

## ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA POR PENMAN-MONTEITH-FAO-56 USANDO MÁQUINA DE VETORES DE SUPORTE

MAURÍCIO B. P. SILVA<sup>1</sup>, CÍCERO. M. DOS SANTOS<sup>2</sup>, JOSÉ LEONALDO DE SOUZA<sup>3</sup>, RICARDO ARAÚJO FERREIRA JÚNIOR<sup>4</sup>, GUSTAVO BASTOS LYRA<sup>5</sup>

<sup>1</sup>Engenheiro Agrônomo, Doutorando em Irrigação e Drenagem, UNESP-FCA/Botucatu-SP, mauricio.prado19@hotmail.com;

<sup>2</sup>Físico, Doutor em Agronomia, professor, Universidade Federal do Pará/Altamira-PA;

<sup>3</sup>Meteorologista, Doutor em Agronomia, professor, Universidade Federal de Alagoas/Maceió-AL;

<sup>4</sup>Engenheiro Agrônomo, Doutor em Agronomia, professor, Universidade Federal de Alagoas/Rio Largo-AL;

<sup>5</sup>Meteorologista, Doutor em Agronomia, professor, Universidade Federal do Rio de Janeiro/Seropédica-RJ.

XLVI Congresso Brasileiro de Engenharia Agrícola - CONBEA 2017  
30 de julho a 03 de agosto de 2017 - Maceió - AL, Brasil

**RESUMO:** A disponibilidade da Evapotranspiração de Referência ( $ET_0$ ) é de grande importância para o ciclo hidrológico, dimensionamento e manejo adequado de água em culturas agrícolas, que leva ajustes necessários para sua melhor utilização. Existem muitos meios de medir  $ET_0$ , mas, devido ao custo de aquisição dos sensores e a escassez de informações espaciais de variáveis meteorológicas, a  $ET_0$  não está disponível em muitos locais. Objetivou-se neste trabalho estimar a  $ET_0$  utilizando Máquina de Vetores de Suporte (SVM), que é procedimento de regressão, e comparar com a  $ET_0$  pelo método de Penman-Monteith-FAO-56 ( $ET_{OPMF-56}$ ). São utilizados dados meteorológicos de temperatura do ar, umidade relativa do ar, precipitação, irradiação solar e velocidade do vento, do período de 2009 a 2011, obtidos da estação agrometeorológica localizada no Centro de Ciências Agrárias da Universidade Federal de Alagoas. São avaliadas duas combinações nas variáveis de entrada (SVM<sub>1</sub> – todas variáveis) e (SVM<sub>2</sub> – exceto precipitação). Os índices estatísticos de comparação de modelos foram: MBE (rMBE), RMSE (rRMSE) e “d” de Willmott. As estimativas de  $ET_0$  com SVM concordam com o  $ET_{OPMF-56}$  e segue a mesma tendência com elevado coeficiente de determinação ( $R^2=0,960$  com SVM<sub>1</sub> e  $R^2=0,957$  com SVM<sub>2</sub>). O SVM<sub>1</sub> teve melhor desempenho (MBE=-0,032 mm dia<sup>-1</sup>, RMSE=0,225 mm dia<sup>-1</sup> e d=0,991) que a combinação SVM<sub>2</sub> (MBE=-0,024 mm dia<sup>-1</sup>, RMSE=0,244 mm dia<sup>-1</sup> e d=0,989). Em geral, a SVM dá excelente estimativa e pode ser utilizada na estimativa de  $ET_0$  com boa acurácia.

**PALAVRAS-CHAVE:** Aprendizado de Máquinas, SVM, Regressão, Evapotranspiração.

## ESTIMATION OF REFERENCE EVAPOTRANSPIRATION BY PENMAN-MONTEITH-FAO56 USING SUPPORT VECTOR MACHINES

**ABSTRACT:** The availability of Reference Evapotranspiration ( $ET_0$ ) is of great importance for the hydrological cycle, sizing and proper management of water in agricultural crops, which takes adjustments necessary for its best use. There are many ways to measure  $ET_0$ , but because of the cost of sensor acquisition and the scarcity of spatial information from weather variables,  $ET_0$  is not available in many locations. The objective of this article was to estimate the  $ET_0$  using Supporting Vector Machines (SVM), which are regression procedures, and compare with  $ET_0$  by the Penman-Monteith-FAO-56 ( $ET_{OPMF-56}$ ) method. Using meteorological data on air temperature, relative air humidity, precipitation, solar irradiance and wind speed, period from 2009 to 2011, obtained from the agrometeorological station

