



**Universidade Federal da Paraíba**  
**Centro de Ciências Agrárias**  
**Graduação em Ciências Biológicas**

**ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA  
ATRAVÉS DE REDES NEURAS ARTIFICIAIS**

**ANTONIO ISMAEL FILHO**

AREIA – PB

2015

**ANTONIO ISMAEL FILHO**

**ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA  
ATRAVÉS DE REDES NEURAS ARTIFICIAIS**

**Trabalho de Conclusão de Curso  
apresentado na Universidade  
Federal da Paraíba como requisito  
básico para a conclusão do Curso de  
Licenciatura em Ciências Biológicas.**

AREIA – PB

2015

**ANTONIO ISMAEL FILHO**

**ESTIMATIVA DA EVAPOTRANSPIRAÇÃO DE REFERÊNCIA  
ATRAVÉS DE REDES NEURAS ARTIFICIAIS**

**Trabalho de Conclusão de Curso  
apresentado na Universidade  
Federal da Paraíba como requisito  
básico para a conclusão do Curso de  
Licenciatura em Ciências Biológicas.**

Aprovado em 14 de Dezembro de 2015

**Banca Examinadora**



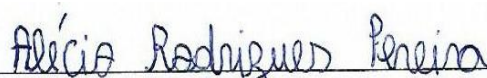
---

**Dr. Péricles de Farias Borges — Orientador**  
Professor do DCFS/CCA/ UFPB



---

**Dr. Lázaro de Souto Araújo — Membro**  
Professor do DCFS/CCA/ UFPB



---

**Alécio Rodrigues Pereira – Membro**  
Mestrando UFCG/DCA

## **DEDICATÓRIA**

*Dedico este trabalho a minha esposa Taís Machado da Silva*

*A minha mãe Ivonete Paulino Teixeira*

*A minha irmã Almênia*

*Aos demais familiares*

*Aos meus amigos*

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus por ter me abençoado durante todo o período Acadêmico

Agradeço a minha mãe **Ivonete Paulino Teixeira** por sempre me incentivar nos estudos

A minha esposa **Taís Machado da Silva** que sempre me apoiou e auxiliou com muito amor  
quando necessitei

Ao professor **Péricles de Farias Borges** que me orientou desde quando ingressei na UFPB, se tornando durante esse período um grande amigo.

Aos meus **amigos** que fiz durante o período em que cursei minha graduação e que tornaram os momentos difíceis mais amenos

A **Universidade Federal da Paraíba** que me concedeu a oportunidade de estudar

## SUMÁRIO

RESUMO .....	7
ABSTRACT .....	8
1. INTRODUÇÃO.....	9
2. REVISÃO BIBLIOGRÁFICA.....	11
2.1 Evapotranspiração de Referência.....	11
2.2 Estimativa da Evapotranspiração.....	12
2.3 Redes Neurais Artificiais .....	13
2.4 Evapotranspiração estimada por RNA.....	16
3. MATERIAL E MÉTODOS.....	17
3.1 Descrição do local e dos dados .....	17
3.2 Softwares utilizados.....	17
3.2 Obtenção da $ET_0$ .....	17
3.3 Características e Modelagem da Rede Neural .....	18
3.4 Ferramentas de avaliação de desempenho da RNA.....	20
4. RESULTADOS E DISCUSSÕES.....	23
5. CONCLUSÕES.....	27
6. REFERÊNCIAS BIBLIOGRÁFICAS .....	28

## RESUMO

Este trabalho foi realizado com os dados climáticos diários de temperatura do ar máxima e mínima, radiação solar, velocidade do vento, e umidade relativa do ar máxima e mínima, referente a cidade Areia - Paraíba, coletados junto ao banco de dados do Instituto Nacional de Meteorologia (INMET), após a coleta foi calculado a evapotranspiração de referência pelo método padrão de Penman-Monteith no período entre 2008 e 2012, tendo por objetivo utilizar das redes neurais artificiais para estimar a  $ET_0$  bem como avaliar seu desempenho, utilizou-se do MATLAB para criar o modelo de RNA com arquitetura [6-7-1]. A fase de treinamento foi usada as variáveis climáticas de 2008 a 2011 como dados de entrada e a  $ET_0$  como dado de saída, e para testar a rede foi usada os dados climáticos de 2012 como entrada para a predição da  $ET_0$ , todos os dados de entrada da rede foram normalizados no intervalo de  $[-1, 1]$ . Foram obtidos excelentes resultados comparando a  $ET_0$  obtida na rede em relação a  $ET_0$  pelo método padrão, com o erro relativo percentual de 0,5%, o SSE de 0,003, MSE de 0,054, o coeficiente de determinação  $r^2$  foi de 0,9966, o coeficiente de exatidão  $d$  de 0,955 e o coeficiente de desempenho  $c$  de 0,953 que é classificado como ótimo por CAMARGO e SENTELHAS (1997), mostrando que é possível obter resultados de boa qualidade utilizando as RNAs para estimativa da evapotranspiração de referência.

**Palavras-Chaves:** Redes Neurais, Evapotranspiração, Variáveis Climáticas.

## ABSTRACT

This work was carried out with the daily weather data of the maximum and minimum air temperature, solar radiation, wind speed, and relative humidity of maximum and minimum air concerning the city Areia - Paraíba, collected from the database of the Instituto Nacional de Meteorologia (INMET) after collection was estimated reference evapotranspiration by the standard Penman-Monteith in the period between 2008 and 2012, with the objective use of artificial neural networks to estimate  $ET_0$  and evaluate their performance, we used the MATLAB to create the RNA template with architecture [6-7-1]. The training phase was used climate variables from 2008 to 2011 as input data and  $ET_0$  as output data, and to test the network was used the 2012 climate data as input to the prediction of  $ET_0$ , all input data network were normalized in the range [-1, 1]. Excellent results were obtained by comparing the obtained  $ET_0$  the network from  $ET_0$  by the standard method with the relative error rate of 0.5%, 0.003 SSE, MSE 0.054, the coefficient of determination  $r^2$  was 0.9966, the d accuracy coefficient of 0.955 and performance coefficient c of 0.953 which is classified as excellent by CAMARGO and Sentelhas (1997), showing that it is possible to obtain good quality results using the RNAs to estimate the reference evapotranspiration.

**Key Words:** Neural Networks, Evapotranspiration, Climate Variables.



## 1. INTRODUÇÃO

Segundo a ALLEN et al (1998), a evapotranspiração ( $ET_0$ ) pode ser denominada como a combinação de dois processos, por um lado a evaporação que é a perda de água do solo para atmosfera e por outro lado a transpiração que é a perda de água da cultura (vegetação).

O conhecimento da evapotranspiração é de fundamental importância em atividades ligadas à gestão de bacias hidrográficas, em modelagem meteorológica e hidrológica e, sobretudo, no manejo hídrico da agricultura irrigada (BEZERRA et al., 2008).

Informações da quantidade de água evaporada e ou evapotranspirada são necessárias em diversos estudos hidrológicos e para adequado planejamento e manejo. O conhecimento da evapotranspiração é essencial para estimar a quantidade de água requerida para irrigação. O conhecimento do consumo de água nas diversas etapas de desenvolvimento das plantas cultivadas permite que a administração da irrigação seja feita de forma mais racional, de acordo com a real exigência da cultura. Esse conhecimento também tem a sua importância na agricultura não irrigada, pois permite o planejamento de épocas de semeadura em função da disponibilidade hídrica média da região considerada, permitindo maior eficiência no aproveitamento das precipitações (MELLO & SILVA, 2007).

Nas duas últimas décadas os avanços tecnológicos na área de eletrônica e automação apresentaram substancial desenvolvimento, permitindo o monitoramento das mais diversas variáveis em tempo real e com níveis de precisão até então não experimentados; e os sensores eletrônicos passaram a apresentar duas características distintas: maior resolução/precisão e menor tamanho (Souza et al., 2002).

