



UNIVERSIDADE FEDERAL DO MARANHÃO
CENTRO DE CIÊNCIAS AGRÁRIAS E AMBIENTAIS
CURSO DE ENGENHARIA AGRÍCOLA



KLARA CUNHA DE MENESES

**ESTIMATIVA DA EVAPOTRANSPIRAÇÃO POTENCIAL DIÁRIA DO BAIXO
PARNAÍBA UTILIZANDO REDES NEURAIS ARTIFICIAIS**

Chapadinha- MA

2019

ESTIMATIVA DA EVAPOTRANSPIRAÇÃO POTENCIAL DIÁRIA DO BAIXO PARNAÍBA UTILIZANDO REDES NEURAS ARTIFICIAIS

Trabalho de Conclusão de Curso apresentado a Coordenação de Curso de Engenharia Agrícola da Universidade Federal do Maranhão como requisito para a obtenção do título de Engenheira Agrícola.

KLARA CUNHA DE MENESES

Orientadora: Prof^ª. Dr^ª. Maryzélia Furtado de Farias

Co-orientadora: MsC. Kamila Cunha de Menezes

Chapadinha- MA

Junho de 2019

TCC defendida e aprovada, em ____ de _____ de _____, pela Comissão Examinadora constituída pelos professores:

Banca Examinadora

Prof.^a. Dr.^a. Maryzélia Furtado de Farias (Orientadora)

Universidade Federal do Maranhão

Prof.^a. Dr.^a. Luisa Julieth Parra Serrano

(Examinadora)

Universidade Federal do Maranhão

Prof. Dr. Regis Catarino Da Hora

(Examinador)

Universidade Federal do Maranhão

Dedico esse trabalho, primeiramente a Deus por ser minha maior fonte de fortaleza, aos meus pais, irmãos, amigos e professores pelo apoio e incentivo durante toda essa jornada.

AGRADECIMENTOS

Agradeço primeiramente a Deus, pelo dom da vida e por ter me dado força e coragem durante toda essa caminhada.

Aos meus pais Francisco Feitosa de Meneses e Maria dos Milagres Santos Cunha, que com muito esforço me proporcionaram essa grande oportunidade. Sei o quanto vocês se doaram para realização desse sonho.

A minha orientadora Prof^a. Dr^a. Maryzélia Furtado de Farias, pela paciência, pelos conselhos, ensinamentos, incentivos para continuar os estudos e pela orientação para realização desse trabalho.

A minha irmã e co-orientadora Kamila Meneses, pela amizade, carinho, compreensão, incentivo e por compartilhar comigo todos os seus conhecimentos para realização desse trabalho.

Aos professores Dr^a. Luisa Julieth Parra Serrano e Dr. Régis Catarino da Hora por aceitarem fazer parte da banca da minha defesa.

Aos meus irmãos Anderson e Matheus que acompanharam minha dedicação e torceram por mim.

Aos meus avós Joaquim, Joana, Gracieth, Maria (*In memorian*) e Raimundo (*In memorian*) por todos os conselhos e ensinamentos que levarei comigo por toda minha vida.

A minha amiga Renata Coutinho, que esteve ao meu lado em todos os momentos bons e ruins dessa caminhada.

Aos meus amigos Boni, Armando e Adson pela amizade, apoio e pelos momentos de descontração.

Aos meus amigos que fiz durante a graduação, principalmente, Lindykeila, Tamires, Karliane, Maiane, Maiara, Tiago, Alessandro, Kamylla, Jobson, Héliida e Marcos. Obrigada por todos os momentos compartilhados e pela amizade de vocês.

A todos do grupo de pesquisa MASCEMA do qual eu tenho orgulho de fazer parte.

Ao coordenador do curso de Engenharia Agrícola Prof. Dr. Washigton da Silva Sousa pelo suporte acadêmico, pelo apoio, conselhos, amizade e dedicação e aos secretários, Neliane e Leodoro pelo suporte acadêmico, paciência e amizade durante todo esse processo.

A todos os meus professores, que compartilharam comigo seus conhecimentos e me deram conselhos que levarei comigo por toda a minha vida.

Por fim, obrigada a todos que de alguma forma, diretamente ou indiretamente, participaram para realização desse projeto.

Queremos ter certezas e não dúvidas, resultados e não experiências, mas nem mesmo percebemos que as certezas só podem surgir através das dúvidas e os resultados somente através das experiências.

Carl Jung

SUMÁRIO

1. INTRODUÇÃO	11
2. REVISÃO DE LITERATURA	13
2.1. Evapotranspiração Potencial	13
2.2. Temperatura Do Ar	14
2.3. Machine Learning	15
2.4. Redes Neurais Artificiais	16
3. MATERIAL E MÉTODOS	17
4. RESULTADOS E DISCUSSÃO	20
5. CONCLUSÕES	26
6. REFERENCIAS BIBLIOGRAFICAS	27

LISTA DE FIGURAS

Figura 1. Rede neural <i>Multilayer Perceptron</i> (MLP) simplificada.....	19
Figura 2. Boxplot com os dados de temperatura máxima, mínima e média do ar diária da microrregião do Baixo Parnaíba no período de 1984-2017.....	21
Figura 3. Valores médios mensais de precipitação e temperatura do ar da microrregião do Baixo Parnaíba.....	22
Figura 4. Valores médios de Evapotranspiração Potencial Penman-Monteith da microrregião do Baixo Parnaíba.....	23
Figura 5. Treinamento da rede neural.....	25
Figura 6. Validação da rede neural.....	25

RESUMO

A escassez de água e a crescente demanda por fornecimento de alimentos aumenta a importância de desenvolvimento de métodos melhorados para a estimativa da evapotranspiração potencial. Diante desse contexto, objetivou-se fazer uma estimativa de evapotranspiração potencial no Baixo Parnaíba maranhense utilizando redes neurais artificiais. Os dados agrometeorológicos coletados foram de 33 anos, a partir do ano de 1984 até o ano de 2017 em escala diária, retirados do site NASA/POWER. Posteriormente, foram calculadas a radiação líquida e a evapotranspiração potencial pelo método padrão Penman-Monteith. Para prever a evapotranspiração potencial diária foi escolhida a Perceptron Multi-Layer (MLP), que é uma Rede Neural Artificial tradicional. O período que apresentou um maior índice de evapotranspiração foi o mesmo que apontou precipitações com um menor volume e temperaturas elevadas. O modelo de rede neural artificial escolhido para estimativa da evapotranspiração potencial foi a MLP 2-5-1. Com isto, conclui-se que as redes neurais artificiais podem ser utilizadas para a estimativa da evapotranspiração potencial diária.

Palavras-chave: elementos climáticos, inteligência artificial, modelagem.