located at the Center of Agrarian Sciences of the Federal University of Alagoas. Two combinations are evaluated in the input variables (SVM<sub>1</sub> - all variables) and (SVM<sub>2</sub> - except precipitation). The statistical indices of model comparison were: MBE (rMBE), RMSE (rRMSE) and “d” of Willmott. The estimates of ET<sub>O</sub> with SVM agree with ET<sub>OPMF-56</sub> and follow the same trend with high coefficient of determination (R<sup>2</sup>=0.960 with SVM<sub>1</sub> and R<sup>2</sup>=0.957 with SVM<sub>2</sub>). SVM<sub>1</sub> had better performance (MBE=-0.032 mm day<sup>-1</sup>, RMSE=0.225 mm day<sup>-1</sup> and d=0.991) than the SVM<sub>2</sub> combination (MBE=-0.024 mm day<sup>-1</sup>, RMSE=0.244 mm day<sup>-1</sup> and d=0.989). In general, SVM gives an excellent estimate and can be used to estimate ET<sub>O</sub> with good accuracy.

**Keywords:** Machine Learning, SVM, Regression, Evapotranspiration.

## Introdução

A Evapotranspiração (ET) consiste na combinação de dois processos separados, a perda de água através da superfície do solo por evaporação e em parte por transpiração da cultura para a atmosfera (Pereira et al., 1997; Allen et al., 1998). A ET é um processo muito complexo que depende da interação de vários parâmetros atmosféricos, de plantas e de solo. Fisicamente, ET reflete a demanda atmosférica de água e representa o efeito integrado de vários elementos meteorológicos sobre o uso da água da vegetação (Liu et al., 2017).

O conhecimento e a quantificação da ET são de grande importância para gestão de recursos hídricos, para muitas disciplinas de estudos hidrológicos, estudos ambientais e agrícolas, na meteorologia, na área florestal, 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., 2011; Adeloje et al., 2012; Huo et al., 2012).

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 (Allen et al., 1998; Tabari et al., 2011). Esses modelos são divididos em: modelos físicos que exigem um estudo mais complexo e os modelos empíricos com uma abordagem mais simples. Atualmente o modelo físico modificado por Penman-Monteith (ET<sub>OPMF-56</sub>) tem sido o mais recomendado para o cálculo da Evapotranspiração de Referência (ET<sub>O</sub>) após ser testado e comparado com outros métodos clássicos (Blaney-Criddle, radiação, Penman-modificado e tanque Classe A) e ter proporcionado melhores resultados com relação a uma cultura de referência (grama) (Allen et al., 1998). Este método consiste na taxa de evapotranspiração de uma cultura hipotética com uma altura assumida de 12 centímetros, uma resistência fixa da copa de 70 s<sup>m</sup><sup>-1</sup> e albedo de 0,23, muito parecida com a evapotranspiração de uma extensa superfície de grama verde de altura uniforme (Allen et al., 1998; Adeloje et al., 2012).

Embora um grande número de avaliações sobre o modelo de ET<sub>O</sub> pode ser encontrado na literatura, eles foram feitos principalmente contra estimativas com o modelo ET<sub>OPMF-56</sub>. Mardikis et al., (2005) compararam duas abordagens para estimar ET<sub>O</sub> na Grécia com o ET<sub>OPMF-56</sub>. Dinpashoh (2006) usou a interpolação espacial no Irã para preencher lacunas em séries climáticas ao uso do método ET<sub>OPMF-56</sub>. Na bacia experimental do riacho Gameleira, Vitória de Santo Antão – Pernambuco, (Moura et al., 2013), estimaram a ET<sub>O</sub> por métodos indiretos em várias escalas de tempo e comparam as estimativas com o ET<sub>OPMF-56</sub>. De acordo com autores, o método baseado na radiação solar é o que apresenta melhor estimativa.

Recentemente a técnica de aprendizado de máquina (AM), Máquina de Vetores de Suporte (SVM), vem ganhando destaque na modelagem de ET<sub>O</sub> devido à sua capacidade de capturar e representar relações complexas entrada – saída sem o conhecimento detalhado da

fenomenologia do processo. Portanto, a AM fornece explicação de um processo sem uma necessidade de modelos físicos complexos. Kisi e Cimen (2009) estudaram o potencial da SVM na modelagem de ETo para o centro da Califórnia. Eles descobriram que os modelos de SVM podem ser efetivamente usados para modelagem ETo. Wen et al., (2015) usaram SVM para modelar ETo com dados climáticos limitados em regiões áridas. Tabari et al., (2012) avaliaram o desempenho de SVM, sistema de inferência neuro-fuzzy adaptativo, regressão e modelos baseados no clima para modelagem de ETo. Kisi (2013) empregou máquina de vetores de suporte menos quadrado (LS-SVM) para estimar valores diários de ETo.