Na ausência de equipamentos para medição da evapotranspiração dos cultivos, os pesquisadores, muitas vezes, lançam mão de estimativas baseadas na evapotranspiração de referência e no coeficiente de cultura ( $K_c$ ) (Medeiros et al., 2003).

O método Penman-Monteith (PM) é considerado pela FAO, *Food and Agriculture Organization*, como método empírico mais apropriado para calcular a evapotranspiração que já vem sendo usado a décadas, representando de maneira consistente o fenômeno da evapotranspiração no qual utiliza-se vários elementos meteorológicos observados nas estações tais como temperatura, radiação, velocidade do vento, umidade relativa do ar entre outros. Atualmente a Inteligência Artificial (IA) tem sido bastante utilizadas nas várias áreas das ciências até mesmo na de recursos hídricos. As Redes Neurais Artificiais (RNAs) são sistemas inteligentes que tem demonstrado eficácia na estimativa da evapotranspiração.

Para as áreas irrigadas, é de grande importância o conhecimento dos métodos simples de estimativa da evapotranspiração, que demandam dados de fácil obtenção e de baixo custo, porém com confiabilidade local razoável para a adoção de um manejo adequado de irrigação (BONOMI, 1999).

O monitoramento do consumo de água, tendo como referência o solo e a planta, ainda não são muito aplicáveis às condições de campo, seja pela falta de representatividade de alguns métodos, por utilizar sistemas pontuais de medição, seja devido ao custo elevado dos equipamentos, ou pela demanda elevada de mão de obra para realizar as medições (SUGAWARA, 2008).

O objetivo deste trabalho foi estimar a evapotranspiração de referência utilizando uma rede neural artificial desenvolvida no MATLAB, com dados meteorológicos de velocidade do vento, radiação, temperatura máxima e mínima, umidade relativa do ar máxima e mínima tendo como parâmetro a  $ET_0$  calculada pelo método Penman-Monteith e avaliar seu desempenho.

## **2. REVISÃO BIBLIOGRÁFICA**

### **2.1 Evapotranspiração de Referência**

A combinação de dois processos distintos por meio dos quais ocorre a perda de água, de um lado pela superfície do solo devido à evaporação e de outro pela cultura por meio da transpiração, é referida como evapotranspiração (ET). Evaporação é o processo por meio do qual a água líquida é convertida em vapor (vaporização) e removida da superfície evaporante (remoção de vapor). Água evapora de uma variedade de superfícies, como lagos, rios, pavimentos, solos e vegetação molhada. Transpiração consiste na vaporização da água líquida contida nos tecidos das plantas e a remoção do vapor à atmosfera. Predominantemente as culturas perdem a água pelos estômatos. Estes são aberturas pequenas na folha da planta pelo qual ocorre a passagem dos gases e de vapor de água (ALLEN et al., 1998).

A evapotranspiração é um fenômeno complexo e não linear, pois depende da interação entre os vários elementos climáticos, tais como radiação solar, velocidade do vento, temperatura e umidade do ar (KUMAR et al., 2002).

Quanto à evapotranspiração de referência ( $ET_0$ ), o conceito refere-se a uma cultura hipotética que se assemelha a um gramado, em crescimento ativo e mantida a uma altura uniforme de 0,12m, sombreando completamente o terreno e sem escassez de água (ALLEN et al., 1998).

Conforme SETTI et al (2001), para o acompanhamento, análise e gerenciamento dos recursos hídricos, é fundamental a medição regular dos principais elementos que controlam o ciclo hidrológico para a determinação da quantidade de água disponível, e assim, otimizar o seu uso. Os principais elementos são a precipitação, a evapotranspiração, o escoamento e o armazenamento da água no solo, aquíferos, represas e geleiras.

Outro fator importante do processo de evapotranspiração é que através do balanço de vapor d'água em toda a região Amazônica, SALATI et al. (1979) determinou que a precipitação na região é uma composição da quantidade de água evaporada localmente (evapotranspiração) adicionada de uma contribuição de água advinda do Oceano Atlântico. Desta maneira, pode-se estimar que 50 % do vapor d'água que precipita pelas chuvas são gerados localmente (pela evapotranspiração), sendo o restante importado para a região pelo fluxo atmosférico proveniente do Oceano Atlântico.

## 2.2 Estimativa da Evapotranspiração

Para o manejo adequado da água de irrigação é necessário o monitoramento da umidade do solo e/ ou da evapotranspiração durante a maior parte do ciclo de desenvolvimento da cultura. Para tanto, é indispensável o conhecimento de parâmetros relacionados às plantas, ao solo e ao clima, para determinar o momento oportuno de irrigar e a quantidade de água a ser aplicada (SILVA & MAROUELLI, 1998).

A determinação da  $ET_0$  pode ser realizada por meio de métodos de estimativa (indiretos). Dentre os modelos indiretos, a Organização das Nações Unidas para Alimentação e Agricultura (FAO) recomenda o uso do método de FAO-Penman-Monteith como método padrão (ALLEN et al., 1998).

Existem muitas maneiras de medir a evapotranspiração, mas, devido aos altos custos dos equipamentos, tais técnicas quase sempre se restringem à pesquisa (Pereira et al., 1997).

Como alternativa para solucionar este problema, destaca-se o uso dos métodos empíricos de estimativa da  $ET_0$ , os quais, por serem desenvolvidos e calibrados com dados locais, não podem ter aplicação universal, porém apresentam melhores resultados do que aqueles mais genéricos e fisicamente mais reais (Pereira et al., 1997).

PEREIRA et al. (1997) mencionam que os métodos de obtenção da evapotranspiração real estão divididos em métodos diretos e indiretos. Os diretos determinam diretamente a evapotranspiração por meio de lisímetros, balanço hídrico e controle da umidade do solo. Os indiretos estimam a evapotranspiração real por meio da evapotranspiração de referência ( $ET_0$ ) e do coeficiente de cultivo ( $K_c$ ), necessitando de dados meteorológicos para o cálculo da  $ET_0$ .

Existem métodos diretos e indiretos para o cálculo da evapotranspiração. Os métodos indiretos geralmente se baseiam em fórmulas que combinam diferentes elementos climáticos. Segundo PEREIRA et al., (1997), a evapotranspiração pode ser estimada a partir de uma série de modelos, tais como: THORNTHWAITE (1948), MONTEITH (1965), RADIAÇÃO SOLAR (DOORENBOS & PRUITT, 1977), HARGREAVES (1977), BLANEY-CRIDDLE (1977), PENMAN-MONTEITH (ALLEN et al., 1998), entre vários outros (MENDES, 2006).

Para padronização dos procedimentos de cálculo da evapotranspiração da cultura de referência, baseando-se na equação de Penman-Monteith, a FAO propôs a seguinte notação, que passou a ser conhecida como equação de Penman-Monteith-FAO (MELLO & SILVA, 2007).

$$ET_0 = \frac{0,408\Delta(Rn - G) + \gamma \frac{900}{T + 273} U_2(es - ea)}{\Delta + \gamma(1 + 0,34U_2)}$$

**Equação 1** - Equação de Penman-Monteith.

em que:  $R_n$  é a radiação líquida na superfície da planta (MJ m<sup>2</sup> por dia);  $G$  é a densidade de fluxo de calor no solo (MJ m<sup>2</sup> por dia);  $T$  é a temperatura média do ar a 2 m de altura (°C);  $U_2$  é a velocidade do vento a 2 m de altura (m s<sup>-1</sup>);  $e_s$  é a pressão de saturação de vapor (kPa), obtida pela média entre  $T_{máx}$  e  $T_{mín}$ ;  $e_a$  é a pressão atual de vapor (kPa);  $\Delta$  é a declividade da curva de pressão de vapor (kPa °C<sup>-1</sup>);  $\gamma$  é a constante psicrométrica (kPa °C<sup>-1</sup>); e 0,408 é o fator de conversão para o termo ( $R_n - G$ ), de MJ m<sup>2</sup> por dia para milímetro por dia.

