

BARTOLOMEU FÉLIX TANGUNE

**EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO:
MÉTODOS EMPÍRICOS, APRENDIZADO DE MÁQUINA E GEOESPACIAL**

Botucatu

2017

BARTOLOMEU FÉLIX TANGUNE

**EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO:
MÉTODOS EMPÍRICOS, APRENDIZADO DE MÁQUINA E GEOESPACIAL**

Tese apresentada à Faculdade de Ciências
Agronômicas da Unesp Câmpus de Botucatu,
para obtenção do título de Doutor em
Agronomia (Irrigação e Drenagem).

Orientador: Prof. Dr. João Francisco Escobedo

Botucatu

2017

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

T164e Tangune, Bartolomeu Félix, 1982-
Evapotranspiração de referência no estado de São Paulo: métodos empíricos, aprendizado de máquina e geoespacial / Bartolomeu Félix Tangune. - Botucatu : [s.n.], 2017
124 p. : grafs. color., ils. color., tabs.

Tese (Doutorado) - Universidade Estadual Paulista, Faculdade de Ciências Agrônômicas, Botucatu, 2017
Orientador: João Francisco Escobedo
Inclui bibliografia

1. Evapotranspiração. 2. Krigagem. 3. Meteorologia. 4. Redes neurais (Computação). 5. Radiação solar. I. Escobedo, João Francisco. II. Universidade Estadual Paulista "Júlio de Mesquita Filho" (Câmpus de Botucatu). Faculdade de Ciências Agrônômicas. III. Título.

"Permitida a cópia total ou parcial deste documento, desde que citada a fonte"

CERTIFICADO DE APROVAÇÃO

TÍTULO DA TESE: EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: MÉTODOS EMPÍRICOS, APRENDIZADO DE MÁQUINA E GEOESPACIAL

AUTOR: BARTOLOMEU FÉLIX TANGUNE

ORIENTADOR: JOÃO FRANCISCO ESCOBEDO

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



Prof. Dr. JOÃO FRANCISCO ESCOBEDO
Depto de Engenharia Rural / UNESP - Faculdade de Ciências Agrônômicas de Botucatu



Prof. Dr. CÉLIA REGINA LOPES ZIMBACK
Depto de Solos e Recursos Ambientais / Faculdade de Ciências Agrônômica - UNESP



Prof. Dr. PAULO ANDRÉ DE OLIVEIRA
Depto. Informática / Faculdade de Tecnologia de Botucatu



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



Profa. Dra. VALÉRIA CRISTINA RODRIGUES SARNIGHAUSEN
Depto de Bioprocessos e Biotecnologia / UNESP - Faculdade de Ciências Agrônômicas de Botucatu

Botucatu, 08 de maio de 2017.

A Deus,

Pela vida, proteção, sustento e presença em todos os momentos

OFEREÇO

Aos meus pais Félix Sobrinho Tangune e Mónica Francisco Miambo, pelo amor, presença em todos os momentos e pela motivação.

À minha esposa: Ângela Carvino Chibamo, pela motivação e apoio oferecido.

Aos meu sogros: Carvino Chibamo e Angélica Mabecua, pelo amor e motivação.

Aos meus avós (*in memória*), pela lição da vida.

Aos meus irmãos: Jorgina Tangune, Anacleto Tangune, Isabel Tangune, Jonas Tangune e Moíses Tangune, pela confiança, motivação e amor

DEDICO

AGRADECIMENTOS

À Deus, pelo amparo.

Aos meus pais, pela motivação, ensinamento e amor imensurável.

À Universidade Estadual Paulista, em particular a Faculdade de Ciências Agrônômicas – Câmpus de Botucatu, pela oportunidade de frequentar o curso.

Ao Prof. Dr. João Francisco Escobedo (orientador), pelo apoio, amizade, ensinamento e pela motivação. Muito obrigado!

À todo corpo docente do curso de Pós- Graduação em Agronomia (Irrigação e Drenagem) da UNESP, Câmpus de Botucatu;

Aos amigos do laboratório: Cícero Manoel, Maurício Prado, Esteban Conde, pelos conhecimentos compartilhados.

Á todos amigos e colegas do curso, pela troca de conhecimento e experiência.

Aos amigos: Zeca Timbe, Catine Chimene, Joel Nuvunga, os meus agradecimentos.

À todos irmãos em Cristo do Templo do Poder de Deus e da Assembleia de Deus em Botucatu, pelo amor, carinho e ensinamentos.

À CAPES – Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pela bolsa de doutorado.

À Universidade Eduardo Mondlane, em particular a Escola Superior de Desenvolvimento Rural, pela autorização concedida a fim de dar continuidade aos estudos.

À todos que direta ou indiretamente tenham contribuídos para a realização desta pesquisa.

RESUMO

A evapotranspiração de referência (ET_o) é importante na agricultura para satisfazer as necessidades de água das culturas e para o manejo dos sistemas de irrigação. A ET_o pode ser estimada com precisão a partir do método padrão de Penman Monteith FAO 56, porém, o seu uso é bastante complexo. Sendo assim, vários métodos empíricos de uso simples vem sendo desenvolvidos por diversos pesquisadores, todavia, a sua escolha deve ser feita de forma cuidadosa, pois apresentam um desempenho que varia em função das condições climáticas de cada local. A variabilidade do desempenho dos métodos empíricos tem levado os pesquisadores a procurarem outros métodos alternativos. Como resultado dessas pesquisas, há que destacar a técnica de aprendizado de máquinas (TAM): redes neurais artificiais (RNAs) e máquina vetor de suporte (MVS). Diante do exposto, o presente trabalho foi dividido em três capítulos, onde no primeiro capítulo foi avaliado o desempenho dos métodos empíricos de temperatura (Benevides e Lopez - BenL, Hamon -Ham, Blaney Criddle Original e Hargreaves Samani -HS) e de radiação solar (Abtew, Jensen Haise - JensH, Makkink e Irmak) na estimativa da ET_o no estado de São Paulo. Todos os métodos foram avaliados em relação ao método padrão em escala anual e sazonal. Os resultados obtidos na escala anual mostraram que o método de Abtew apresentou o melhor desempenho. Na escala sazonal, observou-se que o método de JensH foi melhor no inverno, o de Irmak e de Abtew no verão e outono. O método de Abtew foi também melhor na primavera. No segundo capítulo, foi avaliado o desempenho dos métodos de HS, e de Abtew (melhores métodos empíricos em escala anual), RNAs e MVS. A RNA utilizada foi do tipo *Multilayer Perceptron*, com algoritmo de aprendizado *Backpropagation* e na MVS utilizou-se a função *Radial Basic Function* de Kernel, com *algoritmo Regression Sequential Minimal Optimization*. Os resultados obtidos na escala anual mostraram que a R6 (da RNA) e a M6 (da MVS) compostas por temperatura máxima (T_{max}), mínima (T_{min}), média do ar (T), radiação extraterrestre (R_a) e R_s produziram o melhor desempenho. Na escala sazonal, os melhores resultados foram observados nas arquiteturas R3 e M3, R4 e M4, R5 e M5, R6 e M6, compostas por: T_{max}, T_{min}, T, R_a e velocidade do vento; T_{max}, T_{min}, T, R_a e umidade relativa do ar; T e R_s,

respectivamente. Tanto no capítulo 1 quanto no 2, as análises estatísticas foram feitas com base nos índices MBE (*Mean Bias Error*), RSME (*Root Mean Square Error*), “d” de Willmott e R^2 (coeficiente de determinação). No terceiro capítulo, foi avaliada a técnica de interpolação por krigagem ordinária pontual (KOP), cujos variogramas obtidos foram avaliados com base na soma dos quadrados dos resíduos, em escala anual e sazonal. Todos os modelos variográficos obtidos apresentaram uma dependência espacial forte. A posterior, fez-se a validação cruzada da KOP com base nos coeficientes angular (β_1) e linear (β_0) da reta de regressão linear simples, MBE, RSME e MSDR (*Mean squared deviation ratio*), cujos resultados mostraram um ótimo desempenho da KOP.

Palavras – chave: Krigagem ordinária. Máquina vetor de suporte. Métodos de temperatura. Penman – Monteith.

ABSTRACT

The reference evapotranspiration (ET_o) is important in agriculture for crop water management and irrigation systems management. The ET_o can be estimated accurately by the FAO 56 standard method of Penman Monteith, however, its use is complex. Thus, several empirical methods of simple use have been developed by many researchers, but their choice must be made carefully because they present a performance that change according to the climate conditions of each location. The variability of the performance of empirical methods has led researchers to look for alternative methods. As the result, we must highlight the machine learning technique (MLT), such as artificial neural networks (ANNs) and support vector machine (SVM). This work was divided into three chapters. In the first chapter, four temperature-based (Benevides e Lopez - BenL, Hamon -Ham, Blaney Criddle Original e Hargreaves Samani -HS) and four radiation- based (Abtew, Jensen Haise - JensH, Makkink and Irmak) ET_o methods were tested against FAO 56 method, using annual and seasonal scale in the state of São Paulo. The results obtained in the annual scale showed that the Abtew method presented the best performance. On the seasonal scale, it was observed that the JensH method was better in the winter, the Irmak and Abtew methods were better in the summer and autumn. The Abtew method was also better in the spring. In the second chapter, HS and Abtew methods, ANNs and SVM were used. The ANN used was Multilayer Perceptron with Backpropagation learning algorithm, and in the SVM, was used Kernel Radial Basic Function with Regression Sequential Minimal Optimization learning algorithm. The obtained results in the annual scale showed that R6 for RNA and M6 for MVS composed of maximum temperature (T_{max}), minimum temperature (T_{min}), average air temperature (T), extraterrestrial radiation (R_a) and global solar radiation (R_s) had a better performance. On the seasonal scale, the better performance was observed in R3 e M3, R4 e M4, R5 e M5, R6 e M6 architectures, composed of T_{max}, T_{min}, T, R_a and wind speed; T_{max}, T_{min}, T, R_a and relative humidity; T and R_s; R6 and M6, respectively. All methods were analyzed using MBE (Mean Bias Error), RMSE (Root Mean Square Error), “d” of Wilmot (1985) and R² (determination coefficient). In the third chapter, the technique of interpolation by ordinary punctual kriging (OPK) was

evaluated, whose variograms were evaluated based on the residuals sum of squares, on an annual and seasonal scale. All the variographic models obtained showed a strong spatial dependence. Afterwards, cross-validation of OPK was performed based on the angular (β_1) and linear (β_0) coefficients of the simple linear regression line, MBE, RSME and MSDR (Mean squared deviation ratio), whose results showed an excellent performance of OPK.

Key words: Backpropagation. Support vector machine. Artificial neural networks.

LISTA DE ABREVIATURAS E SIGLAS

ET	Evapotranspiração
ET _o	Evapotranspiração de referência (mm d ⁻¹)
INMET	Instituto Nacional de Meteorologia, Brasil
CEPAGRI	Centro de Pesquisas Meteorológicas e Climáticas Aplicadas a Agricultura da Unicamp
FAO	Food and Agriculture Organization
PMF 56	Método padrão de Penman Monteith FAO 56
BenL	Método de Benevides e Lopez
Ham	Método de Hamon
BCO	Método de Blaney Criddle Original
HS	Método de Hargreaves e Samani
JensH	Método de Jensen e Haise
Mak	Método de Makkink
AB	Método de Abtew
MBE	<i>Mean Bias Error</i>
RMSE	<i>Root Mean Square Error</i>
d	Índice de Willmott
R ²	Coeficiente de determinação
R _a	Radiação extraterrestre (mm d ⁻¹)
R _s	Radiação solar global (mm d ⁻¹)
dr	Distância relativa terra – sol (rad)
ws	Ângulo horário do nascer e do por do sol (rad)
δ	Declinação solar (rad)
T _{max}	Temperatura máxima do ar (°C)
T _{min}	Temperatura mínima do ar (°C)
$\bar{T}$	Temperatura média do ar (°C)
UR	Umidade relativa do ar (°C)
U ₂	Velocidade do vento a 2 m de altura (m s ⁻¹)
TAM	Técnica de Aprendizado de Máquinas
MLP	<i>Multilayer Perceptron</i>

RNAs	Redes Neurais Artificiais
MVS	Máquina Vetor de Suporte
R1 a R6	Arquiteturas das RNAs
M1 a M6	Arquiteturas da MVS
WEKA	Weikato Environment of Knowledge Analysis
RgSMO	Algoritmo <i>Regression Sequential Minimal Optimization</i>
RBF	<i>Kernel Radial Basic Funtion</i>
C , γ e ε	Parâmetros do WEKA
KOP	Krigagem Oridinária Pontual
KO	Krigagem Oridinária
IDW	Método de inverso da distância ponderada
MSDR	<i>Mean squared deviation ratio</i>
SD	Desvio padrão
CV	Coeficiente de variação (%)
Co	Efeito pepita
Co+C	Patamar
IDE	Índice de dependência espacial (%)
SQR	Soma dos quadrados dos resíduos
β_1	Coeficiente angular da reta de regressão
β_0	Coeficiente linear da reta de regressão
GS+	<i>Geoestatistical for the Environmental Sciences</i>

SUMÁRIO

INTRODUÇÃO GERAL	19
CAPÍTULO 1 - ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: MÉTODOS EMPÍRICOS.....	23
1.1 INTRODUÇÃO	25
1.2 MATERIAL E MÉTODOS	27
1. 2.1 Localização e descrição do estudo	27
1.2.2 Método padrão de estimativa da ETo.....	29
1.2.2.1 Declividade da curva de pressão de saturação de vapor	30
1.2.2.2 Constante psicrométrica.....	30
1.2.2.3 Pressão de saturação e atual do vapor d'água	30
1.2.2.4 Saldo de radiação	31
1.2.3 Validação dos métodos empíricos.....	34
1.2.4 Análise de sazonalidade.....	35
1.3.1 Métodos empíricos de estimativa da ETo em escala anual.....	35
1.3.1.1 Métodos empíricos de temperatura para a estimativa da ETo	35
1.3.1.2 Métodos empíricos de radiação solar para a estimativa da ETo	38
1.3.2 Erros dos métodos empíricos no estado de São Paulo em escala anual....	41
1.3.3 Comportamento da ETo no estado de São Paulo em escala anual	42
1.3.4 Desempenho sazonal dos métodos empíricos no estado de São Paulo.....	45
1.3.5 Análise de sazonalidade dos oitos métodos de estimativa da ETo	48

1.4 DISCUSSÃO.....	50
1.5 CONCLUSÃO	52
Escala anual:	52
Escala sazonal:.....	53
REFERÊNCIAS	54
CAPÍTULO 2 - MODELAGEM DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: TÉCNICA DE APRENDIZADO DE MÁQUINAS E MODELOS EMPÍRICOS.....	59
2.1 INTRODUÇÃO.....	61
2.2 MATERIAL E MÉTODOS	63
2.2.1 Localização e descrição do estudo	63
2.2.2 Método padrão de estimativa da ETo	65
2.2.3 Métodos empíricos de estimativa da ETo	66
2.2.3.1 Método de Hargreaves – Samani	66
2.2.3.2 Método Abtew	66
2.2.4 ETo nas escalas anual, sazonal e softwares utilizados	66
2.2.4.1 Redes Neurais Artificiais (RNAs)	67
2.2.4.2 Máquina vetor de suporte (MVS)	68
2.2.5 Validação dos métodos empíricos e das TAM.....	69
2.3 RESULTADOS	70

2.3.1 Desempenho das TAM e métodos empíricos nas cidades do estado de São Paulo	70
2.3.2 Desempenho anual dos métodos empíricos, RNas e MVS.....	75
2.3.3 Erros dos métodos empíricos e da TAM em escala anual	77
2.3.4 Comportamento da ETo no estado de São Paulo em escala anual	78
2.3.5 Desempenho sazonal dos métodos empíricos, RNas e MVS	81
2.3.6 Erros dos métodos empíricos e da TAM em escala sazonal.....	84
2.4 DISCUSSÃO	84
2.5 CONCLUSÃO.....	86
Escala anual:.....	86
Escala sazonal:	87
REFERÊNCIAS.....	88
CAPÍTULO 3 - EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: MÉTODO GEOESPACIAL	94
3.1 INTRODUÇÃO	96
3.2 MATERIAL E MÉTODOS.....	98
3.2.1 Área de estudo	98
3.2.2 Método padrão de estimativa da ETo.....	101
3.2.3 Análise espacial dos dados.....	101
3.2.3.1 Validação cruzada e interpolação	102
3.3 RESULTADOS	104

3.3.1 Estatística descritiva dos valores da ETo	104
3.3.2 Análise variográfica da ETo no estado de São Paulo na escala anual e sazonal	106
3.3.3 Krigagem da ETo	108
3.3.4 Validação cruzada dos modelos variográficos	112
3.3.5 Erros de estimativa produzidos pela validação cruzada	114
3.4 DISCUSSÃO	114
3.5 CONCLUSÃO	115
REFERÊNCIAS	117
CONSIDERAÇÕES FINAIS	121
REFERÊNCIAS	122

INTRODUÇÃO GERAL

A evapotranspiração (ET) é utilizada para expressar o processo de perda de água de uma determinada superfície vegetada, pela junção dos processos de evaporação da superfície do solo, rios e lagos e da transpiração das superfícies vegetadas. A disponibilidade de água no solo, fisiologia das plantas e os elementos meteorológicos (radiação solar, vento, temperatura, umidade, etc.) influenciam na taxa da ET (ALLEN et al., 1998; MAVI;TUPPER, 2004).

Conhecendo-se o valor da ET, é possível executar o balanço hídrico de cultivos (agronômico ou florestal) e verificar se há necessidade de irrigações corretivas. É possível também executar o balanço hídrico climatológico regional e planejar o uso dos recursos hídricos disponíveis pelas diferentes atividades humanas (PEREIRA et al., 2013). Para os mesmos autores, o termo ET é associado às diversas adjetivações, sendo o de referência (ET_o) um deles.

Jensen (1973) definiu a ET_o como sendo a ET máxima que ocorre numa cultura de alfafa (*Medicago sativa* L.) com altura de 0,3 a 0,5 m e com aproximadamente 100 m de área tampão. Por seu porte, a alfafa seria mais representativa das condições aerodinâmicas (rugosidade) de outras culturas do que a grama que é de porte rasteiro. Em regiões de clima com inverno muito frio, a alfafa adapta-se melhor aos rigores térmicos do que as gramíneas típicas de postos meteorológicos (PEREIRA et al., 2013). Mais tarde, os boletins da FAO 24 (DOOREMBOS;PRUITT, 1975) e FAO 33 (DOOREMBOS;KASSAM, 1994), expandiram o conceito de ET_o, definindo como a perda de água por evaporação e transpiração de uma superfície extensa vegetada de grama com uma altura de 0,08 a 0,15 m, em pleno crescimento ativo, com uma cobertura total do solo e sem restrição hídrica. Por último, a *Food and Agriculture Organization* (FAO 56), introduziu o conceito de superfície de referência. Neste boletim (FAO 56), a ET_o é definida como sendo a perda de água por evaporação e por transpiração em uma cultura hipotética, com altura fixa de 0,12 m, albedo de 0,23 e resistência do dossel de 70 s m⁻¹ (ALLEN et al., 1998). Vale ressaltar que segundo Pereira et al (2013), a grama é adotada como vegetação padrão (superfície de referência), pois ela é utilizada na maioria dos postos meteorológicos de regiões com climas que permitem cultivo agrônomo.

A estimativa precisa da ETo em áreas irrigadas é necessária para melhor planejamento das atividades agrícolas e boa gestão das fontes de água, conforme já mencionado. Para tal, torna-se necessário o uso de lisímetros, porém, são pouco utilizados em virtude dos elevados custos de sua aquisição e complexidade na sua instalação (SENTELHAS et al., 2010). Kumar et al (2008) acrescentaram que o uso de lisímetros demanda tempo e necessita de experimentos cuidadosamente planejados. Diante disso, na prática, a ETo é estimada com base nos métodos indiretos. Dentre os métodos indiretos, o de Penman Monteith FAO 56 (PMF 56) é considerado padrão (ALLEN et al., 1998). Este método pode ser utilizado em qualquer local sem necessidade de calibração e é relatado por diversos autores como sendo um método que apresenta ótimo desempenho quando comparado com o uso dos lisímetros (CAO et al., 2015; GOCIC;TRAJKOVIC, 2008). De acordo com Martinez e Thepadia (2009), o método de PMF 56 apresenta a grande desvantagem de requerer uma série de dados (radiação solar, umidade relativa do ar, temperatura do ar e velocidade do vento), os quais muitas das vezes não se encontram disponíveis em vários locais, além de por vezes os registros serem incompletos ou de qualidade questionável.

Em resposta às dificuldades encontradas no uso do método de PMF 56, pesquisadores como: Tabari (2010) e Tabari et al. (2011) relataram a necessidade de uso de métodos indiretos mais simples (métodos empíricos). Para Sobrinho et al. (2011), a utilização de métodos indiretos proporciona resultados satisfatórios, é barato e demanda pouco tempo do que os métodos diretos. Os métodos empíricos podem ser separados em três categorias. Na primeira estão aqueles que utilizam medidas apenas da temperatura do ar, os quais são de aplicação mais fácil e de uso geral. Na segunda, estão aqueles que além da temperatura, utilizam também a radiação solar e na terceira os que utilizam medidas de evaporação direta em tanque ou evapórimetros (PEREIRA et al., 2013).

De acordo com Khoob (2008), os métodos baseados na temperatura do ar para a estimativa da ETo são frequentemente utilizados e recomendados, pois exigem poucos dados de entrada, são de fácil obtenção, além da simplicidade dos cálculos envolvidos. Contudo, há que se ressaltar que todos os métodos empíricos apresentam grande variabilidade do seu desempenho em função das condições de

clima de cada local. Portanto, como o estado de São Paulo apresenta uma diversidade climática (ROLIM et al., 2007), existe uma necessidade de se avaliar o desempenho desses métodos, sob risco de escolher métodos que apresentem elevada sub ou superestimativa da ETo.

Uma alternativa diante do exposto, pode ser o uso de técnicas de aprendizado de máquinas (TAM). De acordo com Fonseca Junior et al. (2011), a TAM é uma subárea da inteligência artificial, cuja importância não é só prever, como também estimar valores perdidos em base de dados, o mesmo foi relatado por Leal et al. (2011). A TAM é de fácil utilização e apresenta ótimos resultados, muitas vezes superiores aos métodos empíricos (KISI, 2013; LADLANI et al., 2012; WU;LIU, 2012). Existem vários tipos de TAM, por exemplo: redes neurais artificiais (RNAs), máquina vetor de suporte (MVS), sistemas neuro fuzzy, etc.

As RNAs são modelos matemáticos similares aos neurónios biológicos, dotadas de capacidade computacional adquirida através do aprendizado e da generalização (BRAGA et al., 2000) e são ferramentas úteis para a modelagem de sistemas não lineares, portanto, podem ser utilizados para a modelagem da ETo. Vários trabalhos relatam que as RNAs produzem resultados confiáveis na estimativa da ETo (ZANETTI et al., 2008; CHAUHAN;SHIRIVASTAVA, 2012).

A MVS é também uma ferramenta poderosa para modelar processos não lineares. Ela foi originalmente desenvolvida por Vapnik (1995) e é bastante robusta, segundo o mesmo autor. He et al. (2014) e Wen et al. (2015) constataram que a MVS produz resultados mais satisfatórios do que a RNAs e Mohammadi et al. (2015) relataram que a MVS tem ganhado um grande destaque para resolver problemas não lineares em diversas áreas de conhecimento. Não obstante o sucesso das RNAs e a MVS, poucos são os trabalhos realizados com a ETo no Brasil, em particular no estado de São Paulo, principalmente com a MVS.

Outra preocupação dos pesquisadores consiste em encontrar métodos que permitam estimar de forma eficiente valores desconhecidos num determinado ponto a partir de valores amostrados em pontos vizinhos, utilizando métodos de interpolação. Segundo Kurtzman e Kadmon (1999), os métodos de interpolação podem ser determinísticos (não geoestatísticos) e geoestatísticos. Os métodos

geoestatísticos, como a krigagem, têm a vantagem de considerar as relações espaciais entre os dados em qualquer posição, sem tendência e com variância mínima, sendo assim, um ótimo interpolador (BURGESS;WEBSTER, 1980). Existem vários tipos de krigagem, sendo a krigagem ordinária, opção pontual (KOP) de utilização mais simples.

Com base nas constatações acima, o presente trabalho teve como objetivo principal modelar a ETo no estado de São Paulo, utilizando métodos empíricos, TAM (RNAS e MVS) e método geoespacial (KOP). Para tal, dividiu-se o trabalho em três capítulos, o primeiro capítulo intitulado " ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO:MÉTODOS EMPÍRICOS", o segundo intitulado "MODELAGEM DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: TÉCNICA DE APRENDIZADO DE MÁQUINAS E MODELOS EMPÍRICOS" e o terceiro intitulado "EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: MÉTODO GEOESPACIAL".

CAPÍTULO 1

ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: MÉTODOS EMPÍRICOS

RESUMO

A evapotranspiração de referência (ET_o) é fundamental na agricultura, pois permite quantificar a demanda hídrica das culturas irrigadas, dimensionar sistemas de irrigação e fazer o manejo de água na irrigação. Este trabalho teve como objetivo avaliar o desempenho dos métodos empíricos de temperatura (Benevides e Lopez - BenL, Hamon -Ham, Blaney Criddle Original e Hargreaves Samani -HS) e de radiação solar (Abtew, Jensen Haise - JensH, Makkink e Irmak) na estimativa da ET_o em relação ao método padrão FAO 56, utilizando dados meteorológicos de 22 estações automáticas do estado de São Paulo (temperatura máxima, mínima e média do ar; umidade relativa do ar; velocidade do vento e radiação solar global - Rs), em escalas anual e sazonal. Os índices estatísticos utilizados foram: MBE (*Mean Bias Error*), RMSE (*Root Mean Square Error*), índice “d” de Willmott e coeficiente de determinação (R^2). Os resultados da escala anual mostraram que o método de Abtew apresentou melhor desempenho. Contudo, o método de HS pode ser utilizado na ausência de dados de Rs. Na escala sazonal, observou-se que o método de JensH apresentou melhor desempenho no inverno, o de Irmak e Abtew no verão e outono, sendo que o método de Abtew também apresentou melhor desempenho na primavera. Na falta de dados de Rs, pode-se utilizar o método de HS na primavera e no inverno, de Ham no verão e de BenL no outono. Foi observado o efeito de sazonalidade, em que as equações anuais (métodos) subestimaram as sazonais na primavera e no verão, enquanto no outono e no inverno, foi observado o oposto.