ABSTRACT

Water scarcity and increasing demand for food supplies increase the importance of developing improved methods for estimating potential evapotranspiration. In view of this context, the objective was to estimate potential evapotranspiration in the Baixo Parnaíba of Maranhão using artificial neural networks. The collected agrometeorological data were 33 years, from 1984 to 2017 on daily basis, taken from NASA/ POWER site. Subsequently, net radiation and potential evapotranspiration were calculated using the standard Penman-Monteith method. In order to predict potential daily evapotranspiration, the Perceptron Multi-Layer (MLP) was chosen, which is a traditional artificial neural network. The period that presented a higher rate of evapotranspiration was the same that indicated precipitations with a lower volume and higher temperatures. The artificial neural network model chosen for estimating potential evapotranspiration was MLP 2-5-1. With this, it is concluded that artificial neural networks can be used to estimate potential daily evapotranspiration.

Keywords: artificial intelligence, climatic elements, modeling.

1. INTRODUÇÃO

A escassez de água na região Nordeste do Brasil é grande em comparação as outras regiões do país, com isso, para expansão do setor agrícola é essencial a aplicação de tecnologia e planejamento para que ocorra a irrigação mais eficiente na região, utilizando água de forma racional (ANDRADE JUNIOR et al., 2018; FREITAS et al., 2018). O aumento da temperatura e redução da precipitação causam o aumento da demanda hídrica para os cultivos (GAVA et al., 2015).

Estabelecer a necessidade hídrica da planta em suas diferentes fases de desenvolvimento é de fundamental importância para o manejo da irrigação quando se objetiva além de boa produtividade, o uso racional da água (COSTA et al., 2018). Com isso, é necessário conhecer a taxa de evapotranspiração da planta para irrigar com a quantidade correta, visando no aumento da produção sem que ocorra desperdício de água.

A evapotranspiração é o processo em que a água da superfície terrestre evapora para atmosfera, sendo uma parte importante do ciclo hidrológico. O processo da evapotranspiração não ocorre somente em água superficial, mas envolve também a perda de água do solo e da vegetação úmida na forma de vapor e a perda de água dos animais e vegetais através da transpiração. Assim o estudo das taxas diárias de evapotranspiração é muito útil para estabelecer a necessidade hídrica na agricultura (MARTINS & ROSA, 2019).

Para estimar a quantidade de água requerida pela planta é feito o cálculo da evapotranspiração potencial. A avaliação da evapotranspiração potencial pode ser feita por vários métodos empíricos (ANDRADE JUNIOR et al., 2018). A Organização das Nações Unidas para a Alimentação e a Agricultura (*Food and Agriculture Organization* – FAO) recomenda como método padrão o de Penman-Monteith, devido ser um modelo com maior precisão (ALLEN et al., 1998), abrange vários fatores como a umidade relativa, a radiação solar, a temperatura do ar e a velocidade do vento. Este método requer um número maior de variáveis meteorológicas e que muitas vezes esses elementos não estão disponíveis devido ao pequeno número de estações meteorológicas disponíveis nas regiões, as quais podem ter dados insuficientes. Na literatura, há outros métodos empíricos com menos entradas de variáveis climáticas (SILVA et al., 2018, CAPORUSSO e ROLIM, 2015), como Hargreaves-Samani, Radiação Solar, Blaney-Criddle e de Priestley-Taylor (ALLEN et al., 1998) mas utilizam o método Penman-Monteith nas calibrações dos novos modelos.

O uso de dados climáticos oriundos de grid é uma forma de resolver essa ausência de dados para a estimativa da evapotranspiração potencial (APARECIDO et al., 2016), como encontrados na plataforma da NASA/POWER (2019). Essa plataforma combina várias informações agrometeorológicas oriundas da superfície, oceano e sensoriamento remoto (MALDONADO JÚNIOR; VALERIANO; ROLIM, 2019).

Na última década, os modelos computacionais inteligentes foram desenvolvidos como métodos alternativos para estimar a evapotranspiração potencial (YASSIN et al., 2016). As redes neurais artificiais (RNA) é uma das técnicas que pode ser utilizadas para a estimativa de evapotranspiração potencial, as quais são modelos matemáticos similares a estruturas neurais do cérebro humano e com inteligência computacional obtida por meio de aprendizagem e generalização (DI DOMENICO et al., 2017). Esse método possuem uma estrutura não linear e que captam as características mais complexas dos dados, sendo isso difícil de se conseguir usando outras técnicas tradicionais de estatística (NUNES, 2018).

A aprendizagem usada na técnica de redes neurais artificiais é definida como a maneira pelo qual os dados livres de uma RNA se adequam por meio de um processo de estimulação pelo ambiente em que a rede está inserida. O modo pela qual ocorre a modificação dos parâmetros é o que determina o tipo de aprendizagem (CONTI, 2016).

A escassez de água e a crescente demanda por fornecimento de alimentos aumenta a importância de desenvolvimento de métodos melhorados para a estimativa da evapotranspiração potencial (PATIL E DEKA, 2016). Nos últimos anos, as aplicações de RNA foram utilizadas na estimativa da evapotranspiração potencial e os resultados sugeriram que as redes neurais artificiais são mais precisas que os métodos convencionais (DAI et al., 2009; ABDULLAHI et al., 2017). Contudo, a utilização de modelos empíricos de evapotranspiração potencial com entrada apenas de dados de temperatura do ar é relevante em regiões com escassez de dados climáticos, sendo que no mercado comercial se encontra aparelhos de medição dessa variável com baixo custo, como exemplo, os termohigrômetros.

Diante desse contexto, objetivou-se fazer uma estimativa de evapotranspiração potencial no Baixo Parnaíba maranhense utilizando redes neurais artificiais.

2. REVISÃO DE LITERATURA

2.1.. Evapotranspiração Potencial

A evapotranspiração é um processo natural em que ocorre a transferência da água de qualquer superfície terrestre para a atmosfera por meio da transpiração e da evaporação. Em campo, as duas são avaliadas juntas devido à dificuldade em diferenciar esses processos (PAIVA & DE SOUZA, 2016). A evapotranspiração potencial (ET_o) leva em consideração uma vegetação rasteira “grama”, de altura uniforme, a qual é definida como cultura de referência (FERNANDES et al., 2010; ARMANI et al., 2018). O seu estudo é essencial na agricultura, pois essa evapotranspiração é utilizada no balanço hídrico do solo, junto com registros de precipitação, permitindo elaborar e definir com maior exatidão o manejo de irrigação e a estimativa da produtividade (MINUZZI et al., 2018).

