

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA**

**SISTEMA WEB E MOBILE PARA ESTIMATIVA DE
EVAPOTRANSPIRAÇÃO DE REFERÊNCIA
UTILIZANDO REDES NEURAS ARTIFICIAIS**

TESE DE DOUTORADO

RAFAEL CAMARGO FERRAZ

**Santa Maria, RS, Brasil.
2013**

**SISTEMA WEB E MOBILE PARA ESTIMATIVA DE
EVAPOTRANSPIRAÇÃO DE REFERÊNCIA UTILIZANDO
REDES NEURAIS ARTIFICIAIS**

RAFAEL CAMARGO FERRAZ

Tese de Doutorado apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, Área de Concentração Engenharia de Água e Solo, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do grau de
Doutor em Engenharia Agrícola

Orientador: Dr. Adroaldo Dias Robaina

**Santa Maria, RS, Brasil.
2013**

Ficha catalográfica

**Universidade Federal de Santa Maria
Centro de Ciências Rurais
Programa de Pós-Graduação em Engenharia Agrícola**

A Comissão Examinadora, abaixo assinada, aprova a
Tese de Doutorado

**SISTEMA WEB E MOBILE PARA ESTIMATIVA DE
EVAPOTRANSPIRAÇÃO DE REFERÊNCIA UTILIZANDO REDES
NEURAIS ARTIFICIAIS**

elaborado por:
Rafael Camargo Ferraz

Como requisito parcial para a obtenção do grau de
Doutor em Engenharia Agrícola

Comissão Examinadora:

Adroaldo Dias Robaina, Dr. (Presidente/Orientador)

João Fernando Zamberlan, Dr. (UFSM)

Liane de Souza Weber, Dr^a (UFSM)

Ricardo Luis Schons, Dr. (UFPeI)

Ana Carla dos Santos Gomes, Dr^a (IFFarroupilha)

Santa Maria, RS, 19 de abril de 2013.

Dedico...
... a meu pai e minha amada tia Cila
Mesmo não estando em plano físico,
Estarão sempre torcendo por mim.

Agradecimentos

À Deus por iluminar meu caminho e me dar forças para seguir sempre em frente. Autor da grande obra da vida.

À Universidade Federal de Santa Maria, em especial ao Programa de Pós-Graduação em Engenharia Agrícola e ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, ambos pelo apoio durante a realização do curso e por ter proporcionado as oportunidades de crescimento profissional.

Ao Professor Adroaldo Dias Robaina e a equipe do Laboratório de Engenharia de Irrigação, no qual deixo meu agradecimento pelo acolhimento e orientações.

Agradeço à minha família, Marta (minha mãe), Valson (meu padastro), Ruciel (minha irmã), Gabi (sobrinha), a minha querida e cheirosa vó Eva, meus tios amados e meus primos, em especial meu primo Régis (pelos papos virtuais e motivadores). Agradeço a todos pelo apoio, compreensão, carinho e amor dedicado e por serem as pessoas importantes em minha vida.

À meu grande amor, Angélica, agradeço por tudo que és e representa para mim. Obrigado por todos os momentos que estive e estarás comigo, sempre confiando no meu potencial e me motivando a seguir em frente. Quero que saibas que és muito especial, e agradeço por ter aberto mão de muitas coisas por mim e para estarmos juntos hoje. Sem você, certamente não seria o que sou hoje. Agradeço também a sua família que me acolheu com tanto amor e que são pessoas especiais para mim.

À todos que contribuíram durante essa caminhada, e que de alguma forma estiveram presentes, em especial, João Fernando Zamberlan, Eduardo Beltrame, Mario Nunes, Charles Seidel, Luís Carlos Nunes e demais colegas.

Aos meus amigos Everton, Dani, Cassinho e que me apoiaram e ajudaram com suas amizades verdadeiras. Obrigado por tudo. À meu amigo Darlan que, por várias vezes, me socorreu e auxiliou na programação mesmo sem ter tempo. Isso só verdadeiro amigo faz.

Melhor ser pirata do que marinheiro...
Steve Jobs

RESUMO

Tese de Doutorado
Programa de Pós-Graduação em Engenharia Agrícola
Universidade Federal de Santa Maria

SISTEMA WEB E MOBILE PARA ESTIMATIVA DE EVAPOTRANSPIRAÇÃO DE REFERÊNCIA UTILIZANDO REDES NEURAS ARTIFICIAIS

AUTOR: RAFAEL CAMARGO FERRAZ

ORIENTADOR: Dr. ADROALDO DIAS ROBAINA

Data e Local da Defesa: Santa Maria, 19 de Abril de 2013.