Palavras – chave: Dados meteorológicos. Penman – Monteith. Radiação solar.

ABSTRACT

The reference evapotranspiration (ET_o) is fundamental in agriculture because it is used to quantify crop water requirements, design irrigation systems and irrigation water management. The aim of this study was to evaluate the performance of four temperature based (Benevides and Lopez - BenL, Hamon - Ham, Blaney Criddle Original and Hargreaves Samani - HS) and four radiation ET_o methods (Abtew, Jensen Haise - JensH, Makkink and Irmak) against FAO 56 standard method. It was used meteorological data (maximum, minimum and average air temperature, relative humidity, wind speed and global solar radiation - R_s) from 22 automatic stations in São Paulo, on annual and seasonal scales. Statistical indicators, such as MBE (Mean Bias Error), RMSE (Root Mean Square Error), “d” of Wilmot (1985) and R² (determination coefficient) were used. The results on the annual scale showed that the Abtew method presents better performance, however, the HS method can be used in the absence of R_s data. On the seasonal scale, it was observed that the JensH method presented better performance in the winter, the Irmak and Abtew methods in the summer and autumn. The Abtew method also presented better performance in the spring. In the absence of R_s data, the HS method can be used in the spring and winter, Ham in the summer and BenL in the autumn. The seasonality effect was observed, in which the annual equations (methods) underestimated the seasonal methods in the spring and summer. In the autumn and winter, the opposite results were observed.

Keywords: Meteorological data. Penman - Monteith. Solar radiation.

1.1 INTRODUÇÃO

A evapotranspiração de referência (ET_o) é definida como sendo a taxa de perda de água de uma cultura hipotética que cobre totalmente o solo, com uma altura de 0,12 m, em pleno crescimento ativo e uniforme, com uma taxa de reflexão de 23%, resistência da superfície de 70 m s⁻¹ e adequadamente irrigada (ALLEN et al., 1998). O conhecimento do valor da ET_o permite dimensionar sistemas de irrigação, fazer o manejo da água na agricultura e fazer o balanço hídrico para diferentes finalidades.

A disponibilidade de água no solo, a fisiologia das plantas e os elementos meteorológicos (radiação solar, vento, temperatura, umidade, etc.) influenciam na taxa de evapotranspiração (ALLEN et al., 1998; MAVI;TUPPER, 2004). Segundo Liu e Scott (2001), a radiação solar está diretamente relacionada aos processos físicos, químicos e biológicos que ocorrem na interação solo-planta-atmosfera, sendo considerada um dos fatores mais importantes para o desenvolvimento das plantas, interações plantas/hospedeiros/patógenos e germinação de sementes (VAN DIJK et al., 2005).

A estimativa mais precisa da ET_o em áreas irrigadas é necessária para melhor planejamento das atividades agrícolas e gestão das fontes de água. Para tal, torna-se necessário o uso de lisímetros, porém, são poucos utilizados em virtude dos elevados custos de sua aquisição e complexidade na sua instalação (SENTELHAS et al., 2010), além de demandarem tempo e necessitarem de experimentos cuidadosamente planejados (KUMAR et al., 2008). Diante disso, na prática, a ET_o é estimada com base nos dados climáticos disponíveis em estações meteorológicas (XING et al., 2008).

Allen et al. (1998) apresentaram o método de Penman Monteith FAO 56 (PMF 56) como padrão para a estimativa da ET_o com base nos dados climáticos, o qual é mundialmente reconhecido. Este método apresenta ótimo desempenho quando comparado com o método de lisímetro (CAI et al., 2007; CAO et al., 2015; MOHAWESH, 2011; XU;CHEN, 2005), todavia, requer uma série de elementos meteorológicos, os quais nem sempre se encontram disponíveis em várias situações (MARTINEZ;THEPADIA, 2010; VICENTE SERRANO et al., 2014). Sendo assim, vários métodos alternativos (empíricos) vêm sendo testados em diversas literaturas,

os quais, podem ser divididos em métodos baseados na temperatura do ar, métodos baseados na radiação solar e métodos baseados na transferência de massa (BERENGENA;GAVILÁN, 2005; XU;SINGH, 2002).

De acordo com Khoob (2008), os métodos baseados na temperatura do ar para a estimativa da ETo são frequentemente utilizados e recomendados, pois exigem poucos dados de entrada, são de fácil obtenção, além da simplicidade dos cálculos envolvidos. Tabari (2010) relatou a necessidade de uso de métodos mais simples. Não obstante a simplicidade desses métodos, existe a necessidade de se estimar a ETo com métodos mais precisos.

Landeras et al. (2008) observaram melhor desempenho do método de radiação de Makkink em relação à alguns métodos de temperatura no Norte da Espanha. Por outro lado, melhores desempenhos do método de radiação solar de Turc que o método de temperatura de Hargreaves Samani foram relatados por diversos pesquisadores em clima úmidos (NANDAGIRI;KOOVOR, 2006; XU et al., 2013; YODER et al., 2005). Porém, Tabari et al. (2012) observaram melhor desempenho dos métodos de temperatura (Hargreaves Samani e Blaney Criddle) do que os métodos de radiação de solar (Turc, Makkink, Jensen Haise, Abtew, etc). Outros autores relataram melhor desempenho de alguns métodos de temperatura em comparação aos de radiação solar em diferentes locais (ER RAKI et al., 2010; VICENTE SERRANO et al., 2014; DJAMAN et al., 2015; AHOOGHALANDARI et al., 2016). Entretanto, o desempenho dos métodos empíricos varia de local para local de acordo com o clima. Sendo assim, a sua escolha deve ser feita de forma cuidadosa, sob risco de escolher métodos que apresentam baixo desempenho.

Diante do exposto, a presente pesquisa teve como objetivo avaliar o desempenho estatístico dos métodos empíricos de temperatura (Benevides – Lopez - 1970; Blaney Criddle - 1950; Hamon - 1961 e Hargreaves Samani - 1985) e de radiação solar (Abtew - 1966; Jensen Haise – 1963; Makkink - 1957 e Imak -2003) na estimativa da ETo no estado de São Paulo, em escalas anual e sazonal. Os dados meteorológicos utilizados (temperatura máxima, mínima e média do ar; umidade relativa do ar; velocidade do vento e radiação solar global) são de 22 estações


meteorológicas automáticas disponibilizados pelo Instituto Nacional de Meteorologia do Brasil (INMET).

1.2 MATERIAL E MÉTODOS

1. 2.1 Localização e descrição do estudo

Na Figura 1 está exposta a localização das 22 estações/cidades do estado de São Paulo que foram utilizadas para realizar este trabalho. Ressalta-se que o período utilizado em cada cidade, apresentava pelos menos 80% de dados.

Figura 1- Mapa de 22 estações automáticas do estado de São Paulo



Com base na Tabela 1, nas cidades do estado de São Paulo que compõem o presente estudo, destacam-se quatro tipos de clima, a saber: Aw, Cwa, Af e Am, conforme a classificação climática de Köppen apresentada por Cepagri (2016). De acordo com Vianello e Alves (2012), as letras Aw, Af e Am caracterizam o clima tropical de savana, clima tropical de selva chuvosa e clima de montanha, respectivamente, enquanto as letras Cwa representam o clima temperado ou tropical de altitude. Mais detalhes dos tipos climáticos em questão foram apresentados por alguns autores (KOTTEK et al., 2006; SOUZA et al., 2013), a saber:

Aw: neste tipo de clima a temperatura média do mês mais frio é superior a 18°C, com inverno seco no qual pelo menos um dos meses apresenta uma precipitação média inferior a 60 mm; Cwa: a temperatura do mês mais frio do ano varia entre -3° e 18°C, com inverno seco e cuja precipitação média é inferior a 60 mm em um dos meses dessa estação. O verão é quente com temperatura média do mês mais quente superior a 22°C; Af: apresenta chuvas durante todo ano, com precipitação do mês mais seco superior a 60 mm, e Am: apresenta uma estação seca curta, chuvas intensas durante a maior parte do período do ano e temperatura média do mês mais frio superior a 18°C.

Dentre vários tipo de clima que o estado de São Paulo apresenta, o clima Aw é um dos mais predominantes (ROLIM et al., 2007). Este tipo climático é também predominante nas 22 estações meteorológicas utilizadas.

Tabela 1- Estações meteorológicas automáticas do estado de São Paulo

Código	Estações (Cidades)	Latitude (graus)	Longitude (graus)	Altitude (m)	Período (anos)	Clima
A-736	Ariranha	-21,01	-48,83	525	2008 - 2015	Aw
A-725	Avaré	-23,00	-48,88	654	2007 - 2015	Cwa
A-705	Bauru	-22,30	-49,70	550	2005 - 2015	Aw
A-738	Casa Branca	-21,77	-47,01	730	2008 - 2015	Aw
A-708	Franca	-20,57	-47,37	1026	2005 - 2015	Aw
A-737	Ibitinga	-21,85	-48,80	492	2008 - 2015	Aw
A-712	Iguape	-24,70	-47,55	3	2007 - 2015	Af
A-714	Itapeva	-23,97	-48,85	707	2007 - 2015	Cwa
A-733	Jales	-20,02	-50,58	457	2008 - 2015	Aw
A-735	José Bonifácio	-21,00	-49,68	405	2008 - 2015	Aw
A-727	Lins	-21,65	-49,73	459	2007 - 2015	Aw
A-716	Ourinhos	-22,95	-49,85	448	2007 - 2015	Am
A-726	Piracicaba	-22,70	-47,62	574	2007 - 2015	Cwa
A-707	Presidente Prudente	-22,01	-51,40	436	2005 - 2015	Aw
A-718	Rancharia	-22,37	-50,97	350	2007 - 2015	Aw
A-711	São Carlos	-21,95	-47,87	863	2007 - 2015	Cwa
A-740	Luis do Paraitinga	-23,22	-45,52	874	2008 - 2015	Cwa
A-715	São Miguel de Arcanjo	-23,85	-48,00	678	2007 - 2015	Cwa
A-701	São Paulo	-23,50	-46,62	792	2007 - 2015	Cwa

A-728	Taubaté	-23,00	-45,52	571	2007 - 2015	Cwa
A-734	Valparaíso	-21,32	-50,92	374	2007 - 2015	Aw
A-729	Votuporanga	-20,40	-49,95	486	2007 - 2015	Aw

Além dos dados da Tabela 1, coletou-se dados de temperatura máxima, mínima, umidade relativa média do ar, velocidade do vento e radiação solar global, os quais, foram disponibilizados na escala horária pelo INMET. Posteriormente, estes dados foram transformados para escala diária a fim de se estimar a ETo. Na transformação, utilizou-se o critério de média aritmética para a temperatura do ar, umidade relativa do ar e velocidade do vento, todavia, foi utilizado o critério de integração para a radiação solar global.

A ETo foi estimada com base em 8 métodos empíricos, os quais foram divididos em 2 grupos, sendo métodos de temperatura do ar e de radiação solar. Os métodos de temperatura (Benevides -Lopez, Hamom, Blaney-Criddle Original e Hargreaves-Samani) foram selecionados para representar as estações meteorológicas que medem apenas a temperatura ou temperatura e umidade relativa do ar (situação comum no Brasil) e os de radiação (Abtew, Jensen-Haise, Makkink e Irmak) para representar uma situação pouco comum, na qual além da temperatura, a estação meteorológica mede a radiação solar global. Em seguida, todos os métodos foram avaliados em relação ao método padrão de PMF 56, em escala anual e sazonal. A seguir, são apresentadas as equações utilizadas no método padrão (Equação 1) e nos métodos empíricos (Tabela 2).

1.2.2 Método padrão de estimativa da ETo

A Equação 1 recomendada por Allen et al. (1998) foi utilizada como referência para a estimativa da ETo.

$$ET_o = \frac{0,408 * \Delta * (R_n - G) + \gamma * \frac{900}{T + 273} * U_2 * (e_s - e_a)}{\Delta + \gamma * (1 + 0,34 * U_2)} \quad (1)$$

Em que: E_{To} = Evapotranspiração de referência, mm d^{-1} ; R_n = Saldo da radiação, $\text{MJ m}^{-2} \text{d}^{-1}$; G = Densidade de fluxo de calor para o solo, $\text{MJ m}^{-2} \text{d}^{-1}$; γ = Constante psicrométrica, $\text{kPa } ^\circ\text{C}^{-1}$; T = Temperatura média do ar, $^\circ\text{C}$; U_2 = Velocidade do vento a 2 metros de altura, m s^{-1} ; e_s = Pressão de saturação a temperatura de bulbo seco, kPa ; e_a = Pressão real ou atual de vapor d'água, kPa ; Δ = Declividade da curva da pressão de saturação de vapor, $\text{kPa } ^\circ\text{C}^{-1}$; 0,408 = Fator de conversão de $\text{MJ m}^{-2} \text{d}^{-1}$ para mm d^{-1} .

1.2.2.1 Declividade da curva de pressão de saturação de vapor

$$\Delta = \frac{4098 * \left[0,6108 * \exp\left(\frac{17,27 * T}{T + 237,3}\right) \right]}{(T + 237,3)^2} \quad (2)$$

1.2.2.2 Constante psicronométrica

$$\gamma = 0,665 * 10^{-3} * P \quad (3)$$

$$P = 101,3 * \left(\frac{293 - 0,0065 * A}{293} \right)^{5,25} \quad (4)$$

Em que: P = Pressão atmosférica do local, kPa e A = Altitude, m .

1.2.2.3 Pressão de saturação e atual do vapor d'água

$$e_s = 0,6108 * \exp\left(\frac{17,27 * T}{T + 237,3}\right) \quad (5)$$

$$ea = \frac{e_s}{UR} * 100 \quad (6)$$

Em que UR = Umidade relativa do ar, %.

1.2.2.4 Saldo de radiação

$$Rn = Rns - Rnl \quad (7)$$

$$Rns = (1 - \alpha) * Rs \quad (8)$$

Em que: Rns = Radiação solar de ondas curtas, $\text{MJ m}^{-2} \text{ d}^{-1}$; Rnl = Radiação solar de ondas longas, $\text{MJ m}^{-2} \text{ d}^{-1}$, Rs = Radiação solar global, $\text{MJ m}^{-2} \text{ d}^{-1}$ e α = albedo. O albedo médio da grama é de 0,23, considerado como referência para o estudo da ETo em agricultura.

$$Rnl = \sigma * [T_k^4] * (0,34 - 0,14 * \sqrt{ea}) * \left(1,35 * \frac{Rs}{Rso} - 0,35 \right) \quad (9)$$

$$Rso = (a + b) * Ra \quad (10)$$

$$a = 0,29 * \cos(\phi) \quad (11)$$

$$Ra = \left(\frac{24 * 60}{\pi} \right) * Gsc * dr * [ws * \sin(\phi) \sin(\delta) + \cos(\phi) \cos(\delta) * \sin(ws)] \quad (12)$$

$$dr = 1 + 0,033 * \cos\left(\frac{2 * \pi * J}{365}\right) \quad (13)$$

$$\delta = 0,409 * \sin\left[\left(\frac{2 * \pi}{365} * J - 1,39\right)\right] \quad (14)$$

$$ws = \arccos[-\tan(\phi) * \tan(\delta)] \quad (15)$$

A densidade do fluxo de calor no solo (G) foi considerada igual a zero (0), pois de acordo com o boletim da FAO 56, em escalas diárias assume valores desprezíveis.

Em que: σ = Constante de Stefan – Boltzamn, $4,903 * 10^{-9} \text{ MJ m}^{-2} \text{ K}^{-4} \text{ d}^{-1}$; T_k = Temperatura média do ar, K; Rso = Radiação solar teórica para dia de céu aberto, $\text{MJ m}^{-2} \text{ d}^{-1}$; a e b = Constantes que dependem da composição atmosférica de cada

local em função da época do ano (adimensional); R_a = Radiação solar no topo da atmosfera, $\text{MJ m}^{-2} \text{d}^{-1}$; G_{sc} = Constante solar, $0,082 \text{ MJ m}^{-2} \text{min}^{-1}$; ϕ = Latitude, rad; δ = Declinação solar, rad; dr = Distância relativa terra-sol, rad; ws = Ângulo horário do nascer ou pôr do sol, rad; J = Dias julianos.

Tabela 2 - Métodos empíricos de estimativa da ETo

Método/Modelo	Referência	Equação	Parâmetros
Métodos de temperatura do ar			
Método de Benevides e Lopez (BenL)	Benevides e Lopez (1970)	$ET_o = 1,21 * 10^{\left(\frac{7,5 * T}{237,5 + T}\right)} * (1 - 0,01 * UR) + 0,21 * T - 2,3$	T, UR
Hamon (Ham)	Hamon (1961)	$ET_o = 0,55 * \left(\frac{N}{12}\right)^2 * \left(\frac{4,95 * \exp^{0,062 * T}}{100}\right) * 25,4$	T
Blaney Criddle Original (BCO)	Blaney Criddle Original (1950)	$ET_o = p * (0,457 * T + 8,13)$	T
Hargreaves e Samani (HS)	Hargreaves e Samani (1985)	$ET_o = 0,0023 * 0,408 * Ra * (T_{\max} - T_{\min})^{0,5} * (T + 17,8)$	T, Tmax, Tmin, Ra
Métodos de radiação solar			
Abtew	Abtew (1966)	$ET_o = \frac{0,53}{\lambda} * R_s$	T, Rs
Jensen-Haise (JensH)	Jensen e Haise (1963)	$ET_o = 0,408 * R_s * (0,0252 * T + 0,078)$	T, Rs
Makkink (MAK)	Makkink (1957)	$ET_o = 0,408 * 0,61 * R_s * \frac{\Delta}{(\Delta + \gamma)} - 0,12$	T, Rs
Irmak	Irmak et al. (2003)	$ET_o = 0,149 * R_s + 0,079 * T - 0,611$	T, Rs

1.2.3 Validação dos métodos empíricos

A validação dos dados foi feita com base nos seguintes índices estatísticos: erro relativo médio ($MBE = \text{Mean Bias Error}$), raiz quadrada do quadrado médio do erro ($RMSE = \text{Root Mean Square Error}$), coeficiente de Willmott (1985), “d”, e coeficiente de determinação (R^2). Valores positivos de MBE indicam que o método superestima os valores medidos ou de referência e os negativos indicam uma subestimativa. É indicativo da precisão do método e quanto mais próximo de zero estiver, mais preciso é o método avaliado. Os índices MBE, RMSE, R^2 foram utilizados em trabalhos sobre ETo por vários autores (MOELETSI et al., 2013; SENTENHAS et al., 2010).

Os índices “d” e o R^2 indicam uma concordância (perfeição) e ajuste matemático do método avaliado, respectivamente. Estes índices, quanto mais próximos de um estiverem, melhor é o desempenho do modelo e variam de 0 a 1. Em seguida são apresentadas as equações utilizadas para fazer as análises estatísticas.

$$MBE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i) \quad (16)$$

$$RMSE = \left[\sum_{i=1}^N \frac{(P_i - O_i)^2}{N} \right]^{0,5} \quad (17)$$

$$d = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (|P_i - O| + |O_i - O|)^2} \quad (18)$$

$$R^2 = 1 - \left(\frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (O_i - O)^2} \right) \quad (19)$$

Em que: P_i = Valores estimados pelos métodos estatísticos, mm d^{-1} ; O_i = Valor estimado pelo método Padrão, mm d^{-1} ; N = Número de estimativas por período e O = Média aritmética de ETo estimado pelo método padrão, mm d^{-1} .

1.2.4 Análise de sazonalidade

A análise de sazonalidade das equações anuais em relação as sazonais foi feita com base no cálculo dos desvios lineares percentuais (DL,%), conforme a Equação 20. $DL < 0$, significa que a equação anual subestima a sazonal e $DL > 0$, significa o inverso.

$$DL(\%) = 100 * \frac{(\overline{ETo_a} - \overline{ETo_s})}{(\overline{ETo_a})} \quad (20)$$

Em que: $\overline{ETo_a}$ = Valor médio de ETo do método empírico na escala anual e $\overline{ETo_s}$ = Valor médio da ETo do método empírico na escala sazonal, expressos em mm d^{-1} .

1.3 RESULTADOS

1.3.1 Métodos empíricos de estimativa da ETo em escala anual

A seguir estão apresentados os resultados dos métodos empíricos baseados na temperatura do ar e radiação solar em escalas anual.

1.3.1.1 Métodos empíricos de temperatura para a estimativa da ETo

Na Tabela 3 estão apresentados os índices estatísticos dos métodos empíricos de temperatura para a estimativa da ETo em relação ao método padrão de PMF 56 no estado de São Paulo.

Tabela 3 - Estimativa da ETo a partir dos metodos de temperatura do ar


Estações	Benevides Lopez (BenL)				Hamon (Ham)				Blaney Criddle Original (BCO)				Hargreaves Samani (HS)			
	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²
Ariranha	-0,49	0,76	0,79	0,88	-0,78	0,89	0,81	0,85	-0,90	1,08	0,79	0,86	0,99	1,03	0,81	0,94
Avaré	-1,07	1,19	0,66	0,81	-1,15	1,25	0,67	0,72	-1,15	1,28	0,62	0,74	0,30	0,46	0,95	0,88
Bauru	-0,50	0,64	0,81	0,88	-0,71	0,82	0,79	0,76	-0,77	0,89	0,70	0,77	0,88	0,95	0,79	0,92
Casa Branca	-0,38	0,53	0,84	0,85	-0,69	0,84	0,76	0,67	-0,75	0,89	0,69	0,69	0,86	0,93	0,77	0,88
Franca	-1,10	1,17	0,59	0,86	-1,46	1,58	0,51	0,37	-1,46	1,57	0,48	0,42	-0,07	0,57	0,87	0,58
Ibitinga	-0,97	1,12	0,70	0,86	-1,20	1,30	0,69	0,76	-1,29	1,44	0,61	0,76	0,59	0,65	0,91	0,94
Iguape	-0,29	0,58	0,88	0,85	-0,12	0,34	0,97	0,90	-0,18	0,55	0,88	0,90	0,68	0,73	0,89	0,94
Itapeva	-0,99	1,09	0,70	0,83	-0,95	1,04	0,74	0,81	-0,94	1,07	0,69	0,81	0,41	0,52	0,94	0,92
Jales	-0,72	0,86	0,74	0,88	-1,24	1,45	0,60	0,40	-1,61	1,76	0,50	0,44	-0,79	1,08	0,69	0,42
José Bonif.	-0,92	1,08	0,70	0,86	-1,36	1,47	0,65	0,67	-1,51	1,65	0,57	0,69	0,36	0,48	0,94	0,90
Lins	-0,72	0,88	0,76	0,88	-1,11	1,24	0,70	0,71	-1,27	1,41	0,61	0,74	-1,27	1,41	0,61	0,88
Ourinhos	-0,51	0,65	0,85	0,88	-0,65	0,77	0,85	0,81	-0,74	0,89	0,74	0,83	0,96	1,02	0,80	0,92
Piracicaba	-0,87	0,98	0,73	0,86	-0,99	1,10	0,73	0,74	-1,05	1,18	0,66	0,76	0,68	0,73	0,87	0,92
President. P	-0,33	0,60	0,82	0,79	-0,79	0,93	0,78	0,72	-0,94	1,09	0,67	0,74	0,49	0,59	0,91	0,90
Rancharia	-0,59	0,74	0,83	0,85	-0,65	0,79	0,85	0,79	-0,74	0,91	0,75	0,79	1,25	1,28	0,72	0,94
São Carlos	-1,01	1,08	0,66	0,85	-1,17	1,25	0,64	0,71	-1,15	1,25	0,60	0,74	1,22	1,31	0,68	0,86
S. Luis Pi.	-1,01	1,09	0,70	0,88	-0,87	0,94	0,77	0,85	-0,84	0,96	0,71	0,86	0,77	0,80	0,85	0,94
S. Miguel A.	-0,92	1,01	0,72	0,85	-0,75	0,83	0,81	0,85	-0,74	0,87	0,74	0,86	0,74	0,79	0,86	0,94
São Paulo	-0,67	0,77	0,77	0,85	-0,79	0,87	0,77	0,79	-0,80	0,90	0,70	0,81	0,41	0,55	0,92	0,90
Taubaté	-0,56	0,69	0,83	0,85	-0,63	0,76	0,84	0,79	-0,68	0,83	0,75	0,81	1,01	1,06	0,78	0,92
Valparaíso	-0,88	1,04	0,71	0,83	-1,27	1,44	0,65	0,56	-1,45	1,60	0,57	0,59	0,41	0,60	0,91	0,83
Votuporanga	-0,76	0,89	0,72	0,85	-1,25	1,41	0,61	0,50	-1,45	1,58	0,53	0,52	0,31	0,56	0,90	0,76

Com base na Tabela 3, observou-se que os métodos de BenL, de Ham e BCO subestimaram o método de PMF 56 em todas as cidades do estado de São Paulo ($MBE < 0$). Com relação ao método de HS, notou-se que superestimou a ETo ($MBE > 0$), com a exceção das cidades de Franca, Jales e Lins onde se observou o inverso. Observou-se ainda que os métodos de BenL e de Ham apresentaram valores máximos de MBE de $-1,10$ e $-1,46 \text{ mm d}^{-1}$, acontecendo na cidade de Franca, respectivamente. Nos métodos de BCO e HS observou-se valores máximos de $-1,61$ e $-1,27 \text{ mm d}^{-1}$ nas cidades de Jales e Lins, respectivamente.