Para determinar a evapotranspiração é preciso utilizar métodos adequados para fins operacionais. Dentre tais métodos estão o lisímetro, a razão de Bowen, a correlação turbulenta, a determinação da umidade do solo, entre outros. Contudo apesar da variedade, estes métodos além de pouco práticos, possuem elevados custos para sua implementação e manutenção, o que faz de difícil acesso a aplicação dessas técnicas (PRIMO et al., 2018). Objetivando a simplificação do uso da evapotranspiração potencial (ALLEN et al., 1998; PRIMO et al., 2018), há métodos de estimativa da evapotranspiração, os quais precisam apenas de dados meteorológicos, dentre os quais constam a temperatura do ar, a radiação solar, a umidade relativa do ar, a pressão atmosférica e a velocidade do vento para sua quantificação, pode ser determinada decorrente às condições específicas de vegetação e umidade do solo. (MANTOVANI, 1993; PRIMO et al., 2018).

Dentre os diversos métodos de estimativa de ET_o, a Organização das Nações Unidas para Agricultura e Alimentação (*Food and Agriculture Organization* – FAO) recomenda como padrão o método de Penman-Monteith (PM). Para aplicação desse método, são necessários elementos meteorológicos que são difíceis de serem medidos na maioria das estações meteorológicas devido ao alto custo de implantação e manutenção dos instrumentos de meteorologia. Na maioria das estações são disponíveis apenas observações de temperatura do ar e precipitação, o que compromete a aplicação do método de PM-FAO56 (SANTOS et al., 2018).

Segundo Zanetti et al. (2018), a mensuração direta da evapotranspiração é difícil e onerosa demandando equipamentos e pessoas especializadas. Por este motivo, os métodos

indiretos são mais utilizados por possuírem maior simplicidade e praticidade e os custos são relativamente menores que o método direto. Os métodos de Hargreaves e Samani, Makkink e Camargo são métodos indiretos da estimativa de evapotranspiração potencial. O método de estimativa de evapotranspiração potencial sugerido por Samani e Hargreaves usa como variáveis de entrada temperaturas mínima, média e máxima e a radiação solar no topo da atmosfera. A equação apresentada por Camargo também utiliza a temperatura e a radiação solar no topo da atmosfera, nessa equação existe um fator K, que é adequado de acordo com a temperatura, e um fator D, que é determinado de acordo com o período da evapotranspiração. O método de Jensen-Haise é mais fácil de ser aplicado, pois a variável radiação incidente de onda curta é facilmente determinado, se tratando de uma constante tabelada em função dos meses do ano e latitude do local. (OLIVEIRA et al., 2018).

Vários estudos em todo o mundo concluíram que a FAO-56 Penman-Monteith (FAO-PM) é o modelo mais preciso, sob diferentes condições climáticas (ALLEN et al., 1998). Esse modelo foi testado em muitas regiões do mundo como Brasil, Estados Unidos da América, Áustria, Bolívia e entre outros. Um desses trabalhos é o de Vicente et al.(2018) que estimaram a evapotranspiração de potencial a partir de dados de temperatura máxima e mínima utilizando o método de FAO Penman Monteith para o Vale de Jequitinhonha, localizado no Brasil. Outro trabalho foi o de Samadi (2016), que avaliou a sensibilidade dos parâmetros físico da SWAT para os métodos de estimativa de evapotranspiração potencial (Penman-Monteith, Hargreaves e Priestley-Taylor) ao longo da bacia hidrográfica da planície costeira no sudeste dos Estados Unidos.

2.2. Temperatura Do Ar

A temperatura do ar ocorre alterações ao longo do tempo e nas regiões. A classificação da temperatura no globo terrestre é dependente de vários fatores como distância entre corpos hídricos, a radiação incidente no local, o relevo, os ventos predominantes e as correntes oceânicas (POHLMANN & LAZZARI, 2018).

A temperatura do ar, dentro de intervalos ótimos de temperatura, causa o aumento da velocidade das reações metabólicas, fazendo com que ocorra uma maior produção fotossintética e outros processos específicos da produtividade (DOS SANTOS et al., 2018). É uma das variáveis que mais interferem no desenvolvimento das plantas e vem sendo usada como variável de entrada em modelos ambientais, em especial, na modelagem agrometeorológica, quantifica

o efeito do clima nas fases de desenvolvimento das plantas. A temperatura é uma variável climática de grande importância na estimativa da lâmina de irrigação sendo utilizada em muitos métodos indiretos para estimar a evapotranspiração potencial (GOMES et al., 2018). O estresse ocasionado por temperaturas do ar elevadas tem um efeito direto na atividade fotossintética. As temperaturas do ar maiores que 32°C provocam a redução do desenvolvimento da planta, principalmente de plantas do tipo C3, como o café, a soja e o feijão, ocasionando em uma baixa produtividade (GUSSO, 2015).

2.3. Machine Learning

O conhecimento de armazenamento de dados e a velocidade de processadores são insuficientes para formar conjunto de percepções agregadas que gera uma maior produtividade e inovação (LOCHEN, 2018), surgiu a técnica de Machine Learning (Aprendizado de máquina) que são técnicas de inteligência artificial, que se baseiam no aprendizado a partir de amostras, são utilizadas na análise de modelos. Dessa forma, as máquinas são habilitadas a aprender, a se adaptar e a agir de forma autônoma a partir de dados de processos que tem acesso (CARMO et al., 2018).

Segundo CERRI et al. (2019) existem dois tipos de tarefas dentro do Machine Learning que são chamadas de tarefas descritivas e preditivas. Em tarefas descritivas tem o objetivo de criar algoritmos que irão descrever os dados. Já nas tarefas preditivas são divididas em tarefas de classificação e de regressão. Nas tarefas de classificação tem por finalidade conceder categorias já definidas aos dados. Nas tarefas de regressão, busca-se analisar o valor de uma variável numérica (atributo de saída), através de outras variáveis (atributos de entrada), assim, tem que se encontrar uma função para mapear um modelo para um número.

Os métodos de Machine Learning mais conhecidos incluem redes neurais artificiais, métodos de árvores e máquinas de vetores de suporte (CARTER & SHULLIN, 2019). Nos últimos anos, os métodos de Machine Learning têm sido implementados para estimativa de impactos hidrológicos e meteorológicos, como a temperatura do ar, temperatura do ponto de orvalho, precipitação, radiação solar e evapotranspiração (FENG et al., 2019).

Xu et al. (2018) empregaram diferentes abordagens de Machine Learning para aumentar a evapotranspiração das torres de fluxo para regionais escalar. No entanto, as

aplicações de técnicas de Machine Learning para problemas de estimativa de evapotranspiração são atuais e o conhecimento sobre o tema é parcial e fragmentado (GRANATA, 2019).

2.4. Redes Neurais Artificiais

As Redes Neurais Artificiais (RNA, *Artificial Neural Network*) são modelos computacionais que simulam a estrutura e o processamento de informações e a aquisição de conhecimento do cérebro humano, estabelecendo relações matemática entre variáveis dependentes e independentes (FERREIRA et al., 2019). São capazes de generalizar conhecimento aprendido por meios de exemplos a um conjunto de dados desconhecidos (HAYKIN, 2001; GORGENS et al., 2009; SILVA et al., 2018).