Portanto, a avaliação de novas metodologias possibilita um maior estudo temporal e espacial da variável de interesse. Além disso, informações de aplicação da SVM na estimativa de ETo no Brasil e, assim como no Estado de Alagoas são escassos ou inexistentes.

Diante das considerações o estudo tem como objetivos: (i) avaliar o desempenho da SVM com a função de Kernel Radial Basis Function (RBF) na estimativa de ETo, iii) comparar as estimativas de ETo obtidas a partir de SVM com ETo pela metodologia ET<sub>OPMF</sub>.

56.

## Materiais e Métodos

### Área de estudo e dados climáticos

Os dados utilizados neste estudo foram medidos 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 altitude de 127 m), situado nos Tabuleiros Costeiros do Estado de Alagoas (Figura 1).

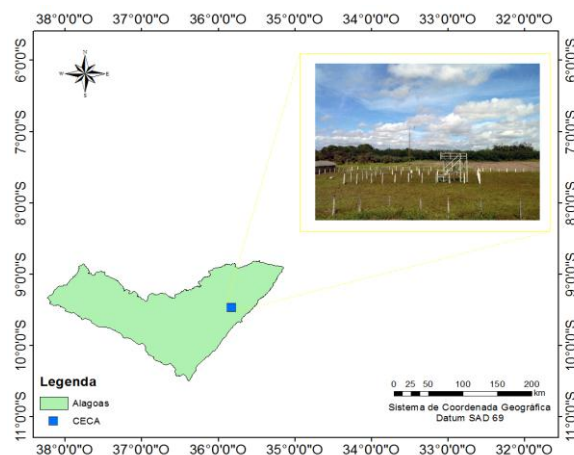


Figura 1. Localização da área experimental.

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, a temperatura do ar média anual de 25,4 °C, umidade relativa do a média anual de 81,8% e fração da nebulosidade de 42,9%.

Os dados das variáveis meteorológicas foram obtidos da estação agrometeorológica automática (aquisição automática - CR10X, 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, a 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 organizados e processados em programas desenvolvidos para tal finalidade.

#### *Cálculo da Evapotranspiração de referência (ET<sub>o</sub>)*

As técnicas de lisimetria ou micrometeorológicas utilizadas para medição de ET<sub>o</sub> não estão facilmente disponíveis. Isto acontece por vários motivos, podendo ser listado o custo de instalação e manutenção, a extensão territorial da área, por exemplo. Os valores de ET<sub>o</sub> calculados pelo método FAO-56 (PMF-56) serão considerados como padrão para ajustar e validar os modelos. A FAO aceitou o modelo de Penman-Monteith como a equação padrão para a estimativa de ET<sub>o</sub>. O método é uma combinação do balanço energético e dos processos aerodinâmicos com mais dois fatores de resistência, a aerodinâmica e as resistências de superfície (em massa). A Evapotranspiração de Referência (ET<sub>o</sub>) (mm dia<sup>-1</sup>) foi obtida pelo método de Penman-Monteith (Allen et al., 1998), através do Boletim da FAO-56 (ET<sub>OPMF-56</sub>), expresso conforme eq. (1):

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

em que,  $R_n$  (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;  $u_2$  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), “ $e_s$ ” é a pressão do vapor d’água do ar (kPa), e  $T$  é a temperatura do ar média (°C),  $\Delta$  = inclinação da curva de pressão de vapor saturado versus temperatura (kPa °C<sup>-1</sup>) e  $\gamma$  = coeficiente psicrométrico (kPa °C<sup>-1</sup>). O saldo de radiação ( $R_n$ ) foi obtido como fração da  $R_g$  ( $R_n = 0,576 H_G$ ; com coeficiente de determinação ( $r^2$ ) igual a 0,927), realizada pelo Laboratório de Agrometeorologia e Radiometria Solar (LARAS) da UFAL (Ferreira Júnior, 2010).  $H_G$  é a irradiação solar global medida.

#### *Técnicas de Aprendizado de Máquinas para estimativa de ET<sub>o</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 AM, aqui será considerada e avaliada a Máquina de Vetores de Suporte (SVM).