O método de BenL apresentou uma precisão (RMSE) variando de $0,53$ a $1,19 \text{ mm d}^{-1}$, cujos valores são observados nas cidades de Casa Branca e de Avaré; o de Ham de $0,34$ a $1,58 \text{ mm d}^{-1}$ para as cidades de Iguape e Franca; o de BCO de $0,55$ a $1,76 \text{ mm d}^{-1}$ para as cidades de Iguape e Jales, e o de HS de $0,46$ a $1,41 \text{ mm d}^{-1}$ para as cidades de Avaré e Lins, respectivamente. O método de HS apresentou mais valores de $RMSE < 1,0 \text{ mm d}^{-1}$, mostrando a tendência de maior precisão (Tabela 3). Na mesma tabela, verificou-se que o índice “d” de Willmott (1985) nos métodos de BenL, Ham e BCO variou de $0,59$ a $0,88$; de $0,51$ a $0,97$; e de $0,48$ a $0,88$ para as cidades de Franca e Iguape, respectivamente, e no método de HS assumiu valor de $0,61$ para a cidade de Lins e de $0,95$ para a cidade de Avaré. Com base nesses resultados, notou-se que o desempenho mínimo (“d” = $0,61 \text{ mm d}^{-1}$) observado no método de HS é superior em relação aos desempenhos mínimos observados nos demais métodos e o desempenho máximo (“d” = $0,95$) é superior ao observado nos métodos de BenL e de BCO.

Em média, notou-se que o método de HS apresentou melhor desempenho na estimativa da ETo em comparação aos métodos de BenL ($MBE = -0,74 \text{ mm d}^{-1}$ e $RMSE = 0,88 \pm 0,212 \text{ mm d}^{-1}$; “d” = $0,75 \pm 0,074$ e $R^2 = 0,85 \pm 0,025$), Ham ($MBE = -0,94 \text{ mm d}^{-1}$ e $RMSE = 1,06 \pm 0,312 \text{ mm d}^{-1}$; “d” = $0,74 \pm 0,104$ e $R^2 = 0,71 \pm 0,141$) e BCO ($MBE = -1,02 \text{ mm d}^{-1}$ e $RMSE = 1,17 \pm 0,329 \text{ mm d}^{-1}$; “d” = $0,66 \pm 0,098$ e $R^2 = 0,73 \pm 0,133$), pois apresentou menor valor de MBE ($0,51 \text{ mm d}^{-1}$), menor valor de RMSE ($0,82 \pm 0,287 \text{ mm d}^{-1}$), maior valor de “d” ($0,84 \pm 0,095$) e maior valor de R^2 ($0,87 \pm 0,129$), significando menor superestimativa, maior precisão, alta concordância e alto ajuste matemático, respectivamente, expostos nas Figuras 2 (a, b, c,d).

Figura 2 - Desempenho médio dos métodos de temperatura do ar



Os resultados apresentados mostraram que o método de BCO apresentou o menor desempenho. Isto deve-se ao fato deste método não considerar os coeficientes de ajuste local, os quais são recomendados no boletim da FAO-24 por Doornbos e Pruitt (1975). Comportamento similar foi observado por Kariyama (2014) e Tabari et al. (2012).

1.3.1.2 Métodos empíricos de radiação solar para a estimativa da ETo

A seguir está apresentada a Tabelas 4 que ilustra o desempenho dos métodos de radiação solar (Abtew, Jensen Haise - JensH, Makkink - Mak e Irmak) na estimativa da ETo no estado de São Paulo em relação ao método padrão.

Tabela 4 - Estimativa da ETo a partir dos metodos de radiação solar


Estações	Abtew				Jensen Haise				Makkink				Irmak			
	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²
Ariranha	-0,37	0,58	0,92	0,86	0,65	1,03	0,86	0,85	1,12	1,35	0,77	0,85	-0,36	0,54	0,92	0,83
Avaré	-0,06	0,23	0,98	0,94	0,60	0,78	0,89	0,94	1,38	1,45	0,70	0,94	-0,32	0,44	0,93	0,94
Bauru	-0,09	0,25	0,97	0,92	0,77	0,90	0,83	0,92	1,35	1,41	0,66	0,92	-0,16	0,32	0,95	0,92
Casa Branca	-0,23	0,38	0,93	0,90	0,58	0,69	0,86	0,90	1,17	1,21	0,67	0,90	-0,25	0,40	0,91	0,88
Franca	-0,25	0,43	0,89	0,81	0,56	0,69	0,84	0,81	1,38	1,43	0,59	0,83	-0,53	0,66	0,76	0,81
Ibitinga	-0,04	0,30	0,97	0,92	1,05	1,21	0,80	0,92	1,65	1,72	0,66	0,92	-0,30	0,48	0,93	0,92
Iguape	0,26	0,32	0,97	0,98	1,00	1,14	0,83	0,98	1,49	1,55	0,72	0,98	0,25	0,35	0,96	0,96
Itapeva	0,06	0,21	0,99	0,98	0,61	0,75	0,90	0,96	1,42	1,47	0,69	0,98	-0,19	0,32	0,96	0,96
Jales	-0,88	1,09	0,68	0,58	0,89	1,20	0,72	0,56	1,05	1,28	0,66	0,52	-0,83	1,03	0,67	0,50
José Bonif.	-0,57	0,77	0,86	0,76	0,69	1,10	0,83	0,76	1,13	1,35	0,74	0,76	-0,68	0,85	0,81	0,74
Lins	-0,30	0,50	0,92	0,88	0,95	1,10	0,81	0,86	1,41	1,48	0,68	0,86	-0,43	0,61	0,87	0,86
Ourinhos	0,05	0,29	0,97	0,96	0,97	1,06	0,82	0,96	1,53	1,56	0,66	0,96	-0,06	0,32	0,96	0,95
Piracicaba	0,00	0,29	0,97	0,94	0,87	0,99	0,83	0,92	1,54	1,58	0,65	0,94	-0,21	0,40	0,94	0,92
President. P	-0,61	0,66	0,87	0,90	0,46	0,74	0,89	0,90	0,86	0,98	0,82	0,92	-0,51	0,60	0,87	0,92
Rancharia	0,03	0,32	0,97	0,96	0,90	1,01	0,84	0,96	1,46	1,49	0,70	0,96	-0,07	0,34	0,96	0,94
São Carlos	0,02	0,28	0,96	0,92	0,63	0,72	0,87	0,92	1,49	1,52	0,61	0,92	-0,28	0,42	0,91	0,90
S. Luis Pi.	0,42	0,47	0,93	0,98	0,90	0,98	0,83	0,98	1,83	1,86	0,60	0,98	0,06	0,26	0,97	0,96
S. Miguel A.	0,33	0,39	0,95	0,98	0,86	0,97	0,84	0,98	1,68	1,73	0,63	0,98	0,05	0,23	0,98	0,96
São Paulo	-0,17	0,27	0,97	0,98	0,43	0,56	0,92	0,96	1,14	1,18	0,72	0,96	-0,27	0,36	0,94	0,96
Taubaté	-0,13	0,30	0,97	0,96	0,57	0,71	0,90	0,96	1,19	1,24	0,74	0,96	-0,18	0,33	0,96	0,92
Valparaíso	-0,59	0,77	0,84	0,76	0,68	1,00	0,83	0,76	1,09	1,24	0,75	0,77	-0,67	0,85	0,79	0,77
Votuporanga	-0,55	0,72	0,81	0,76	0,82	1,01	0,78	0,74	1,22	1,32	0,66	0,76	-0,62	0,79	0,76	0,74

Os métodos de JenH e de Mak superestimaram a ETo em relação ao método padrão em todas cidades, atingido valores máximos de MBE de 1,05 mm d⁻¹ na cidade de Ibitinga e de 1,83 mm d⁻¹ na cidade de São Luís de Piraitinga, respectivamente. Já os métodos de Abtew e de Irmak apresentaram um comportamento diferenciado com tendência à subestimativa, atingido valores máximos de -0,88 e -0,83 mm d⁻¹ na cidade de Jales, respectivamente (Tabela 4).

Com base no RMSE, observou-se que os métodos de Abtew, JensH, Mak e Irmak apresentaram valores de 1,09; 1,21; 1,86 e 1,03 mm d⁻¹, respectivamente. Estes valores são observados nas cidades de Jales para os métodos de Abew e Irmak, Ibitinga para o método de JensH e São Luís de Piraitinga para o método de Mak. Os valores máximos de RMSE dos métodos de Abtew e de Irmak são inferiores em relação aos valores máximos dos demais métodos, indicando que eles têm a tendência de serem mais precisos na estimativa da ETo. Em relação ao índice “d”, observou-se que variou de 0,68 a 0,99 no método de Abtew, de 0,67 para 0,98 no método de Irmak, de 0,72 para 0,92 no método de JenH e de 0,59 para 0,82 no método de Mak, mostrando que os métodos de Abtew e de Irmak chegaram a ser mais próximos de 1 (Tabelas 4).

Em média, verificou-se que o método de Abtew apresentou valores médios de MBE = -0,17 mm d⁻¹ e RMSE = 0,45±0,229 mm d⁻¹, os quais foram inferiores em relação aos valores observados nos métodos de Irmak (MBE = -0,30 mm d⁻¹ e RMSE = 0,50±0,268 mm d⁻¹), de JensH (MBE = -0,75 mm d⁻¹ e RMSE = 0,92±0,188 mm d⁻¹) e Mak (MBE = 1,34 mm d⁻¹ e RMSE = 1,43±0,203 mm d⁻¹), mostrando uma subestimativa inferior e uma alta precisão, respectivamente. Já em relação ao índice “d”, observa-se valores de 0,92±0,074; 0,84±0,045; 0,69±0,057 e 0,90±0,085 para os métodos de Abtew, JensH, Mak e Irmak, respectivamente, confirmando que o método de Abtew é o melhor para estimar da ETo no estado de São Paulo (Figura 3 a, b e c). Este método apresentou um ajuste matemático aceitável ($R^2 = 0,89 \pm 0,102$, Figura 3 d).


Figura 3 - Desempenho dos métodos de radiação solar



1.3.2 Erros dos métodos empíricos no estado de São Paulo em escala anual

O diagrama de caixa (*box plot*) ilustra os valores máximos, mínimos, médios e as medianas dos erros produzidos pelos métodos empíricos no estado de São Paulo (Figura 4). Onde: a marca que se encontra dentro da caixa representa o valor médio do erro, as extremidades indicam os valores máximos, e mínimos e a parte central do diagrama representa a mediana.

Figura 4 - Box plot dos erros de oito métodos empíricos em escala anual



Da Figura 4 verificou-se que entre os métodos de temperatura, o de HS produziu erros mais baixos ($0,43 \pm 0,240 \text{ mm d}^{-1}$) e o de BCO erros mais elevados ($-0,86 \pm 0,419 \text{ mm d}^{-1}$), enquanto entre os métodos de radiação solar, os erros mais baixos são observados no método de Abtew ($-0,17 \pm 0,251 \text{ mm d}^{-1}$) e os mais

elevados no método de Mak ($1,23 \pm 0,372 \text{ mm d}^{-1}$). Métodos com erros mais baixos são os que apresentam erros médios mais próximos de zero e com diagrama de caixa com bigode mais estreito e vice-versa. Portanto, comparando todos os métodos, observou-se claramente que o método de Abtew é o mais confiável para a estimativa da ETo. Por outro lado, observou-se que todos os métodos subestimaram a ETo (diagramas de caixa abaixo da reta $Y = 0$), com a exceção dos métodos de HS, JensH e Mak que superestimaram.

1.3.3 Comportamento da ETo no estado de São Paulo em escala anual

Nas Figuras abaixo é apresentado somente o comportamento dos valores da ETo estimados pelos melhores e piores métodos, tanto de temperatura do ar como de radiação solar. Os melhores métodos são observados nas Figuras 5 (a – l) e 6 (m – v) e os piores nas Figuras 7 (a – l) e 8 (m – v).

Nas Figuras 5 (a – l) e 6 (m – v), verifica-se claramente que o método de Abtew teve a tendência de apresentar baixa dispersão dos pares de dados (alta precisão) em comparação ao método de HS, pois o método de Abtew apresentou em geral as suas retas de regressão mais próximas à reta $Y = X$ (reta 1:1), além de ter apresentado um bom ajuste matemático (valores R^2 mais elevados, em geral). Observa-se ainda que em geral as retas de regressão do método de Abtew estiveram abaixo da reta $Y = X$, confirmando a tendência de subestimar a ETo. O inverso é observado no método de HS.

Figura 5 - Dispersão da ETo estimada pelos métodos de HS e de Abtew





Figura 6 - Dispersão da ETo estimada pelos métodos de HS e de Abtew



Nas Figuras 7 (a – l) e 8 (m – v) verificou-se que os métodos de BCO e de Mak apresentaram as suas retas de regressão linear mais afastadas à reta $Y = X$ em comparação aos métodos apresentados nas Figuras 5 e 6, mostrando um desempenho inferior. Comparando o método de BCO e de Mak entre si, verificou-se que o primeiro apresentou em média as suas retas de regressão menos afastada à reta $Y = X$ e apresentou baixa dispersão dos pares de dados. Com isso, pode-se dizer que o método de BCO estimou melhor a ETo. Isso evidencia que embora a Rs seja importante na estimativa da ETo, o seu efeito varia em função da variabilidade climática entre o local de origem do método e o de avaliação.

Figura 7 - Dispersão da ETo estimada pelos métodos de Mak e de BCO






Figura 8 - Dispersão da ETo estimada pelos métodos de Mak e de BCO



1.3.4 Desempenho sazonal dos métodos empíricos no estado de São Paulo

Na Figura 9 está mostrado o desempenho sazonal (primavera, verão, outono e inverno) dos métodos empíricos de estimativa da ETo no estado de São Paulo com base nos seguintes índices estatísticos: MBE, RMSE, “d” de Wilmontt e coeficiente de determinação (R²).

Figura 9 - Desempenho sazonal de oito métodos de estimativa da ETo no estado de São Paulo




Com base na Figura 9, observou-se que os métodos de BenL, Ham e BCO subestimaram a ETo em todas as estações do ano, acontecendo o inverso nos métodos de HS, JensH e Mak. Já os métodos de Abtew e Irmak apresentaram um comportamento variado, no qual notou-se uma superestimativa da ETo no outono e subestimativa nas demais estações do ano.

Os valores de RMSE mostraram que dentre os métodos de temperatura, o de HS apresentou maior precisão na primavera ($RMSE = 0,88 \pm 0,292 \text{ mm d}^{-1}$) e no inverno ($RMSE = 0,57 \pm 0,367 \text{ mm d}^{-1}$), enquanto o de Ham foi mais preciso no verão ($RMSE = 0,72 \pm 0,242 \text{ mm d}^{-1}$), e o de BenL no outono ($RMSE = 0,35 \pm 0,251 \text{ mm d}^{-1}$). Nos métodos de radiação solar, o de Abtew foi mais preciso na primavera ($RMSE = 0,37 \pm 0,172 \text{ mm d}^{-1}$), no verão ($RMSE = 0,16 \pm 0,367 \text{ mm d}^{-1}$) e no outono ($RMSE = 0,15 \pm 0,110 \text{ mm d}^{-1}$), embora nessas duas últimas estações tenha apresentado valores de RMSE próximos aos do método de Irmak: $0,17 \pm 0,100 \text{ mm d}^{-1}$ e $0,18 \pm 0,11 \text{ mm d}^{-1}$, respectivamente, e, no inverno, o método de JensH apresentou elevada precisão ($= 0,15 \pm 0,21 \text{ mm d}^{-1}$). O comportamento dos valores de RMSE seguiu a mesma tendência dos valores de MBE.

Em geral, todos os métodos com elevado desempenho apresentaram valores de “d” e R^2 mais próximos de um (Figura 9). A Figura 10 ilustrou melhor a precisão de todos métodos, onde métodos mais precisos apresentam *Box plot* mais estreitos e com erros médio mais próximo de zero.


Figura 10 - Box plot da ETo na escala sazonal



1.3.5 Análise de sazonalidade dos oito métodos de estimativa da ETo

Na Figura 11 estão ilustrados os desvios relativos percentuais (DL,%) referentes a análise de sazonalidade das equações anuais em relação às sazonais. DL negativos indicam que quando os métodos empíricos foram utilizados na escala anual subestimaram os valores da escala sazonal, e DL positivos mostram que as equações anuais (métodos) superestimaram as sazonais.

Figura 11 – Análise de sazonalidades dos métodos empíricos



Com base na Figura 11, os DL foram negativos na primavera e no verão, e positivos no outono e no inverno. Tanto na primavera quanto no verão, os valores extremos de DL foram observados nos métodos de BenL (-9,87% na primavera e -13,69% no verão) e de Ham (-20,68% na primavera e -27,80% no verão), significando que os valores de ETo da escala anual subestimaram mais os valores do verão. Similarmente à primavera e verão, no outono e no inverno, os valores extremos de DL foram observados nos métodos de BenL (13,06% no outono e 9,55% no inverno) e de Ham (23,05% no outono e 24,75% no inverno), os quais mostram que as equações anuais superestimaram os resultados sazonais dessas estações do ano.

O método de Abtew, o qual apresentou o melhor desempenho da presente pesquisa, apresentou DL = -15,09% na primavera, DL = -15,36% no verão, DL = 15,63% no outono e DL = 13,75% no inverno, conforme a Figura 11. O valor absoluto desses DL é próximo, mostrando que embora tenha havido efeito sazonalidade, ele pode ser considerado similar. Portanto, nos demais métodos, o

efeito de sazonalidade é menos regular devido à maior variação dos valores absolutos de DL, com a exceção do método de Irmak.

1.4 DISCUSSÃO

Na comparação entre os métodos baseados na temperatura do ar, escala anual, constatou-se que a inclusão da radiação extraterrestre (R_a) no método de HS explica o seu melhor desempenho, pois a R_a é uma das principais fontes de energia para a realização da ETo no planeta, cujo efeito depende do grau de espalhamento provocado pelos constituintes atmosféricos (vapor d'água, nuvens, gases, aerossóis). Ademais, como todos os métodos de temperatura utilizados foram desenvolvidos para condições de clima seco, então, é relevante a justificação apresentada. Resultados inferiores a este método foram reportados por Sentelhas et al. (2010): $RMSE = 1,103 \text{ mm d}^{-1}$; Tabari et al. (2012): $MBE = -0,851 \text{ mm d}^{-1}$ e $RMSE = 0,901 \text{ mm d}^{-1}$; Alexandris et al. (2008): $MBE = 0,741 \text{ mm d}^{-1}$, $RMSE = 1,007 \text{ mm d}^{-1}$ e $R^2 = 0,823$; Melo e Fernandes (2012): $RMSE = 1,04 \text{ mm d}^{-1}$, " d " = 0,71 e $R^2 = 0,77$. Contudo, a literatura destaca alguns resultados superiores: $RMSE = 0,224$ e $0,294 \text{ mm d}^{-1}$ em duas cidades (WANG et al., 2008); $MBE = 0,13 \text{ mm d}^{-1}$ e $RMSE = 0,69 \text{ mm d}^{-1}$ (VANDERLINDEN et al., 2004); $RMSE = 0,47 \text{ mm d}^{-1}$ (MAEDA et al., 2011).

Entre os métodos de radiação solar, escala anual, o de Abtew apresentou melhor desempenho. Outras pesquisas também relataram elevado desempenho deste método em diversos locais (DE BRUIN, 1981; ZHAI et al., 2010). Em clima semi-árido de Irã, Tabari et al. (2010) observaram que o método de Abtew ($RMSE = 1,705 \text{ mm d}^{-1}$ e $R^2 = 0,823$) superou o desempenho dos métodos de Irmak ($RMSE = 1,849 \text{ mm d}^{-1}$ e $R^2 = 0,674$) e Mak ($RMSE = 2,098 \text{ mm d}^{-1}$ e $R^2 = 0,715$) e teve desempenho inferior ao método de JensH ($RMSE = 1,274 \text{ mm d}^{-1}$ e $R^2 = 0,734$). Ademais, baixo desempenho do método de Abtew que alguns métodos empíricos foi observado em vários trabalhos (SAMARAS et al., 2014; TABARI et al., 2010; XU; SINGH, 2000).

Ainda na escala anual, quando se fez a análise de todos os métodos, os resultados mostraram que o método de Abtew apresentou o desempenho mais elevado. O uso da R_s neste método foi apontado como um dos motivos que fez com que apresentasse melhor desempenho do que o método de HS, todavia, observou-se que este método apresentou melhor desempenho do que os métodos de JensH e Mak que utilizaram a R_s como uma das variáveis de entrada à semelhança do método de Abtew. Ressalta-se que o método de HS é adequado para condições áridas e semi-áridas (ALLEN et al., 1998; LINGLING et al., 2013; TODOROVIC et al., 2013), o de JensH para condições áridas e semi-áridas (JENSEN HAISE, 1963), o de Mak para condições áridas e semi-áridas (MAKKINK, 1957) e o de Abtew para condições úmidas (ZHAI et al., 2010; LINGLING et al., 2013; SAMARAS et al., 2014). Portanto, isto revela que além das variáveis de entrada, o clima desempenha um papel fundamental, mostrando a necessidade de uma seleção cuidadosa dos métodos empíricos. Os diagramas de caixa com bigodes e os índices estatísticos utilizados confirmaram uma elevada potencialidade do método de Abtew na estimativa da ETo no estado de São Paulo. Por outro lado, evidenciaram que na falta de dados de R_s , o método de HS pode ser utilizado como alternativa.

Na escala sazonal (métodos de temperatura do ar), o método de HS apresentou melhor desempenho no inverno, o qual é adequado para climas secos, conforme já relatado. Portanto, isso justifica o desempenho observado, pois no estado de São Paulo, o inverno é seco (ROLIM et al., 2007), ou seja, apresenta pouco efeito dos constituintes atmosféricos. Este método também apresentou bons resultados na primavera. Segundo Cavalcante Júnior et al. (2011), o método de Ham subestima a ETo em condições áridas e semi-áridas, contradizendo os resultados do presente trabalho. Borges e Mendonça (2007) observaram que este método subestimava a ETo em todos os meses do ano, corroborando com os resultados dessa pesquisa. Em relação ao método de BenL, Bezerra et al. (2014) observaram melhor desempenho em todas as estações do ano, diferindo desta pesquisa (melhor desempenho no outono).

O método de Irmak foi desenvolvido para climas úmidos (IRMAK et al., 2003) e o de Abtew também para climas úmidos, justificando os altos valores de desempenho observados no verão (quente e chuvoso). Os bons resultados observados no outono

nesses dois métodos, talvez sejam explicados pelo fato dessa estação sofrer efeitos climáticos do verão. No método de JensH, o melhor desempenho foi observado em condições de clima quente e úmido (IRMAK et al., 2003; ZHAI et al., 2010), porém, no presente estudo foi observado em condições de clima pouco úmido e seco (inverno). Contudo, segundo Jensen Haise (1963) e Medeiros (2008), o método de JensH foi desenvolvido para condições áridas e semi-áridas, concordando com a presente pesquisa.

Em geral, observou-se que os métodos de Abtew e Irmak foram melhores no verão e no outono, enquanto o de JensH foi no inverno. O método de Abtew também foi melhor na primavera. No entanto, na prática nem todas as estações meteorológicas medem a R_s que é necessária nesses métodos. Sendo assim, na ausência de dados de R_s , pode-se utilizar os métodos de HS na primavera e no inverno, de Ham no verão e de BenL no outono. Observou-se ainda que os métodos da escala anual subestimaram a primavera e o verão, e superestimaram o outono e o inverno. Isto mostrou a existência do efeito de sazonalidade, o qual pode ser explicado pela variação da cobertura do céu ao longo das estações do ano e pelas condições de origem dos métodos.

1.5 CONCLUSÃO

Escala anual:

Dentre os métodos empíricos de temperatura (Benevides – Lopez - BenL, Hamon – Ham , Blaney Criddle Original – BCO e Hargreaves Samani - HS) e de radiação solar avaliados (Abtew, Jensen Haise - JensH, Makkink -Mak e Irmak), observou-se que o de Abtew apresentou melhor desempenho, cujos valores obtidos foram: MBE = $-0,17 \text{ mm d}^{-1}$ e RMSE = $0,45 \text{ mm d}^{-1}$. Estes valores significam que este método apresentou uma menor subestimativa da ETo , maior precisão, respectivamente. O menor desempenho foi apresentado pelo método de Mak, cujos valores obtidos foram: MBE = $1,34 \text{ mm d}^{-1}$ e RMSE = $1,43 \text{ mm d}^{-1}$. É nesse método que observou-se os valores mais baixos de “d” (0,69) e R^2 (0,89).

Foi observado que na ausência de dados de radiação solar global - R_s , o método de HS pode ser utilizado, o qual apresentou os seguintes valores de desempenho: $MBE = 0,51 \text{ mm d}^{-1}$ e $RMSE = 0,82 \text{ mm d}^{-1}$.

Escala sazonal:

Os resultados obtidos mostraram que o método de JensH foi melhor no inverno ($MBE = 0,17 \text{ mm d}^{-1}$ e $RMSE = 0,22 \text{ mm d}^{-1}$), o de Irmak no verão ($MBE = -0,13 \text{ mm d}^{-1}$ e $RMSE = 0,17 \text{ mm d}^{-1}$) e no outono ($MBE = 0,17 \text{ mm d}^{-1}$ e $RMSE = 0,18 \text{ mm d}^{-1}$) e o de Abtew na primavera ($MBE = -0,34 \text{ mm d}^{-1}$ e $RMSE = 0,37 \text{ mm d}^{-1}$), além de outono ($MBE = 0,10 \text{ mm d}^{-1}$ e $RMSE = 0,15 \text{ mm d}^{-1}$) e verão ($MBE = -0,15 \text{ mm d}^{-1}$ e $RMSE = 0,16 \text{ mm d}^{-1}$). Os valores de “d” e R^2 mais baixos foram de 0,83 e 0,90 observados na primavera utilizando o método de Abtew, respectivamente.

Na falta de dados R_s , pode-se utilizar o método de HS na primavera ($MBE = 0,64 \text{ mm d}^{-1}$ e $RMSE = 0,88 \text{ mm d}^{-1}$) e no inverno ($MBE = 0,32 \text{ mm d}^{-1}$ e $RMSE = 0,57 \text{ mm d}^{-1}$), de Ham no verão ($MBE = -0,66 \text{ mm d}^{-1}$ e $RMSE = 0,72 \text{ mm d}^{-1}$) e de BenL no outono ($MBE = -0,3 \text{ mm d}^{-1}$ e $RMSE = 0,35 \text{ mm d}^{-1}$). Os valores mais baixos de “d” e R^2 foram de 0,55 e 0,53 verificados no verão, método de Ham, respectivamente.