A evapotranspiração de referência (ET_o) é um componente de grande importância em diversas áreas, assim como nos estudos agrícolas e na gestão dos recursos hídricos. Vários métodos de determinação são estudados, sendo o modelo de Penman-Monteith utilizado amplamente como padrão. A principal desvantagem deste método é o fato de que os dados meteorológicos necessários normalmente não estão facilmente disponibilizados, ou possuem um custo elevado para determinação. A inserção das redes neurais artificiais (RNA) nestes estudos possibilita obter resultados satisfatórios com número menor de variáveis de entradas. O presente trabalho tem por objetivo principal, desenvolver uma ferramenta web e mobile para a determinação da ET_o utilizando modelos de redes neurais artificiais para o Estado do Rio Grande do Sul. Os dados utilizados para modelagem foram coletados junto as estações do Instituto Nacional de Meteorologia entre 2008 e 2012. Adotou-se como padrão os valores de ET_o estimados pelo método de Penman-Monteith e posteriormente comparado com os obtidos com as RNA's. O algoritmo de programação foi definido a partir da melhor arquitetura de rede neural, considerando o índice de desempenho e avaliação do erro. Ambas as aplicações foram desenvolvidas em ambiente Linux, com ferramentas livres e banco de dados SQLite. Pode-se perceber que as estimativas realizadas com as RNA's apresentam melhor desempenho quando comparado com os métodos empíricos conhecidos, variando seu índice de determinação (R²) entre 0,856 e 1,0. Obteve-se desempenho superior nos modelos com radiação solar diária como variável de entrada. Foi escolhido dois modelos de arquitetura para implementar no sistema, sendo o primeiro com inserção de radiação solar líquida e a segunda arquitetura utiliza-se de radiação solar extraterrestre. Essa definição foi escolhida devido a carência ou custo alto para obtenção dos dados de radiação solar líquida. Concluiu-se que as redes neurais artificiais são capazes de prever com qualidade os valores de evapotranspiração de referência para o Estado do Rio Grande do Sul possibilitando aplicações em sistemas web e mobile.

Palavras-Chave: NeuroEvap, android, dispositivos móveis, Penman-Monteith, tecnologia da informação.

ABSTRACT

Doctoral Thesis
Agricultural Engineering Post Graduation Program
Federal University of Santa Maria, RS, Brazil

WEB AND MOBILE SYSTEM TO ESTIMATE REFERENCE EVAPOTRANSPIRATION USING ARTIFICIAL NEURAL NETWORKS

AUTHOR: RAFAEL CAMARGO FERRAZ
ADVISOR: Dr. ADROALDO DIAS ROBAINA
Santa Maria, RS, April 19th, 2013

The reference evapotranspiration (ET_o) is a component of great importance in several areas, as well as studies in agricultural and water resources management. Several methods of determination are studied, the Penman-Monteith widely used as standard. The main disadvantage of this method is the fact that the meteorological data required are usually not easily available, or have a high cost for determination. The insertion of artificial neural networks (ANN) in these studies provides satisfactory results with fewer input variables. This paper's main objective is to develop a web and mobile tool for determining ET_o models using artificial neural networks for the State of Rio Grande do Sul. The data used for modeling were collected from the stations of the National Meteorological Institute between 2008 and 2012. It was adopted as the standard ET_o values estimated by the Penman-Monteith and then compared with those obtained with the RNA's. The scheduling algorithm was defined as the best neural network architecture, considering the inside performance and error evaluation. Both applications were developed under Linux with free tools and SQLite database. It can be seen that the estimates made with the RNA's have better performance when compared with the known empirical methods, varying its index of determination (R²) between 0,856 and 1,0. Obtained outperform models with daily solar radiation as input. Two model was chosen to implement the system architecture, the first solar radiation with insertion of the second liquid architecture makes use of extraterrestrial radiation. This definition was chosen because of the lack or high cost for obtaining solar radiation data net. It was concluded that artificial neural networks are able to predict the quality of reference evapotranspiration for the State of Rio Grande do Sul enabling applications on web and mobile.