A equação de Penman-Monteith é uma representação bem próxima e simples dos fatores físicos e fisiológicos que governam o processo da evapotranspiração (ALLEN et al., 1998).

### 2.3 Redes Neurais Artificiais

As redes neurais artificiais (RNAs) são sistemas paralelos distribuídos, compostos de unidades simples de processamento, que calculam determinadas funções matemáticas. Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões. Na maioria dos modelos, essas conexões estão associadas a pesos os quais, após o processo de aprendizagem, armazenam o conhecimento adquirido pela rede. O funcionamento dessas redes é inspirado em uma estrutura biológica concebida pela natureza: o cérebro humano (BRAGA et al., 2000; HAYKIN, 2001; KOVÁCS, 2002).

As características, em muitos aspectos complementares às associadas à abordagem simbólica, que tornam a aplicação de redes neurais artificiais interessantes do ponto de vista da solução de problemas, são as seguintes (BITTENCOURT, 2006):

- Capacidade de “aprender” através de exemplos e de generalizar este aprendizado de maneira a reconhecer instâncias similares que nunca haviam sido apresentadas como exemplo;
- Bom desempenho em tarefas mal definidas, onde falta o conhecimento explícito sobre como encontrar uma solução;
- Não requer conhecimento a respeito de eventuais modelos matemáticos dos domínios de aplicação;

– Elevada imunidade ao ruído, isto é, o desempenho de uma rede neural artificial não entra em colapso em presença de informações falsas ou ausentes, como é o caso nos programas convencionais, mas piora de maneira gradativa;

– Possibilidade de simulação de raciocínio “a priori” e impreciso.

As características que definem uma rede neural são: arquitetura, algoritmo de aprendizado e funções de ativação. O desenvolvimento de um modelo baseado em redes neurais implica justamente a definição dessas características (IRIGOYEN, 2010).

As RNA são capazes de mapear relações desconhecidas entre dados de entrada e saída sem conhecimento prévio do processo investigado. Esse mapeamento é alcançado através do ajuste dos parâmetros internos (pesos sinápticos) e bias da rede. Esse processo é denominado aprendizagem ou treinamento. A generalização se refere ao fato de a rede neural artificial produzir saídas adequadas para entradas que não estavam presentes durante o treinamento. Assim, a aplicação das RNA em processos e relações complexas as fazem bastante úteis em diferentes tipos de problemas modernos (TALEB et al., 2009).

Existem dezenas de diferentes modelos de RNA descritos na literatura, tais como MLP, Redes de função de Base Radial (RBF), Redes de Função Sample (SFNN), Redes de Fourier e Redes Wavelet. À primeira vista, o processo de seleção pode parecer uma tarefa difícil diante do número de possibilidades, porém é provável que poucos modelos forneçam uma solução excelente (MASTERS, 1994).


Existem três tipos de camadas: de entrada (recebe os dados ou sinais do entorno), de saída com neurônios que proporcionam a resposta do modelo e, ocultas ou intermediárias. Conforme o sentido do fluxo de informação, as redes podem ser unidirecionais (“feedforward”) ou recorrentes ou realimentadas (“feedback”) (IRIGOYEN, 2010).

O tipo mais utilizado de rede neural é a MLP treinada com o algoritmo backpropagation (BP) ou retropropagação do erro (PATNAIK & MISRA, 2008). Para treinar a rede são utilizados vetores de entrada associados aos seus respectivos vetores de saída desejada, até que a rede aproxime uma determinada função e possa, a partir daí, oferecer saídas adequadas a vetores de entrada diferentes daqueles com os quais foi treinada. O backpropagation padrão é um algoritmo gradiente descendente, por meio do qual os pesos das conexões entre os neurônios são atualizados ao longo de um gradiente descendente de uma determinada função. O termo backpropagation refere-se à forma como o gradiente é calculado para redes de múltiplas camadas não lineares (SOARES & SILVA, 2011).

Três tipos de aprendizado podem ser descritos: a) aprendizado supervisionado (são fornecidos integralmente os resultados desejados), b) aprendizado por reforço (quando apenas um parâmetro externo de comparação é fornecido) e, c) aprendizado não-supervisado (quando a própria rede é capaz de ajustar o seu funcionamento ou auto-organização) (IRIGOYEN, 2010).

Existem algumas variantes de métodos de segunda ordem, como o algoritmo de Levenberg-Marquardt ou o algoritmo conjugado de retropropagação de erros, que podem ser mais eficientes desde o ponto de vista computacional (MAIER & DANDY, 2000).

Conforme IRIGOYEN, 2010, diversos tipos de função de ativação (lineares e não lineares) têm sido utilizados em redes neurais, sendo as mais comuns em redes do tipo “multiperceptron“ como mostra a Figura 1.



**Figura 1** - Tipos de funções de ativação de redes neurais. a. Linear. b. Degrau (Tansig). c. Tangente hiperbólica d. Logística. Fonte: IRIGOYEN, 2010.

Aplicações de redes neurais são inúmeras, tais como: aproximação de funções, reconhecimento de padrões, prognóstico médico, prognóstico de mercados financeiros, controle de processos industriais, aplicações climáticas, robótica, análise e processamento de sinais, dentre outras (LIMA, 2010).

## 2.4 Evapotranspiração estimada por RNA

Na agricultura, as redes neurais artificiais estão sendo inseridas significativamente em diversas aplicações. Vários pesquisadores realizaram trabalhos utilizando RNAs com a finalidade de estimar a evapotranspiração em função de elementos climáticos (ODHIAMBO et al., 2001; KUMAR et al., 2002; SILVA, 2002; SUDHEER et al., 2003; TRAJKOVIC et al., 2003; ARCA et al., 2004; ZANETTI et al., 2008).

Na estimativa da evapotranspiração pode-se utilizar sistemas inteligentes, como Rede Neural Artificial (RNA), produzindo resultados confiáveis (KUMAR et al., 2002; SILVA, 2002; ZANETTI et al., 2007; LANDERAS et al., 2008; ZANETTI et al., 2008; ABRAHART et al., 2009).

Sudheer et al. (2003 apud ZANETTI et al., 2008) utilizaram três opções de dados de entrada para estimar a  $ET_0$  a partir de dados de temperatura média do ar, umidade relativa, velocidade do vento e duração do brilho solar, porém com uma série de dados restrita a poucos dias do ano; na opção mais simplificada, a  $ET_0$  foi estimada em função apenas da temperatura média do ar e da data correspondente à sua ocorrência. Resultados satisfatórios foram obtidos na estimação da  $ET_0$  usando-se RNAs associadas com poucos dados de entrada, entretanto, os autores ressaltam a necessidade de se realizar outros estudos utilizando maior número de dados visando reforçar as conclusões obtidas.

Zanetti et al. (2008) treinaram uma RNA para estimar a evapotranspiração em 17 localidades do estado do Rio de Janeiro, utilizando dados de temperaturas máxima e mínima do ar e das coordenadas geográficas do local. Concluíram que a RNA pode ser utilizada com segurança para essa estimativa. Segundo os autores, a vantagem do método proposto está na utilização de registros diários das temperaturas máxima e mínima do ar, fato que possibilita estimar a  $ET_0$  com a simples utilização de um termômetro de máxima e de mínima (SOBRINHO et al, 2011).

KHOOB (2008) concluiu que a  $ET_0$  pode ser obtida com eficiência a partir de RNA e ser utilizada quando a umidade relativa, a radiação solar e dados de velocidade do vento não são disponíveis. SILVA et al. (2006) concluíram que as RNA apresentam potencial para serem utilizadas na previsão da  $ET_0$  de forma eficiente.



### **3. MATERIAL E MÉTODOS**

#### **3.1 Descrição do local e dos dados**

Foram coletados dados meteorológicos referente à cidade de Areia, no estado da Paraíba, (latitude de 6°58'12 Sul e longitude de 35°42'15" Oeste de Greenwich e altitude de 534 metros), cujo clima da região é classificado como As (Tropical quente e úmido), de acordo com a classificação de Köppen. A precipitação pluviométrica média é de 1.500 mm ano<sup>-1</sup>, a umidade relativa do ar mantém-se em torno de 80% e a temperatura média anual oscila de 22 a 26°C (BRASIL,1972).