Análise de sazonalidade:

Na análise de sazonalidade, observou-se que as equações anuais (métodos) subestimaram as sazonais na primavera e no verão, ocorrendo o oposto no outono e no inverno. O método de Abtew teve efeito de sazonalidade considerado similar, pois apresentou valores absolutos de desvios lineares mais próximos (DL), sendo $DL = -15,09\%$ na primavera, $DL = -15,36\%$ no verão, $DL = 15,63\%$ no outono e $DL = 13,75\%$ no inverno.

REFERÊNCIAS

- ABTEW, W. Evapotranspiration measurements and modeling for three wetland systems in South Florida. **Journal of the American Water Resources Association**, v. 127, n. 3, p. 140-147, 1966.
- AHOOGHALANDINI, M.; KHIADANI, M.; JAHROMI, M. E. Developing equations for estimating reference evapotranspiration in Australia. **Water Resour Manage**, v. 30, p. 3815 – 3828, 2016.
- ALLEN, R. G.; PEREIRA, L.; RAES, D.; SMITH, M. **Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements**. Roma: FAO, (FAO: Irrigation and Drainage Paper, 56), 1998.
- ALEXANDRIS, S.; STRICEVIC, R.; PETKOVIC, S. Comparative analysis of reference evapotranspiration from the surface of rainfed grass in central Serbia, calculated by six empirical methods against the Penman – Monteith formula. **European water**, v.21, n. 22, p. 17-28, 2008.
- BENAVIDES, J. G.; LOPEZ, D. Formula para el calculo de la evapotranspiracion potencial adaptada al tropico (15° N - 15° S). **Agronomia Tropical**, Maracay, v. 20, n. 5, p. 335-345, 1970.
- BERENGENA, J.; GAVILÁN, P. Reference evapotranspiration estimation in a highly advective semiarid environment. **Journal of Irrigation and drainage Engineering ASCE**, v. 131, p.147-163, 2005.
- BEZERRA, J. M.; MOURA DE ALBUQUERQUE, G. B.; FRANÇA, E. F.; SILVA, E. F.; LOPES, P. M. O.; DA SILVA, B. B. Estimativa da evapotranspiração de referência diária para Mossoró (RN, Brasil). **Revista Caatinga**, v. 27, n. 3, p. 211-220, jul-set., 2014.
- BLANEY, H. F.; CRIDDLE, W.O. **Determining water requirements in irrigated areas from climatological and irrigation data**. Washington: USDA Soil Conservation Service, 1950. 48 p. (Technical Paper n. 96).
- BORGES, A. C.; MENDIONDO, E. M. Comparação entre equações empíricas para a estimativa da evapotranspiração de referência na Bacia do Rio Jacupiranga, **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 11, n. 3, p. 293-300, 2007.
- CAI, J.; LÍU, Y.; LEI, T.; PEREIRA, L. S. Estimating reference evapotranspiration with the FAO Penman – Monteith equation using daily weather forecast messages. **Agric. Forest. Meteorol.**, v. 145, p. 22-35, 2007.
- CAO, J. F.; LI, Y. Z.; ZHONG, X. I.; ZHAO, Y. M. Comparison of four combination methods for reference crop evapotranspiration. Chin. **J. Agrometeorol**, v. 36, n. 4, p. 428-436, 2015.

CAVALCANTE JÚNIOR, E. G. Estimativa da evapotranspiração de referência para a cidade de Mossoró – RN. **Revista Brasileira de Agrometeorologia**, Fortaleza, v. 31, n. 2, p.87-92, 2011.

CENTRO DE PESQUISAS METEOROLÓGICAS E CLIMÁTICAS APLICADAS A AGRICULTURA - CEPAGRI. **Clima dos Municípios Paulistas**. Disponível em: <<http://www.cpa.unicamp.br/outras-informacoes/clima-dos-municipios-paulistas.html>>. Acesso em: 10 de out. 2016.

DE BRUIN, H. A. R. The determination of (reference crop) evapotranspiration from routine weather data. **Proceedings and Informations, Committee for Hydrological Research**, v. 28, p. 25-37, 1981.

DJAMAN, K.; BALDE, A. B.; SOW, A.; MULLER, B.; IRMAK, S.; N'DIAYE, M. K.; MANNEH, B.; MOUKOUMBI, Y. D.; FUTAKUCHI, K. SAITO, K. Evaluation of sixteen reference evapotranspiration methods under Sahelian conditions in The Senegal River Valley. **Journal of hydrology: Regional Studies**, v. 3, p. 139 – 159, 2015.

DOORENBOS, J.; PRUITT, W.O. **Guidelines for predicting crop water requirements**. FAO Irrigation and drainage paper 24, Roma, 1975, 179 p.

ER RAKI, S.; CHEHBOUNI, A.; KHABBA, S.; SIMONNEAUX, V.; JARLAN, L.; OULDBBA, A.; RODRIGUES, J. C.; ALLEN, R. Assessment of reference evapotranspiration methods in semi – arid regions: Can weather forecast data be used as alternate of ground meteorological parameters? **Journal of arid environment**, v. 74, p. 1587-1596, 2010.

HAMON, W. R. Estimating potential evapotranspiration. **Journal of Hydraulics Division ASCE**, Nova Iorque, v. 87, p. 107-120, 1961.

HARGREAVES, G. H.; SAMANI, Z. Reference crop evapotranspiration from temperature. **Journal of Applied Engineering in Agriculture**, St Joseph, v.1, n. 2, p.96-99, 1985.

IRMAK, S.; IRMAK, A.; ALLEN, R. G.; JONES, J. W. Solar and net radiation – based equations to estimate reference evapotranspiration in humid climates. **Journal of Irrigation and Drainage Engineering**, v. 129, n. 5, p. 336-347, 2003.

JENSEN, M. E.; HAISE, H. R. Estimating evapotranspiration from solar radiation. **Journal of Irrigation and Drainage Division, ASCE**, v. 89, p.15-41, 1963.

KARIYAMA, I. D. Temperature-based feed-forward backpropagation artificial neural network for estimating reference crop evapotranspiration in the upper west region. **International journal of scientific and technology research**, v. 3, ISSUE 8, 2014.

KHOOB, A. R. Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. **Irrigation Science**, v. 26, n. 3, p. 253–259, 2008.

KOTTEK, M.; GRIESER, J.; BECK, C.; RUDOLF, B.; RUBEL, F. Word map of the Koppen – Geiger climate classification updated. **Meteorologische Zeitschrift**, Berlin, v.15, n. 3, p. 259-263, June 2006.

KUMAR, M.; BANDYOPADHYAY, A.; RAGHUWANSHI, N. S.; SINGH, R. Comparative study of conventional and artificial neural network-based estimation models. **Irrigation Science**, v.26, n.6, p.531-545, 2008.

LANDERAS, G.; ORTIZ BARREDO, A.; LÓPEZ, J. J.; Comparison of artificial neural network models and empirical and semi – empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). **Agricultural water management**, v. 95, p. 553-565, 2008.

LINGLING, Z.; JUN, X.; CHONG YU, X.; ZHONGGEN, W.; LESZEK, S.; GANGRUI, L. Evapotranspiration estimation methods in hydrological models. **J. Geogr. Sci.**, v. 23, n. 2, p. 359-369, 2013.

MAEDA, E. E.; WIBERG, D. A.; PELLIKKA, P. K. E. Estimating reference evapotranspiration using remote sensing and empirical models in a region with limited ground data availability in Kenya. **Applied geography**, v. 31. P. 251-258, 2011.

MAKKINK, G, F. Testing the Penman formula by means of lysimeters. **Journal of Institution of Water Engineers**, v. 13, n. 3, p. 277-288, 1957.

MARTINEZ, C.J., THEPADIA, M. Estimating reference evapotranspiration with minimum data in Florida. **J. Irrig. Drain. Eng**, v. 136, n.7, p. 494–501, 2010.

MAVI, H. S.; TUPPER, G. J. Agrometeorology: principles and applications of climate studies in agriculture. **Food Products Press**. Oxford. London, 364p. 2004.

MEDEIROS, P. V. **Análise de evapotranspiração de referência a partir de medidas lisimétricas e ajuste estatístico de nove equações empíricas teóricas com base na equação de Penman – Monteith**. 2008. 241f. Dissertação (Mestrado em Hidráulica e Saneamento) – Escola de Engenharia de São Carlos. Universidade de São Paulo, São Paulo, 2008.

MELO, G. L.; FERNANDES, A. L. T. Evaluation of empirical methods to estimate reference evapotranspiration in Uberaba, State of Minas Gerais, Brazil. **Eng. Agríc.**, Jaboticabal, v. 32. n. 5, p. 875-888, set/out. 2012.

MOELETSI, M. D.; WALKER, S.; HAMANDAWANA, H. Comparison of the Hargreaves and Samani equation and the thornthwaite equation for estimating dekadal evapotranspiration in the Free State Province, South Africa. **Physics and Chemistry of the Earth**, v. 66, p. 4-15, 2013.

MOHAWESH, O. E. Evaluation of evapotranspiration models for estimating Daily reference evapotranspiration in arid and semiarid environment. **Plant Soil Environ.**, v. 57, n. 4, p. 147-152, 2011.

NANDAGIRI, L.; KOVOOR, G. M. Performance evaluation of reference evapotranspiration equations across a range of Indian climates. **Journal of Irrigation and Drainage Engineering**, v. 132, n. 3, p. 238-249, 2006.

ROLIM, D. DE S.; DE CAMARGO, M. B. P.; LANIA, D. G.; DE MOARES, J. F. L. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo, **Bragantia**, Campinas, v. 66, n. 4, p. 711-720, 2007.

SAMARAS, D. A.; REIF, A.; THEODOROPOULOS, K. Evaluation of radiation based reference evapotranspiration models under different Mediterranean climates in Central Greece. **Water Resour Manage**, v. 28, p. 207-225, 2014.

SENTELHAS, P. C.; GILLESPIE, T. J.; SANTOS, E. A. Evaluation of FAO Penman – Monteith and alternative methods for estimating reference evapotranspiration with missing data in Southern Ontario, Canada. **Agricultural water management**, v. 97, p. 635-644, 2010.

SOUZA, A. P.; MOTA, L. L.; ZAMADEI, T.; MARTIM, C. C.; ALMEIDA, F. T.; PAULINO, J. Classificação climática e balanço hídrico climatológico no estado de Mato Grosso. **Nativa**, Sinop, v. 1, n. 1, p. 34-43, out/dez., 2013.

TABARI, H. Evaluation of reference crop evapotranspiration equations in various climates. **Water Resour. Manage**, v. 24, n. 10, p. 2311-2337, 2010.

TABARI, H.; 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 hidrology**, 444-445, p. 78-89, 2012.

TODOROVIC, M.; KARIC, B. PEREIRA, L. S. Reference evapotranspiration estimate with limited weather data across a range of Mediterranean climates. **Journal of hydrology**, v. 481, p. 166 -176, 2013.

VANDERLINDEN, K.; GIRÁLDEZ, J. V.; MEIRVENNE VAN, M. Assessing reference evapotranspiration by the Hargreaves method in Southern Spain. **J.Irrig. Drain. Eng**, v. 130, n. 3, p. 184-191, May/June 2004.

VAN DIJK, A. I. J. M.; DOLMAN, A. J.; SCHULZE, E. D. Radiation, temperature, and leaf area explain ecosystem carbon fluxes in boreal and temperate European forests. **Global Geochemistry, Cycles**, v. 19, 2005.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. 2. Ed. Viçosa, MG: Ed. UFV, 2012, 460p.

VICENTE SERRANO, S. M.; MOLINA AZORIN, C.; LORENZO SANCHEZ, A.; REVUELTO, J.; MORENO LÓPEZ, J. I.; HIDALGO GONZÁLEZ, J. C.; TEJEDA MORAN, E.; ESPEJO, F. Reference evapotranspiration variability and trends in Spain, 1961 -2011. **Global and Planetary Change**, v. 121, p. 26-40, 2014.

WANG, Y. M.; TRAORE, S.; KERH, T. Neural network approach for estimating reference evapotranspiration from limited climatic data in Burkina Faso. **Wseas transactions on computers**, V. 7, ISSUE 6, 2008.

WILLMOTT, C. J.; CKLESON, S.G.; DAVIS, R. E. Statistics for the Evaluation and Comparison of Models. **Journal of Geophysical Research**. Ottawa, v.90, n.C5, p. 8995-9005, 1985.

XING, Z.; CHOW, L.; MENG, F.; REES, H.W.; MONTEITH, J.; LIONEL, S. Testing reference evapotranspiration estimation methods using evaporation pan and modeling in Maritime Region of Canada. **J. irrig. Drain. Eng.** v.134, n. 4, p. 417-424, 2008.

XU, C. Y.; CHEN, D. Comparison of seven models for estimation of evapotranspiration and groundwater recharge using lysimeter measurement data in German. **Hydrol. Processes**, v. 19, p. 3717-3734, 2005.

XU, C. Y.; SINGH, V. P. Evaluation and generalization of radial based methods for calculating evaporation. **Hydrol. Processes**, v. 14, p. 339-349, 2000.

XU, C. Y.; SINGH, V. P. Cross comparison of empirical equations for calculating potential evapotranspiration with data from Switzerland. **Water Resource Management**, v. 16, p. 197-219, 2002.

XU, J.; PENG, S.; DING, J.; WEI, Q.; YU, Y. Evaluation and calibration of simple methods for daily reference evapotranspiration estimation in humid East China. **Archives of Agronomy and Soil Science**, v. 59, n 6, p. 845-858, 2013.

YODER, R. E.; ODHIAMBO, L. O.; WRIGHT, W. C. Evaluation of methods for estimating daily reference crop evapotranspiration at a site of the humid southeast United States. **Appl. Eng. Agric**, v. 20, n. 2, p. 197-202, 2005.

ZHAI, L.; FENG, Q.; LI, Q.; XU, C. Comparison and modification of equations for calculating evapotranspiration (ET) with data from GANSU Province, Northwest China. **Irrig. and Drain.**, v. 59, p. 477-490, 2010.

CAPÍTULO 2

MODELAGEM DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: TÉCNICA DE APRENDIZADO DE MÁQUINAS E MODELOS EMPÍRICOS

RESUMO

A evapotranspiração de referência (ET_o) é importante na agricultura, pois permite calcular a demanda de água das culturas. Neste trabalho avaliou-se os métodos empíricos (Hargreaves – Samani e Abtew) e duas técnicas de aprendizado de máquinas - TAM (Redes Neurais Artificiais - RNA e Máquina Vetor de Suporte - MVS) em relação ao método padrão da FAO 56 no estado de São Paulo em escalas anual e sazonal, a partir de dados meteorológicos de 22 estações automáticas. A RNA utilizada foi do tipo *Multilayer Perceptron* (MLP), com algoritmo de aprendizado *backpropagation* e na MVS utilizou-se a função *Radial Basic Function* (RBF) de Kernel, com algoritmo de aprendizado *Regression Sequential Minimal Optimization*. Cada TAM foi composta por seis arquiteturas, em que 70% dos dados foram utilizados para treinar e 30% para validar. As análises estatísticas foram feitas com base nos índices MBE (*Mean Bias Error*), RMSE (*Root Mean Square Error*), “d” de Willmott e R^2 (coeficiente de determinação). Os resultados obtidos na escala anual mostraram que a R6 para RNA e M6 para MVS compostas por temperatura máxima (T_{max}), mínima (T_{min}), média do ar (T), radiação extraterrestre (R_a) e radiação solar global (R_s) produziram o melhor desempenho. Na escala sazonal, os melhores desempenhos foram observados nas arquiteturas compostas por T_{max}, T_{min}, T, R_a e velocidade do vento (R3 e M3); T_{max}, T_{min}, T, R_a e umidade relativa do ar (R4 e M4); T e R_s (R5 e M5); e na R6 e M6.

Palavras – chave: *Backprppagation*. Máquina vetor de suporte. Redes neurais artificiais.

ABSTRACT

The reference evapotranspiration (ET_o) is important in agriculture because it allows the calculation of crop water demand. In this work, it was assessed the empirical methods (Hargreaves – Samani and Abtew) and two machine learning techniques – MLT (Artificial Neural Networks – ANNs and Support Vector Machine – SVM) against FAO 56 standard method in the state of São Paulo on annual and seasonal scales, from meteorological data from 22 automatic stations. The ANNs used was of Multilayer Perceptron type (MLP) with backpropagation learning algorithm, and in the MVS, it was used the Kernel Radial BasicFunction (RBF) with Regression Sequential Minimal Optimization learning algorithm. Each MLT was composed of 6 architectures, in which 70% of the data was used for training and 30% for validation. The statistical analyses were performed based on MBE (MeanBias Error), RMSE (Root Mean Square Error), “d” of Wilmot and R^2 (determination coefficient). The obtained results in the annual scale showed that R6 for RNA and M6 for MVS composed of maximum temperature (T_{max}), minimum temperature (T_{min}), average air temperature (T), extraterrestrial radiation (R_a) and global solar radiation (R_s) rendered a better performance. On the seasonal scale, the better performance was observed in architectures composed of T_{max}, T_{min}, T, R_a and wind speed (R3 and M3); T_{max}, T_{min}, T, R_a and relative humidity (R4 and M4); T and R_s (R5 and M5); and in the R6 and M6.

Key words: Backpropagation. Support vector machine. Artificial neural networks.

2.1 INTRODUÇÃO

A evapotranspiração de referência (ET_o) é um fenômeno complexo, o qual consiste na perda d'água na forma de vapor para a atmosfera, podendo ser por transpiração de superfícies vegetadas e por evaporação do solo e/ou de superfícies vegetadas. A ET_o acontece em uma cultura hipotética com 0,12 m de altura, albedo de 0,23, resistência do copado de 70 s m⁻¹, em crescimento uniforme e ativo, cobrindo totalmente uma área extensa e sem restrição hídrica, conforme Allen et al. (1998). A ET_o é fundamental na irrigação para o cálculo da demanda de água das culturas (ET_c) que se obtém multiplicando a ET_o pelo coeficiente de cultura (K_c) (YODER et al., 2005).

A ET_o pode ser estimada utilizando diversos métodos indiretos, dentre os quais, o de Penman Monteith FAO 56 (PMF 56) é considerado padrão por Allen et al. (1998). Vários autores constataram que este método apresenta melhor desempenho comparado aos demais métodos indiretos (CAI et al., 2007; CAO et al., 2015; GARCIA et al., 2004; MOHAWESH, 2011; XU;CHEN, 2005), contudo, é de uso bastante limitado por requerer uma série de elementos meteorológicos, os quais nem sempre se encontram disponíveis em várias estações meteorológicas. Sendo assim, vários métodos alternativos vêm sendo desenvolvidos (GEORGE et al., 2002; ITENFISU et al., 2003), principalmente os métodos empíricos, tais como: Hargreaves samani, Abtew, Makkin, etc. Estes métodos são de uso simples e prático, todavia, a sua escolha deve ser feita de forma cuidadosa, pois o seu desempenho é influenciado pelo clima de cada local.

Khoob (2008) observou que o método de HS subestimou e superestimou o método PMF 56 em 20 e 37% em escala mensal, respectivamente. Kisi (2006) observou que este método superestimou PMF 56 numa faixa de 118 – 167%. Valipour (2015) avaliando 22 métodos de estimativa da ET_o em 31 Províncias de Irã, constatou que o desempenho dos mesmos variava de local para local. Com isso, este autor recomendou o ajuste dos parâmetros dos métodos para cada tipo de clima. A variabilidade do desempenho dos métodos empíricos tem levado os pesquisadores à pesquisas contínuas. Como resultado dessas pesquisas, há que

destacar algumas técnicas de aprendizado de máquinas (TAM): Redes Neurais Artificiais (RNAs), Sistemas Neuro Fuzzy, Máquina Vetor de Suporte (MVS), etc.

As RNAs são modelos matemáticos, cujo princípio assemelha-se aos neurônios biológicos. Elas são adequadas para a modelagem de processos não lineares como a evapotranspiração (ESLAMIAN et al., 2008; HAYKIN, 1998; LANDERAS et al., 2008). Vários pesquisadores utilizaram as RNAs para estimar a ETo a partir de diferentes arquiteturas, cujos resultados apontaram elevado desempenho em relação ao método PMF 56 do que os métodos empíricos (JAIN et al., 2008; KISI, 2006; KISI, 2007; NOURANI;FARD, 2012; TRAORE et al., 2010; ZANETTI et al., 2007). Por outro lado, existem pesquisas que constataram que as RNAs estimam melhor a ETo que o método PMF 56 (KUMAR et al., 2002; PARASURAMAN et al., 2004). Dentre os vários tipos de RNAs existentes, segundo KUMAR et al. (2011), a *Multilayer Perceptron* (MLP) com algoritmo *backpropagation* é a mais utilizada, com mais de 70% de trabalhos publicados. Vários trabalhos relataram elevado desempenho dessas RNAs (AMINI, 2008; TRAORE et al., 2010; WANG et al., 2009; WANG et al., 2011).

Quanto à MVS, existem poucos estudos feitos comparado às RNAs, principalmente sobre estimativa da ETo. Contudo, os trabalhos existentes têm relatado que a MVS é mais eficiente na estimativa de processos complexos do que as RNAs. Segundo Kumar e Kar (2009), a MVS é uma metodologia poderosa para resolver problemas não lineares, a qual Vapnik (1998) relatou que é bastante robusta. Para Amari e Wu (1999), o desempenho da MVS depende fortemente da função Kernel utilizada, portanto, há necessidade de uma escolha cuidadosa do tipo de função a utilizar.

Kisi (2013), avaliando os métodos de estimativa da ETo, observou que a MVS *least square* apresentou melhores resultados que as RNAs e métodos empíricos. Outros trabalhos que sustentam a superioridade da MVS do que as RNAs e métodos empíricos de estimativa da ETo foram apresentados por Kisi e Cimen (2009), Tabari et al. (2013) e Wen et al. (2015). Em outras pesquisas, Samui e Dixon (2012) e Hamidi et al. (2014) observaram melhores resultados da MVS que as RNAs na estimativa das perdas por evaporação e na estimativa da precipitação, respectivamente.

Todavia, resultados opostos foram observados por Tezel e Buyukyildiz (2016), onde as RNAs MLP e *radial basis function network* apresentaram melhor desempenho do que a MVS na estimativa da evaporação.


Com o presente trabalho, pretende-se avaliar o desempenho dos métodos empíricos (Hargreaves – Samani e Abtew) e as TAM (RNAs e da MVS) na estimativa da ETo no estado de São Paulo em relação ao método de PMF 56, em escalas anual e sazonal, a partir de dados meteorológicas de 22 estações automáticas. Nas TAM são utilizadas várias combinações de variáveis de entrada, simulando a estimativa da ETo em diferentes situações.

2.2 MATERIAL E MÉTODOS

2.2.1 Localização e descrição do estudo

Na Figura 1 está exposta a localização das 22 estações meteorológicas automáticas do estado de São Paulo utilizadas no presente estudo. Os dados dessas estações foram disponibilizados pelo Instituto Nacional de Meteorologia do Brasil (INMET).

Figura 1 - Mapa de 22 estações automáticas do estado de São Paulo



Na Tabela 1 estão os dados das coordenadas geográficas (latitude, longitude e altitude), período de coleta dos dados (composto por pelo menos 80% de dados) e do clima das 22 estações meteorológicas que compõem a presente pesquisa. Da mesma tabela, observa-se quatro tipos de clima: Aw, Cwa, Af e Am, os quais seguem o critério de classificação climática de Köppen, conforme Cepagri (2016).

As letras Cwa caracterizam o clima temperado ou tropical de altitude, enquanto as letras Aw, Af e Am caracterizam o clima tropical de savana, clima tropical de selva chuvosa e clima de montanha, respectivamente (VIANELLO;ALVES, 2012). Nos climas Aw, a temperatura média do mês mais frio é superior a 18°C, com inverno seco no qual pelo menos um dos meses apresenta uma precipitação média inferior a 60 mm; No Cwa, a temperatura do mês mais frio do ano varia entre -3° e 18°C, com inverno seco e cuja precipitação média é inferior a 60 mm em um dos meses dessa estação. O verão é quente com temperatura média do mês mais quente superior a 22°C; No Af, ocorrem chuvas durante todo ano, com precipitação do mês mais seco superior a 60 mm, e no Am, ocorre uma estação seca curta, chuvas intensas durante a maior parte do período do ano e temperatura média do mês mais frio superior a 18°C (KOTTEK et al., 2006; SOUZA et al., 2013).

Dentre vários tipo de clima que o estado de São Paulo apresenta, o clima Aw é um dos mais predominantes (ROLIM et al., 2007). Este tipo climático é também predominante nas 22 cidades utilizadas.

Tabela 1 - Estações meteorológicas automáticas do estado de São Paulo

Código	Estações (Cidades)	Latitude (graus)	Longitude (graus)	Altitude (m)	Período (anos)	Clima
A-736	Ariranha	-21,01	-48,83	525	2008 - 2015	Aw
A-725	Avaré	-23,00	-48,88	654	2007 - 2015	Cwa
A-705	Bauru	-22,30	-49,70	550	2005 - 2015	Aw
A-738	Casa Branca	-21,77	-47,01	730	2008 - 2015	Aw
A-708	Franca	-20,57	-47,37	1026	2005 - 2015	Aw
A-737	Ibitinga	-21,85	-48,80	492	2008 - 2015	Aw
A-712	Iguape	-24,70	-47,55	3	2007 - 2015	Af
A-714	Itapeva	-23,97	-48,85	707	2007 - 2015	Cwa
A-733	Jales	-20,02	-50,58	457	2008 - 2015	Aw
A-735	José Bonifácio	-21,00	-49,68	405	2008 - 2015	Aw

A-727	Lins	-21,65	-49,73	459	2007 - 2015	Aw
A-716	Ourinhos	-22,95	-49,85	448	2007 - 2015	Am
A-726	Piracicaba	-22,70	-47,62	574	2007 - 2015	Cwa
A-707	Presidente Prudente	-22,01	-51,40	436	2005 - 2015	Aw
A-718	Rancharia	-22,37	-50,97	350	2007 - 2015	Aw
A-711	São Carlos	-21,95	-47,87	863	2007 - 2015	Cwa
A-740	Luis do Paraitinga	-23,22	-45,52	874	2008 - 2015	Cwa
A-715	São Miguel de Arcanjo	-23,85	-48,00	678	2007 - 2015	Cwa
A-701	São Paulo	-23,50	-46,62	792	2007 - 2015	Cwa
A-728	Taubaté	-23,00	-45,52	571	2007 - 2015	Cwa
A-734	Valparaíso	-21,32	-50,92	374	2007 - 2015	Aw
A-729	Votuporanga	-20,40	-49,95	486	2007 - 2015	Aw

Além dos dados apresentados na Tabela 1, coletou-se dados de temperatura máxima, mínima, umidade relativa média do ar, velocidade do vento e radiação solar global, também disponibilizados pelo INMET. Esses dados estavam na escala horária, sendo assim, foram transformados para escala diária, tendo-se aplicado o critério de integração para a radiação solar global e de média aritmética para os demais dados.