Keywords: NeuroEvap, android, mobile, Penman-Monteith, information technology

LISTA DE TABELA

Tabela 1 - Métodos de estimativa de evapotranspiração mais utilizados conforme bibliografias citadas. Adaptado de Carvalho et al. (2001).	22
Tabela 2 - Funções de ativação e suas representações gráficas.....	28
Tabela 3 - Relação de pesquisas relacionadas a evapotranspiração de referência e redes neurais.....	45
Tabela 4 - Estações meteorológicas de observação de superfície do Instituto Nacional de Meteorologia instalada no Estado do Rio Grande do Sul.	64
Tabela 5 - Modelos de arquiteturas de redes neurais e suas variáveis de entrada...67	
Tabela 6 - Classificação do índice de desempenho. (COSTA, 2004)	71
Tabela 7 - Valores da média, desvio padrão, erro médio (ME), erro médio quadrático (MSE), raiz do erro médio quadrático (RMSE), relação média entre os valores estimados e observados (RR) e coeficiente de determinação (R^2).	74
Tabela 8 - Coeficiente de correlação (r), índice de concordância (c), índice de desempenho (ID) e classificação para os métodos empíricos propostos.....	75
Tabela 9 - Melhor arquitetura de rede para cada modelo, média, desvio padrão, erro médio (ME), erro médio quadrático (MSE), raiz do erro médio quadrático (RMSE), relação média entre os valores estimados e observados (RR) e coeficiente de determinação (R^2).	77
Tabela 10 - Melhor arquitetura de rede para cada modelo, coeficiente de correlação (r), índice de concordância (c), índice de desempenho (Id) e classificação.	78
Tabela 11 - Valores de evapotranspiração de referência em mm.dia^{-1} para Santa Maria/RS estimado pelo método de Penman-Monteith e pelos NeuroEvap (modelos ANN3 e ANN6).	92

LISTA DE FIGURAS

Figura 1 - Estrutura geral de um neurônio biológico.....	26
Figura 2 - Modelo de neurônio artificial	27
Figura 3 - Arquitetura de uma rede neural artificial	30
Figura 5 - Exemplo de rede neural com camada única	31
Figura 6 - Exemplo de rede neural com múltiplas camadas.....	32
Figura 7 - Exemplo de rede neural recorrente.....	33
Figura 8- Estrutura de rede neural do tipo perceptron de única camada	37
Figura 9 - Rede neural artificial multicamadas (Multilayer Perceptron)	38
Figura 10 - Fluxo do algoritmo backpropagation	40
Figura 11 - Diagrama de funcionamento da linguagem de programação PHP	49
Figura 12 - Estrutura de banco de dados SQLite	54
Figura 13 - Comparação entre as estruturas de funcionamento de banco de dados SQL e SQLite	55
Figura 14 - Arquitetura da plataforma Android	58
Figura 15 - Distribuição espacial das estações automáticas no Rio Grande do Sul. (Fonte: Rafael Camargo Ferraz)	60
Figura 16 - Arquitetura de redes com função de ativação sigmoide logística (a) e tangente hiperbólica (b).....	68
Figura 17 - Emulador SDK Android	72
Figura 18 - Comparação entre os valores de evapotranspiração de Penman-Monteith e os modelos de redes neurais ANN1 (a), ANN2 (b), ANN3 (c), ANN4 (d), ANN5 (e), ANN6 (f), ANN7 (g), ANN8 (h), ANN9 (i) e ANN10 (j)	80
Figura 19 - Visualização da página inicial do projeto NeuroEvap.....	83
Figura 20 - Visualização da página de acesso a consulta rápida.....	84
Figura 21 - Visualização da página de estimativa do modelo ANN3	84
Figura 22 - Visualização da página de estimativa do modelo ANN6	85
Figura 23 - Arquitetura de funcionamento do sistema NeuroEvap	86
Figura 24 - Formulário de solicitação de cadastro de acesso ao sistema NeuroEvap	87
Figura 25 - Acesso ao sistema NeuroEvap	87
Figura 26 - Página de opções de cálculo e consulta do sistema NeuroEvap	88

Figura 27 - Estimativa realizada pelo modelo ANN3	88
Figura 28 - Visualização de históricos de lançamentos pelo modelo ANN3.....	89
Figura 29 - Estrutura do banco de dados “neuro.db”	90
Figura 30 - Página inicial do sistema NeuroEvap Mobile	91
Figura 31 - Visualização do modelo ANN3 (A) e modelo ANN6 (B)	91