A RNA é um sistema massivo e simultâneo que possui unidades de processamento simples que são caracterizadas como neurônios artificiais, determinados em uma ou mais camadas e ligados entre si com critérios ajustáveis por um número de conexões (GORGENS et al., 2009; BULLINÁRIA, 2011; LAFETÁ, 2018). É definida por ter analogia neurobiológica, mapeamento de entrada e saída, tolerância a falhas e ruídos, adaptabilidade dos pesos das conexões às modificações do ambiente e capacidade de generalizar o conhecimento assimilado por aprendizagem para um conjunto de dados desconhecidos (BINOTI, 2010; LAFETÁ et al., 2018). As Redes Neurais têm provocado maior acurácia com relação as técnicas estatísticas tradicionais (GORGENS et al., 2015; REIS et al., 2018). Com isto, seu uso tem ganhado destaque nas áreas de ciências agrárias (SILVA et al., 2018).

A *Multilayer Perceptron* é uma rede neural com múltiplas camadas e neurônios (TANG et al., 2019), é altamente popular entre usuarios e pesquisadores e possui três camadas gerais, incluindo as camadas de entrada, oculta e saída (AKHTAR et al., 2018). Para resolver situações complexas são necessárias mais camadas em uma rede neural que tenha uma conexão completa com todos os neurônios, o que é conhecido como rede neural do Multilayer perceptron.

Nos ultimos anos diferentes pesquisas foram realizadas nas areas de ciências agrarias utilizando esta tecnica. Borges et al. (2017) utilizaram a rede Multilayer Perceptron para estimar o consumo de combustivel do trator durante a preparação do solo,de acordo com o sistema adotado. Como dados de entrada de resistencia à penetração mecânica do solo, a área mobilizada por implementos, o equipamento de trabalho e a velocidade do motor do trator. O

número de camadas e os neurônios variaram para formar diferentes arquiteturas. O ajuste foi verificado com base em vários critérios estatísticos.

Alves; Rolim; Aparecido (2017) concluíram que a evapotranspiração potencial pode ser estimada com um dia de sobra em qualquer época do ano por redes neurais artificiais, mostrando alta precisão e utilizando apenas dados de temperatura do ar como variável de entrada.

3. MATERIAL E MÉTODOS

A área de estudo foi na microrregião Baixo Parnaíba no estado do Maranhão, composta de 16 municípios (Tabela 1). Essa região apresenta elevado potencial para exploração agrícola devido à sua boa disponibilidade de solos e recursos hídricos.

Tabela 1. Cidades do Baixo Parnaíba e suas coordenadas geográficas.

Municípios	Latitude	Longitude	Altitude (m)
Água Doce do Maranhão	2°50'S	42° 7'O	16
Anapurus	3°28'S	43°12'O	91
Araioses	2°53'S	41°54'O	16
Belágua	3° 9'S	43°30'O	72
Brejo	3°39'S	42°47'O	104
Buriti	3°56'S	42°55'O	61
Chapadinha	3°44'S	43°21'O	104
Magalhães de Almeida	3°23'S	42°12'O	38
Mata Roma	3°37'S	43° 6'O	77
Milagres do Maranhão	3°32'S	42°40'O	100
Santa Quitéria do Maranhão	3°29'S	42°33'O	30
Santana do Maranhão	3° 6'S	42°24'O	37
São Benedito do Rio Preto	3°19'S	43°31'O	60
São Bernardo do Maranhão	3°22'S	42°25'O	54
Tutoia	2°58'S	42°23'O	48
Urbano Santos	3°12'S	43°23'O	68

Os dados agrometeorológicos de temperatura mínima, máxima e média do ar (°C), radiação global (MJ m² dia), precipitação (mm), velocidade do vento (m s⁻¹) e umidade relativa (%) foram coletados de 33 anos, no ano de 1984 até o ano de 2017 em escala diária, foram

retirados do site NASA/POWER (STACKHOUSE et al., 2017). Essa plataforma de dados tem resolução espacial de 0,5° latitude-longitude.

Com esses dados foram calculadas a radiação líquida (R_n) e a evapotranspiração potencial pelo método padrão Penman-Monteith (Equação 1).

$$ETP = \left(\frac{0,48 \times \Delta \times (R_n - G) + \left(\frac{900}{T + 273} \right) \times U_2 (e_s - e)}{\Delta + \gamma \times (1 + 0,34 \times U_2)} \right) \quad (1)$$

em que: ETP - Evapotranspiração potencial, em mm dia⁻¹; R_n - Radiação líquida, em MJ m⁻² dia⁻¹; G - Densidade do fluxo de calor, em MJ m⁻² dia⁻¹; T - Temperatura média diária do ar, em °C; γ - Constante psicométrica (0,063 KPa °C⁻¹); s - Declividade da curva de saturação de vapor, em KPa °C⁻¹; U_2 - Velocidade média diária do vento a 2 metros de altura, em ms⁻¹; e_a - Pressão parcial de vapor, em KPa; e_s - Pressão de saturação de vapor, média diária, em kPa.

Para calcular a ETP foi necessário estimar os valores de R_n , s , e_s , e_a através das seguintes equações:

a) e_s - pressão de saturação de vapor, média diária, em KPa

$$e_s = \frac{(e_{sT_{\max}} + e_{sT_{\min}})}{2} \quad (2)$$

em que:

$$e_{sT_{\max}} = 0,6108 \times e \left[\frac{(17,27 \times T_{\max})}{(237,3 + T_{\max})} \right] e_{sT_{\max}} \quad (3)$$

$$e_{sT_{\min}} = 0,6108 \times e \left[\frac{(17,27 \times T_{\min})}{(237,3 + T_{\min})} \right] e_{sT_{\min}} \quad (4)$$

b) e_a - pressão parcial de vapor, em KPa

$$e_a = \frac{(U_{r_{med}} \times e_s)}{100} \quad (5)$$

c) s - Declividade da curva de saturação de vapor, em KPa °C⁻¹

$$s = 4098 \times \left[\frac{e_s}{(T + 237,3)^2} \right] \quad (6)$$

d) R_n - radiação líquida, em MJ m⁻² dia⁻¹;

$$R_n = BOC - BOL \quad (7)$$

em que:

$$BOC = (1 - \alpha) \times Rs \quad (8)$$

$$BOL = 4,903 \times 10 - 9 \left[(T_{\max} \times K4 + T_{\min} \times K4) / 2 \right] \left[0,34 - 0,14(e\alpha \times 0,5) \right] \left[1,35 \left(\frac{Rs}{Rso} \right) \right] - 0,35 \quad (9)$$

em que:

$$Rso = (0,75 + 2 \times 10 - 5 \times 11) \times R\alpha \quad (10)$$

Posteriormente, os dados de temperatura mínima, média e máxima do ar e a evapotranspiração potencial em escala diária foram divididos, aleatoriamente, em dois conjuntos, um para o treinamento da rede (139.000) e outro para avaliar a validação da rede treinada (59.613), com uma proporção de cerca de 70% dos dados para treinamento e 30% para validação.