A SVM pode ser usada para problemas de classificação e regressão, sendo um classificador derivado da teoria de aprendizagem estatística introduzidos pela primeira vez por Vapnik (1995). A regressão com SVM consiste em estimar uma função de acordo com um determinado conjunto de dados definidos:  $\{(x_i, y_i)\}_{i=1}^n$ , onde  $x_i \in \mathcal{R}^n$  é o vetor de caracterização que representa as variáveis de entrada;  $y_i \in \{-1, +1\}$  é a saída e  $n$  é o número total de conjuntos de dados (Tabari et al., 2012). Neste estudo, os vetores de entrada ( $x_i$ ) referem-se à temperatura do ar diária, umidade relativa do ar, irradiação solar global diária, velocidade do vento e a precipitação, ( $y_i$ ) refere aos

valores de ETo (Tabela 1). Maiores detalhes da teoria da SVM podem ser encontrados em (Vapnik, 1998).

O desempenho e a capacidade de aprendizado da SVM na regressão são atribuídos ao uso do conjunto de funções de Kernel, que diagramam as informações para um espaço de dimensão mais elevado (Piri et al., 2015). Neste estudo a função Radial Basis Function (RBF) de Kernel foi considerada para a regressão com SVM. A RBF possui três parâmetros: C (custo),  $\gamma$  (gama) e  $\epsilon$  (épsilon), que devem ser ajustados adequadamente. A seleção destes parâmetros é realizada por inúmeros ensaios com diferentes combinações de C,  $\gamma$  e  $\epsilon$  até obter o melhor ajuste.

A SVM utilizada é a compilação LibSVM integrada para a classificação de vetores de suporte, regressão e estimativa de distribuição (disponível no site: <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>). Maiores detalhes de sua estrutura funcional são encontrados em (Hsu et al., 2003; Chang e Lin, 2011). A LibSVM é implementada e utilizada através do *Waikato Environment for Knowledge Analysis* (WEKA). O WEKA é um conjunto de algoritmos de AMs para tarefas de mineração de dados, disponível em: (<http://www.cs.waikato.ac.nz/~ml/weka/>) (Hall et al., 2009). Fornecendo ao usuário uma programação em Java, o WEKA contém ferramentas para pré-processamento de dados, classificação, regressão, regras de associação e visualização. A Tabela 1 apresenta os modelos de SVM com as nomenclaturas e as variáveis de entrada na modelagem para cada combinação.

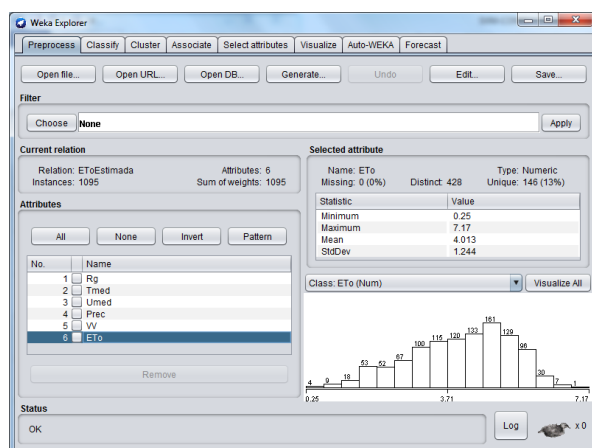


Figura 2. Ferramenta computacional WEKA.

**Tabela 1.** Combinação de SVM e os parâmetros de entrada.

SVM	Variáveis de entrada
SVM <sub>1</sub>	H <sub>G</sub> , T <sub>med</sub> , UR, P, Vv
SVM <sub>2</sub>	H <sub>G</sub> , T <sub>med</sub> , UR, Vv

H<sub>G</sub> = irradiação solar global, T<sub>med</sub> = temperatura do ar média, UR = umidade relativa do ar, P = precipitação e Vv velocidade do vento.

### Índices estatísticos

Na avaliação do desempenho dos modelos SVM foram utilizados: MBE (Mean Bias Error) (Eq. 2), Relative Mean Bias Error (rMBE) (Eq. 3), Root Mean Square Error (RMSE) (Eq. 4), Relative Root Mean Square Error (rRMSE) (Eq. 5) e “d” de Willmott (Eq. 6) (Escobedo et al., 2011). Estes índices estatísticas permitem a detecção de subestimativa ou superestimativa, espalhamento ou tendência sistemática e ajustamento dos modelos.