Em seguida, estimou-se a ETo na escala anual e sazonal, utilizando-se o método empírico de temperatura (Hargreaves Samani - HS), e de radiação solar (Abtew - AB) e as TAM. Os resultados obtidos, tanto nos métodos empíricos quanto nas TAM foram avaliados em relação ao método de PMF 56, considerado como padrão por Allen et al. (1998). A seguir são apresentadas as equações utilizadas no método padrão, métodos empíricos e a arquitetura de cada TAM.

2.2.2 Método padrão de estimativa da ETo

A Equação 1 é recomendada por Allen et al. (1998) e é utilizada como padrão para a estimativa da ETo na ausência de lisímetros.

$$ET_o = \frac{0,408 * \Delta * (R_n - G) + \gamma * \frac{900}{T + 273} * U_2 * (e_s - e_a)}{\Delta + \gamma * (1 + 0,34 * U_2)} \quad (1)$$

Em que: ETo = Evapotranspiração de referência, mm d^{-1} ; Rn = Saldo da radiação, $\text{MJ m}^{-2} \text{d}^{-1}$; G = Densidade de fluxo de calor para o solo, $\text{MJ m}^{-2} \text{d}^{-1}$; γ = Constante psicométrico, $\text{kPa } ^\circ\text{C}^{-1}$; T = Temperatura média do ar, $^\circ\text{C}$; U_2 = Velocidade do vento a 2 metros de altura, m s^{-1} ; e_s = Pressão de saturação a temperatura de bulbo seco, kPa ; e_a = Pressão real ou actual de vapor d'água, kPa ; Δ = Declividade da curva da pressão de saturação de vapor, $\text{kPa } ^\circ\text{C}^{-1}$; 0,408 = Fator de conversão de $\text{MJ m}^{-2} \text{d}^{-1}$ para mm d^{-1} .

2.2.3 Métodos empíricos de estimativa da ETo

2.2.3.1 Método de Hargreaves – Samani

O método de Hargreaves – Samani (1985) estima a ETo (mm d^{-1}) a partir da amplitude térmica, temperatura média do ar e da radiação extraterrestre (Equação 2).

$$ETo = 0,0023 * 0,408 * Ra * (T_{\max} - T_{\min})^{0,5} * (T + 17,8) \quad (2)$$

Em que: $T_{\max}$ = Temperatura máxima do ar e $T_{\min}$ = Temperatura mínima em $^\circ\text{C}$.

2.2.3.2 Método Abtew

A Equação 2 de Abtew (1966) estima a ETo (mm d^{-1}) a partir de dados de radiação solar global (R_s) e o K assume um valor médio de 0,53.

$$ETo = \frac{K}{\lambda} * R_s \quad (3)$$

2.2.4 ETo nas escalas anual, sazonal e softwares utilizados

Para o uso das RNAs e da MVS, tanto na escala anual quanto na sazonal, combinou-se várias variáveis de entrada (arquitetura) para simular inúmeras possibilidades de estimativa da ETo (Tabela 2). Dessas variáveis de entrada, 70 %

(*Percentage Split*) foram utilizados para o treinamento e o remanescente para a validação. Segundo da Silva et al. (2010), o subconjunto de treinamento é composto aleatoriamente com cerca de 60 a 90% das amostras do conjunto total. Ressalta-se que as letras R e M na Tabela 2 correspondem à RNAs e MVS, respectivamente.

Tabela 2 - Arquitetura das RNAs e MVS utilizada na escala anual e sazonal

Variáveis de entrada	Arquitetura da RNAs e da MVS
T	R1 e M1
T, Tmax, Tmin e Ra	R2 e M2
T, Tmax, Tmin, Ra e U_2	R3 e M3
T, Tmax, Tmin, Ra e UR	R4 e M4
T e Rs	R5 e M5
T, Tmax, Tmin, Ra e Rs	R6 e M6


A estimativa da ETo pelas TAM foi feita no programa WEKA versão 3.6.13 (Weikato Environment of Knowledge Analysis), o qual é de acesso livre. Mais detalhes sobre o WEKA foram apresentados por Hall et al. (2009).

2.2.4.1 Redes Neurais Artificiais (RNAs)

As RNAs têm a capacidade de apreender e de se adaptar a qualquer ambiente, podendo ser um ambiente conhecido ou novo, além de que o aprendizado pode ser supervisionado ou não supervisionado.

Dentre as redes existentes, a Perceptron de Múltiplas Camadas (MLP) é mais utilizada (HAYKIN, 1998). Ela é composta por três camadas de neurônios interligadas, sendo a primeira, a segunda e a terceira designadas camadas de entrada ($X_{i,j}$), intermediária ou oculta ($w_{i,j}$) e de saída (y_i), respectivamente. A camada intermediária possui pelo menos uma camada oculta por vários neurônios (Figura 2). É nessa camada que os dados de entrada são multiplicados pelos pesos atribuídos, e a posterior passados para a camada de saída donde são liberados quando os erros da modelagem forem mínimos.

Figura 2 - MLP com uma camada oculta



Existem vários algoritmos de aprendizado que podem ser utilizados para treinar a MLP, mas neste trabalho é utilizado o *backpropagation*. Neste tipo de algoritmo, o aprendizado faz duas passagens nas diferentes camadas da rede, sendo uma para frente, denominada propagação e outra para trás, denominada retropropagação (HAYKIN, 1998). No final, uma função de ativação dos neurônios é aplicada para gerar os dados de saída, geralmente, uma função logística sigmoidal (HUO, et al., 2012), conforme a Equação 4. No WEKA foi aplicada uma função sigmoidal, considerando *learning rate* = 0,3; *momentum* = 0,2 e *training time* = 500. Testou-se várias camadas ocultas (1 a 10 camadas), tendo sido selecionado o parâmetro padrão do WEKA “a”, pois apresentou melhores resultados.

$$f(x) = \frac{1}{(1 + \exp(-x))} \quad (4)$$

2.2.4.2 Máquina vetor de suporte (MVS)

A MVS é um classificador derivado da teoria de aprendizagem estatística e foi introduzida por Vapnik (1995). A MVS pode ser utilizada tanto para fazer a classificação como a regressão. Segundo He et al. (2014), a MVS produz resultados

mais confiáveis e com elevado desempenho do que as RNAs nas mesmas condições de treinamento, contudo, é importante que se faça uma seleção adequada da função, dos algoritmos e dos parâmetros a serem utilizados.

Na MVS existe a necessidade de uso das funções Kernel (DAVID;SÁNCHEZ, 2003; LIN;YEH, 2009). Neste trabalho foi utilizada a função *Radial Basic Funtion* (RBF) de Kernel e o algoritmo *Regression Sequential Minimal Optimization* (RgSMO). Este algoritmo é rápido, consome menos memória e é pouco complexo. Quando se utiliza a RBF é preciso fazer um ajuste adequado dos parâmetros C (custo), γ (gama) e ε (épsilon), porém, este último não é recomendável, deixando-se o valor padrão do WEKA (0,001). Segundo Raghavendra e Deka (2014), os parâmetros C , e γ são dependentes e valores elevados de C produzem uma aprendizagem complexa e baixos uma aprendizagem inadequada. Neste trabalho, os parâmetros $C = 50$ e $\gamma = 0,04$ foram determinados por tentativa, tendo sido selecionado a combinação que produziu melhores resultados. Meyer et al. (2003) relataram valores de $C = 2^{-5}$ a 2^{12} e $\gamma = 2^{-10}$ a 2^5 .

2.2.5 Validação dos métodos empíricos e das TAM

Tanto os métodos empíricos quanto as TAM foram avaliados em relação ao método de PMF 56 com base em índices estatísticos. Os índices estatísticos utilizados foram: erro relativo médio (MBE = *Mean Bias Error*), raiz quadrada do quadrado médio do erro (RMSE = *Root Mean Square Error*), coeficiente de concordância de Willmott (1985), “d” e coeficiente de determinação (R^2). MBE > 0 indica que o método avaliado superestima os dados reais, MBE < 0 indica uma subestimativa, RMSE indica a precisão do método avaliado, “d” indica a exactidão do método e R^2 indica o grau de ajuste matemático. Os valores de MBE e RMSE são considerados melhores quanto mais próximos de zero estiverem, enquanto os de “d” e R^2 , indicam melhores resultados quanto mais próximos de um estiverem e variam de zero a um. As Equações 5 a 8 foram utilizadas para o cálculo dos índices mencionados.

$$MBE = \frac{1}{N} \sum_{i=1}^N (P_i - O_i) \quad (5)$$

$$RMSE = \left[\sum_{i=1}^N \frac{(P_i - O_i)^2}{N} \right]^{0,5} \quad (6)$$

$$d = 1 - \frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (|P_i - O| + |O_i - O|)^2} \quad (7)$$

$$R^2 = 1 - \left(\frac{\sum_{i=1}^N (P_i - O_i)^2}{\sum_{i=1}^N (O_i - O)^2} \right) \quad (8)$$

Em que: P_i = Valores estimados pelos métodos estatísticos, mm d^{-1} ; O_i = Valor estimado pelo método Padrão, mm d^{-1} ; N = Número de estimativas por período e O = Média aritmética de ETo estimado pelo método padrão, mm d^{-1} .

2.3 RESULTADOS

2.3.1 Desempenho das TAM e métodos empíricos nas cidades do estado de São Paulo

Nas Tabelas 3, 4, 5 e 6 estão mostrados os resultados do desempenho estatístico das TAM e dos métodos empíricos de estimativa da ETo em diferentes cidades do estado de São Paulo.

Nas mesmas tabelas, observa-se que a R1 e a R5 tiveram a tendência de superestimar a ETo ($MBE > 0 \text{ mm d}^{-1}$). As demais RNAs e MVS, mostraram tanto resultados de subestimativa ($MBE < 0 \text{ mm d}^{-1}$) quanto de superestimativa, e em algumas cidades não houve sub ou superestimação da ETo ($MBE = 0,00 \text{ mm d}^{-1}$). Todas TAM apresentaram valores absolutos de $MBE < 0,5 \text{ mm d}^{-1}$, com a exceção

da R5 ($MBE = 0,65 \text{ mm d}^{-1}$), cidade de Votuporanga (Tabelas 3, 4 e 5). Na Tabela 6, nota-se que os métodos de Hargreaves Samani (HS) e de Abtew (AB) tiveram a tendência de superestimar e subestimar a ETo em todas cidades, respectivamente, apresentando mais valores de $MBE > 0,5 \text{ mm d}^{-1}$ do que a TAM.

Em relação aos índices RMSE, “d” e R^2 , verificou-se valores extremos de desempenho mais baixos tanto na RNAs como na MVS quando se utilizou a temperatura média do ar como variável de entrada, para RNA: $RMSE = 0,38$ a $0,74 \text{ mm d}^{-1}$, “d” = $0,77$ a $0,96 \text{ mm d}^{-1}$; $R^2 = 0,52$ a $0,88 \text{ mm d}^{-1}$ e para MVS: $RMSE = 0,37$ a $0,62 \text{ mm d}^{-1}$, “d” = $0,80$ a $0,96 \text{ mm d}^{-1}$; $R^2 = 0,53$ a $0,88 \text{ mm d}^{-1}$. Em geral, o aumento do número de variáveis de entrada, melhorou os valores extremos do desempenho (Tabelas 3, 4 e 5). Nos métodos de HS e AB foram observados os seguintes valores extremos: ($RMSE = 0,46$ a $1,41 \text{ mm d}^{-1}$, “d” = $0,61$ a $0,95 \text{ mm d}^{-1}$; $R^2 = 0,42$ a $0,94 \text{ mm d}^{-1}$) e ($RMSE = 0,21$ a $1,09 \text{ mm d}^{-1}$, “d” = $0,68$ a $0,99 \text{ mm d}^{-1}$; $R^2 = 0,58$ a $0,98 \text{ mm d}^{-1}$), respectivamente (Tabela 6).

Tabela 3 - Desempenho estatísticos das redes neurais artificiais e máquina vetor, arquiteturas 1 e 2, em diferentes cidades do estado de São Paulo

Estações	R1(T)				M1(T)				R2 (Tmax, Tmin, T, Ra)				M2(Tmax, Tmin, T, Ra)			
	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²
Ariranha	0,02	0,39	0,96	0,88	-0,03	0,37	0,96	0,88	0,06	0,24	0,99	0,96	0,02	0,23	0,99	0,96
Avaré	0,48	0,70	0,84	0,71	-0,01	0,51	0,90	0,69	0,27	0,40	0,95	0,90	0,05	0,27	0,98	0,92
Bauro	0,41	0,57	0,87	0,77	-0,03	0,38	0,94	0,77	0,22	0,28	0,97	0,96	0,04	0,16	0,99	0,96
Casa Branca	0,11	0,44	0,89	0,71	-0,01	0,41	0,91	0,72	-0,09	0,24	0,98	0,92	0,00	0,22	0,98	0,92
Franca	0,22	0,59	0,77	0,52	-0,16	0,59	0,80	0,53	0,09	0,32	0,95	0,85	-0,68	0,85	0,75	0,61
Ibitinga	0,08	0,54	0,91	0,74	0,00	0,52	0,92	0,74	-0,07	0,28	0,98	0,94	0,00	0,23	0,99	0,96
Iguape	0,22	0,48	0,94	0,85	-0,02	0,44	0,95	0,83	0,02	0,25	0,99	0,94	0,02	0,25	0,99	0,94
Itapeva	0,15	0,46	0,92	0,77	-0,01	0,48	0,93	0,77	0,00	0,25	0,98	0,94	-0,03	0,25	0,98	0,94
Jales	0,35	0,60	0,87	0,71	-0,12	0,50	0,91	0,71	-0,04	0,34	0,96	0,86	-0,11	0,37	0,95	0,85
José Bonif.	0,27	0,62	0,88	0,72	-0,04	0,54	0,92	0,72	-0,15	0,32	0,97	0,92	-0,03	0,27	0,98	0,94
Lins	0,21	0,53	0,91	0,77	-0,06	0,48	0,93	0,77	0,12	0,30	0,97	0,94	0,02	0,24	0,99	0,94
Ourinhos	0,14	0,44	0,94	0,83	-0,13	0,44	0,94	0,83	0,04	0,24	0,98	0,94	0,00	0,24	0,98	0,94
Piracicaba	0,25	0,51	0,91	0,76	-0,04	0,46	0,93	0,76	0,17	0,28	0,97	0,94	0,02	0,22	0,99	0,94
President. P	0,36	0,60	0,88	0,72	0,01	0,48	0,91	0,72	0,21	0,29	0,97	0,96	0,01	0,20	0,99	0,96
Rancharia	0,20	0,54	0,92	0,76	-0,03	0,51	0,92	0,76	0,02	0,30	0,98	0,92	0,01	0,27	0,98	0,92
São Carlos	0,12	0,39	0,93	0,81	-0,09	0,37	0,94	0,81	0,17	0,30	0,96	0,92	-0,02	0,24	0,98	0,92
S. Luis Pi.	0,09	0,38	0,95	0,83	-0,08	0,37	0,95	0,85	0,07	0,19	0,99	0,96	0,06	0,18	0,99	0,96
S. Miguel A.	0,03	0,39	0,95	0,81	-0,04	0,40	0,95	0,81	-0,12	0,24	0,98	0,96	0,01	0,19	0,99	0,96
São Paulo	0,10	0,39	0,93	0,79	-0,01	0,37	0,94	0,79	0,00	0,20	0,98	0,94	-0,02	0,21	0,98	0,94
Taubaté	0,04	0,38	0,95	0,83	-0,02	0,40	0,95	0,81	0,05	0,24	0,98	0,94	0,01	0,22	0,98	0,96
Valparaíso	0,39	0,74	0,82	0,62	-0,04	0,62	0,88	0,64	0,19	0,40	0,96	0,88	0,06	0,36	0,96	0,88
Votuporanga	0,25	0,51	0,91	0,76	-0,04	0,46	0,93	0,76	0,35	0,48	0,92	0,86	-0,01	0,29	0,97	0,88

Tabela 4 - Desempenho estatísticos das redes neurais artificiais e máquina vetor, arquiteturas 3 e 4, em diferentes cidades do estado de São Paulo

Estações	R3 (Tmax, Tmin, T, Ra,U ₂)				M3 (Tmax, Tmin, T, Ra,U ₂)				R4 (Tmax, Tmin, T, Ra,UR)				M4 (Tmax, Tmin, T, Ra,UR)			
	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²
Ariranha	-0,07	0,22	0,99	0,96	-0,02	0,20	0,99	0,96	0,07	0,23	0,99	0,96	0,01	0,19	0,99	0,96
Avaré	0,19	0,29	0,97	0,94	0,05	0,23	0,98	0,94	0,13	0,26	0,98	0,94	0,07	0,22	0,99	0,94
Bauru	0,12	0,19	0,99	0,96	0,03	0,15	0,99	0,96	0,10	0,19	0,99	0,96	0,02	0,14	0,99	0,96
Casa Branca	-0,05	0,16	0,99	0,96	-0,02	0,16	0,99	0,96	0,10	0,19	0,99	0,96	0,00	0,31	0,96	0,85
Franca	0,11	0,26	0,97	0,92	-0,06	0,25	0,97	0,90	-0,15	0,25	0,97	0,94	0,02	0,20	0,95	0,94
Ibitinga	-0,14	0,28	0,98	0,94	0,00	0,22	0,99	0,96	-0,08	0,25	0,98	0,94	0,01	0,20	0,99	0,96
Iguape	-0,02	0,25	0,99	0,94	0,00	0,24	0,99	0,94	-0,02	0,25	0,98	0,96	-0,03	0,24	0,99	0,96
Itapeva	0,02	0,18	0,99	0,96	0,03	0,18	0,99	0,96	0,00	0,18	0,99	0,96	0,02	0,17	0,99	0,96
Jales	-0,03	0,30	0,97	0,88	-0,11	0,33	0,96	0,88	0,06	0,25	0,98	0,92	0,01	0,22	0,98	0,94
José Bonif.	-0,13	0,27	0,98	0,94	-0,04	0,23	0,99	0,96	-0,03	0,24	0,99	0,94	-0,04	0,22	0,99	0,96
Lins	0,01	0,20	0,99	0,96	-0,01	0,18	0,99	0,96	-0,03	0,23	0,99	0,96	-0,02	0,20	0,99	0,96
Ourinhos	0,03	0,21	0,99	0,96	0,00	0,22	0,99	0,94	0,00	0,21	0,99	0,96	0,00	0,21	0,99	0,96
Piracicaba	0,10	0,20	0,99	0,96	-0,01	0,17	0,99	0,96	0,03	0,19	0,99	0,96	0,00	0,17	0,99	0,96
President. P	0,17	0,23	0,98	0,96	-0,03	0,17	0,99	0,96	0,08	0,17	0,99	0,98	0,00	0,16	0,99	0,98
Rancharia	0,06	0,25	0,98	0,94	0,00	0,25	0,98	0,94	0,05	0,25	0,98	0,94	0,01	0,23	0,99	0,94
São Carlos	0,12	0,24	0,98	0,94	0,00	0,21	0,98	0,94	0,01	0,18	0,99	0,96	-0,01	0,17	0,99	0,96
S. Luis Pi.	0,05	0,18	0,99	0,96	0,02	0,15	0,99	0,98	0,09	0,19	0,99	0,98	-0,01	0,15	0,99	0,98
S. Miguel A.	-0,03	0,18	0,99	0,96	0,03	0,18	0,99	0,96	-0,07	0,18	0,99	0,96	0,01	0,15	0,99	0,98
São Paulo	0,09	0,17	0,98	0,96	0,00	0,17	0,99	0,96	0,03	0,16	0,99	0,96	0,01	0,15	0,99	0,96
Taubaté	0,09	0,23	0,98	0,94	-0,02	0,21	0,99	0,94	0,11	0,26	0,98	0,94	-0,01	0,23	0,98	0,94
Valparaíso	0,02	0,22	0,99	0,96	-0,02	0,22	0,99	0,96	0,10	0,25	0,98	0,96	0,06	0,21	0,99	0,96
Votuporanga	0,10	0,24	0,98	0,94	-0,04	0,21	0,99	0,94	0,05	0,22	0,98	0,94	-0,01	0,19	0,99	0,96

Tabela 5 - Desempenho estatísticos das redes neurais artificiais e máquina vetor, arquiteturas 5 e 6, em diferentes cidades do estado de São Paulo

Estações	R5 (T, Rs)				M5 (T, Rs)				R6 (Tmax, Tmin, T, Ra, Rs)				M6 (Tmax, Tmin, T, Ra, Rs)			
	MBE	RMSE	"d"	R ²	MBE	RMSE	"d"	R ²	MBE	RMSE	"d"	R ²	MBE	RMSE	"d"	R ²
Ariranha	0,22	0,42	0,95	0,88	-0,04	0,33	0,97	0,90	0,09	0,19	0,99	0,98	-0,01	0,18	0,99	0,98
Avaré	0,24	0,31	0,97	0,96	0,00	0,20	0,99	0,96	0,22	0,28	0,98	0,96	0,02	0,17	0,99	0,96
Bauru	0,42	0,47	0,92	0,92	-0,08	0,22	0,98	0,94	0,21	0,25	0,98	0,98	0,01	0,11	0,99	0,98
Casa Branca	0,15	0,28	0,97	0,90	-0,08	0,27	0,97	0,90	0,01	0,20	0,98	0,94	-0,05	0,21	0,98	0,94
Franca	0,27	0,40	0,93	0,85	-0,10	0,33	0,95	0,85	0,21	0,29	0,96	0,94	-0,06	0,25	0,97	0,90
Ibitinga	0,23	0,34	0,97	0,94	-0,03	0,25	0,98	0,94	-0,01	0,13	1,00	0,98	0,06	0,59	0,88	0,69
Iguape	0,05	0,13	1,00	0,98	0,01	0,12	1,00	0,98	0,03	0,08	1,00	1,00	0,00	0,05	1,00	1,00
Itapeva	0,17	0,23	0,99	0,98	0,00	0,14	0,99	0,98	0,09	0,14	0,99	0,98	-0,02	0,12	1,00	0,98
Jales	0,36	0,61	0,86	0,71	-0,24	0,57	0,88	0,67	0,03	0,32	0,97	0,88	-0,05	0,34	0,96	0,86
José Bonif.	0,29	0,56	0,91	0,79	-0,08	0,51	0,93	0,77	-0,09	0,28	0,98	0,94	0,00	0,24	0,99	0,94
Lins	0,31	0,45	0,94	0,90	-0,07	0,32	0,97	0,90	0,12	0,22	0,99	0,96	0,12	0,18	0,99	0,96
Ourinhos	0,14	0,21	0,99	0,98	0,03	0,17	0,99	0,98	0,08	0,12	1,00	1,00	0,01	0,08	1,00	1,00
Piracicaba	0,40	0,45	0,94	0,94	-0,03	0,20	0,99	0,96	0,10	0,21	0,99	0,96	0,01	0,19	0,99	0,96
President. P	0,18	0,29	0,97	0,94	-0,08	0,23	0,98	0,94	0,09	0,17	0,99	0,98	-0,01	0,15	0,99	0,98
Rancharia	0,07	0,20	0,99	0,96	0,02	0,19	0,99	0,96	0,01	0,13	1,00	0,98	0,00	0,13	1,00	0,98
São Carlos	0,27	0,35	0,95	0,94	-0,05	0,22	0,98	0,94	0,13	0,19	0,99	0,98	0,00	0,12	0,99	0,98
S. Luis Pi.	0,11	0,16	0,99	0,98	0,00	0,12	1,00	0,98	-0,03	0,07	1,00	1,00	0,00	0,06	1,00	1,00
S. Miguel A.	0,03	0,13	1,00	0,98	-0,02	0,13	1,00	0,98	-0,06	0,12	1,00	0,98	-0,01	0,10	1,00	0,98
São Paulo	0,06	0,16	0,99	0,96	-0,02	0,15	0,99	0,96	-0,02	0,13	0,99	0,98	0,01	0,11	0,99	0,98
Taubaté	-0,01	0,19	0,99	0,96	-0,01	0,18	0,99	0,96	-0,09	0,13	0,99	0,98	0,00	0,10	1,00	0,98
Valparaíso	0,20	0,51	0,93	0,79	-0,08	0,46	0,94	0,81	0,16	0,36	0,97	0,90	0,00	0,32	0,97	0,90
Votuporanga	0,65	0,77	0,81	0,77	-0,18	0,46	0,91	0,77	0,28	0,39	0,94	0,90	-0,01	0,26	0,98	0,90

Tabela 6 - Desempenho estatísticos dos métodos empíricos, em diferentes cidades do estado de São Paulo

Estações	Hargreaves – Samani (HS)				Abtew (AB)			
	MBE	RMSE	“d”	R ²	MBE	RMSE	“d”	R ²
Ariranha	0,99	1,03	0,81	0,94	-0,37	0,58	0,92	0,86
Avaré	0,30	0,46	0,95	0,88	-0,06	0,23	0,98	0,94
Bauru	0,88	0,95	0,79	0,92	-0,09	0,25	0,97	0,92
Casa Branca	0,86	0,93	0,77	0,88	-0,23	0,38	0,93	0,90
Franca	-0,07	0,57	0,87	0,58	-0,25	0,43	0,89	0,81
Ibitinga	0,59	0,65	0,91	0,94	-0,04	0,30	0,97	0,92
Iguape	0,68	0,73	0,89	0,94	0,26	0,32	0,97	0,98
Itapeva	0,41	0,52	0,94	0,92	0,06	0,21	0,99	0,98
Jales	-0,79	1,08	0,69	0,42	-0,88	1,09	0,68	0,58
José Bonif.	0,36	0,48	0,94	0,90	-0,57	0,77	0,86	0,76
Lins	-1,27	1,41	0,61	0,88	-0,30	0,50	0,92	0,88
Ourinhos	0,96	1,02	0,80	0,92	0,05	0,29	0,97	0,96
Piracicaba	0,68	0,73	0,87	0,92	0,00	0,29	0,97	0,94
President. P	0,49	0,59	0,91	0,90	-0,61	0,66	0,87	0,90
Rancharia	1,25	1,28	0,72	0,94	0,03	0,32	0,97	0,96
São Carlos	1,22	1,31	0,68	0,86	0,02	0,28	0,96	0,92
S. Luis Pi.	0,77	0,80	0,85	0,94	0,42	0,47	0,93	0,98
S. Miguel A.	0,74	0,79	0,86	0,94	0,33	0,39	0,95	0,98
São Paulo	0,41	0,55	0,92	0,90	-0,17	0,27	0,97	0,98
Taubaté	1,01	1,06	0,78	0,92	-0,13	0,30	0,97	0,96
Valparaíso	0,41	0,60	0,91	0,83	-0,59	0,77	0,84	0,76
Votuporanga	0,31	0,56	0,90	0,76	-0,55	0,72	0,81	0,76


2.3.2 Desempenho anual dos métodos empíricos, RNAs e MVS

Em média, observou-se que o método empírico de HS e as RNAs superestimaram a ETo no estado de São Paulo. O método de HS apresentou um valor de MBE = 0,51 mm d⁻¹ e as RNAs apresentaram valores mais elevados na R1 (MBE = 0,20 mm d⁻¹) e na R5 (MBE = 0,22 mm d⁻¹), os quais mostraram uma menor superestimativa comparado com o método de HS. Já o método de AB (MBE = -0,17 mm d⁻¹) e a MVS (MBE = -0,05 mm d⁻¹ na M1 e M5) subestimaram a ETo. M1 e M5 representam os valores máximos observados, sendo assim, a MVS teve uma

subestimativa inferior. Com base no índice RMSE, observou-se que o método de AB teve uma precisão mais elevada ($RMSE = 0,45 \pm 0,229 \text{ mm d}^{-1}$) que o método de HS ($RMSE = 0,82 \pm 0,287 \text{ mm d}^{-1}$), R1 ($RMSE = 0,51 \pm 0,106 \text{ mm d}^{-1}$) e M1 ($RMSE = 0,46 \pm 0,072 \text{ mm d}^{-1}$), Figura 3.