A definição da arquitetura das redes, ou seja, número de neurônios por camada e número de camadas foi otimizada pela ferramenta Intelligent Problem Solver (IPS) do software Statistica 7 (STATSOFT, 2007). O treinamento propriamente dito e a verificação da rede e a validação do processo foram realizadas pelo IPS.

Para prever a evapotranspiração potencial diária foi escolhida a Perceptron Multi-Layer (MLP), é uma Rede Neural Artificial tradicional que possui três estágios: entrada, processamento e saída (Figura 1). Numerosas topologias e variações foram testadas entre os neurônios nas camadas intermediária e externa até que as mais precisas fossem obtidas.

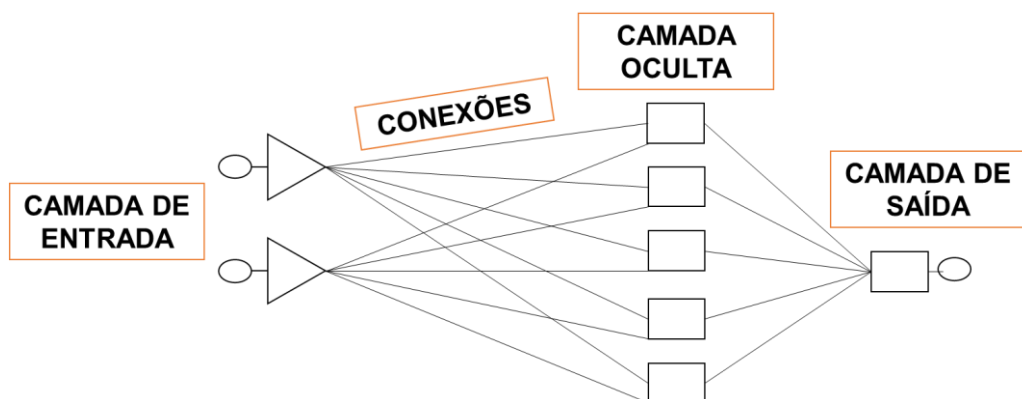


Figura 1. Rede neural *Multilayer Perceptron* (MLP) simplificada.

Matematicamente, um MLP com camadas, H neurônios ocultos e um neurônio de saída podem ser expressos pela Equação 11:

$$Y = SK(\sum Hh = 10hWhWo) \quad (11)$$

em que,

Y é a saída do RNA;

Oh é o valor de saída do h-ésimo neurônio oculto, sendo oh dado pela Equação 12:

$$Oh = Sk(\sum Hh = 1XnhWoh) \quad (12)$$

em que,

Xn é entrada do RNA;

Wh e (Wnh) são os pesos sinápticos entre os neurônios ocultos e as saídas e entradas de RNA, respectivamente, e X0 é 1, W0 e W0h são valores iniciais dos algoritmo de treinamento de RNA.

A função de ativação é o sigmóide logístico dado ela Equação 13:

$$Sk(x) = 1 + e^{-x} \quad (13)$$

Os critérios para avaliar o desempenho da RNA foram exatidão, precisão e tendência. A exatidão foi avaliada por erro absoluto (MAPE%), precisão pelo coeficiente de determinação ajustado (R^2) e tendência por erro sistemático (nas mesmas unidades que os dados originais) (Equações 14 e 16, respectivamente).

$$R^2_{ajustado} = \left[1 - \frac{(1 - R^2) \times (n - 1)}{n - k - 1} \right] \quad (14)$$

$$MAPE = \frac{\sum |Y_{esti} - Y_{obsi}|}{\sum Y_{obsi}} \times 100 \quad (15)$$

$$ES = \frac{\sum (Y_{obsi} - Y_{esti} - c)^2}{2n} \quad (16)$$

em que,

R2 é o coeficiente de determinação (%);

n é o número de dados (anos);

k é o número de variáveis independentes nas regressões;

Yesti é a variável estimada;

Yobsi é a variável observada;

Yest-C é estimada por regressão linear entre as outras variáveis observadas (Yobsi) e estimadas (Yesti).

4. RESULTADOS E DISCUSSÃO

Os valores médios das temperaturas máximas, mínimas e médias do ar nas 16 localidades no período de 1984-2017 foram próximos de 32°C, 24°C e 28°C, respectivamente

(Figura 2). A temperatura máxima da região em alguns momentos dos anos avaliados chegou próximos de 40°C.

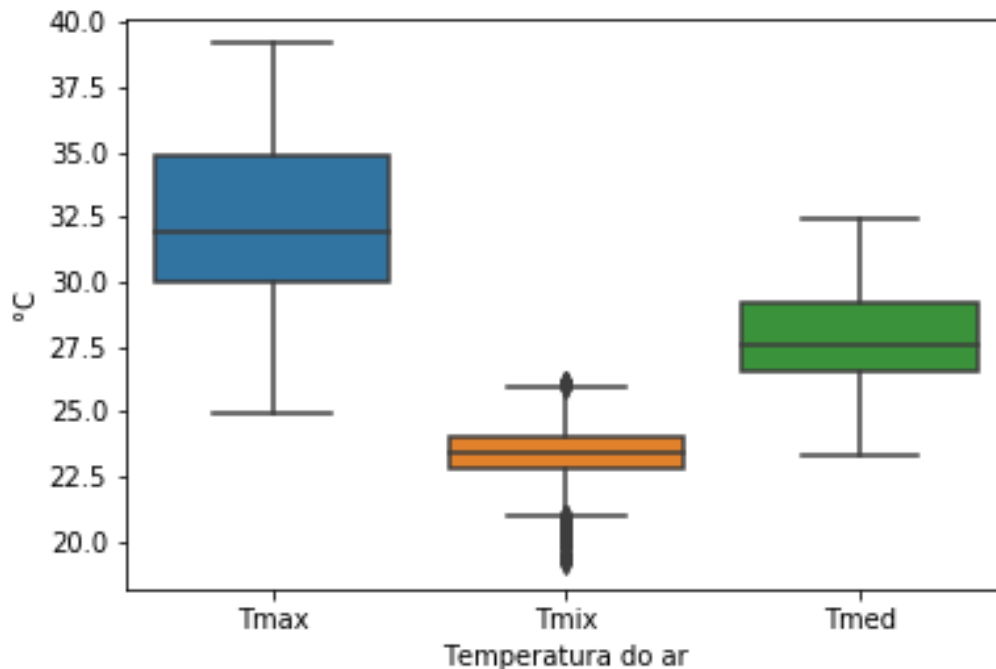


Figura 2. Boxplot com os dados de temperatura máxima, mínima e média do ar diária da microrregião do Baixo Parnaíba no período de 1984-2017.