SUMÁRIO

INTRODUÇÃO	16
2 REVISÃO DE LITERATURA	18
2.1 Evapotranspiração	18
2.1.1 Fatores que influenciam na evapotranspiração	19
2.1.2 Determinação da Evapotranspiração	20
2.2 Redes Neurais Artificiais (RNAs).....	24
2.2.1 Neurônios Biológicos.....	25
2.2.2 Neurônios Artificiais.....	26
2.2.3 Funções de ativação e transferência.....	28
2.2.4 Arquitetura de uma RNA	29
2.2.4.1 Tipos de arquiteturas de RNAs	31
2.2.4.1.1 Redes Feedforward (Única Camada)	31
2.2.4.1.2 Redes Feedforward (Multicamadas).....	32
2.2.4.1.3 Redes Recorrentes.....	32
2.2.5 Treinamento das RNAs	33
2.2.6 Aprendizado da RNA.....	34
2.2.6.1 Aprendizado Supervisionado.....	35
2.2.6.2 Aprendizado Não Supervisionado	36
2.2.7 Redes Perceptron	36
2.2.8 Rede Perceptron de Múltiplas Camadas (MLP)	37
2.2.8.1 Algoritmo Backpropagation	39
2.2.9 Modelando RNA	41
2.2.9.1 Coleta de dados	41
2.2.9.2 Divisão dos dados	41
2.2.9.3 Normalização dos dados	42

2.2.9.4 Determinação das variáveis de entrada	42
2.2.9.5 Arquitetura da rede.....	43
2.2.9.6 Treinamento	44
2.2.9.7 Verificação do desempenho	44
2.3 Redes Neurais e Evapotranspiração	45
2.4 – Aplicativos <i>Web</i>	46
2.4.1 – Linguagem de programação PHP	48
2.4.2 - Linguagem de programação HTML.....	50
2.4.3 - Linguagem de programação <i>Javascript</i>	51
2.4.4 – Banco de Dados	51
2.4.4.1 - Banco de dados relacional	52
2.4.4.2 - SQLite	53
2.5 – Tecnologia Móvel	55
2.5.1 – Dispositivos móveis	56
2.5.2 - Android.....	57
3 MATERIAIS E MÉTODOS.....	60
3.1 Base de dados para estimativas	60
3.2 Estimativa da Evapotranspiração de Referência.....	61
3.3 Arquitetura e modelagem das Redes Neurais Artificiais	63
3.4 Método Computacional.....	68
3.5 Avaliação dos modelos.....	69
3.6 - Sistema <i>web</i>	71
3.7 - Aplicativo Móvel	72
4 RESULTADOS	74
4.1 Comparação entre métodos de estimativas	74
4.2 Desempenho das redes neurais artificiais.....	76
4.3 Sistema NeuroEvap	81

4.3.1 Algoritmo para programação NeuroEvap	81
4.3.2 NeuroEvap – Sistema Web	82
4.3.2.1 Versão Consulta Rápida.....	83
4.3.2.2 Versão Usuário.....	85
4.3.2.3 Banco de Dados.....	89
4.3.3 NeuroEvap – Mobile	90
4.4 Resultados NeuroEvap.....	92
5 CONCLUSÃO.....	94
REFERÊNCIAS BIBLIOGRAFIAS.....	95
APÊNDICES.....	105

INTRODUÇÃO

O conhecimento da evapotranspiração de referência (ET_o) é de fundamental importância em diversas áreas, como por exemplo, em atividades ligadas a gestão de bacias hidrográficas, em modelagem meteorológica e hidrológica e, sobretudo, no manejo hídrico da agricultura irrigada. Vários modelos de balanço hídrico de cultura utilizados no dimensionamento e planejamento de sistemas de irrigação necessitam das informações de evapotranspiração de referência como variável de estudo.

A ET_o pode ser medida diretamente por técnicas e equipamentos micrometeorológicos ou estimadas por modelos matemáticos. Os equipamentos necessários para a determinação direta possuem alto custo e demanda de tempo na sua utilização, motivo pelo qual se utiliza os métodos empíricos.

A utilização dos modelos indiretos proporcionam resultados satisfatórios, quando comparados com os métodos diretos, além de reduzirem o custo e tempo operacional. Embora possuam pontos positivos, há necessidade de dados climáticos para sua determinação e, alguns modelos, necessitam de cálculos complexos para a estimativa. O modelo de Penman-Monteith é considerado como padrão internacionalmente, mas necessita das informações de temperatura, umidade relativa do ar, velocidade do vento, insolação e principalmente a radiação solar incidente.

Dentre as variáveis utilizadas, insolação e radiação solar incidente são as mais escassas, por necessitarem de equipamentos com elevado custo de aquisição e operacional, sendo que para suprir essa carência, outros modelos foram desenvolvidos com menor número de variáveis, como por exemplo, os métodos de Thornthwaite e Hargreaves que utilizam apenas temperatura e latitude. A determinação da ET_o através destes métodos devem ser analisadas e, muitas vezes, calibradas para cada região de estudo, a fim de escolher o método que melhor estima a evapotranspiração.