Foram utilizados 5 séries históricas de elementos climáticos compreendidos no período de 2008 a 2012, coletadas a partir do banco de dados do Instituto Nacional de Meteorologia (INMET) referente a Estação Meteorológica do Centro de Ciências Agrárias da Universidade Federal da Paraíba, em Areia-PB. Os dados são de radiação solar, temperaturas máximas e mínimas, velocidade do vento e umidade relativa do ar máxima e mínima, todos em valores diários, vale lembrar que são dados de uma estação automática.

#### **3.2 Softwares utilizados**

O cálculo da evapotranspiração de referência será feito por intermédio do software *PMday*, desenvolvido com base em planilhas do Excel, que utiliza os métodos de Penman-Monteith a uma superfície de referência de 0,12 m e a 0,50 m e Hargreaves e Samani. Este software pertence à Universidade da Califórnia – EUA, desenvolvido por Richard L. Snyder e S. Eching. Para o presente estudo utilizou-se as variáveis climáticas de radiação solar, temperatura máxima e mínima, velocidade do vento, umidade relativa do ar máxima e mínima como as variáveis independentes e a evapotranspiração a 0,12 m como variável dependente.

O programa para treinamento e teste da RNA foi desenvolvido no software *MATLAB* (MATrix LABoratory) R2014a versão 8.3.

#### **3.2 Obtenção da $ET_0$**

Para a criação da rede neural foi necessário anteriormente calcular a  $ET_0$  por meio do software *PMday* que teve como dados de entrada a Radiação Solar ( $R_s$ ), Temperatura máxima ( $T_x$ ), Temperatura mínima ( $T_n$ ), Velocidade do vento ( $U_2$ ), Umidade relativa do ar máxima e

mínima ( $RH_x$  e  $RH_n$  respectivamente), além do ano (2008 a 2012), a altitude (574,62) e latitude (-6,97) destacados em amarelo, exemplificado na Figura 2 abaixo, a evapotranspiração de referência é representada por ( $ET_{os}$ ) destacada em vermelho.

The image shows a screenshot of the PMday software interface. At the top, there are input fields for Year (2011), Station Name (Areia), Station Number (82696), Latitude (-7.0), and Elevation (574.6). Below these are physical constants: albedo = 0.23 and Press = 94.7. A note says 'To use RH data, delete the T<sub>2</sub> data'. Another note says 'If you copy these data to another program, use paste special as values.' Below the inputs, there are instructions: 'For missing data, leave the cells blank.' and 'optional humidity'. The main data table has columns for DOY, Date,  $ET_{os}$ ,  $HS ET_o$ ,  $ET_{os}$ ,  $R_n$ ,  $T_i$ ,  $T_n$ ,  $U_2$ ,  $T_o$ ,  $RH_x$ ,  $RH_n$ , and two sets of Energy Balance  $ET_{os}$  (Rn, G, H, LE) and Energy Balance  $ET_{os}$  (Rn, G, H, LE). The  $ET_{os}$  column is highlighted in red. The  $RH_x$  and  $RH_n$  columns are highlighted in blue. The  $R_n$ , G, H, and LE columns are highlighted in yellow.

DOY	Date	$ET_{os}$ (mm d <sup>-1</sup> )	$HS ET_o$ (mm d <sup>-1</sup> )	$ET_{os}$ (mm d <sup>-1</sup> )	$R_n$ MJm <sup>-2</sup> d <sup>-1</sup>	$T_i$ °C	$T_n$ °C	$U_2$ ms <sup>-1</sup>	$T_o$ °C	$RH_x$ %	$RH_n$ %	Energy Balance $ET_{os}$				Energy Balance $ET_{os}$			
												Rn	G	H	LE	Rn	G	H	LE
												MJm <sup>-2</sup> d <sup>-1</sup>	MJm <sup>-2</sup> d <sup>-1</sup>	MJm <sup>-2</sup> d <sup>-1</sup>	MJm <sup>-2</sup> d <sup>-1</sup>	MJm <sup>-2</sup> d <sup>-1</sup>	MJm <sup>-2</sup> d <sup>-1</sup>	MJm <sup>-2</sup> d <sup>-1</sup>	MJm <sup>-2</sup> d <sup>-1</sup>
1	1-Jan-11	4.21	1.63	3.58	17.8	23.9042	22.6875	3.57083		87.29	81.83	11.54	0.00	2.77	8.76	11.54	0.00	2.77	8.76
2	2-Jan-11	4.99	1.66	4.25	21.3	24.2958	23.0583	3.1625		83.29	78.25	13.39	0.00	2.98	10.41	13.39	0.00	2.98	10.41
3	3-Jan-11	6.00	1.63	5.02	25.8	24.5667	23.4	4.05417		81.21	76.21	15.86	0.00	3.55	12.31	15.86	0.00	3.55	12.31
4	4-Jan-11	5.17	1.56	4.21	20.3	24.1167	23.0208	4.475		82.96	77.88	12.81	0.00	2.51	10.31	12.81	0.00	2.51	10.31
5	5-Jan-11	5.12	1.61	4.25	21.2	24.0708	22.9083	4.12917		83.46	78.54	13.31	0.00	2.91	10.40	13.31	0.00	2.91	10.40
6	6-Jan-11	5.23	1.63	4.38	22.2	24.3458	23.1625	4.00833		83.71	78.96	13.93	0.00	3.19	10.74	13.93	0.00	3.19	10.74
7	7-Jan-11	5.37	1.63	4.35	21.7	24.2833	23.1083	5.2375		83.92	78.83	13.64	0.00	2.97	10.66	13.64	0.00	2.97	10.66
8	8-Jan-11	4.00	1.62	3.15	14.0	23.6167	22.5583	5.5		87.04	82.63	9.39	0.00	1.67	7.72	9.39	0.00	1.67	7.72
9	9-Jan-11	4.61	1.50	3.73	18.9	23.7833	22.7625	5.85417		87.00	82.25	12.12	0.00	2.97	9.15	12.12	0.00	2.97	9.15
10	10-Jan-11	4.97	1.57	4.02	20.8	23.8	22.6833	6.1		86.38	81.13	13.19	0.00	3.34	9.85	13.19	0.00	3.34	9.85
11	11-Jan-11	2.40	1.33	2.13	12.5	21.8667	20.9875	5.25		96.00	91.96	8.63	0.00	3.41	5.22	8.63	0.00	3.41	5.22
12	12-Jan-11	3.66	1.35	3.13	17.0	23.2292	22.3875	5.01667		90.79	87.42	11.17	0.00	3.51	7.66	11.17	0.00	3.51	7.66
13	13-Jan-11	4.37	1.51	3.62	18.6	24.0625	23.0458	5.29167		88.25	83.83	12.03	0.00	3.16	8.86	12.03	0.00	3.16	8.86
14	14-Jan-11	3.98	1.51	3.33	17.5	23.6375	22.5958	5.25833		89.92	85.13	11.43	0.00	3.26	8.16	11.43	0.00	3.26	8.16
15	15-Jan-11	4.93	1.48	3.89	18.0	24.025	23.0542	5.73333		84.54	79.58	11.63	0.00	2.10	9.53	11.63	0.00	2.10	9.53
16	16-Jan-11	4.79	1.67	4.00	20.7	23.55	22.2667	4.25833		85.96	79.75	13.05	0.00	3.24	9.81	13.05	0.00	3.24	9.81
17	17-Jan-11	4.23	1.44	3.67	19.1	23.325	22.3708	3.1875		87.04	82.50	12.21	0.00	3.22	8.99	12.21	0.00	3.22	8.99
18	18-Jan-11	2.69	1.12	2.21	9.6	22.8042	22.2125	4.3125		90.96	88.17	7.00	0.00	1.59	5.41	7.00	0.00	1.59	5.41

Figura 2 - Exemplo do banco de dados no PMday.