Em relação ao índice “d” e R^2 , observou-se que tanto o método de AB (“d” = $0,92 \pm 0,074$) quanto a TAM (“d” = $0,90 \pm 0,047$ na R1 e “d” = $0,92 \pm 0,034$ na M1, sendo os valores mais baixos) apresentaram melhor concordância em relação ao método de HS (“d” = $0,84 \pm 0,095$), todavia, o método de HS ($R^2 = 0,87 \pm 0,128$) apresentou melhores ajustes matemáticos em relação a R1 ($R^2 = 0,76 \pm 0,079$) e M1 ($R^2 = 0,76 \pm 0,076$), expostos na Figura 3. Com a exceção da R1 e M1 que apresentaram baixos resultados do que o método de AB, nota-se claramente que as TAM produziram maiores desempenhos.

Figura 3 - Desempenho médio das RNAs, MVS e métodos empírico, escala anual




Em geral, observou-se que o aumento do número de variáveis de entrada nas TAM melhorou o seu desempenho. As arquiteturas R6 (MBE = 0,07 mm d⁻¹; RMSE = 0,20±0,090 mm d⁻¹; “d” = 0,99 ±0,015 e R² = 0,96±0,033) e M6 (MBE = 0,00 mm d⁻¹; RMSE = 0,18±0,120 mm d⁻¹; “d” = 0,98 ±0,026 e R² = 0,95±0,069) produziram resultados mais elevados. Este comportamento também foi relatado na literatura, sendo nas RNAs: RMSE = 0,21 a 3,19 mm d⁻¹; R² = 0,79 a 1,00 (YASSIN et al., 2016), RMSE = 0,31e 0,43 mm d⁻¹; R² = 0,90 e 0,95 (TRAJKOVIC, 2009), RMSE = 0,27 mm d⁻¹; “d” = 0,99 e R² = 0,99 (LAABOUDI et al., 2012) e na MVS: RMSE = 0,09 a 0,19 mm d⁻¹ e R² = 0,91 a 0,99 (ABDULLAH et al., 2015), RMSE = 0,02 a 0,07 mm d⁻¹ e R² = 0,95 a 1,00 (TABARI et al., 2012). Alguns desses desempenhos são inferiores aos constatados no presente estudo.

2.3.3 Erros dos métodos empíricos e da TAM em escala anual

O diagrama de caixa (*box plot*) mostra os valores dos erros produzidos pelos métodos empíricos e pelas TAM em relação ao método de PMF 56. A marca que se encontra no centro da caixa representa o erro médio e as extremidades representam os valores extremos dos erros. Nesse diagrama, observou-se que a R6 e a M6 apresentaram um erro médio mais próximo de zero e caixas mais estreitas. Isto confirma a tendência desses métodos não sub ou superestimarem a ETo (MBE≅ 0,00 mm d⁻¹) e a elevada precisão relatada através dos índices RMSE, sendo M6 mais preciso que R6. Os demais métodos apresentaram caixas mais largas, significando serem menos confiáveis do que a R6 e a M6 quanto menos estreita for a sua caixa e mais distante de zero estiver. Os piores resultados são observados no método de HS. Observa-se também que o método de Abtew tem melhor precisão que R1 e M1, confirmando os resultados já relatados (Figura 4).

Figura 4 - Box plot de erros dos doze métodos, escala anual



2.3.4 Comportamento da ETo no estado de São Paulo em escala anual

A seguir é apresentado os gráficos que ilustram o comportamento da ETo estimada pelos melhores (AB, R6 e M6) e piores métodos (HS, R1 e M1). As Figuras 5 (a – l) e 6 (m – v) representam os melhores métodos e as Figuras 7 (a – l) e 8 (m – v), os piores.

Nas figuras em questão, notou-se que tanto a R6 quanto a M6 apresentaram em geral as suas retas de regressão sobrepostas à reta $Y = X$ (1:1), significando que os valores de ETo estimados por esses métodos são muito próximos aos do método de PMF 56. Observou-se também que o par de dados da ETo (formado pelos métodos de PMF 56 vs R6 e M6) está muito próximo da reta de regressão de cada TAM, mostrando uma melhor precisão e elevados ajustes matemáticos, confirmando os resultados já relatados. Em relação ao método de AB, verificou-se uma tendência de subestimar a ETo, pois em geral as suas retas de regressão estiveram abaixo da reta $Y = X$ e apresentaram um alto grau de espalhamento dos pares de dados da ETo, conferindo que a R6 e a M6 apresentaram melhor desempenho. Embora seja difícil verificar a diferença entre a R6 e M6, este último apresentou desempenho mais elevado, contudo, provavelmente as diferenças entre elas não tenham relevância estatística.

Figura 5 - Dispersão da ETo estimada pelos melhores métodos





Figura 6 - Dispersão da ETo estimada pelos melhores métodos



Ao contrário das figuras anteriores, nas Figuras 7 (a – l) e 8 (m – v) observou-se que as retas de regressão da R1, M1, e HS distanciaram-se mais da reta de regressão $Y = X$ e apresentaram os pares de dados mais espalhados. Isto significa que esses métodos apresentaram valores de subestimativa (gráficos abaixo da reta $Y = X$) ou superestimativa (gráficos acima da reta $Y = X$) mais elevados do que os métodos anteriores e baixa precisão, consequentemente, pior desempenho estatístico. Observou-se ainda que o método de HS foi o pior de todos, seguido pela R1.

A tendência da TAM apresentar melhor desempenho em relação aos métodos empíricos foi reportado por diversos pesquisadores (KHOOB, 2008; KISI, 2013; KUMAR et al., 2008; LADLANI et al., 2012).

Figura 7 - Dispersão da ETo estimada pelos piores métodos





Figura 8 - Dispersão da ETo estimada pelos piores métodos




2.3.5 Desempenho sazonal dos métodos empíricos, RNas e MVS

O método de HS superestimou a ETo em todas as estações do ano, o de AB superestimou somente no outono e as TAM apresentaram um comportamento variado. Observou-se ainda que estes métodos apresentaram valores absolutos de MBE superiores do que as RNAs e a MVS em todas as estações do ano, significando que tanto as RNAs quanto a MVS subestimaram ou superestimaram menos os valores da ETo. Resultados de subestimativa e superestimativa mais baixos das TAM são observados no verão e no outono. Os piores resultados de MBE aconteceram no método de HS, seguido pelo método de AB (Figura 9). A tendência do método de AB subestimar e superestimar a ETo em alguns período do ano foi observada por Abtew et al. (2011).

Com base no RMSE, notou-se que o método de HS apresentou elevada precisão no outono ($0,60 \pm 0,367 \text{ mm d}^{-1}$), e no inverno ($0,57 \pm 0,251 \text{ mm d}^{-1}$) e o de AB no verão ($0,16 \pm 0,110 \text{ mm d}^{-1}$) e no outono ($0,15 \pm 0,110 \text{ mm d}^{-1}$). As RNAs e MVS mostraram precisão mais baixa na primavera e no inverno principalmente nas seguintes

arquiteturas: R1, M1, R2 e M2, cujos resultados foram de $0,41 \pm 0,116$; $0,38 \pm 0,115$; $0,26 \pm 0,111$; e $0,28 \pm 0,112 \text{ mm d}^{-1}$ e $0,25 \pm 0,112$; $0,27 \pm 0,117$; $0,18 \pm 0,09$ e; $0,11 \pm 0,09 \text{ mm d}^{-1}$, respectivamente (Figura 9). Todas essas precisões são superiores as melhores precisões observadas no método de HS, porém, em média inferiores as melhores precisões observadas no método de AB.


Figura 9 - Desempenho médio das RNAs, MVS e dos métodos empíricos no estado de São Paulo, escala sazonal



2.3.6 Erros dos métodos empíricos e da TAM em escala sazonal

Os resultados do *box plot* (Figura 10) ilustraram de forma clara que as arquiteturas: R3, M3, R4, M4, R5, M5, R6 e M6 são melhores para a estimativa da ETo em relação aos demais métodos avaliados em todas as estações do ano, pois apresentaram *box plots* mais estreitos e erros médios mais próximos de zero. Entretanto, são confiáveis na estimativa da ETo em relação ao método padrão. Observou-se ainda que essas arquiteturas produziram resultados mais confiáveis no verão e no outono. Analisando os métodos empíricos, verificou-se que o método de AB produziu resultados mais confiáveis no verão e o de HS no outono e inverno, confirmando os resultados anteriores.

Figura 10 - Box plot de erros dos doze métodos, escala sazonal



2.4 DISCUSSÃO

Comparando o desempenho dos métodos em avaliação na escala anual, observou-se o pior desempenho no método empírico de HS. Já o método empírico de AB ($RMSE = 0,45 \pm 0,229 \text{ mm d}^{-1}$) comportou-se melhor em relação ao método de HS ($RMSE = 0,82 \pm 0,287 \text{ mm d}^{-1}$), R1 ($RMSE = 0,51 \pm 0,106 \text{ mm d}^{-1}$) e M1 ($RMSE = 0,46 \pm 0,072 \text{ mm d}^{-1}$). A elevada precisão do método de AB em relação a R1 e M1, pode ser explicada por ter utilizado mais variáveis de entrada (T e Rs), pois quando

se combinou essas variáveis nas TAM, verificou-se uma precisão mais elevada (R5: RMSE = $0,35 \pm 0,171 \text{ mm d}^{-1}$ e M5: RMSE = $0,26 \pm 0,132 \text{ mm d}^{-1}$). Existem estudos que relataram o aumento do desempenho das TAM com o aumento do número de variáveis de entrada (ADELOYE et al., 2012; HUO et al., 2012; LANDERAS et al., 2008; TRAORE et al., 2010; TRAORE et al., 2016; WEN et al., 2015), corroborando com os resultados apresentados. Embora o método de AB tenha sido mais preciso em relação a R1 e M1, apresentou valor de MBE ($-0,17 \text{ mm d}^{-1}$) mais elevado, contudo, foi considerado bom por estar próximo de zero.

Comparando as TAM com o mesmo número de variáveis de entrada, observou-se que em média a MVS apresentou melhor desempenho. A tendência da MVS apresentar melhores resultados do que as RNAs para a mesma arquitetura foi observada por vários pesquisadores (KISI, 2013; WEN et al., 2015). Segundo Tabari et al. (2013), a MVS possui uma boa flexibilidade e habilidade de modelar fenômenos complexos em relação as RNAs, pois procura soluções mais otimizadas.

A R6 (MBE = $0,07 \text{ mm d}^{-1}$; RMSE = $0,20 \pm 0,090 \text{ mm d}^{-1}$; “d” = $0,99 \pm 0,015$ e $R^2 = 0,96 \pm 0,033$) e M6 (MBE = $0,00 \text{ mm d}^{-1}$; RMSE = $0,18 \pm 0,120 \text{ mm d}^{-1}$; “d” = $0,98 \pm 0,026$ e $R^2 = 0,95 \pm 0,069$) apresentaram o desempenho mais elevado da presente pesquisa. O elevado desempenho em relação as arquiteturas R1, M1, R2, M2, R5, M5 foi justificado pelo uso de mais variáveis de entrada, conforme anteriormente demonstrado. A R3, M3, R4 e M4 utilizaram o mesmo número de variáveis de entrada utilizado na R6 e M6, cuja diferença está na U_2 utilizada na R3 e M3 e na UR utilizada na R4 e M4 no lugar da R_s utilizada na R6 e M6. Com isso, notou-se que a inclusão da R_s na R6 e M6 explica o seu melhor desempenho, pois é um dos elementos meteorológicos que mais influencia na ETo. Comportamento similar foi observado em outros trabalhos (ARUN RAJ; JAIRAJ, 2014; LANDERAS et al., 2008; TABARI et al., 2012; VYAS; SUBBAIAH, 2016; WEN et al., 2015). O elevado desempenho da R6 e M6 foi confirmado pelo diagrama de caixa com bigodes, o qual mostrou estimativas mais confiáveis (elevada precisão e erros de estimativa próximos de zero).

À semelhança da escala anual, o método de HS apresentou o pior desempenho. O método de AB apresentou melhor desempenho do que a R1, M1, R2, M2 e HS no

verão. Este método é adequado para estimar a ETo em climas quentes e úmidos (LINGLING et al., 2013; SAMARAS et al., 2014; ZHAI et al., 2010), portanto, isto justifica os resultados obtidos no verão, o qual é quente e chuvoso. Contudo, a superioridade desse método não é observado quando é comparado com outras arquiteturas das TAM, evidenciando que o aumento das variáveis de entrada melhora a qualidade de estimativa das TAM e que a Rs é uma das variáveis mais importantes na taxa de ETo.

Em geral, as arquiteturas R3, M3, R4, M4, R5, M5, R6 e M6 produziram melhores resultados na estimativa da ETo em todas estações do ano, pois apresentaram valores de MBE e de RMSE mais próximos de zero e de “d” e R^2 mais próximos de um, significando baixa sub ou superestimativa, elevada precisão, elevada concordância e elevado ajuste matemático, respectivamente.

2.5 CONCLUSÃO

Escala anual:

O método empírico de HS apresentou menor desempenho que o método de Abtew (AB), redes neurais artificiais (RNAs) e máquina vetor de suporte (MVS).

O método de AB apresentou um desempenho melhor ($MBE = -0,17 \text{ mm d}^{-1}$ e $RMSE = 0,45 \text{ mm d}^{-1}$) em comparação as RNAs (R1) e MVS (M1) que tiveram a temperatura média do ar (T) como variável de entrada. Todavia, apresentou um desempenho inferior as arquiteturas: R5 ($MBE = 0,22 \text{ mm d}^{-1}$ e $RMSE = 0,35 \text{ mm d}^{-1}$) e M5 ($MBE = -0,05 \text{ mm d}^{-1}$ e $RMSE = 0,26 \text{ mm d}^{-1}$), as quais usaram as mesmas variáveis de entrada exigidas no método de AB (T e Rs).

A R6 ($MBE = 0,07 \text{ mm d}^{-1}$ e $RMSE = 0,20 \text{ mm d}^{-1}$) e M6 ($MBE = 0,00 \text{ mm d}^{-1}$ e $RMSE = 0,18 \text{ mm d}^{-1}$), as quais utilizaram a temperatura máxima -Tmax, mínima -Tmin, T, radiação extraterrestre - Ra e Rs como variáveis de entrada, superaram o desempenho de todos modelos/métodos.

Escala sazonal:

Observou-se que o método de HS apresentou piores desempenhos em todas as estações do ano. O método de AB apresentou melhores resultados no verão ($MBE = -0,15 \text{ mm d}^{-1}$ e $RMSE = 0,16 \text{ mm d}^{-1}$) e no outono ($MBE = 0,10 \text{ mm d}^{-1}$ e $RMSE = 0,15 \text{ mm d}^{-1}$), os quais superaram os resultados produzidos pela R1, M1, R2 e M2. A R2 e M2 utilizaram a T_{max} , T_{min} , T e R_a como variáveis de entrada.

As arquiteturas R3, M3, R4, M4, R5, M5, R6 e M6 produziram melhores resultados que os demais modelos avaliados, pois os seus valores de MBE e $RMSE$ foram praticamente iguais a $0,00 \text{ mm d}^{-1}$ e os de “ d ” e R^2 foram mais próximos de um. R3 e M3 utilizaram a T_{max} , T_{min} , T , R_a e U_2 , enquanto R4 e M4, utilizaram U_R no lugar de U_2 , permanecendo as demais variáveis. É de ressaltar que todos os métodos relatados como melhores, apresentaram elevados valores dos índices “ d ” e R^2 , tanto na escala anual quanto sazonal.

REFERÊNCIAS

- ABDULLAH, S. S.; MALEK, M. A.; ABDULLAH, N. S.; KISI, O.; YAP, K. S. Extreme learning machines: A new approach for prediction of reference evapotranspiration. **Journal of Hydrology**, v. 527, p. 184-195, 2015.
- ABTEW, W. Evapotranspiration measurements and modeling for three wetland systems in South Florida. **Journal of the American Water Resources Association**, v. 127, n. 3, p. 140-147, 1966.
- ABTEW, W.; OBEYSEKERA, J.; IRICANIN, N. Pan evaporation and potential evapotranspiration trends in South Florida. **Hydrol. Process.**, v. 25, p. 958 –969, 2011.
- ADELOYE, A. J.; RUSTUM, R.; KARIYAMA, I. D. Neural computing modeling of the reference crop evapotranspiration. **Environmental Modelling & Software**, v. 29, p. 61-73, 2012.
- AMARI, S, WU, S. Improving support vector machine classifiers by modifying Kernel funtions. **Neural Network**, v. 12, p. 783-789, 1999.
- AMINI, J. Optimum learning rate in backpropagation neural network for classification of satellite images (IRS -1D). **Scientia Iranica**, v. 15, p. 558-567, 2008.
- ALLEN, R. G.; PEREIRA, L.; RAES, D.; SMITH, M. **Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements**. Roma: FAO, (FAO: Irrigation and Drainage Paper, 56), 1998.
- ARUN RAJ, V. E.; JAIRAJ, P. G. Reference evapotranspiration modelling using support vector regression. **International Journal of Scientific & Engineering Research**, v. 5, issue 7, 2014.
- CAI, J.; LÍU, Y.; LEI, T.; PEREIRA, L. S. Estimating reference evapotranspiration with the FAO Penman – Monteith equation using daily weather forecast messages. **Agric. Forest. Meteorol.**, v. 145, p. 22-35, 2007.
- CAO, J. F.; LI, Y. Z.; ZHONG, X. I.; ZHAO, Y. M. Comparison of four combination methods for reference crop evapotranspiration. Chin. **J. Agrometeorol**, v. 36, n. 4, p. 428-436, 2015.
- CENTRO DE PESQUISAS METEOROLÓGICAS E CLIMÁTICAS APLICADAS A AGRICULTURA - CEPAGRI. **Clima dos Municípios Paulistas**. Disponível em: <<http://www.cpa.unicamp.br/outras-informacoes/clima-dos-municipios-paulistas.html>>. Acesso em: 10 de out. 2016.
- Da SILVA, I.N.; SPATt, D.H.;FLAUZINO, R.A. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. São Paulo: Artliber Editora. 2010. 399p.

DAVID, V.; SÁNCHEZ, A. Advanced support vector machines and Kernel methods. **Neurocomputing**, v. 55, p. 5-20, 2003.

ESLAMIAN, S. S.; GOHARI, S. A.; BIABANAKI, M.; MALEKIAN, R. Estimation of monthly pan evaporation using artificial neural network and support vector machines. **J Appl Sci**, v. 8, n. 19, p. 3497-3502, 2008.

GARCIA, M.; RAES, D.; ALLEN, R.; HERBAS, C. Dynamics of reference evapotranspiration in the Bolivian highlands (Altiplano). **Agric. Forest. Meteorol.**, v. 125, p. 67-82, 2004.

GEORGE, B. A.; REDDY, B. R. S.; RAGHUWANSHI, N. S.; WALLENDER, W. W. Decision support system for estimating reference evapotranspiration. **Journal of Irrigation and Drainage Engineering**, v. 128, n. 1, p. 1-10, 2002.

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P.; WITTEN, I. H. **The WEKA Data Mining Software: An Update**; SIGKDD Explorations, Volume 11, Issue 1, 2009.

HAMIDI, O. H.; POOROLAJAL, J.; SADEGHIFAR, M.; ABBASI, H.; MARYANAJI, Z.; FARIDI, H. R.; TAPAK, L. A comparative study of support vector machine and artificial neural networks for prediction precipitation in Iran. **Theor Appl Climatol**. Doi: 10.1007/s00704-014-1141-z, 2014.

HAYKIN, S. Neural network: **A Comprehensive Foundation**. 2nd ed. Hamilton: Prentice Hall, 1998, 897 p.

HE, Z.; WEN, X.; LIU, H.; DU, J. A comparative study of artificial neural network , adaptive neuro fuzzy inference systems and support vector machine for forecasting river flow in the semiarid mountain region. **J Hydrol**, v. 509, p. 379-386, 2014.

HUO, Z.; FENG, S.; KANG, S.; DAI, X. Artificial neural network models for reference evapotranspiration in arid area of northwest China. **Journal of Arid Environments**, v. 82, p. 81-90, 2012.

ITENFISU, D.; ELLIOTT, R. L.; ALLEN, R. G.; WALTER, I. A. Comparison of reference evapotranspiration calculations as part of the ASCE standardization effort. **Journal of Irrigation and Drainage Engineering**, v. 129, n. 60, p. 440-448, 2003.

JAIN, S. K.; NAYAK, P. C.; SUDHEER, K. P. Models for estimating evapotranspiration using neural networks and their physical interpretation. **Hydrol Process**, v. 22, p. 2225-2234, 2008.

KISI, O. Evapotranspiration estimating using feed forward neural networks. **Nordic Hydrology**, v. 37, n. 3, p. 247-260, 2006.

KISI, O. Evapotranspiration modeling for climatic data using a neural computing neural technique. **Hydrol Process**, v. 21, p. 1925-1934, 2007.

KISI, O.; CIMEN, M. Evapotranspiration modeling using support vector machines. **Hydrol. Sci. J.**, v. 54, n. 5, p. 918-928, 2009.

KISI, O. Least squares support vector machine for modeling daily reference evapotranspiration. **Irrig Sci**, v. 31, p. 611-619, 2013.

KOTTEK, M.; GRIESER, J.; BECK, C.; RUDOLF, B.; RUBEL, F. World map of the Koppen – Geiger climate classification updated. **Meteorologische Zeitschrift**, Berlin, v.15, n. 3, p. 259-263, June 2006.

KHOOB, A. R. Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. **Irrig Sci**, v. 26, n. 3, p. 253-259, 2008.

KUMAR, M.; RAGHUWANSHI, N. S.; SINGH, R.; WALLENDER, W. W.; PRUITT, W. O. Estimating evapotranspiration using artificial neural network. **Journal of Irrigation and Drainage Engineering**, v. 128, n. 4, p. 224-233, 2002.

KUMAR, M.; BANDYOPADHYAY, A.; RAHGUWANSHI, N. S.; SINGH, R. Comparative study of conventional and artificial neural network-based ETo estimation models. **Irrig Sci**, v. 26, n. 6, p. 531-545, 2008.

KUMAR, M.; KAR, I. N. Non-linear HVAC computations using least square support vector machines. **Energy Convers Manage**, v. 50, p. 1411-1418, 2009.

KUMAR, M.; RAHGUWANSHI, N. S.; SINGH, R. Artificial neural networks approach in evapotranspiration modeling: a review. **Irrig Sci**, v. 29, p. 11-25, 2011.

LAABOUDI, A.; MOUHOUCHE, B.; DRAONI, B. Neural network approach to reference evapotranspiration modeling from limited climatic data in arid regions. **Int. J. Biometeorol.**, v. 56, p. 831-841, 2012.

LADLANI, I. HOUICHI, L.; DJEMILI, L.; HEDDAM, S.; BELOUZ, K. Modeling daily reference evapotranspiration (ETo) in the north of Algeria using generalized regression neural networks (GRNN) and radial basic function neural network (RBFNN): a comparative study. **Meteorol Atmos Phys**, v. 118, p. 163-178, 2012.

LANDERAS, G.; ORTIZ BARREDO, A.; LÓPEZ, J. J.; Comparison of artificial neural network models and empirical and semi – empirical equations for daily reference evapotranspiration estimation in the Basque Country (Northern Spain). **Agricultural water management**, v. 95, p. 553-565, 2008.

LIN, H-J.; YEH, J. P. Optimal reduction of solutions for support vector machines. **Applied Mathematics and Computation**, v. 214, p. 329-335, 2009.

LINGLING, Z.; JUN, X.; CHONG YU, X.; ZHONGGEN, W.; LESZEK, S.; GANGRUI, L. Evapotranspiration estimation methods in hydrological models. **J. Geogr. Sci.**, v. 23, n. 2, p. 359-369, 2013.

MEYER, D.; LEISCH, F.; HORNIK, K. The support vector machine under test. **Neurocomputing**, v. 55, p. 169-186, 2003.