Os meses com os maiores valores de precipitação foram março e abril. O período de agosto a novembro ocorreu menor precipitação (Figura 3). Em março, a precipitação mensal acumulada apresentou 312 mm, enquanto o mês de setembro apresentou 12 mm. Com relação ao resultado obtido com a precipitação neste trabalho, Primo et al.(2018) encontraram resultado parecido com esse estudo na região de nascentes do alto curso do Rio Acaraú no estado do Ceará, ou seja, os meses de janeiro, fevereiro e março apresentaram um maior índice pluviométrico, ao contrário dos meses de agosto e setembro que tiveram uma menor taxa de precipitação.




Figura 3. Valores médios mensais de precipitação e temperatura do ar da microrregião do Baixo Parnaíba.

O aumento da temperatura do ar na região do Baixo Parnaíba ocorreu a partir de agosto. Entre fevereiro e julho, a temperatura média do ar mensal foi de 26°C.

No período de abril a outubro, há um crescente aumento da evapotranspiração potencial na microrregião do Baixo Parnaíba (Figura 4). Março ocorreu a menor evapotranspiração potencial da região. Já em outubro ocorreu o maior valor de evapotranspiração potencial da região.

Nota-se que o período que apresentou um maior índice de evapotranspiração foi o mesmo que apontou precipitações com um menor volume e temperaturas elevadas. Freitas et al. (2018) observaram que os meses que apresentaram maior precipitação apresentaram também a menor taxa de evapotranspiração, isto foi devido à ocorrência do evento chuvoso, as massas de ar criam uma barreira que dificulta a incidência de radiação solar, em consequência, as taxas de evapotranspiração são reduzidas.




Figura 4. Valores médios de Evapotranspiração Potencial Penman-Monteith da microrregião do Baixo Paraíba.

O modelo de rede neural artificial escolhido para estimativa da evapotranspiração potencial foi a MLP 2-5-1, ou seja, com duas variáveis de entrada, cinco neurônios na camada oculta e uma saída. Entre os modelos apresentados, a MLP 2-5-1 foi a que mais conseguiu expressar de forma simplificada a evapotranspiração potencial pelo método de Penman-Monteith. Isto é porque este método de RNA com múltiplas camadas (MLP) possui uma capacidade de resolver soluções mais complexas (não-linearmente separáveis) do que métodos com apenas uma camada que tem a capacidade de resolver apenas problemas linearmente separáveis. Tabari e Talaei (2013) indicaram que a principal dificuldade na aplicação da equação de PM é devida exigir uma grande variedade de dados meteorológicos para serem usadas como entradas para o cálculo de ETP. Além disso, a ETP é não-linear, o que dificultaria a precisão dos efeitos das alterações dos parâmetros climáticos. Com isto, o uso das técnicas de redes neurais MLP podem apresentar melhores desempenhos, pois consegue resolver equações não-lineares separáveis.

Na análise de sensibilidade das variáveis de entrada da rede neural artificial estudada, a temperatura média e mínima do ar foram as variáveis mais sensíveis na estimativa da evapotranspiração potencial, respectivamente (Tabela 2). Na execução da rede neural no programa o modelo deu peso e classificação para as variáveis. A temperatura máxima foi a que apresentou uma maior sensibilidade, a temperatura média ficou em segundo lugar na análise de sensibilidade e a temperatura mínima não apresentou sensibilidade no modelo, provavelmente ser correlacionada à essas variáveis.

Tabela 2. Análise de sensibilidade.

	Tmáx	Tmin	Tmed
Relação	1.510989	1.148545	-
Classificação	1°	2°	-

A correlação entre a ETP diária por redes neurais e a ETP diária de Penman-Monteith foi forte e positiva (Tabela 3). Se houver o aumento da ETP diária de Penman-Monteith consequentemente ocorrerá o aumento também da ETP diária por redes neurais. A acurácia do modelo foi boa, pois o valor da Média Percentual Absoluta do Erro (MAPE - Mean Absolute Percentage Error) foi baixo.

Tabela 3. Estatística descritiva da Evapotranspiração potencial gerada pela rede neural.

	ETP_RN
Média	0.915375
S.D.	0.435450
Erro médio	0.299765
Erro S.D.	0.135173
MAPE (%)	30
Correlação	0.957475

O processo de treinamento da rede conseguiu explicar 91% da variação dos dados da evapotranspiração potencial de Penman-Monteith a partir da evapotranspiração potencial diária calculada pela rede neural artificial (Figura 5). A sensibilidade média da ETP de Penman-Monteith diária na ETP de redes neurais diária foi $0,8064 \text{ mm dia}^{-1}/\text{mm dia}^{-1}$. A sensibilidade do treinamento de $0,8064 \text{ mm dia}^{-1}/\text{mm dia}^{-1}$ com a média da ETP por rede neural diária de 1 mm representa o aumento de 0,8064 mm para cada 1,40 mm de ETP de Penman-Monteith diária. Assumindo o valor da ETP de Penman-Monteith diária de zero, a ETP diária por redes neurais será $0,1242 \text{ mm dia}^{-1}$.

O treinamento é uma das etapas importantes das redes neurais artificiais, pois são feitos alguns ajustes nos pesos para que a rede possa organizar de forma correta as entradas apresentadas para que o resultado corresponda com valor desejado para cada vetor de entrada.

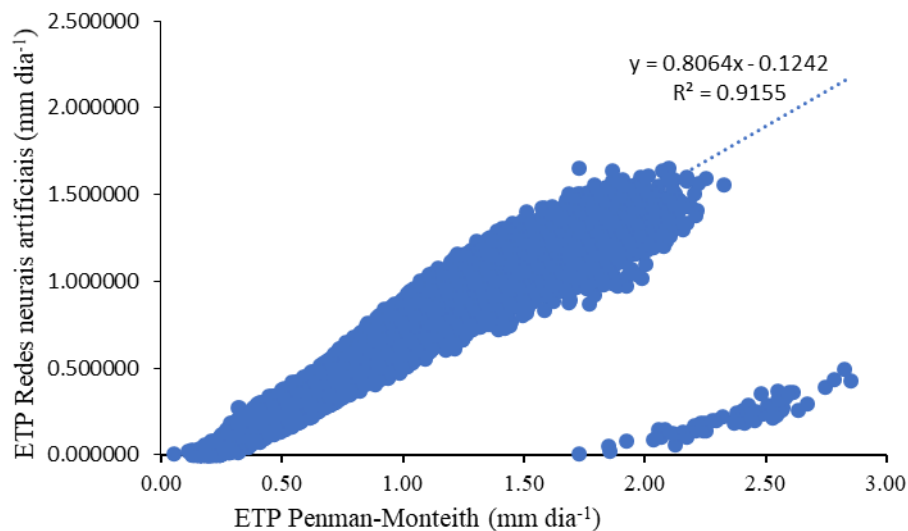


Figura 5. Treinamento da rede neural

Na validação dos dados de evapotranspiração potencial, a rede neural conseguiu explicar 92% da variação total dos dados observados (Figura 6). Os resultados da validação (generalização) do modelo foram parecidos com o de treinamento.