$$MBE = \frac{\sum_{i=1}^{N'} (P_i - O_i)}{N'} \quad (2)$$

$$rMBE(\%) = 100 \times \frac{\sum_{i=1}^{N'} (P_i - O_i)}{\bar{X}} \quad (3)$$

$$RMSE = \left[ \frac{\sum_{i=1}^{N'} (P_i - O_i)^2}{N'} \right]^{\frac{1}{2}} \quad (4)$$

$$rRMSE(\%) = 100 \times \frac{\left[ \frac{\sum_{i=1}^{N'} (P_i - O_i)^2}{N'} \right]^{\frac{1}{2}}}{\bar{X}} \quad (5)$$

$$d = 1 - \frac{\sum_{i=1}^{N'} (P_i - O_i)^2}{\sum_{i=1}^{N'} (|P_i| + |O_i|)^2} \quad (6)$$

em que:  $P_i$  representa os valores estimados de ETo por SVM,  $O_i$  os valores de ETo<sub>PMF-56</sub>,  $|P_i|$  o valor absoluto da diferença  $P_i - \bar{O}_i$ , em que  $\bar{O}_i$ , representa a média de  $O_i$ ,  $|O_i|$  representa o valor absoluto da diferença  $O_i - \bar{O}_i$ .  $\bar{X}$  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 (excellent if) rRMSE < 10%;

Bom se (good if) 10% ≤ rRMSE < 20%;

Aceitável se (fair if) 20% ≤ rRMSE < 30%;

Pobre se (poor if) rRMSE ≥ 30%.

O valor de RMSE (rRMSE) é o índice conclusivo sobre o desempenho dos modelos neste estudo. Todos os cálculos estatísticos foram realizados por programas no Microcal™ Origin 6.0®.

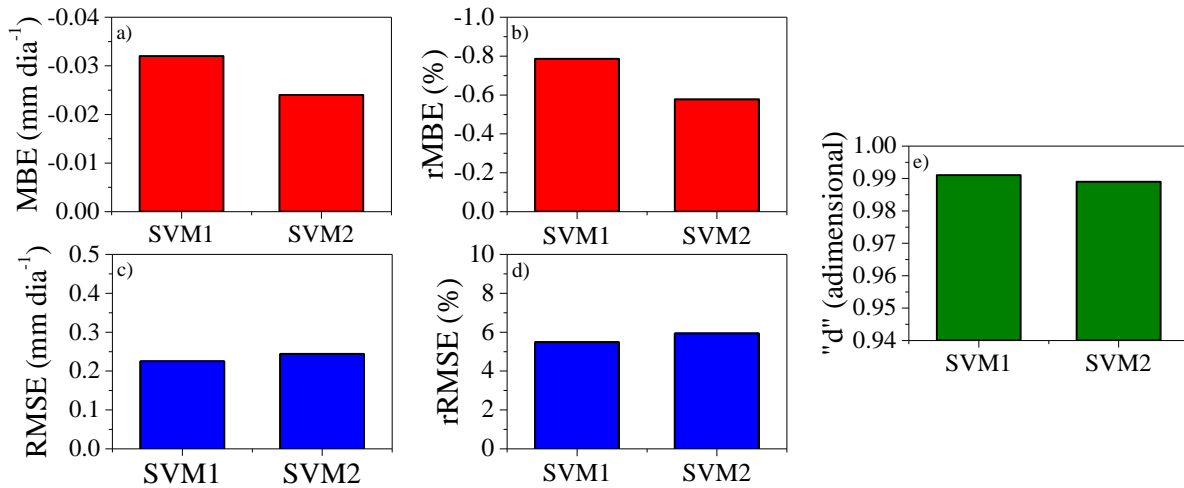
## Resultados e Discussão

A SVM foi utilizada na determinação de ETo. A Radial Basis Function (RBF) foi à função adotada para a SVM. Foi utilizado a ferramenta percent Split do WEKA, sendo 70% (correspondendo a 767 dias) dos dados utilizados para o treinamento dos modelos e 30% (correspondendo a 328 dias) para a validação. A escolha dos dados para treinamento e validação é feita aleatoriamente. Os três parâmetros a ser ajustados da RBF de Kernel são: C,  $\gamma$  e  $\varepsilon$ . Os parâmetros: C,  $\varepsilon$  e  $\gamma$  foram ajustados através de inúmeros ensaios com diferentes combinações por validação cruzada e foram considerados os seguintes conjuntos de valores: C = {10; 50; 100; 200; 400 e 500},  $\varepsilon$  = {0,001; 0,002; 0,003; 0,004; 0,005 e 0,006} e  $\gamma$  = {0,1; 0,2; 0,3; 0,4; 0,5 e 0,6}. Os valores ideais dos parâmetros obtidos e utilizados foram: C = 500,  $\gamma$  = 0,002 e  $\varepsilon$  = 0,001 (Tabela 2). Estes parâmetros foram considerados por resultarem em menores erros nas estimativas de ETo.