MOHAWESH, O. E. Evaluation of evapotranspiration models for estimating Daily reference evapotranspiration in arid and semiarid environment. **Plant Soil Environ.**, v. 57, n. 4, p. 147-152, 2011.

NOURANI, V.; FARD, M. S. Sensitivity analysis of the artificial neural network outputs in simulation of the evaporation process at different climatologic regimes. **Adv. Eng. Software**, v. 47, n. 1, p. 127-146, 2012.

PARASURAMAN, K.; ELSHORBAGY, A.; CAREY, S. K. Modeling the dynamics of the evapotranspiration using genetic programming. **Hydrol. Sci. J.**, v. 52, p. 563 -578, 2004.

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.

ROLIM, D. DE S.; DE CAMARGO, M. B. P.; LANIA, D. G.; DE MOARES, J. F. L. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo, **Bragantia**, Campinas, v. 66, n. 4, p. 711-720, 2007.

SAMARAS, D. A.; REIF, A.; THEODOROPOULOS, K. Evaluation of radiation based reference evapotranspiration models under different Mediterranean climates in Central Greece. **Water Resour Manage**, v. 28, p. 207-225, 2014.

SAMUI, P.; DIXON, B. Application of support vector machine and relevance vector machine do determine evaporative losses in reservoirs. **Hydrol Process**, v. 26, p. 1361-1369, 2012.

SOUZA, A. P.; MOTA, L. L.; ZAMADEI, T.; MARTIM, C. C.; ALMEIDA, F. T.; PAULINO, J. Classificação climática e balanço hídrico climatológico no estado de Mato Grosso. **Nativa**, Sinop, v. 1, n. 1, p. 34-43, out/dez., 2013.

TABARI, H.; 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 hidrology**, 444-445, p. 78-89, 2012.

TABARI, H.; MARTINEZ, C.; EZANI, A.; TALAEE, P. H. Applicability of support vector machines and adptative neurofuzzy inference system for modeling potato crop evapotranspiration. **Irrig Sci**, v. 31, p. 575-588, 2013.

TRAJKOVIC, S. Comparison of radial basic fuction networks and empirical equations for converting from pan evaporation to reference evapotranspiration. **Hydrol. Process**, v. 23, p. 874-880, 2009.

TRAORE, S.; WANG, Y-M.; KERH, T. Artificial neural network for modeling reference evapotranspiration complex process in Sudano – Sahelian zone. **Agricultural Water Management**, v. 97, p. 707-7014, 2010.

TRAORE, S.; LUO, Y.; FIPPS, G. Deployment of artificial neural network for short-term forecasting of evapotranspiration using public weather forecast restricted messages. **Agricultural Water Management**, v. 163, p. 363-379, 2016.

TEZEL, G.; BUYUKYILDIZ, M. Monthly evaporation forecasting using artificial neural networks and support vector machines. **Theor. Appl. Climatol**, v.124, p. 69- 80, 2016.

VALIPOUR, M. Comparative evaluation of radiation based methods for estimation of potential evapotranspiration. **J. Hydrol. Eng.**, v. 20, n. 5, 2015.

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

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. 2. Ed. Viçosa, MG: Ed. UFV, 2012, 460p.

VYAS, K. N.; SUBBAIAH, R. Application of artificial neural network approach for estimating reference evapotranspiration. **Current World Environment**, v. 11, n. 2, p. 637-647, 2016.

WANG, Y- M.; KERH, T.; TRAORE, S. Neural network approaches for modeling river suspended sediment concentration due to Tropical Storms. **Global Nest Journal**, v. 11, n. 4, p. 457-466, 2009.

WANG, Y-M.; TRAORE, S.; KERH, T.; LEU, J-M. Modelling reference evapotranspiration using feed forward backpropagation algorithm in arid regions of Africa. **Irrig. and Drain.**, v. 60, p. 404-417, 2011.

WEN, X.; SI, J.; HE, Z.; WU, J.; SHAO, H.; YU, H. Support vector machine based models for modelling daily reference evapotranspiration with limited climatic data in extreme arid Regions. **Water Resour Manage**, v. 29, p. 3195-3209, 2015.

WILLMOTT, C. J.; CKLESON, S.G.; DAVIS, R. E. Statistics for the Evaluation and Comparison of Models. **Journal of Geophysical Research**. Ottawa, v.90, n.C5, p. 8995-9005, 1985.

XU, C. Y.; CHEN, D. Comparison of seven models for estimation of evapotranspiration and groundwater recharge using lysimeter measurement data in German. **Hydrol. Processes**, v. 19, p. 3717-3734, 2005.

YASSIN, M. A.; ALAZBA, A. A.; MATTAR, M. A. Artificial neural network versus gene expression programming for estimating reference evapotranspiration in arid climate. **Agricultural Water Management**, v. 163, p. 110-124, 2016.

YODER, R. E.; ODHIAMBO, L. O.; WRIGHT, W. C. Evaluation of methods for estimating daily reference crop evapotranspiration at a site of the humid southeast United States. **Appl. Eng. Agric.**, v. 20, n. 2, p. 197-202, 2005.

ZHAI, L.; FENG, Q.; LI, Q.; XU, C. Comparison and modification of equations for calculating evapotranspiration (ET) with data from GANSU Province, Northwest China. **Irrig. and Drain.**, v. 59, p. 477-490, 2010.

ZANETTI, S. S.; SOUSA, E. F.; OLIVEIRA, V. P. S.; ALMEIDA, F. T.; BERNARDO, S. Estimating evapotranspiration using artificial neural network and minimum climatological data. **Journal of Irrigation and Drainage Engineering**, v.33, n.2, p.83-89, 2007.

CAPÍTULO 3

EVAPOTRANSPIRAÇÃO DE REFERÊNCIA NO ESTADO DE SÃO PAULO: MÉTODO GEOESPACIAL

RESUMO

A interpolação da evapotranspiração de referência (ET_o) permite o seu conhecimento em locais onde não se dispõe de nenhuma informação, facilitando a realização de inúmeras atividades agrícolas. Com este trabalho, pretende-se apresentar a variabilidade espacial da ET_o no estado de São Paulo a partir de dados meteorológicos de 31 estações, utilizando a krigagem ordinária pontual (KOP) como interpolador geoestatístico. A ET_o foi estimada a partir do método de Penman Monteith FAO 56, em escala anual e sazonal (primavera, verão, outono e inverno). Os variogramas obtidos foram analisados com base na soma dos quadrados dos resíduos, tendo-se verificado que o modelo esférico foi melhor em todas as escalas, com a exceção da primavera onde o modelo gaussiano apresentou melhor desempenho. Todos os modelos apresentaram uma dependência espacial forte. A posterior, fez-se a validação cruzada da KOP com base nos coeficientes angular (β_1) e linear (β_0) da reta de regressão linear simples, R^2 (Coeficiente de determinação), MBE (*Mean Bias Error*), RMSE (*Root Mean Square Error*) e MSDR (*Mean squared deviation ratio*), cujos resultados mostraram um ótimo desempenho da KOP. Finalmente, fez-se a confecção dos respectivos mapas.

Palavras – chave: Interpolação de dados. Krigagem Ordinária. Método de Penman – Monteith.

ABSTRACT

The interpolation of the reference evapotranspiration (ET_o) allows its knowledge in places where there is no information available, facilitating the accomplishment of many agricultural activities. This study carried out is intending to present the spatial variability of the ET_o in the state of São Paulo by collecting and using data from 31 meteorological gauge stations using ordinary point kriging (OPK) method as geostatistic interpolator. The ET_o was estimated from the Penman-Monteith method FAO 56, on an annual and seasonal scale (spring, summer, autumn and winter). The obtained variograms were analyzed based on residuals sum of squares and verified that the spherical model was better in all the scales with the exception of the spring where the Gaussian distribution model has shown better performance. All models showed strong spatial dependence. Afterwards, it was carried out cross-validated for OPK based on the angular (β_1) and linear (β_0) coefficients of the simple linear regression line, R^2 (Determination Coefficient), RMSE (Root Mean Square Error) and MSDR (Mean squared deviation ratio) whose results showed a good performance of OPK. Finally, the respective maps were outlined.

Keywords: Data interpolation. Ordinary Kriging. Penman - Monteith method.

3.1 INTRODUÇÃO

Uma estimativa precisa da evapotranspiração de referência (ET_o) é fundamental para estudos agrícolas, hidrológicos, gestão de recursos hídricos, e bacias hidrográficas, principalmente para estimar a demanda das culturas, planejamento da irrigação, gestão da seca e estudos sobre mudanças climáticas (RAZIELI; PEREIRA, 2013). Segundo Allen et al. (1998), a ET_o representa a perda de água por evaporação e transpiração de uma extensa superfície vegetada em condições padrão: sem estresse hídrico; cobertura total da superfície terrestre; albedo de 0,23; crescimento ativo e uniforme (0,12 m de altura).

Existem várias equações de estimativa da ET_o, dentre elas, a equação de Penman Monteith, recomendada em 1998 no boletim da FAO 56 tem apresentado ótimo desempenho em diferentes condições climáticas (ALLEN et al., 1998; JIA et al., 2009; KANG et al., 2003; MOHAWESH, 2011). Contudo, não são todos os locais que dispõem de elementos climáticos suficientes para utilizar essa equação. Segundo Kamali et al. (2015), a ET_o em locais com falta de informação pode ser estimada a partir dos valores de outros locais, utilizando o método de interpolação. Por outro lado, Zhou et al. (2007) relataram que os métodos de interpolação espacial vêm sendo utilizados em diversas áreas, principalmente em ciências ambientais. É de ressaltar que a precisão de estimativa dos valores depende do desempenho do tipo de interpolador escolhido.

Os métodos de interpolação podem ser divididos em dois grupos, sendo determinísticos e geoestatísticos. Os métodos determinísticos estimam os valores de um determinado ponto a partir de valores registrados nos pontos vizinhos (KURTZMAN; KADMON; 1999), por exemplo, o método de inverso da distância ponderada (IDW) e método Spline. Estes métodos baseiam-se no princípio básico de que os pontos próximos devem estar fortemente relacionados em relação aos pontos mais distantes do local interpolado. Os métodos geoestatísticos como a krigagem têm uma base estatística bastante poderosa, sendo utilizados em diversas áreas. A krigagem pressupõe que a distância e a direção entre pontos amostrados reflete uma correlação espacial que pode ser utilizada para explicar as variações na superfície (CHILDS, 2004). Segundo Matheron (1963), a krigagem quantifica a

correlação espacial entre os dados e depois faz uma previsão dos valores em locais sem dados medidos. Para obter as previsões desses locais, a krigagem usa modelos de variograma, correlação espacial entre os dados e os dados medidos em pontos vizinhos (KAMALI et al., 2015). O termo krigagem é em homenagem ao engenheiro Sul Africano chamado Krige.

Segundo Li e Heap (2011), os métodos IDW, krigagem ordinária (OK) e a Cokrigagem são frequentemente mais utilizados, porém, os métodos de krigagem produzem melhores resultados do que os métodos não geoestatísticos. Para Dalezios et al. (2002), uma ótima interpolação usando técnicas da geoestatística, como a krigagem, pode ser utilizada para o mapeamento de variáveis regionalizadas. Dentre os vários tipos de krigagem, a krigagem ordinária é mais comum (CHILDS, 2004).

Cob-Martínez (1996), avaliando três interpoladores geoestatísticos (OK, cokrigagem e krigagem residual) na predição da ETo e da precipitação, observaram bons resultados dos três, embora a krigagem residual tenha produzido um resultado relativamente inferior. Na China, Liu e Yang (2010) selecionaram a OK como melhor interpolador. Outro trabalho realizado na China por Yang et al. (2011), mostrou que a OK é ótimo interpolador da ETo tanto na escala anual quanto sazonal em relação aos métodos IDW e Spline. A OK pode ser o método mais preciso para fazer a interpolação e produz superfícies visualmente atraentes a partir de dados irregularmente espaçados (RAZIEI;PEREIRA, 2013). Contudo, a literatura relata alguns trabalhos em que a krigagem ordinária apresentou erros mais elevados em relação aos outros interpoladores (ASHRAF et al, 1997; DALEZIOS et al., 2002; RAY;DADHWAL, 2001). Entretanto, qualquer interpolador precisa ser avaliado antes da confecção dos mapas.


Diante do exposto, o presente trabalho teve como objetivo avaliar o desempenho da OK, opção pontual na representação da variabilidade espacial da ETo no estado de São Paulo em escala anual e sazonal. Foram utilizados elementos meteorológicos de 31 estações (temperatura média do ar, umidade relativa do ar, velocidade do vento, insolação e radiação solar global), das quais, nove são estações vizinhas.

3.2 MATERIAL E MÉTODOS

3.2.1 Área de estudo

O mapa dos locais onde foram coletados os dados meteorológicos para realizar o presente estudo encontra-se na Figura 1. No total são 31 estações meteorológicas, das quais 22 são estações automáticas localizadas dentro do estado de São Paulo e as remanescentes, são estações vizinhas a fim de se obter uma boa interpolação dos dados. É de ressaltar que todos os dados meteorológicos foram disponibilizados pelo Instituto Nacional de Meteorologia do Brasil (INMET).

Figura 1 - Estações meteorológicas utilizadas na interpolação da ETo



Na Tabela 1 está apresentado as coordenadas geográficas utilizadas para confeccionar o mapa da Figura 1, período de coleta dos dados em cada estação (composto por pelo menos 80% dos dados) e o código de cada estação. A letra A que antecede o código significa que a estação é automática, sendo o oposto, estação convencional.

O estado de São Paulo apresenta uma grande diversidade climática, devido ao seu relevo acidentado, posição geográfica e diferentes influências de massas de ar (ROLIM et al., 2007). Cepagri (2016), utilizando a classificação climática de Köppen, identificou a existência de sete tipos de clima no estado de São Paulo: Cwa, Cwb,

Aw, Am, Cfa, Cfb e Af. Dentre vários tipos climáticos existentes no estado de São Paulo, Rolim et al. (2007) relataram que os climas de maior ocorrência são Aw e Cfa.

De acordo com Vianello e Alves (2012), as letras Aw caracterizam o clima tropical de savana. Nesse tipo de clima, a temperatura média do mês mais frio é superior a 18°C, com inverno seco no qual pelo menos um dos meses apresenta uma precipitação média inferior a 60 mm (KOTTEK et al., 2006; SOUZA et al., 2013). O clima Cfa apresenta verão quente, sem estação seca do inverno e com temperatura média do mês mais frio entre 18 e - 3°C, conforme Cepagri (2016).

Tabela 1 - Estações meteorológicas do estado de São Paulo e de áreas vizinhas

Códigos	Estações (Cidades)	Latitude (graus)	Longitude (graus)	Altitude (m)	Período (anos)
Estado de São Paulo					
A-736	Ariranha	-21,01	-48,83	525	2008 - 2015
A-725	Avaré	-23,00	-48,88	654	2007 - 2015
A-705	Bauru	-22,30	-49,70	550	2005 - 2015
A-738	Casa Branca	-21,77	-47,01	730	2008 - 2015
A-708	Franca	-20,57	-47,37	1026	2005 - 2015
A-737	Ibitinga	-21,85	-48,80	492	2008 - 2015
A-712	Iguape	-24,70	-47,55	3	2007 - 2015
A-714	Itapeva	-23,97	-48,85	707	2007 - 2015
A-733	Jales	-20,02	-50,58	457	2008 - 2015
A-735	José Bonifácio	-21,00	-49,68	405	2008 - 2015
A-727	Lins	-21,65	-49,73	459	2007 - 2015
A-716	Ourinhos	-22,95	-49,85	448	2007 - 2015
A-726	Piracicaba	-22,70	-47,62	574	2007 - 2015
A-707	Presidente Prudente	-22,01	-51,40	436	2005 - 2015
A-718	Rancharia	-22,37	-50,97	350	2007 - 2015
A-711	São Carlos	-21,95	-47,87	863	2007 - 2015
A-740	Luis do Paraitinga	-23,22	-45,52	874	2008 - 2015
A-715	São Miguel de Arcanjo	-23,85	-48,00	678	2007 - 2015
A-701	São Paulo	-23,50	-46,62	792	2007 - 2015
A-728	Taubaté	-23,00	-45,52	571	2007 - 2015
A-734	Valparaíso	-21,32	-50,92	374	2007 - 2015

A-729	Votuporanga	-20,40	-49,95	486	2007 - 2015
Estações vizinhas					
A-849	Diamante do Norte	-22,63	-52,89	362	2005-2015
83738	Resende	-22,45	-44,44	434	2005-2015
83565	Paranaíba	-19,75	-51,18	331	2005-2015
83767	Maringá	-23,4	-51,91	542	2005-2015
83683	Machado	-21,68	-45,94	873	2005-2015
83766	Londrina	-23,31	-51,13	566	2005-2015
83813	Castro	-24,78	-50,00	1009	2005-2015
83577	Uberaba	-20,00	-47,95	737	2005-2015
83579	Araxá	-19,6	-46,94	1024	2005-2015

Além dos dados mencionados, fez-se a coleta dos dados de temperatura do ar, umidade relativa do ar, velocidade de vento, radiação solar global e de insolação. Os dados de insolação foram utilizados apenas em estações meteorológicas convencionais a fim de se estimar a radiação solar global, a partir da equação de Angstrom (Equação 1).

$$R_s = \left(a + b * \frac{n}{N} \right) * R_a \quad (1)$$

Em que: R_s = Radiação solar global, $\frac{n}{N}$ = Razão insolação, R_a = Radiação no topo da atmosfera, a e b = Fração de R_a que chega na superfície terrestre em dias claros. Os valores de a e b podem ser assumidos iguais a 0,25 e 0,5, respectivamente (ALLEN et al., 1998).

Todos os dados foram fornecidos na escala horária e a posterior foram transformados para a escala diária. A partir dos dados na escala diária, estimou a ETo pela equação padrão de Penman Monteith FAO 56 para as escalas anual e sazonal (primavera, verão, outono e inverno), Equação 2 (ALLEN et al., 1998).

3.2.2 Método padrão de estimativa da ETo

$$ET_o = \frac{0,408 * \Delta * (R_n - G) + \gamma * \frac{900}{T + 273} * U_2 * (e_s - e_a)}{\Delta + \gamma * (1 + 0,34 * U_2)} \quad (2)$$

Em que: ETo = Evapotranspiração de referência, mm d⁻¹; Rn = Saldo da radiação, MJ m⁻² d⁻¹; G = Densidade de fluxo de calor para o solo, MJ m⁻² d⁻¹; γ = Constante psicométrico, kPa °C⁻¹; T = Temperatura média do ar, °C; U₂ = Velocidade do vento a 2 metros de altura, m s⁻¹; e_s = Pressão de saturação a temperatura de bulbo seco, kPa; e_a = Pressão real ou actual de vapor d'água, kPa; Δ = Declividade da curva da pressão de saturação de vapor, kPa °C⁻¹; 0,408 = Fator de conversão de MJ m⁻² d⁻¹ para mm d⁻¹.

3.2.3 Análise espacial dos dados

Após a estimativa da ETo, fez-se a análise descritiva dos dados e o teste de normalidade de Kolmogorov – Smirnov à 95% de intervalo de confiança. Em seguida, procedeu-se com a seleção dos modelos teóricos de variogramas que melhor representam quantitativamente a variação da ETo no estado de São Paulo, utilizando o Programa Geoestatístico GS+ “*Geostatistical for the Environmental Sciences*”, Versão 7.0.17 Gama. Os melhores modelos foram escolhidos com base na soma dos quadrados dos resíduos (SQR). Segundo Da Silva et al. (2011), o variograma analisa o grau de dependência espacial das amostras e define os parâmetros necessários para a estimativa de valores para locais não amostrados, utilizando a interpolação por krigagem. O variograma deve ser estimado de forma confiável e modelado com funções matemáticas válidas (OLIVER;WEBSTER, 2014). O variograma é representado na Equação 3.

$$\gamma(h) = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [z(x_i) - z(x_i + h)]^2 \quad (3)$$

Em que: $\gamma(h)$ = Variância estimada na distância h; N(h) = Número de pares de pontos separados por distância h; z(x_i) = Valor da variável no ponto x_i; z(x_i+h) =

Valor da variável no ponto x_i+h . $\gamma(h)$ versus h representa o variograma experimental, o qual expressa a variabilidade espacial dos dados amostrados.

À medida que aumenta o valor de h da Equação 3, a variância $[\gamma(h)]$ também aumenta até atingir um valor máximo, denominado patamar (C_0+C) e a distância correspondente denomina-se alcance. Por outro lado, quando o valor de h tende a zero, atinge-se o efeito pepita (C_0).

A classificação da variabilidade espacial da ETo foi realizada com base no índice de dependência espacial $\left(IDE = \frac{C}{C_0+C} \right)$ proposto por Zimback (2001). Segundo o mesmo autor, quando $IDE \leq 25\%$: tem-se fraca dependência espacial; quando $IDE = 25$ a 75% : moderada dependência espacial e quando $IDE \geq 75\%$: dependência espacial forte.

3.2.3.1 Validação cruzada e interpolação

Verificada a existência da dependência espacial, fez-se a adequação dos variogramas escolhidos através da técnica de validação cruzada. Esta técnica é simples, consiste na remoção de cada ponto individualmente do conjunto de dados amostrados e a posterior é estimado com base nos interpoladores, conforme Myers (1997); Oliver e Webster (2014). Os resultados obtidos foram analisados com base nos parâmetros da equação de regressão linear simples (Equação 4).

$$z^*(x_0) = \beta_0 + \beta_1 * z(x_i) + \varepsilon_1 \quad (4)$$

Em que: $z^*(x_0)$ = Valor de ETo estimado pela krigagem; $z(x_i)$ = Valor de ETo real; β_1 = Coeficiente angular da reta; β_0 = Coeficiente linear; ε_i = Erro de estimativa.

As melhores estimativas dos valores da ETo, $z^*(x_0)$ são encontradas quando $z^*(x_0) = \beta_1 * z(x_i)$, ou seja, quando os pares de dados obtidos na validação cruzada estão sobre a reta $Y = X$. Portanto, isso é observado quando os parâmetros β_0, β_1 e ε_i são iguais a zero, um e zero, respectivamente. Por conseguinte, o R^2 fica igual a um, o qual é obtido a partir da Equação 5.

$$R^2 = 1 - \left\{ \frac{\sum_{i=1}^N [z(x_i) - Z^*(x_i)]^2}{\sum_{i=1}^N [z(x_i) - \bar{z}(x_i)]^2} \right\} \quad (5)$$

Além dos parâmetros da regressão linear simples, foram analisados os seguintes índices estatísticos: MBE (*Mean error*), RMSE (*Root Mean Square Error*) e MSDR (*Mean squared deviation ratio*). Valores de MBE indicam uma subestimativa ($MBE < 0$) ou superestimativa ($MBE > 0$), de RMSE indicam a precisão do modelo e os de MSDR indicam o grau de ajuste do modelo. Ressalta-se que quando $MBE \cong 0$; $RMSE \cong 0$ e $MSDR \cong 1$, o desempenho do modelo escolhido é ótimo.

As Equações 6, 7 e 8 foram utilizadas para calcular os índices MBE, , MSDR, respectivamente.

$$MBE = \frac{1}{N} \sum_{i=1}^N [Z^*(x_i) - z(x_i)] \quad (6)$$

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N [Z^*(x_i) - z(x_i)]^2} \quad (7)$$

$$MSDR = \frac{1}{N} \sum_{i=1}^N \left\{ \frac{[Z^*(x_i) - z(x_i)]^2}{\sigma_k^{*2}(x_i)} \right\} \quad (8)$$

Em que: $z(x_i)$ = Valor real na ponto x_i ; $Z^*(x_i)$ = Valor estimado pela krigagem na posição x_i , N = Número de observações e $\sigma_k^{*2}(x_i)$ = Variância da krigagem.

A KO utilizada foi a pontual. A KO é uma técnica de interpolação utilizada em geoestatística para fornecer as estimativas dos valores não amostrados (GUTIÉRREZ DE RAVÉ et al., 2014; NOSHADI; SEPASKHAH, 2005; OLIVER; WEBSTER, 1990), conforme a Equação 9.

$$Z^*(x_0) = \sum_{i=1}^N \lambda_i * z(x_i) \quad (9)$$

Em que: $z^*(x_0)$ = Valor estimado no local x_0 ; N = Números de observações; $z^*(x_i)$ = Valor real no local x_i e λ_i = Pesos associados ao valor real na posição x_i . Melhores resultados de $z^*(x_0)$ são obtidos quando o estimador é não tendencioso e a variância da estimativa é mínima.

Finalmente, confeccionou-se os mapas de distribuição espacial da ETo no estado de São Paulo no programa QGIS versão 2.8.3 –Wien.

3.3 RESULTADOS

3.3.1 Estatística descritiva dos valores da ETo

A Tabela 2 mostra os valores máximos, mínimos, médios, desvio padrão (SD) e coeficiente de variação (CV) da ETo no estado de São Paulo, em diferentes períodos. De acordo com a mesma tabela, os valores da ETo estimados pelo método padrão da FAO 56 são menos homogêneos no inverno (CV = 22,15%) e mais homogêneos na primavera (CV = 11,25%) e verão (CV = 11,19%).

Tabela 2 - Estatística descritiva da ETo no estado de São Paulo

Período	ETo (mm d ⁻¹)				CV (%)
	Máximo	Mínimo	Médio	SD	
Primavera	5,20	3,12	4,16	0,47	11,25
Verão	5,54	3,42	4,48	0,50	11,19
Outono	4,04	2,02	3,03	0,43	14,21
Inverno	4,68	1,94	3,31	0,73	22,15
Anual	5,00	2,64	3,82	0,51	13,43

Em termos médios, observou-se que a primavera e o verão apresentaram elevados valores da ETo. Este resultado era de se esperar, pois nessas estações do ano, o estado de São Paulo é caracterizado por chuvas e temperaturas elevadas, por conseguinte, elevada demanda atmosférica (Tabela 2). É de ressaltar que além da estatística descritiva apresentada, fez-se o teste de normalidade de Kolmogorov – Smirnov, o qual foi significativo a 5% de nível de significância em todos os períodos. O teste de normalidade é recomendado em diversos trabalhos como um prê-

requisito para o uso da krigagem ordinária (KAMALI et al., 2015; WEBSTER;OLVER, 2001; XIAO et al., 2016).

