N'} (P_i - O_i)}{N'}}{\bar{X}} \quad RMSE = \left[ \frac{\sum_{i=1}^{N'} (P_i - O_i)^2}{N'} \right]^{\frac{1}{2}}$$

$$rRMSE (\%) = 100 \times \frac{\left[ \frac{\sum_{i=1}^{N'} (P_i - O_i)^2}{N'} \right]^{\frac{1}{2}}}{\bar{X}} \quad d = 1 - \frac{\sum_{i=1}^{N'} (P_i - O_i)^2}{\sum_{i=1}^{N'} (|P_i'| + |O_i'|)^2}$$

em que:  $P_i$  representa os valores estimados de  $ET_0$  por ANN,  $O_i$  os valores de  $ET_{OPMF-56}$ ,  $|P_i'|$  o valor absoluto da diferença  $P_i - \bar{O}_1$ , em que  $\bar{O}_1$ , representa a média de  $O_i$ ,  $|O_i'|$  representa o valor absoluto da diferença  $O_i - \bar{O}_1$ .  $\bar{X}$  é o valor médio medido e  $N'$  o número de observações. Diferentes intervalos de rRMSE são definidos para avaliar a acurácia dos modelos (Heinemann et al., 2012): Excelente se  $rRMSE < 10\%$ ; Bom se  $10\% \leq rRMSE < 20\%$ ; Aceitável se  $20\% \leq rRMSE < 30\%$ ; Pobre se  $rRMSE \geq 30\%$ . O valor de (rRMSE) é o índice conclusivo sobre o desempenho dos modelos neste estudo. Todos os cálculos estatísticos foram feitos no Microcal™ Origin 6.0®.

## RESULTADOS E DISCUSSÃO

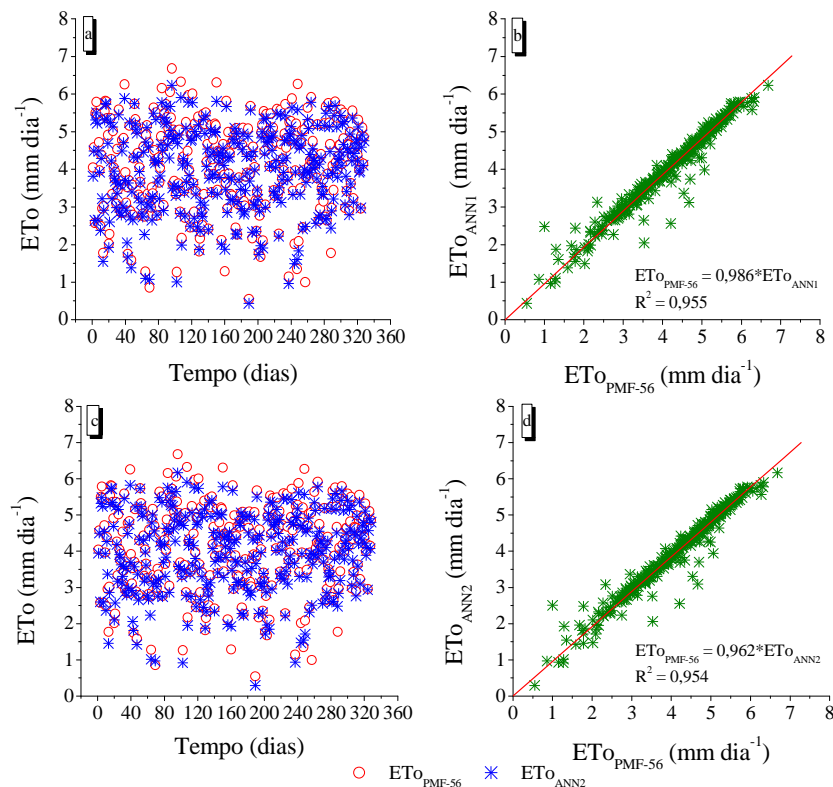
A ANN foi utilizada na determinação da  $ET_0$ . Para a ANN foi considerado os valores padrão do WEKA (Learning rate = 0,3, Momentun = 0,2 e Number of Iteration = 500). Estes parâmetros foram acatados por resultarem em menores erros nas estimativas de  $ET_0$ . Foram utilizados 70% no treinamento da ANN 30% para testar e validar, utilizando o *Percentage Split* do WEKA.

Os resultados da análise estatística da técnica ANN, na estimativa de  $ET_0$  comparada com PMF-56 são apresentados na Tabela 2. O modelo ANN1 com as variáveis de entrada: teve melhor desempenho (MBE = -0,146 mm dia<sup>-1</sup>, RMSE = 0,286 mm dia<sup>-1</sup> e  $d = 0,984$ ) que o modelo ANN2 (MBE = -0,146 mm dia<sup>-1</sup>, RMSE = 0,293 mm dia<sup>-1</sup> e  $d = 0,984$ ). A inserção da precipitação melhorou o desempenho do ANN1 quando comparado com ANN2. Os resultados indicam que os dois modelos de ANN subestimam  $ET_{OPMF-56}$ .