**Tabela 2.** Parâmetros definidos para SVM.

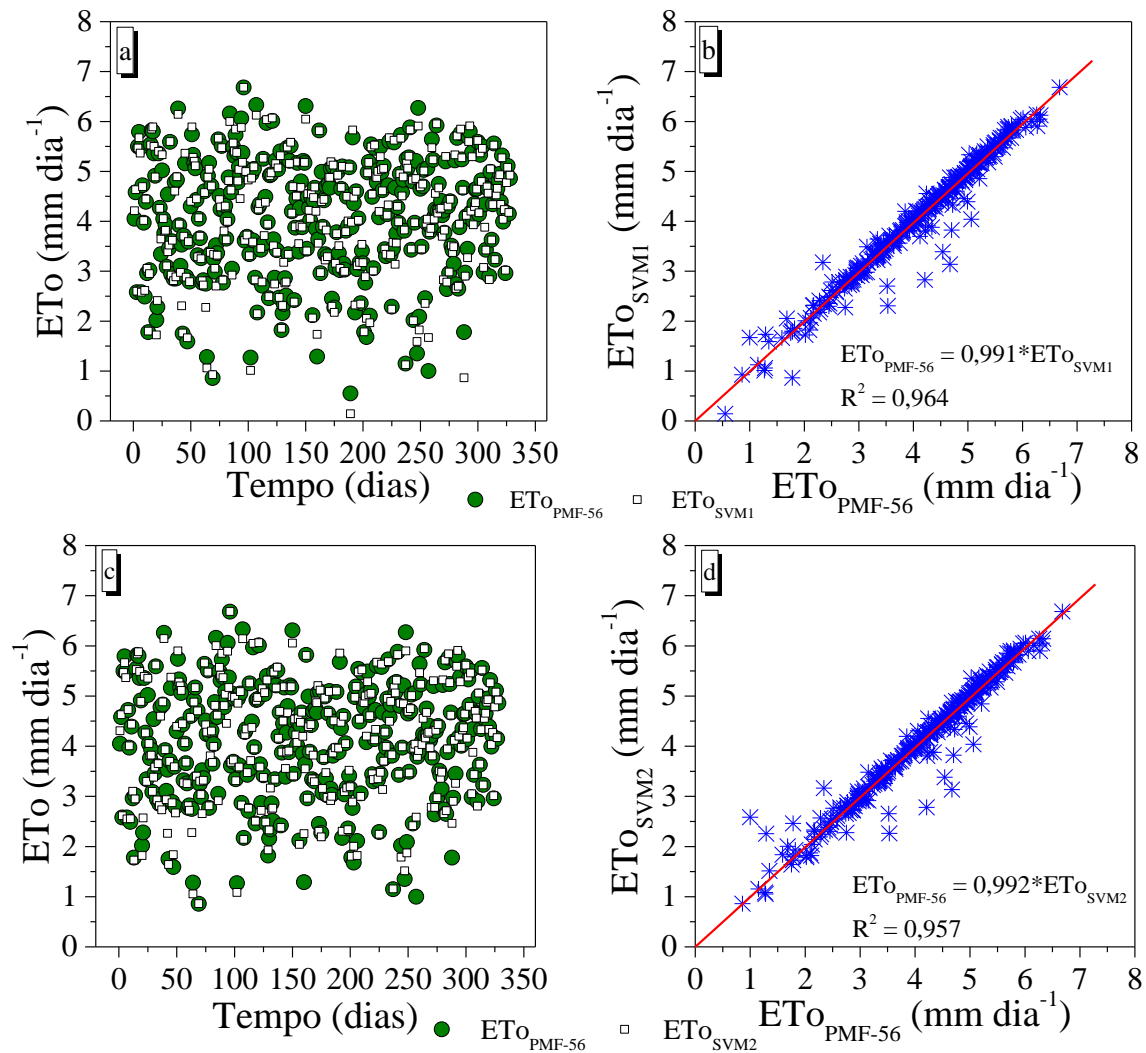
Máquina de Vetores de Suporte	Radial Basis Function (RBF)		
	C	$\gamma$	$\varepsilon$
	500	0,002	0,001