Na validação separa o conjunto de dados em um conjunto de treinamento que é usado apenas para derivar os parâmetros que minimizam a função de perda e um conjunto de validação que é usado apenas para avaliar o desempenho do modelo (JAHN, 2018). Após cada iteração, a sessão de treinamento é interrompida visando verificar o erro.

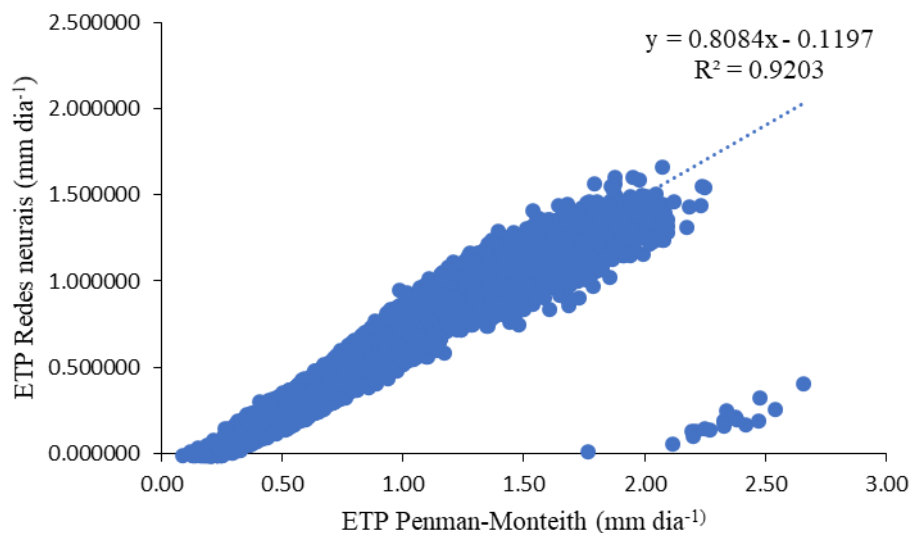


Figura 6. Validação da rede neural.

5. CONCLUSÕES

As redes neurais artificiais podem ser utilizadas para a estimativa da evapotranspiração potencial diária.

As temperaturas mínima e máxima do ar foram as variáveis mais sensíveis do modelo ML 5-2-1.

Esse estudo contribuirá para as futuras pesquisas sobre a eficiência do uso da água na produção agrícola do estado do Maranhão.

6. REFERENCIAS BIBLIOGRAFICAS

ABDULLAHI, J.; ELKIRAN, G.; NOURANI, V. Application of Artificial Neural Network to predict reference evapotranspiration in Famagusta, North Cyprus. In: **11th International Scientific Conference on Production Engineering Development And Modernization of Production**. 2017. p. 549-554.

AKHTAR, Aly et al. Prediction and analysis of pollution levels in Delhi using multilayer perceptron. In: **Data Engineering and Intelligent Computing**. Springer, Singapore, 2018. p. 563-572.

ALLEN, R.G.; PEREIRA, L.S.; RAES, D.; SMITH, M. Crop evapotranspiration: guidelines for computing crop water requirements. Rome: FAO, 1998. (Irrigation and Drainage Paper, n. 56).

ANDRADE JUNIOR, Aderson Soares et al. Avaliação de métodos para estimativa da evapotranspiração de referência no estado do Piauí. **Agrometeoros**, v. 25, n. 1, 2018.

ARMANI, Fernando Augusto Silveira; DE FREITAS, Lucas Araujo; MOREIRA, Virnei Silva. Avaliação do método de turc para a estimativa da evapotranspiração de um ambiente litorâneo. **Revista Técnico-Científica**, n. 14, 2018.

BORGES, P. H. M. et al. Estimation of Fuel Consumption in Agricultural Mechanized Operations Using Artificial Neural Networks. *Eng. Agríc., Jaboticabal*, v. 37, n. 1, p. 136- 147, Feb. 2017.

CARTER, Corinne; LIANG, Shunlin. Evaluation of ten machine learning methods for estimating terrestrial evapotranspiration from remote sensing. **International Journal of Applied Earth Observation and Geoinformation**, v. 78, p. 86-92, 2019.

CERRI, Ricardo et al. Aprendizado de máquina: breve introdução e aplicações. **Cadernos de Ciência & Tecnologia**, v. 34, n. 3, p. 297-313, 2019.

CONTI, Giuvane; WIGGERS, Kelly Lais; RIBEIRO, Selma Regina Aranha. Representação em malhas 3d a partir de dados de textura do solo interpolados mediante rede neural artificial: estudo de caso fescon-ponta grossa–pr. **Geo UERJ**, n. 28, p. 410-429, 2016.

COSTA, Juliana Alcântara et al. Avaliação de métodos de estimativa da evapotranspiração de referência para Alagoas. **Agrometeoros**, v. 25, n. 1, 2018.

DAI, Xiaoqin et al. Artificial neural network models for estimating regional reference evapotranspiration based on climate factors. **Hydrological Processes: An International Journal**, v. 23, n. 3, p. 442-450, 2009.

DE OLIVEIRA, Vinicius Mendes Rodrigues et al. Estimativa de evapotranspiração de referência na região de Rio Paranaíba-MG. **Irriga**, v. 20, n. 4, p. 790, 2018.

DI DOMENICO, Camila Nicola Boeri; DA SILVA, Fernando José Neto; FERREIRA, Jorge Augusto Fernandes. O uso de redes neurais artificiais na otimização do processo de secagem convectiva de alimentos e redução do consumo energético. **ÁGORA Revista Eletrônica**, n. 24, 2017.

DI DOMENICO, Camila Nicola Boeri; DA SILVA, Fernando José Neto; FERREIRA, Jorge Augusto Fernandes. O uso de redes neurais artificiais na otimização do processo de secagem convectiva de alimentos e redução do consumo energético. **ÁGORA Revista Eletrônica**, n. 24, 2017.