Após obter a evapotranspiração o conjunto de dados formado pela  $ET_0$  e as variáveis climáticas foram exportadas para o MATLAB.

### 3.3 Características e Modelagem da Rede Neural


Os dados climatológicos foram definidos como dados de entrada (Input) da rede e a  $ET_0$  como o dado de saída (Output), em seguida foram separados em dois conjuntos de dados o primeiro compreendido pelos dados de janeiro de 2008 a dezembro 2011 para treinamento da rede e o ano completo de 2012 para fase de teste (simulação), essa fase de teste consiste na entrada de dados climatológicos em que a rede ainda não teve contato e a partir daí ela vai gerar novos valores de  $ET_0$ .

Como no trabalho realizado por ZANETTI et al, 2007, utilizou-se uma RNA do tipo Perceptron de Múltiplas Camadas (MLP, multilayer perceptron), nesse tipo de rede o sinal de entrada se propaga para frente (feedforward), camada por camada, sendo em seguida retropropagado para a correção do erro (ajuste dos pesos sinápticos); este procedimento é repetido durante várias iterações até a finalização do treinamento.

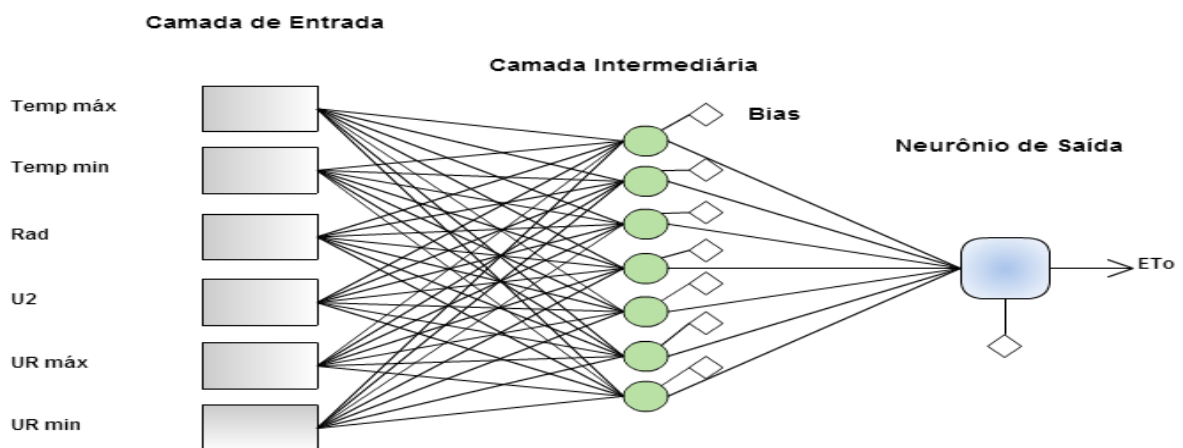
Para camada intermediária foi utilizada uma função de ativação do tipo *Tansig* que assume valores no intervalo de [-1, 1], e a mesma função na camada de saída. Assim os dados

de entrada da rede foram normalizados no MATLAB pela função *mapminmax* onde os valores ficaram no intervalo de [-1, 1].

Foi utilizado o algoritmo Levenberg-Marquardt para treinamento da rede. A RNA apresenta uma camada de entrada com seis neurônios representando as variáveis climatológicas de temperatura máxima e mínima, radiação solar, velocidade do vento e umidade relativa do ar máxima e mínima, uma camada oculta com sete neurônios seguindo a recomendação de HECHT-NIELSEN, 1987, em que a camada oculta deve ter por volta de  $2i+1$  neurônios, onde  $i$  é o número de variáveis de entrada, e a camada de saída representada pela  $ET_0$ . A RNA está esquematizada nas Figuras 3 e 4. A estrutura da rede assemelha-se a mesma utilizada em KUMAR et al (2002) sendo do tipo [6-7-1]




**Figura 3** - Topologia da rede, Input (entrada), Hidden Layer (camada oculta), Output Layer (camada de saída) e Output (saída).



**Figura 4** - Arquitetura da rede [6-7-1].

Foi escolhido o método de validação cruzada como critério de parada no treinamento da rede. O método consiste em acompanhar a evolução do aprendizado nas curvas correspondentes aos subconjuntos de dados de treinamento e de validação Figura 5. Deste

modo, o treinamento é interrompido, quando a curva de validação decresce a um erro mínimo, e antes de começar a crescer, conforme o treinamento continua (GUIMARÃES et al, 2008).



**Figura 5** - Regra de parada antecipada baseada na validação cruzada. Fonte Haykin (2001).

Na Tabela 1 encontram-se as configurações para o modelo de rede neural artificial utilizada neste trabalho.

**Tabela 1** – Configurações utilizadas na rede neural.

Parâmetro	Valor
Função de treinamento	TRAINLM
Função de adaptação	LEARNGDM
Medida de desempenho	MSE
Números de camadas ocultas	1
Função de ativação na camada oculta	TANSIG
Função de ativação na camada de saída	TANSIG

### 3.4 Ferramentas de avaliação de desempenho da RNA

Conforme a metodologia descrita por SOBRINHO (2011) e ZANETTI et al (2007) os valores estimados pela RNA foram comparados utilizando-se erro relativo percentual (ERP), o erro médio quadrático (MSE), o erro padrão de estimativa (SEE), o coeficiente de exatidão de Willmott (d) e o coeficiente de desempenho (c) em relação ao método padrão (Penman-Monteith).

O erro médio quadrático pode ser obtido a partir da equação 2:

$$MSE = \frac{\sum_{i=1}^n (Y_0 - Y_e)^2}{n}$$

**Equação 2-** Erro médio quadrático.

em que: n = número de observações;  $Y_o = ET_0$  estimada pelo método de Penman-Monteith, mm d<sup>-1</sup>; e,  $Y_e = ET_0$  estimada pela rede neural artificial.

O Erro Padrão de Estimativa (SEE) pode ser calculado através da Equação 3:

$$SEE = \left[ \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n - 1} \right]^{0,5}$$

**Equação 3** - Erro padrão de estimativa.

em que:  $\hat{Y}_i$  = média da taxa de evapotranspiração calculada pelo método padrão (Penman-Monteith) no i-ésimo mês;  $Y_i$  = estimativa de evapotranspiração correspondente; n = número total de observações.

Segundo CAMARGO e SENTELHAS (1997) apud SOBRINHO (2011), os seguintes indicadores estatísticos são considerados para correlacionar os valores estimados com os medidos: exatidão - índice de Willmott “d”; e de confiança ou desempenho “c”.

A exatidão, relacionada ao afastamento dos valores estimados em relação aos observados, é dada estatisticamente pelo índice de concordância d proposto por WILLMOTT et al. (1985). Seus valores variam de zero, para nenhuma concordância, a 1, para a concordância perfeita. O índice é dado pela equação 4:

$$d = 1 - \left[ \frac{\sum (P_i - O_i)^2}{\sum (|P_i - O| + |O_i - O|)^2} \right]$$

**Equação 4** - Coeficiente de exatidão de Willmott.

em que:  $P_i$  = valor estimado;  $O_i$  = valor observado;  $O$  = média dos valores observados.

O índice de desempenho c, apresentado por CAMARGO E SENTELHAS (1997), avalia o desempenho dos diferentes métodos de estimativa da evapotranspiração de referência. Este índice reúne os índices de precisão, dado pelo coeficiente de correlação (r) que indica o grau de dispersão dos dados obtidos em relação à média, ou seja, o erro aleatório e o de concordância d. O índice c é calculado conforme equação 5:

$$c = r * d$$

**Equação 5** - Coeficiente de desempenho.


Os critérios interpretação o desempenho dos métodos de estimativa da  $ET_0$  pelo índice c, proposto por CAMARGO e SENTELHAS (1997), e utilizados em outros trabalhos como SOBRINHO (2011), ZANETTI et al (2007, 2008), encontra-se na Tabela 2.