**Tabela 2.** Desempenho dos modelos ANN para a estimativa de  $ET_0$  diária com diferentes indicadores estatísticos.

Modelos	MBE (mm dia <sup>-1</sup> )	rMBE (%)	RMSE (mm dia <sup>-1</sup> )	rRMSE (%)	d
ANN1	-0,136	-3,302	0,286	6,954	0,984
ANN2	-0,146	-3,559	0,293	7,126	0,984

As estimativas de  $ET_0$  para os modelos de ANN estão apresentadas na Figura 2. As subestimativas são claramente vistas com a maioria dos pontos azuis ( $ANN1$  e  $ANN2$ ) abaixo dos pontos vermelhos ( $ET_{0PMF-56}$ ) (Figura 2a, c) e os pontos verdes crescentes linearmente com a regressão (Figura 2b, d). As estimativas de  $ET_0$  com ANN concordam com o  $ET_{0PMF-56}$  e segue a mesma tendência com elevado coeficiente de determinação,  $R^2 = 0,955$  com  $ANN1$  e  $R^2 = 0,954$  com  $ANN2$ . Comparando os valores de  $ET_{0PMF-56}$  e os valores estimados pelos modelos de ANN, observa-se o grande potencial da ANN na modelagem das variáveis e estimativa de  $ET_0$ .



**Figura 2.** Dispersão das estimativas: a) e b)  $ET_{0ANN1} \times ET_{0PMF-56}$ . c) e d)  $ET_{0ANN2} \times ET_{0PMF-56}$ .

## CONCLUSÕES

No presente trabalho foi avaliado a ANN para estimar  $ET_0$  em Maceió. O método de PMF-56 é considerado como referência para comparação com os modelos. Foi verificado que a técnica dá excelente estimativa ( $rRMSE < 10\%$ ) e pode ser utilizada na estimativa de  $ET_0$  com boa acurácia.

**AGRADECIMENTOS:** CNPq, CAPES.

## REFERÊNCIAS BIBLIOGRÁFICAS

Adeloye, J. A. et al. Neural computing modeling of the reference crop evapotranspiration. **Environmental modeling & software**, v. 29, p. 61-73, 2012.

Allen, R. A. et al. Crop evapotranspiration: guidelines for computing crop requirements. Roma: FAO, 1998. 328p. In: Irrigation and drainage paper, 56.



## XIX Congresso Brasileiro de Agrometeorologia

23 a 28 de agosto de 2015

Lavras – MG – Brasil

Agrometeorologia no século 21:

### *O desafio do uso sustentável dos biomas brasileiros*



Allen, R. A. et al. Evapotranspiration information reporting: I. Factors governing measurement accuracy. In: *Agricultural water management*, v. 98, p. 899-920, 2011.

Chauhan, S.; Shrivastava, R. K. Performance evaluation of reference evapotranspiration estimation using climate based methods and artificial neural networks. **Water Resources Management**, v. 23, p.825-837, 2009.

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.

Ferreira Junior, R. A. **Crescimento de variedades RB de cana-de-açúcar irrigadas e fotossíntese modelada pela radiação solar**. Rio Largo: CECA – UFAL, 2010. 70 f. Dissertação de mestrado.

Goyal, M. K. et al. Modeling of daily pan evaporation in sub tropical climates using ANN, LS-SVR, Fuzzy Logic, and ANFIS. **Expert Systems with Applications**, v.41, p.5267–5276, 2014.

Haykin, S. *Neural networks: A comprehensive foundation*. 2nd ed. Hamilton: **Prentice Hall**, 1998, 842p.

Heinemann, A. B.; Van Oort, P. A. J.; Fernandes, D. S.; Maia, A. H. N. Sensitivity of APSIM/ORYZA model due to estimation errors in solar radiation. **Bragantia, Campinas**, v. 71, n. 4, p.572-582, 2012.

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

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.

Kişİ, Ö.; Çimen, M. **Evapotranspiration modelling using support vector machines**. Hydrological Sciences Journal, v.54, p.918–928, 2009.

Lorena, A. C.; Jacintho, L. F. O.; Siqueira, M. F.; Giovanni, R.; Lohmann, L. G.; Carvalho, A. C.P.L.F.; Yamamoto, M. Comparing machine learning classifiers in potential distribution modelling. **Expert Systems with Applications**, v.38, p.5268–5275, 2011.

Mitchell, T. *Machine Learning*. **McGraw Hill**, 1997.

Pereira, A. R.; Angelocci, L. R.; Sentelhas, P. C. **Agrometeorologia: fundamentos e aplicações**. Agropecuária, Guaíba, 2002, 478p.

Santos C. M.; Souza J. L.; Teramoto E. T.; Tiba C.; Melo R. O. Modelagem da irradiação solar global média horária mensal ( $h_g^h$ ) para quatro localidades de Alagoas/Brasil. **Nativa, Sinop**, v. 02, n. 02, p. 79-88, abr./jun, 2014.

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.



## XIX Congresso Brasileiro de Agrometeorologia

23 a 28 de agosto de 2015

Lavras – MG – Brasil

Agrometeorologia no século 21:



### *O desafio do uso sustentável dos biomas brasileiros*

Tabari, H.; Ozgur Kisi, O.; Ezani, A.; Talaee, P. H. 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.

Teodoro, I. **Respostas técnico-econômicas da cana de açúcar a níveis de irrigação e adubação nitrogenada**. Campina Grande: UFCG, 2011. 100 f. Tese de doutorado.

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