Na Figura (3a, b, c, d, e) são mostrados os resultados dos valores de MBE, rMBE, RMSE, rRMSE e “d” de Willmott da análise estatística das combinações de SVM na estimativa de ETo comparada com  $ET_{OPMF-56}$ . A combinação SVM<sub>1</sub> com as variáveis de entrada  $T_{med}$ ,  $H_G$ , UR,  $V_v$  e “P” teve desempenho inferior (MBE = -0,032 mm dia<sup>-1</sup> (-0,785 %), RMSE = 0,225 mm dia<sup>-1</sup> (5,484 %) e d = 0,991) que a combinação SVM<sub>2</sub> (MBE = -0,024 mm dia<sup>-1</sup> -0,577 %), RMSE = 0,244 mm dia<sup>-1</sup> (5,928) e d = 0,989). A inserção da precipitação não melhorou o desempenho do SVM<sub>1</sub> quando comparado com SVM<sub>2</sub>. No entanto, a diferença entre os erros é pequena. Os resultados indicam que os dois modelos de SVM subestimam  $ET_{OPMF-56}$ . Os valores de rRMSE < 10,00 % mostram que o desempenho da SVM é excelente para as duas combinações.



**Figura 3.** Índices estatísticos de desempenho das combinações SVM<sub>1</sub> e SVM<sub>2</sub>: a) MBE, b) rMBE, c) RMSE, d) rRMSE e e) “d” de Willmott.

A Figura (4a, b, c e d) apresenta as estimativas de ETo para as combinações SVM<sub>1</sub> e SVM<sub>2</sub>. Os resultados obtidos com SVM para estimativa de ETo mostra que as duas combinações de variáveis de entrada subestimaram os valores estimados por  $ET_{OPMF-56}$ , com SVM<sub>2</sub> e SVM<sub>1</sub>, a maior e menor subestimativa, respectivamente. As subestimativas são claramente vistas com a maioria dos pontos verdes (SVM<sub>1</sub> e SVM<sub>2</sub>) acima dos quadradinhos brancos ( $ET_{OPMF-56}$ ) (Figura 4a, c) e os asteriscos azuis crescentes linearmente com a regressão (Figura 4b, d). As estimativas de ETo com SVM concordam com o  $ET_{OPMF-56}$  e segue a mesma tendência com elevado coeficiente de determinação  $R^2 = 0,964$  com SVM<sub>1</sub> e  $R^2 = 0,957$  com SVM<sub>2</sub>. Estes resultados indicam que cerca de 96,00% da variação de ETo é explicado pelas variáveis de entradas e pelo o modelo utilizado.



**Figura 4.** Dispersão das estimativas: a) e b)  $ETo_{SVM1}$  vs  $ETo_{PMF-56}$ . c) e d)  $ETo_{SVM2}$  vs  $ETo_{PMF-56}$ .

Os resultados mostram  $SVM_1$  com rRMSE de 5,484 % o melhor para estimar  $ETo$  na região de estudo. A combinação  $SVM_2$  com rRMSE = 5,928 % é a segunda opção. Estes resultados estão condicionados ao ajuste dos parâmetros, a técnica de aprendizado de máquina utilizada e das variáveis de entrada. Os parâmetros  $C$ ,  $\gamma$  e  $\epsilon$  da RBF definidos adequadamente são fatores responsáveis pelo desempenho da SVM. No modelo de PMF-56 a precipitação não é uma variável de entrada. Nos resultados obtidos a precipitação foi inserida e melhorou o desempenho dos modelos. Os resultados obtidos neste estudo são semelhantes aos obtidos por (Tabari et al., 2012), que utilizaram diferentes métodos para estimativa de  $ETo$  na cidade de Hamadan – Irã e obtiveram com RBF valores de RMSE entre 0,017 – 0,075 mm dia<sup>-1</sup>. Os resultados obtidos neste trabalho assemelham-se aos obtidos em Windsor, Oakville e Santa Rosa na Califórnia – USA, (Kişi e Çimen, 2009) que estimaram  $ETo$  com SVM e obtiveram valores de RMSE variando de 0,114 a 0,493 mm dia<sup>-1</sup> e  $R^2$  entre 0,948 e 0,994. As vantagens da SVM são a sua capacidade e a flexibilidade de modelar as relações não-lineares, buscando uma solução otimizada que leva a um melhor desempenho de generalização que outros modelos (Tabari et al., 2012). A principal desvantagem da SVM é que não tem nenhuma base física e se assemelha a uma caixa preta. Mesmo assim, a SVM é capaz de lidar bem com todas as condições de ruídos dos dados modelados.