**Tabela 2** - Critério de interpretação do desempenho dos métodos de estimativa da  $ET_0$  pelo índice  $c$ .

<b>Valor de <math>c</math></b>	<b>Desempenho</b>
$> 0,85$	Ótimo
0,76 a 0,85	Muito Bom
0,66 a 0,75	Bom
0,61 a 0,65	Mediano
0,51 a 0,60	Sofrível
0,41 a 0,50	Mau
$\leq 0,40$	Péssimo

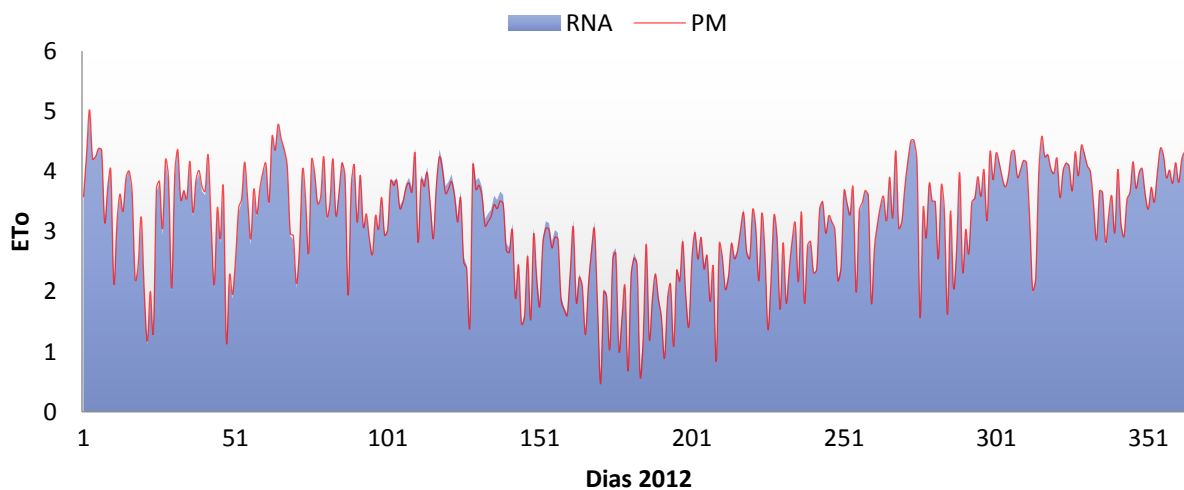
## 4. RESULTADOS E DISCUSSÕES

O gráfico da Figura 6 mostra a performance do treinamento da RNA com os dados climáticos de 2008 a 2011, onde se pode observar que na epoch 29 obteve o menor erro médio quadrático (MSE) de 0.00286, após a epoch 29 o MSE começou a aumentar parando o processo de treinamento da rede na epoch (ciclo) 35.



**Figura 6** - MSE em função da epoch.

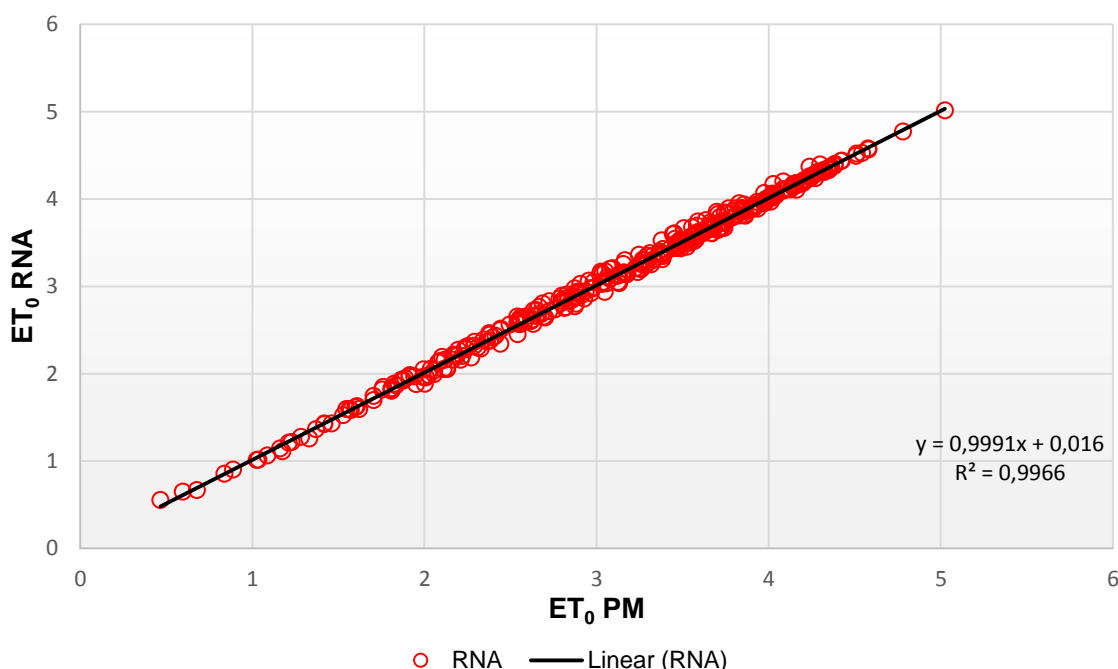
O gráfico ilustrado na Figura 7 representa a relação entre a  $ET_0$  calculada pelo método de Penman-Monteith e a  $ET_0$  simulada na rede neural [6-7-1], em que foram utilizados os dados climáticos inéditos à rede equivalente ao ano de 2012, no qual mostra graficamente quase que uma perfeita relação entre as duas  $ET_0$  estimadas por Penman-Monteith (PM) e pela RNA. Constatando que uma rede neural bem treinada adequadamente pode gerar valores de previsão que acompanham a tendência da evapotranspiração.



**Figura 7** - Relação entre  $ET_0$  estimada por PM e a  $ET_0$  simulada na RNA para o ano de 2012.

O coeficiente de determinação,  $0 \leq r^2 \leq 1$ , indica a proporção da variação dos valores observado que é explicada (determinada) pela regressão (valores estimados), sendo tanto mais útil quanto mais próximo de 1 estiver o  $r^2$  (HOFFMAN e& VIERIRA, 1983).

Observa-se na Figura 8 o gráfico de dispersão regressão linear entre valores de  $ET_0$  estimada pela RNA em relação ao método de referência Penman-Monteith para o período de 2012. Onde podemos observar no gráfico 2 que a  $ET_0$  simulada na rede neural se aproxima bastante daquela obtida pelo método padrão de Penman-Monteith tendo o coeficiente de determinação ( $r^2$ ) de 0,9966 mostrando-se um modelo quase que perfeito na estimativa da  $ET_0$  por meio das redes neurais.



**Figura 8** - Relação entre  $ET_0$  estimada por PM e a  $ET_0$  simulada na RNA, com sua respectiva equação e coeficiente de determinação ( $r^2$ ).

Na Tabela 3 podem-se observar os indicadores estatísticos utilizados para avaliar o desempenho da RNA na predição da evapotranspiração pela RNA em relação à de Penman-Monteith. Os resultados obtidos a partir da RNA apresentaram uma pequena subestimação ou subestimação da  $ET_0$  de apenas 0,5 %. O erro padrão da estimativa (SEE) foi de 0,003 entre a  $ET_0$  simulada na rede neural e a do método padrão.

O índice  $c$  foi de 0,953 sendo interpretada o seu desempenho como ótimo conforme os critérios da Tabela 2 prepostos por CAMARGO e SENTELHAS (1997), indicando a qualidade dos ajustes presentes na rede, que vem sendo confirmado pelo baixo erro relativo perceptual e erro médio quadrático (MSE) de 0,054.