3.3.2 Análise variográfica da ETo no estado de São Paulo na escala anual e sazonal


Tabela 3 - Parâmetros variográficos da ETo


Período	Modelo	Efeito pepita	Patamar	Alcance	R ²	SQR	Estrutura	Dependência
		Co	C+Co				C/(C+Co)	espacial
Anual	Esférico	0,0010	0,370	5,380	0,914	0,0090	0,997	Forte
Primavera	Gaussiano	0,0420	0,368	6,045	0,987	0,0010	0,886	Forte
Verão	Esférico	0,0001	0,296	4,040	0,801	0,0114	1,0	Forte
Outono	Esférico	0,0001	0,262	5,320	0,910	0,0046	1,0	Forte
Inverno	Esférico	0,0010	0,749	5,480	0,854	0,0670	0,999	Forte

Com base na Tabela 3, observou-se que o modelo esférico foi escolhido para o ajuste dos variogramas em todos os períodos, com a exceção da primavera que foi escolhido o modelo gaussiano. A escolha do melhor modelo teórico, baseou-se nos valores da SQR, conforme já mencionado. Quanto mais próximo de zero for o valor da SQR, melhor é o modelo de ajuste dos variogramas. Em estudos similares, Mardikis et al. (2005) e Kamali et al. (2015) também utilizaram a SQR para a escolha dos modelos teóricos na Grécia e no Irã, respectivamente.

Na Tabela 3, observou-se ainda uma dependência espacial forte tanto no período anual quanto sazonal, com base na classificação de Zimback (2001). Para o melhor entendimento dos parâmetros da Tabela 3, a seguir está apresentado na Figura 2 (a, b, c, d, e) os variogramas isotrópicos para a ETo.

Figura 2 (a, b, c, d, e) - Variogramas isotrópicos da ETo





Os variogramas isotrópicos mostraram que a maior distância (alcance) na qual verificou-se a dependência espacial entre os valores da ETo aconteceu na primavera (6,045 graus decimais) e a menor, no verão (4,040 graus decimais). Acima dos valores de alcance apresentados na Tabela 3, os valores da ETo apresentam distribuições espaciais aleatórias, ou seja, são independentes e por conseguinte, devem ser analisados a partir da estatística clássica. Segundo Trangmar et al. (1985), amostras separadas por distâncias menores do que o alcance são espacialmente relacionadas e vice-versa.

O patamar expressa a variabilidade dos valores da variável em análise. Entretanto, a Figura 2 (a, b, c, d, e) mostra claramente que no inverno existe uma maior variabilidade da ETo do que nos outros períodos, pois observou-se maior valor conforme apresentado na Tabela 3 ($Co+C = 0,749$) e também observou-se maior desvio padrão na Tabela 2 ($SD = 0,73$).

3.3.3 Krigagem da ETo

Nos mapas abaixo, a cor vermelho alaranjado representa os locais com maior demanda atmosférica (ETo) e a azul representa os locais com menor demanda. Os níveis de demanda atmosférica variam conforme a tonalidade das cores. Em média, observou-se os seguintes valores de ETo: 4,24; 4,74; 2,98; 3,36 e 3,81 mm d⁻¹ na primavera, verão, outono, inverno e ao longo do ano, respectivamente. Portanto, verificou-se elevada demanda atmosférica no verão e baixa no outono.

Em todos períodos verificou-se maiores valores da ETo nas regiões compreendidas entre as latitudes 20 e 22° S, decrescendo à medida que a latitude aumenta. Por outro lado, verificou-se uma tendência de diminuição da ETo com o decréscimo da longitude, sendo mais nítido no verão (Figura 3 c). O decréscimo da ETo com a latitude é explicada pelo fato das regiões de menor latitude estarem mais próximas do Equador, portanto, recebem mais energia irradiante. O comportamento da ETo verificado ao longo da longitude não é explicado por nenhum fator astronômico. Entretanto, o microclima de cada local precisa ser analisado para o entendimento da variação da ETo com a longitude.

Figura 3 a - Krigagem da ETo ao longo do ano




Figura 3 b - Krigagem da ETo na primavera




Figura 3 c - Krigagem da ETo no verão




Figura 3 d - Krigagem da ETo no outono





Figura 3 e - Krigagem da ETo no inverno



3.3.4 Validação cruzada dos modelos variográficos


Na Tabela 4 estão dispostos os resultados da validação cruzada da krigagem ordinária pontual (KOP): onde β_1 representa o coeficiente angular da reta de regressão linear simples e β_0 representa o coeficiente linear.

Tabela 4. Validação cruzada da Krigagem ordinária pontual dos valores da ETo.

Período	β_1	β_0	R^2	MBE	RMSE	MSDR
Anual	0,884	0,41	0,536	0,027	0,348	0,671
Primavera	0,984	0,06	0,531	0,016	0,315	0,825
Verão	0,885	0,48	0,506	0,049	0,352	0,765
Outono	0,842	0,44	0,482	0,029	0,311	0,775
Inverno	0,954	0,14	0,548	0,014	0,486	0,729

Com base na Tabela 4, observou-se que o inverno apresentou maior valor de RMSE (0,486 mm d⁻¹), significando que a KOP teve uma precisão mais baixa nesse período. Esta constatação é confirmada na Figura 4 e, pois observou-se um maior grau de espalhamento dos pares de dados à volta da reta de regressão $Y = X$ (1:1) do que nos demais períodos. Na mesma tabela, observou-se que todos os valores de MBE foram positivos e muito próximo de zero. Estes valores mostram que a KOP apresentou uma baixíssima tendência de superestimar os valores reais da ETo.

Figura 4 (a, b, c, d, e) - Dispersão dos valores da ETo no estado de São Paulo




Os coeficientes β_1 e β_0 apresentaram valores próximos de um e zero em todo período, respectivamente, Figura 4 (a, b, c, d, e). Isto mostra que as equações de regressão linear simples de cada período sobrepõem-se a equação $Y = X$ (situação desejada), confirmando que a KOP produziu resultados que representam a variabilidade espacial da ETo no estado de São Paulo. Este resultado já era previsível, pois na análise variográfica apresentada na Tabela 3 observou-se uma dependência espacial forte. Contudo, observa-se na Tabela 4 que a validação cruzada da KOP apresentou valores de R^2 que provavelmente não representem um bom ajuste matemático. Os valores de R^2 possivelmente aumentariam trabalhando com uma base de dados maior. Neste trabalho, isso não foi possível, pois o estado de São Paulo apresenta poucas estações meteorológicas automáticas e pequena base de dados por estação.

3.3.5 Erros de estimativa produzidos pela validação cruzada

O diagrama de caixa (*Box plot*), Figura 5, demonstra que a KOP apresentou um valor médio de erros (marca central nas caixas) próximo de zero em todo período avaliado. Com base nesses resultados pode-se dizer que a KOP não apresentou nenhuma tendência de subestimar e nem de superestimar a ETo estimada pelo método da FAO 56, mostrando ser um ótimo interpolador espacial. Observou-se ainda que no inverno, o diagrama de caixa apresentou mais valores adjacentes (valores atípicos) do que nos outros períodos, principalmente abaixo da reta $Y = \beta_0 = 0$, confirmando o elevado RMSE observado na Tabela 4 (elevado grau de espalhamento).

Figura 5 - Box and plot de erros da Krigagem ordinária pontual



3.4 DISCUSSÃO

Em todos modelos variográficos escolhidos, sendo esférico para verão, outono, inverno, e escala anual e gaussiano para primavera, verificou-se uma forte dependência espacial. Essa dependência, mostrou que a escala utilizada para sua identificação foi adequada, portanto, é relevante a aplicação da geoestatística. Não obstante a existência da dependência espacial, o patamar observado no inverno ($Co+C = 0,749$) mostrou uma maior variabilidade dos dados em relação aos demais períodos. Mesmo assim, o variograma selecionado mostrou-se adequado à semelhança dos outros períodos, pois verificou-se baixo efeito pepita ($Co \cong 0$), SQR

próximo de zero $SQR \cong 0$ e elevado ajuste matemático ($R^2 \cong 1$), embora este último não seja decisivo na seleção de variogramas.

Se o modelo de variograma for corretamente escolhido, os valores de MSDR devem estar próximos de um (KERRY;OLIVER, 2007; MINASNY;MCBRATNEY, 2005; OLIVER;WEBSTER, 2014). Sendo assim, embora se verificou baixa precisão no inverno ($RMSE = 0,486 \text{ mm d}^{-1}$), mais uma vez, pode-se afirmar que todos variogramas foram bem escolhidos para expressar a variabilidade espacial da ETo no estado de São Paulo. Por conseguinte, justificando o ótimo desempenho do interpolador utilizado (KOP), ou seja, a escolha inadequada dos variogramas influencia negativamente o desempenho dos interpoladores e vice-versa. Por outro lado, a análise dos erros dos modelos feita através de *Box plot* confirmou que a KOP é um ótimo interpolador, pois apresentou erros médios próximos de zero e caixas estreitas. Vários trabalhos também constataram que a krigagem ordinária é um ótimo interpolador da ETo (COB – MARTÍNEZ;CUENCA, 1992; LIANG et al., 2011; LIU et al., 2010; XU et al., 2006).

A KOP mostrou ainda uma elevada demanda atmosférica no verão ($ETo = 4,74 \text{ mm d}^{-1}$) e baixa no outono ($ETo = 2,98 \text{ mm d}^{-1}$), a qual, é explicada pelo fato deste ser mais quente e mais chuvoso no estado de São Paulo. Vários autores relatam que a disponibilidade energética e a água são os principais fatores que determinam a taxa de evapotranspiração (BUDYKO, 1974; DONOHUE et al., 2007), justificando os presentes resultados.

3.5 CONCLUSÃO

A distribuição espacial da evapotranspiração de referência (ETo) no estado de São Paulo pode ser melhor representada através dos variogramas esféricos tanto na escala anual quanto sazonal (primavera, verão, outono e inverno), com a exceção da primavera que o melhor modelo é gaussiano. Todos os modelos apresentaram a soma dos quadrados dos resíduos, efeito pepita próximos de zero e R^2 próximo de um, além de uma forte dependência espacial.

A validação cruzada da interpolação por krigagem ordinária pontual (KOP) mostrou-se eficiente para gerar os mapas de variabilidade espacial da ETo. Os valores máximos dos principais índices estatísticos utilizados foram: MBE = 0,049 mm d⁻¹ no verão, RMSE = 0,486 mm d⁻¹ no inverno, evidenciando uma baixa superestimativa dos valores reais da ETo e elevada precisão da KOP, respectivamente. Já os valores do índice MSDR estiveram próximos de um, variando de 0,671 a 0,825, mostrando que os variogramas foram corretamente escolhidos.

REFERÊNCIAS

- ALLEN, R. G.; PEREIRA, L.; RAES, D.; SMITH, M. **Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements**. Roma: FAO, (FAO: Irrigation and Drainage Paper, 56), 1998.
- ASHRAF, M.; LOFTIS, J. C.; HUBBARD, K. G. Application of geostatistics to evaluate partial weather station networks. **Agricultural and Forest Meteorology**, v. 84, p. 255-271, 1997.
- BUDYKO, M. I. **Climate and Life**. Academic Press. 1974, 508 p.
- CENTRO DE PESQUISAS METEOROLÓGICAS E CLIMÁTICAS APLICADAS A AGRICULTURA - CEPAGRI. **Clima dos Municípios Paulistas**. Disponível em: <<http://www.cpa.unicamp.br/outras-informacoes/clima-dos-municipios-paulistas.html>>. Acesso em: 10 de out. 2016.
- CHILDS, C. Interpolating surfaces in ArcGis spatial analysis. **ArcUser**, ESRI Education Services, p. 32-35, 2004.
- COB – MARTÍNEZ, A.; CUENCA, R. H. Influence of elevation on regional evapotranspiration using multivariate geostatistics for various climatic regimes in Oregon. **Journal of Hydrology**, v. 136, p. 353-380, 1992.
- DALEZIOS, N. R.; LOUKAS, A.; BAMPZELIS, D. Spatial variability of reference evapotranspiration in Greece. **Physics and Chemistry of the Earth**, v. 27, p. 1031-1038, 2002.
- DA SILVA, A. F.; QUARTEZANI, W. Z.; ZIMBACK, C. R. L.; LANDIM, P. M. B. **Aplicação da geoestatística em ciências agrárias**. In: II Simpósio de geoestatística aplicada em ciências agrárias (SGeA), 2011, Botucatu, FEPAF, 2011, 136 p.
- DONOHUE, R. J.; RODERICK, M. L.; MCVICAR, T. R. On the importance of including vegetation dynamics in Budyko's hydrological model. **Hydrology and Earth System Sciences**, v. 11, p. 983-995, 2007.
- GUTIÉRREZ DE RAVÉ, E.; JIMÉNEZ-HORNERO, E. J.; ARIZA-VILLAVERDE, A. B.; GÓMEZ-LOPEZ. Using general-purpose computing on graphics processing units (GPGPU) to accelerate the ordinary kriging algorithm. **Computers and Geosciences**, v. 64, p. 1-6, 2014.
- JIA, X.; DUKES, M. D.; JACOBS, J. M. Bahiagrass crop coefficients from eddy correlation measurements in central Florida. **Irrig. Sci.**, v. 28, n. 1, p. 5-15, 2009.
- KAMALI, M. I.; NAZARI, R.; FARIDHOSSEINI, A.; ANSARI, H.; ESLAMIAN, S. The determination of reference evapotranspiration for spatial distribution mapping using Geostatistic. **Water Resour Manage**, v. 29, p. 3929-3940, 2015.

KANG, S. Z.; GU, B. J.; DU, T. S.; ZHANG, J. H. Crop coefficient and ratio of transpiration to evapotranspiration of winter wheat and maize in a semi – humid region. **Agricultural Water Management**, v. 59, p. 239-254, 2003.

KERRY, R.; OLIVER, M. A. Comparing sampling needs for variograms of soil properties computed by the method of moments and residual maximum likelihood. **Geoderma**, v. 140, n. 4, p. 383-396, 2007.

KOTTEK, M.; GRIESER, J.; BECK, C.; RUDOLF, B.; RUBEL, F. World map of the Koppen – Geiger climate classification updated. **Meteorologische Zeitschrift**, Berlin, v.15, n. 3, p. 259-263, June 2006.

KURTZMAN, D.; KADMON, R. Mapping of temperature variables in Israel: A comparison of different interpolation methods. **Climate Res.**, v. 13, n. 1, p. 33-43, 1999.

LIANG, L.; LI, L.; LIU, Q. Spatio – temporal variations of reference crop evapotranspiration and pan evaporation in the West Songnen Plain of China. **Hydrological Sciences Journal**, v. 56, n. 7, 2011.

LIU, Q.; YANG, Z. Quantitative estimation of the impact of climate change on actual evapotranspiration in the Yellow River Basin, China. **Journal of hydrology**, v. 395, p. 226-234, 2010.

MARDIKIS, M. G.; KALIVAS, D. P.; KOLLIAS, V. J. Comparison of interpolation methods for the prediction of reference evapotranspiration – An application in Greece. **Water Resources Management**, v. 19, p. 251-278, 2005.

MATHERON, G. Principles of geostatistics. **Econ. Geol.**, v. 58, p. 1246-1266, 1963.

MEYERS, J. C. Geostatistical error management. Qualifying uncertainty for environmental sampling and mapping. New York, **Van Nostrand Reinhold**, 1997, 571 p.

MINASNY, B.; MCBRATNEY, A. B. The Matern function as a general model for soil variograms. **Geoderma**, v. 128, n. 3-4, p. 192-207, 2005.

MOHAWESH, O. E. Evaluation of evapotranspiration models for estimating Daily reference evapotranspiration in arid and semiarid environment. **Plant Soil Environ.**, v. 57, n. 4, p. 147-152, 2011.

LI, J.; HEAP, A. A review of comparative studies of spatial interpolation methods in environmental science: performance and impact factors. **Ecol. Inf.**, v. 6, p. 228-241, 2011.

LIU, Q.; YANG, Z.; CUI, B.; SUN, T. The temporal trends of reference evapotranspiration and its sensitivity to key meteorological variables in the Yellow River Basin, China. **Hydrol. Process.**, v. 24, p. 2171-2181, 2010.

NOSHADI, M.; SEPASKHAH, A. R. Application of geostatistics for potential evapotranspiration estimation. **Iranian Journal of science and Technology B, Engineering**, v. 29, n. B3, May, 2005.

OLIVER, M. A.; WEBSTER, R. Kriging: a method of interpolation for geographical information systems. **Int. J. Geogr. Inf. Sci.**, v. 4, n. 3, p. 313-332, 1990.

OLIVER, M. A.; WEBSTER, R. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. **Catena**, v. 113, p. 56-69, 2014.

RAY, S. S.; DADHWAL, V. K. Estimation of crop evapotranspiration of irrigation command area using remote sensing and GIS. **Agricultural Water Management**, v. 49, n. 3, p. 239-249, 2001.

RAZIEI, T.; PEREIRA, L. S. Spatial variability analysis of reference evapotranspiration in Iran utilizing fine resolution gridded datasets. **Agricultural Water Management**, v. 126, p. 104-118, 2013.

ROLIM, D. DE S.; DE CAMARGO, M. B. P.; LANIA, D. G.; DE MOARES, J. F. L. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo, **Bragantia**, Campinas, v. 66, n. 4, p. 711-720, 2007.

SOUZA, A. P.; MOTA, L. L.; ZAMADEI, T.; MARTIM, C. C.; ALMEIDA, F. T.; PAULINO, J. Classificação climática e balanço hídrico climatológico no estado de Mato Grosso. **Nativa**, Sinop, v. 1, n. 1, p. 34-43, out/dez., 2013.

TRANGMAR, B. B.; YOST, R. S.; UEHARA, G. Application of geostatistics to spatial studies of soil properties. **Advances in Agronomy**, Orlando, v. 38, p. 45-94, 1985.

VIANELLO, R. L.; ALVES, A. R. **Meteorologia básica e aplicações**. 2. Ed. Viçosa, MG: Ed. UFV, 2012, 460 p.

XIAO, Y.; GU, X.; YIN, S.; SHAO, J.; CUI, Y.; ZHANG, Q.; NIU, Y. Geostatistical interpolation model selection based on ArcGis and spatio-temporal variability analysis of groundwater level in piedmont plains, northwest China. **Springer Plus**, 5:425, 2016.

XU, C-Y.; GONG, L.; JIANG, T.; CHEN, D.; SINGH, V. P. Analysis of spatial distribution and temporal trend of reference evapotranspiration an pan evaporation in Changjiang (Yangtze River). **Journal of Hydrology**, v. 327, p. 81-93, 2006.

WEBSTER, R.; OLIVER, M. A. **Geostatistics for environmental scientists**. Willey, Chichester, 2001, 271 p.

YANG, Z.; LIU, Q.; CUI, B. Spatial distribution and temporal variation of reference evapotranspiration during 1961-2006 in the Yellow River Basin, China. **Hydrological Sciences Journal**, v. 56, n. 6, 2011.

ZIMBACK, C. R. L. **Análise espacial de atributos químicos de solos para fins de mapeamento da fertilidade do solo**. 2001. 114 f. Tese (Livre – Docência) – Faculdade de Ciências Agronômicas, Universidade Estadual Paulista, Botucatu, 2001.

ZHOU, F.; GUO, H.-C.; HO, Y.-C.; WU, C.-Z. Scientometric analysis of geostatistics using mulvariate methods. **Scientometrics**, v. 73, p. 265-279, 2007.

CONSIDERAÇÕES FINAIS

Para o manejo ou dimensionamento de sistemas de irrigação é fundamental que os métodos empíricos sejam selecionados de forma cuidadosa para garantir uma máxima produtividade das culturas agrícolas. É também fundamental que se analise o efeito de sazonalidade das equações anuais em relação às sazonais a fim de se escolher métodos que apresentam baixo efeito de sazonalidade, por conseguinte, evitando sob ou superdimensionamento de sistemas de irrigação.

As redes neurais artificiais, principalmente a máquina vetor de suporte, são excelentes ferramentas para a estimativa da ETo em qualquer estação do ano. Contudo, produziram desempenho estatístico quase similar em diferentes arquiteturas. Sendo assim, testes de análise de significância dos resultados devem ser realizados, assim como estudos de viabilidade econômica, para que seja feita uma escolha mais adequada possível.

Embora a krigagem ordinária pontual tenha se mostrado eficiente para estimar a ETo em lugares não amostrados no estado de São Paulo, outras técnicas de interpolação devem ser analisados.

REFERÊNCIAS

- ALLEN, R. G. et al. **Crop Evapotranspiration: Guidelines for Computing Crop Water Requirements**. Roma: FAO, (FAO: Irrigation and Drainage Paper, 56), 1998.
- BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000, 262 p.
- BURGESS, T. M.; WEBSTER, R. Optimal interpolation and isarithmic mapping of soil properties. The semivariogram and punctual kriging. **The Journal of Soil Science**, v.31, p. 315-331, 1980.
- CAO, J. F.; LI, Y. Z.; ZHONG, X. I.; ZHAO, Y. M. Comparison of four combination methods for reference crop evapotranspiration. **Chin. J. Agrometeorol**, v. 36, n. 4, p. 428-436, 2015.
- CHAUHAN, S.; SHRIVASTAVA, R. K. Estimating reference evapotranspiration using neural computing technique. **J. of Indian Water Resour. Soc.**, v. 32, n. 1-2, 2012.
- DOOREMBOS, J.; KASSAM, A. H. **Efeito de água no rendimento das culturas**. Estudos FAO-Irrigação e drenagem 33 (Traduzido por H R Gheyi et al.-UFPB, Campina Grande), 1994, 306 p.
- DOOREMBOS, J.; PRUITT, W.O. **Guidelines for predicting crop water requirements**. FAO Irrigation and drainage paper 24, Roma, 1975, 179 p.
- FONSECA JUNIOR, F. G. S. et al. Analysis of the use of support vector regression and neural networks to forecast insolation for 25 locations in japan. **Anais ISES Solar World Congress**. 2011.
- GOCIC, M.; TRAKKOVIC, S. Software for estimating reference evapotranspiration using limited weather data. **Comput. Electron. Agric**, v.71, p. 158-162, 2008.
- HE, Z.; WEN, X.; LIU, H.; DU, J. A comparative study of artificial neural network , adaptive neuro fuzzy inference systems and support vector machine for forecasting river flow in the semiarid mountain region. **J Hydrol**, v. 509, p. 379-386, 2014.
- JENSEN, M. E. **Consumptive use of water and irrigation water requirements**. New York:ASCE, 1973. 215 p.
- KISI, O. Least squares support vector machine for modeling daily reference evapotranspiration. **Irrig Sci**, v. 31, p. 611-619, 2013.
- KHOOB, A. R. Comparative study of Hargreaves's and artificial neural network's methodologies in estimating reference evapotranspiration in a semiarid environment. **Irrigation Science**, v. 26, n. 3, p. 253–259, 2008.
- KUMAR, M. et al. Comparative study of conventional and artificial neural network-based estimation models. **Irrigation Science**, v.26, n.6, p.531-545, 2008.

KURTZMAN, D.; KADMON, R. Mapping of temperature variables in Israel: A comparison of different interpolation methods. **Climate Res.**, v. 13, n. 1, p. 33-43, 1999.

LADLANI, I. HOUICHI, L.; DJEMILI, L.; HEDDAM, S.; BELOUZ, K. Modeling daily reference evapotranspiration (ET_o) in the north of Algeria using generalized regression neural networks (GRNN) and radial basic function neural network (RBFNN): a comparative study. **Meteorol Atmos Phys**, v. 118, p. 163-178, 2012.

LEAL, S. S.; TÍBA, 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.

LIU, D. L.; SCOTT, B. J. Estimation of solar radiation in Australia from rainfall and temperature observations. **Agricultural and Forest Meteorology**, Philadelphia, v. 106, p. 41-59, 2001.

MARTINEZ, C.J.; THEPADIA, M. Estimating reference evapotranspiration with minimum data in Florida, USA. **J. Irrig. Drain. Eng.** [http://dx.doi.org/10.1061/\(ASCE\)IR.1943-4774.0000214](http://dx.doi.org/10.1061/(ASCE)IR.1943-4774.0000214).

MAVI, H. S.; TUPPER, G. J. Agrometeorology: principles and applications of climate studies in agriculture. **Food Products Press**. Oxford. London, 364p. 2004.

MOHAMMADI, K. 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, 2015.

PEREIRA, A. R.; SEDIYAMA, G. C.; NOVA, N. A.V. **Evapotranspiração**. Campinas: Fundag, 2013. 323 p.

PEREIRA, A. R.; VILLA NOVA, N. A.; SEDIYAMA, G. C. **Evapo(transpi)ração**. Piracicaba: FEALQ/USP, 1997. 183 p.

ROLIM, D. DE S. et al. Classificação climática de Köppen e de Thornthwaite e sua aplicabilidade na determinação de zonas agroclimáticas para o estado de São Paulo, **Bragantia**, Campinas, v. 66, n. 4, p. 711-720, 2007.

SENTELHAS, P. C.; GILLESPIE, T. J.; SANTOS, E. A. Evaluation of FAO Penman-Monteith and alternative methods for estimating reference evapotranspiration with missing data in Southern Ontario, Canada. **Agricultural Water Management**, Amsterdam, v. 97, n. 5, p. 635-644, 2010.

SOBRINHO, T.A. et al. Estimativa da evapotranspiração de referência através de redes neurais. **Revista brasileira de meteorologia**, São José dos Campos, v. 26, n. 2, p.1997-2003, 2011.

TABARI, H. Evaluation of reference crop evapotranspiration equations in various climates. **Water Resour. Manage**, v. 24, p. 2311-2337, 2010.

TABARI, H.; GRISMER, M. E.; TRAJKOVIC, S. Comparative analysis of 31 reference evapotranspiration methods under humid conditions. **Irrig. Sci.**, **2011**. <http://dx.doi.org/10.1007/s00271-011-0295-z>.

TABARI, H. 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 hidrology**, 444-445, p. 78-89, 2012.

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 modelling daily reference evapotranspiration with limited climatic data in extreme arid Regions. **Water Resour Manage**, v. 29, p. 3195-3209, 2015.

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.

ZANETTI, S. S. et al. Estimaco de evapotranspiraco de referncia no estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrcola e Ambiental**, Campina Grande, v.12, n.2, p.174–180, 2008.