## Conclusões

No presente trabalho a SVM foi avaliada na estimativa de ETo. O método de PMF-56 é considerado como referência para comparação. Foi verificado que a SVM dá excelente estimativa ( $rRMSE < 10\%$ ) e pode ser utilizadas na estimativa de ETo com boa acurácia. As combinações de SVM resultaram em baixos espalhamentos. O ajuste dos parâmetros  $C$ ,  $\gamma$  e  $\varepsilon$  proporcionou melhor ajuste da RBF. A inserção da precipitação acumulada como variável de entrada melhorou o desempenho da SVM. Portanto, a SVM pode auxiliar em projetos de irrigação, modelagem hidrológica e estimativa da ETo para gestão de recursos hídricos. Os resultados deste estudo de caso, também, podem fornecer orientações básicas engenheiros de irrigação e agricultores para uma melhor estimativa de ETo. Destaca-se a necessidade de pesquisas adicionais para testar a técnica usada aqui em outros climas para avaliação de efeitos climáticos e para culturas com as diferentes condições de superfície.

## Referência

- Adebayo, 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.
- Allen, R. A. et al. Evapotranspiration information reporting: I. Factors governing measurement accuracy. In: *Agricultural water management*, v. 98, p. 899-920, 2011.
- Chang, C.-C.; Lin, C.-J. LIBSVM: a library for support vector machines. *ACM Transactions on Intelligent Systems and Technology*, 2:27:1--27:27. 2011. Software available at: <http://www.csie.ntu.edu.tw/~cjlin/libsvm/>.
- Dinpashoh, Y. Study of reference crop evapotranspiration in I.R. of Iran. *Agric. Water Manag.* 84 (1–2), 123–129, 2006.
- 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.
- Hall, M.; Frank, E.; Holmes, G.; Pfahringer, B.; Reutemrna, P.; Witten. I. H. The WEKA Data Mining Software: An Update; *SIGKDD Explorations*, v.11, Issue 1, 2009.
- 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.
- Hsu, C. C.; Chang, C. C.; Lin, C. J A practical guide to support vector classification. 2010. <http://www.csie.ntu.edu.tw/~cjlin/papers/cuide/guide.pdf>.
- 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.
- Kisi, O. Least squares support vector machine for modeling daily reference evapotranspiration. *Irrig. Sci.* 31, 611–619, 2013.
- Kisi, O., Cimen, M. Evapotranspiration modelling using support vector machines/Modélisation de l'évapotranspiration à l'aide de "support vector machines". *Hydrol. Sci. J.* 54, 918–928, 2009.
- Kişi, O.; Çimen, M. Evapotranspiration modelling using support vector machines. *Hydrological Sciences–Journal–des Sciences Hydrologiques* v.54, p.918-928, 2009.

Liu, X.; Xu, C.; Zhong, X.; Li, Y.; Yuan, X.; Cao, J. Comparison of 16 models for reference crop evapotranspiration against weighing lysimeter measurement. *Agricultural Water Management* 184, 145–155, 2017.

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.

Mardikis, M.G., Kalivas, D.P., Kollias, V.J. Comparison of interpolation methods for the prediction of reference evapotranspiration – an application in Greece. *WaterResour. Manag.* 19 (3), 251–278, 2005.

Mitchell, T. *Machine Learning*. McGraw-Hill, New York, 1997.

Moura, A. R. C.; Montenegro, S. M. G. L.; Antonino, A. C. D.; Azevedo, J. R. G.; Silva, B. B.; Oliveira, L. M. M. Evapotranspiração de referência baseada em métodos empíricos em bacia experimental no estado de Pernambuco - Brasil. *Revista Brasileira de Meteorologia*, v.28, n.2, 181 - 191, 2013.

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

Piri, J.; Shamshirband, S.; Dalibor Petkovic, D.; Tong, C. W.; Rehman, M. H. Prediction of the solar radiation on the Earth using support vector regression technique. *Infrared Physics & Technology*, v.68, p.179–185, 2015.

Tabari, H.; Ozgur Kisi, O.; Ezani, A.; Talaei, 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.

Vapnik, V. N. *Statistical learning theory*. New York: Wiley, 1998.

Vapnik, V. N. *The nature of statistical learning theory*. New York: Springer, 1995.

Wen, X., Si, J., He, Z., Wu, J., Shao, H., Yu, H. Support-vector-machine-based models for modeling daily reference evapotranspiration with limited climatic data in extreme arid regions. *Water Resour. Manage.* 29, 3195–3209, 2015.