**Tabela 3** – Indicadores estatísticos entre a  $ET_0$  simulada na rede neural e pelo método Penman.

ERP %	SEE	MSE	$r^2$	$d$	$c$	Classificação
0,5	0,003	0,054	0,9966	0,955	0,953	Ótimo

Os autores SOBRINHO et al (2011), FERRAZ (2014), ZANETTI (2007, 2008) ao comparar modelos de redes neurais e método empíricos, tem-se que as RNAs apresentam desempenhos superiores e baixo erro médio quadrático.

Em trabalho realizado por PEREIRA et al (2009), na Serra da Mantiqueira em Minas Gerais, em que se objetivou avaliar o desempenho de 10 diferentes métodos de estimativa da  $ET_0$  em períodos secos e chuvosos tendo como referência o método Penman-Monteith. Os métodos avaliados foram: Makkink ( $ET_0M$ ), FAO Radiação Solar ( $ET_0R$ ), Jensen-Haise ( $ET_0JH$ ), Linacre ( $ET_0L$ ), Hargreaves-Samani ( $ET_0HS$ ), Blaney-Criddle FAO ( $ET_0BC$ ), Priestley-Taylor ( $ET_0PT$ ), Penman ( $ET_0P$ ), Hamon ( $ET_0HM$ ) e Karrufa  $ET_0KM$ . Ele concluiu que os métodos de Jensen-Haise, FAO Radiação, Penman e Blaney-Criddle são adequados para estimar a evapotranspiração de referência em escala diária, independentemente da época do ano na região da Serra da Mantiqueira.

**Tabela 4-** Indicadores com os melhores resultados obtidos em PEREIRA et al (2009).

Método	Período	SEE	$r^2$	$d$	$c$	Classificação
$ET_0JH$	Chuvoso	0,57	0,92	0,96	0,92	Ótimo
	Seco	0,64	0,79	0,94	0,83	Muito bom
$ET_0R$	Chuvoso	0,72	0,94	0,94	0,91	Ótimo
	Seco	0,88	0,82	0,91	0,83	Muito bom
$ET_0P$	Chuvoso	0,82	0,98	0,92	0,91	Ótimo
	Seco	0,87	0,98	0,91	0,90	Ótimo
$ET_0BC$	Chuvoso	0,53	0,89	0,95	0,90	Ótimo
	Seco	0,95	0,81	0,88	0,80	Muito bom

Comparando os resultados Tabela 3 e Tabela 4, é possível verificar que o desempenho deste modelo de RNA é superior aos demais métodos utilizados em PEREIRA et al (2009) tendo como referência a  $ET_0$  de Penam-Monteith, independentemente se o período é seco o chuvoso conseguem fazer uma boa previsão da  $ET_0$ .

As RNAs têm se mostrado bastante eficaz nessa estimativa como em ZANETTI et al (2007, 2008) utilizando como variáveis climáticas a temperatura do ar máxima e mínima além de dados das coordenadas geográficas para tal finalidade.

Assim como em ZANETTI et al (2007, 2008), SOBRINHO (2011) utilizou-se as variáveis climáticas referentes as temperaturas comparando-se à diferentes métodos como o de Blanney-Criddle e Hargreaves, no qual concluiu que as RNAs têm melhores resultados na obtenção da  $ET_0$  tendo como referência o método de Penman-Monteith. Apesar de terem bons resultados com média entre 70% e 80% no índice de desempenho, poderiam ter resultados ainda mais próximos do método padrão se fossem utilizadas mais variáveis climáticas como velocidade do vento, umidade relativa do ar e principalmente radiação solar que são as variáveis climáticas ,junto com a temperatura, que mais influenciam a evapotranspiração de referência, no qual pode ser justificado no trabalho realizado por FILHO et al (2015), onde tem-se que a temperatura é correlacionada a  $ET_0$ , pouco mais de 70%, a radiação 94% e a umidade tem efeito negativo de 87%, o que indica que para treinar uma rede neural tem que ao menos ter essas variáveis climáticas. SOBRINHO (2011) concluiu que a utilização de RNA apresenta vantagens quando comparada aos outros métodos estudados, pois possibilita a obtenção dos valores de evapotranspiração de referência a partir da temperatura, única variável a ser considerada no cálculo.

A RNA com arquitetura 6-7-1 apresentou estimativas consistentes de evapotranspiração em comparação ao método de Penman-Monteith, apresentando valores próximos em relação ao método padrão de referência, para os dias referentes a 2012.

## 5. CONCLUSÕES

De acordo com a pesquisa realizada, observou-se que através das redes neurais artificiais é possível obter resultados confiáveis na estimativa da evapotranspiração de referência, quando comparado ao método Penman-Monteith, tendo todos indicadores estatísticos utilizados nesse estudo favoráveis a utilização das RNAs.

As componentes meteorológicas são decisivas na estimativa da  $ET_0$ , tendo em vista, que as mesmas foram normalizadas para treinar a rede, principalmente os dados de radiação, temperatura e umidade relativa do ar ou até mesmo a temperatura de ponto de orvalho, para obter um melhor resultado gerado pela RNA.

Este modelo de estimativa da  $ET_0$  para o município de Areia, utilizando o método padrão de Penman-Monteith, por meio do uso de redes neurais artificiais, apresentou excelentes resultados, comparados com outros métodos para a obtenção da  $ET_0$ .

## 6. REFERÊNCIAS BIBLIOGRÁFICAS

ABRAHART, R. J.; GHANI, N. A.; SWAN, J. **Discussion of “An explicit neural network formulation for evapotranspiration**. Hydrological Sciences Journal, v.53, n.2, p.893-904, 2009.

ALLEN, R.G.; PEREIRA, L.S., RAES, K., SMITH, M. 1998. **Crop evapotranspiration (guidelines for computing crop water requirements)**. Rome: FAO. 300 p. (Irrigation and Drainage Paper, 56).

ARCA, B.; BENISCASA, F.; VINCENZI, M. **Evaluation of neural network techniques for estimating evapotranspiration**. National Research Council. Disponível em <[http://server.ss.ibimet.cnr.it/~arca1/papers/Evaluation%20of%20neural%20network%20techniques%20for%20estimating%20evapotranspiration\\_EANN\\_2001.PDF](http://server.ss.ibimet.cnr.it/~arca1/papers/Evaluation%20of%20neural%20network%20techniques%20for%20estimating%20evapotranspiration_EANN_2001.PDF)> Acesso em: 22 Jul. 2001.

BEZERRA, B.G.; SILVA, B.B.; FERREIRA, N.J. **Estimativa da evapotranspiração real diária utilizando-se imagens digitais TM - Landsat 5**. Revista Brasileira de Meteorologia, v.23, n.3, p.305-317, 2008.

BITTENCOURT, G. **Inteligência Artificial: Ferramentas e Teorias**. 3ª Edição. ed. Florianópolis: Editora da UFSC, 2006.

BONOMI, R. **Análise da irrigação na cafeicultura em áreas de cerrado de Minas Gerais**. Viçosa, MG, Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa. 1999.

BRAGA, A.P.; LUDEMIR, T.B.; CARVALHO, A. C. P. L. F. **Redes neurais artificiais: Teoria e aplicações**. Rio de Janeiro: LTC, 2000. 262p.

FERRAZ, R. C. **Estimativa de Evapotranspiração de Referência utilizando Redes Neurais Artificiais para o Estado do Rio Grande Do Sul**. Revista Tecnológica. Maringá, v. 23, p. 25-31, 2014.

FILHO, A. I.; BORGES, P. F.; ARAÚJO, L. S.; PEREIRA, A. R.; LIMA, E. M.; SILVA, L. S.; JUNIOR, CARLOS V. **Influência das variáveis climáticas sobre a evapotranspiração**. GAIA SCIENTIA (2015). VOLUME 9(1): 62-66. 2015.