DO CARMO, Elisa C. Werneck et al. Monitoramento de partículas em caldeira de recuperação kraft por machine learning. **O PAPEL**, v. 79, n. 6, p. 83-89, 2018.

DOS SANTOS, Luiz Fernando; MARTINS, Fabrina Bolzan; GARCIA, Sâmia Regina. Padrões climatológicos de precipitação e temperatura do ar associados ao rendimento do feijão comum em Minas Gerais. **Revista Brasileira de Climatologia**, v. 1, 2018.

FENG, Yu et al. Estimation of soil temperature from meteorological data using different machine learning models. **Geoderma**, v. 338, p. 67-77, 2019.

FERREIRA, Jéssica Cristina Barbosa et al. ALTURA DE MUDAS DA *Tibouchina granulosa* COGN.(MELASTOMATACEAE) ESTIMADA POR REDES NEURAIIS ARTIFICIAIS. **Revista da Sociedade Brasileira de Arborização Urbana**, v. 9, n. 1, p. 151-160, 2019.

FREITAS, Pedro Alisson et al. Evapotranspiração de referência diária por diferentes modelos na bacia hidrográfica do Rio Capibaribe (Pernambuco-Brasil). **Revista Brasileira de Meio Ambiente**, v. 4, n. 1, 2018.

GOMES, Daniela Pinto et al. Estimativa da temperatura do ar e da evapotranspiração de referência no estado do Rio de Janeiro. **Irriga**, v. 19, n. 2, p. 302, 2018.

GÖRGENS, E. B. et al. A performance comparison of machine learning methods to estimate the fast-growing forest plantation yield based on laser scanning metrics. **Computers and Electronics in Agriculture**, v. 116, n. 1, p. 221-227, 2015. DOI: 10.1016/j.compag.2015.07.004

GRANATA, Francesco. Evapotranspiration evaluation models based on machine learning algorithms—A comparative study. **Agricultural Water Management**, v. 217, p. 303-315, 2019.

GUSSO, Anibal. Integração de imagens NOAA/AVHRR: Rede de cooperação para monitoramento nacional da safra de soja. **Ceres**, v. 60, n. 2, 2015.

JAHN, Malte. **Artificial neural network regression models: Predicting GDP growth**. HWWI Research Paper, 2018.

JIANG, Wei et al. Multilayer perceptron neural network for surface water extraction in Landsat 8 OLI satellite images. **Remote Sensing**, v. 10, n. 5, p. 755, 2018.

LAFETÁ, Bruno Oliveira et al. Eficiência de utilização de macronutrientes em eucalipto por método não destrutivo estimados por redes neurais artificiais. **Ciência Florestal**, v. 28, n. 2, p. 613-623, 2018.

LOSCHEN, Christoph. Perception of Chemical Bonds via Machine Learning. 2018.

MINUZZI, Rosandro Boligon et al. Estimativa da evapotranspiração de referência diária por Penman-Monteith FAO com dados de temperatura do ar para Santa Catarina. **Irriga**, v. 19, n. 4, p. 548, 2018.

NUNES, Ricardo Tocantins Modugno. CÁLCULO PREDITIVO DE CLASSIFICAÇÃO DAS NOTAS DO ENADE UTILIZANDO REDES NEURAS ARTIFICIAIS. **Revista de Tecnologia Aplicada**, v. 7, n. 2, 2018.

PAIVA, Célia Maria; DE SOUZA, Alexandre da Silva Pinheiro. Avaliação de Métodos de Estimativa da Evapotranspiração de Referência para Fins de Manejo da Irrigação. **Anuário do Instituto de Geociências**, v. 39, n. 1, p. 42-51, 2016.

PATIL, A.P., DEKA, P.C. An extreme learning machine approach for modeling evapotranspiration using extrinsic inputs. **Comput. Electron. Agr.** 121, 385–392, 2016.

POHLMANN, Valeria; LAZZARI, Marcondes. Caracterização climática de Cachoeira do Sul, RS quanto à temperatura do ar. **Revista Eletrônica Científica da UERGS**, v. 4, n. 5, p. 643-650, 2018.

PRIMO, Daniele Freitas; TREVISAN, Diego Peruchi; DUARTE, Rogério Teixeira. Análise comparativa de métodos de estimativa de evapotranspiração para fins agrícolas na região de São Carlos-SP. **Revista Brasileira de Iniciação Científica**, v. 6, n. 1, p. 13-32, 2018.

Reis, L. P. et al. Estimation of mortality and survival of individual trees after harvesting wood using artificial neural networks in the amazon rain forest. **Ecological Engineering**, v. 112, n.1, p.140-147, 2018. DOI:10.1016/j.ecoleng.2017.12.014

SAMADI, S. Zahra. Assessing the sensitivity of SWAT physical parameters to potential evapotranspiration estimation methods over a coastal plain watershed in the southeastern United States. **Hydrology Research**, v. 48, n. 2, p. 395-415, 2017.

SANTOS, Anderson Amorim Rocha et al. Evapotranspiração de referência em função dos extremos da temperatura do ar no estado do Rio de Janeiro. **Irriga**, v. 21, n. 3, p. 449, 2018.

SILVA, Jeferson Pereira Martins et al. Redes neurais artificiais para estimar a densidade básica de madeiras do cerrado. **Pesquisa Florestal Brasileira**, v. 38, 2018.

SILVA, Julianna Catonio et al. Evapotranspiração e coeficiente de cultura da cenoura irrigada no agreste alagoano. **Revista Ceres**, v. 65, n. 4, p. 297-305, 2018.

STACKHOUSE PW Jr., Chandler WS, Zhang T, Westberg D, Barnett AJ, Hoell JM. 2016. **Surface Meteorology and Solar Energy (SSE) Release 6.0 Methodology**. Version 3.2.0. <https://eosweb.larc.nasa.gov/sse/documents/SSE6Methodology.pdf>. Acesso em: 22 de maio de 2019

TABARI, Hossein; TALAEI, P. Hosseinzadeh. Multilayer perceptron for reference evapotranspiration estimation in a semiarid region. **Neural Computing and Applications**, v. 23, n. 2, p. 341-348, 2013.

TANG, Xiao; ZHANG, Lei; DING, Xiaoli. SAR image despeckling with a multilayer perceptron neural network. **International journal of digital earth**, v. 12, n. 3, p. 354-374, 2019.

XU, Tongren et al. Evaluating different machine learning methods for upscaling evapotranspiration from flux towers to the regional scale. **Journal of Geophysical Research: Atmospheres**, v. 123, n. 16, p. 8674-8690, 2018.

ZANETTI, Sidney Sara et al. Calibração da equação de hargreaves-samani para estimar a evapotranspiração de referência no estado do Espírito Santo. **Revista Brasileira de Agricultura Irrigada-RBAI**, v. 12, n. 3, p. 2692-2701, 2018.