GUIMARÃES, A. M.; MATHIAS, I. M.; DIAS, A. H.; FERRARI, J. W.; OLIVEIRA, C. R.; JUNIOR, C. **Módulo de validação cruzada para treinamento de redes neurais artificiais com algoritmos backpropagation e resilient propagation**. Publ. UEPG Ci. Exatas Terra, Ci. Agr. Eng., Ponta Grossa, 14 (1): 17-24, abr. 2008.

HAYKIN, S. **Redes Neurais: Princípios e prática**. 2.ed. Porto Alegre: Bookman, 2001. 900p.

HECHT-NIELSEN R, 1987. **Kolmogorov's Mapping Neural Network Existence Theorem**. IEEE Conf. On Neural Networks. San Diego, CA. III: 11–14.1987.

HOFFMAN, R.; VIEIRA, S.; **Análise de regressão – Uma Introdução á Econometria**. Editora HUCITEC, são Paulo, 2ª Edição, 1983. 389p.

IRIGOYEN, A. I. **Modelagem da evapotranspiração de referência e da evapotranspiração de limeira ácida com aplicação de técnicas de regressão e redes neurais artificiais**. Tese (Doutorado). Escola Superior de Agricultura Luiz Queiros. Piracicaba, 2010. 204p.

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.

KOVÁCS, Z.L. **Redes neurais artificiais: Fundamentos e aplicações**. 3.ed. São Paulo: Livraria da Física, 2002. 174p.

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.

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, n.95, p.553-565, 2008.

LIMA, V.R. **Desenvolvimento e Avaliação de Sistema Neural para Redução de Tempo de Ensaio de Desempenho de Compressores**. 2010.173f. Dissertação (Mestrado em Metrologia Científica e Industrial). Universidade Federal de Santa Catarina. Florianópolis 2010.

MAIER, H.; DANDY, G.C. **Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications.** Environmental Modelling & Software, Amsterdam, v. 15, p.101-124, 2000.

MASTERS, T. **Signal and image processing with neural networks – a C++ Sourcebook.** New York: John Wiley & Sons, 1994. 417 p.

MEDEIROS, A. T., SENTELHAS, P. C., LIMA, R. N. **Estimativa da evapotranspiração de referência a partir da equação de penmanmonteith, de medidas lisimétricas e de equações empíricas.** PARAIPABA - CE. Eng. Agríc., Jaboticabal, v.23, n.1, p.31-40, jan. 2003.

MELLO, J.L.P.; SILVA, L.D.B. **Estudos Climáticos: Evapotranspiração.** In: Irrigação. Universidade Federal Rural do Rio de Janeiro - Instituto de Tecnologia. Rio de Janeiro, 2007. Cap II. p.1-36.

MENDES R.S. **Determinação da evapotranspiração por métodos direto e indiretos e dos coeficientes de cultura da soja para o Distrito Federal.** 2006. 71 f. Dissertação (Mestrado em Ciências Agrárias). Universidade de Brasília - Faculdade De Agronomia e Medicina Veterinária. Brasília. 2006.

ODHIAMBO, L. O.; YODER, R. E.; YODER, D. C.; HINES, J. W. **Optimization of fuzzy evapotranspiration model through neural training with input-output examples.** Transactions of the ASAE, v.44, n.6, p.1625-1633, 2001.

PATNAIK, A.; MISRA, R.K. **ANN Techniques in Microwave Engineering.** Microwave Magazine, IEEE, [S.l.], v. 1, n. 1, p. 55-60, mar. 2000.

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

PEREIRA, D. R.; YANAGI, S. N. M.; MELLO, C. R.; SILVA. A. M.; SILVA, L. A. **Desempenho de métodos de estimativa da evapotranspiração de referência para a região da Serra da Mantiqueira, MG .** Ciência Rural, Santa Maria, v.39, n.9, p.2488-2493, dez, 2009.

SALATI, E.; VOSE, P. B. **Amazon Basin: a system in equilibrium.** Science, 225(4658): 129- 138, 1984.

SETTI, A.A.; LIMA, J.E.F.W.; CHAVES, A.G.M.; PEREIRA, I.C. **Introdução ao gerenciamento de recursos hídricos**. Brasília: ANEEL: ANA, 2001. 328 p.

SILVA, A. F. **Previsão da evapotranspiração de referência utilizando redes neurais**. 2002. 68p. Dissertação (Mestrado em Engenharia agrícola), Universidade Federal de Viçosa, 2002.

SILVA, A. F.; COSTA, L. C.; SEDIYAMA, G. **Previsão da evapotranspiração de referência utilizando redes neurais**. Engenharia na Agricultura, v.14, n.2, p.93-99, 2006.

SILVA, E.; OLIVEIRA, A.C. **Dicas para configuração de Redes Neurais**. 2002. Disponível em: <[http://equipe.nce.ufrj.br/thome/grad/nn/mat\\_didatico/dicas\\_configuracao\\_rna.pdf](http://equipe.nce.ufrj.br/thome/grad/nn/mat_didatico/dicas_configuracao_rna.pdf)>. Acesso: em 08 de mar. 2015.

SILVA, W.L.C.; MAROUELLI, W.A. **Manejo de irrigação em hortaliças no campo e em ambientes protegidos**. In: FARIA, M.A. (Coord.). Manejo de irrigação. Lavras:UFLA/SBEA, 1998. p. 311-348.

SOARES P.L.B; SILVA J.P. **Aplicação de Redes Neurais Artificiais em Conjunto com o Método Vetorial da Propagação de Feixes na Análise de um Acoplador Direcional Baseado em Fibra Ótica**. Revista Brasileira de Computação Aplicada, Passo Fundo, v.3, n.2, p.58-72, set. 2011.

SOBRINHO T.A.; RODRIGUES, D.B.B.; OLIVEIRA, P.T.S.; REBUCCI, L.C.S.; PERTUSSATTI, C.A. **Estimativa da Evapotranspiração de Referência Através de Redes Neurais Artificiais**. Revista Brasileira de Meteorologia, v.26, n.2, 197 - 203, 2011.

SOUSA, E. F. et al. **Estimativa da demanda hídrica provável na região norte fluminense**. Engenharia Agrícola, Jaboticabal, v.22, n.3, p.322-331, 2002.

SUDHEER, K. P.; GOSAIN, A. K.; RAMASASTRI, K. S. **Estimating actual evapotranspiration from limited climatic data using neural computing technique**. Journal of Irrigation and Drainage Engineering, v.129, n.3, p.214-218, 2003.

SUGAWARA, M.T. **Sistema automatizado para estimação da evapotranspiração de referência e do balanço hídrico para região norte fluminense utilizando Redes Neurais Artificiais (RNA's)**. 2008. 56f.Tese (Doutorado em Produção Vegetal) – Universidade Estadual do Norte Fluminense Darcy Ribeiro, Centro de Ciências e Tecnologias Agropecuárias. Campos dos Goytacazes, RJ, 2008.

TALEB, R.; MEROUFEL, A.; WIRA, P. **Neural Network Control of Asymmetrical Multilevel Converters**. Leonardo Journal of Sciences, n. 15, Julho 2009. 53-70.

TRAJKOVIC, S.; TODOROVIC, B.; STANKOVIC, M. **Forecasting of Reference Evapotranspiration by Artificial Neural Networks**. Journal of Irrigation and Drainage Engineering, v.129, n.6, p.454-457, 2003.

WILLMOTT, C. J.; DAVIS, R. E.; FEDDEMA, J. J.; JOHANNES, J.; KLINK, K. M.; LEGATES, D. R.; ROWE, C. M.; ACKLESON, S. G.; O'DONNELL, J. **Statistics for the Evaluation and Comparison of Models**. Journal of Geophysical Research, v.90, p.8995-9005, 1985.

ZANETTI, S.S.; SOUSA, E.F. CARVALHO, D.F.; BERNARDO, S. **Estimação da evapotranspiração de referência no Estado do Rio de Janeiro usando redes neurais artificiais**. Revista Brasileira de Engenharia Agrícola e Ambiental, v.12, n.2, p.174-180, 2008.

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.