Em busca de novos métodos, várias pesquisas estão sendo realizadas utilizando as redes neurais artificiais com a finalidade de estimar a evapotranspiração em função de elementos climáticos, sendo que todos obtiveram resultados satisfatórios .

As redes neurais artificiais (RNA's) são sistemas paralelos distribuídos, compostos de unidades simples de processamento, que calculam determinadas funções matemáticas a fim de solucionar problemas através de simulação da lógica, semelhante ao processamento usado pelo cérebro humano. As RNA's têm sido utilizadas com sucesso para modelar relações utilizando séries temporais e principalmente não-lineares, como o caso da evapotranspiração de referência.

Algumas pesquisas já foram realizadas abordando redes neurais e evapotranspiração, porém são poucos os trabalhos que buscaram desenvolver um modelo de rede simplificando as variáveis de entrada e que seja aplicado em uma área espacial maior, ou seja, que não seja apenas determinações para um local específico e sim uma região. Além disto, a obtenção de dados através das RNA's, necessitam de conhecimentos computacionais e matemáticos, o que desfavorece sua utilização no dia a dia.

As novas tendências tecnológicas obrigam todos os setores econômicos, produtivos e de pesquisas a se desenvolver e inovar em suas atividades. As aplicações web e a mobilidade são as novas tendências de desenvolvimento e com previsão de crescimento ainda maior desde os lançamentos dos dispositivos móveis, que agregam cada vez mais funcionalidades e aplicações.

Tendo em vista a necessidade de obter os dados de evapotranspiração de referência e, aliado a isso, as crescentes aplicações dos conceitos de redes neurais artificiais, o presente trabalho tem por objetivos definir a melhor arquitetura de redes neurais artificiais para a estimativa de ETo e desenvolver um sistema web e mobile que determine os valores para o Estado do Rio Grande do Sul.

2 REVISÃO DE LITERATURA

2.1 Evapotranspiração

As atividades agrícolas necessitam de grandes quantidades de água, o que se torna preocupante devido à escassez deste recurso. Várias pesquisas e metodologias estão sendo realizadas no âmbito da eficiência do uso da água. Neste sentido, o correto conhecimento da evapotranspiração das culturas, seja para projeto ou manejo de irrigação, assume fundamental importância (CARVALHO et al., 2011).

A evaporação da água é um fenômeno físico que implica na mudança de estado da fase líquida para gasosa diretamente de uma superfície de água livre ou úmida. Quando esta mudança se dá através das plantas recebe o nome de transpiração. No caso de solos parcialmente vegetados estes procedimentos ocorrem simultaneamente e independente, sendo utilizado o termo evapotranspiração (BERLATO & MOLION, 1981).

A evapotranspiração é um termo bastante estudado devido à sua importância para a estimativa do consumo de água pelas plantas. A primeira citação foi efetuada por Thornthwaite em 1948, citado por vários autores entre eles Medeiros (1996). De acordo com Sedyama (1996), Thornthwaite tinha a preocupação de explicar as variações sazonais do balanço de água no solo e tentar definir as diferenças regionais do clima. Por esta razão, este método é apenas uma função da temperatura média do ar e da duração do dia, em média mensal.

Para Thornthwaite, o fenômeno chamado de evapotranspiração de referência (ET_o), é considerado como: a perda máxima de água em uma superfície de solo úmido, completamente coberto com vegetação rasteira, em fase de desenvolvimento ativo, e com dimensões suficientemente grandes, de modo a minimizar os efeitos de energia local. Se algumas dessas condições, não forem atendidas têm-se a evapotranspiração real. Quase que simultaneamente, Penman (1948), na Inglaterra, também definiu a evapotranspiração de referência (PEREIRA et al., 1997).

Segundo Dantas (1995) a evapotranspiração consiste numa das maiores preocupações na medição das variáveis climatológicas, tendo em vista que a perda de água da superfície terrestre possui influência no desenvolvimento das culturas, principalmente nas regiões áridas e semiáridas onde o déficit hídrico é bem caracterizado, e a irrigação desempenha papel importante na suplementação de água exigida por cada cultura.

De acordo com Back (2007), vários modelos de balanço hídrico são empregados com a finalidade de dimensionar sistemas de irrigação, manejar projetos de irrigação ou estudar probabilidades de ocorrências de estiagens ou excessos hídricos. Nesses modelos utilizam-se, em geral, como entrada de água no sistema, a precipitação e a irrigação, e como principal saída a evapotranspiração. Dados de precipitação medida podem ser obtidos com relativa facilidade. Entretanto, existe carência de informações sobre evapotranspiração das culturas. Devido às dificuldades de medida da evapotranspiração das culturas, essa é estimada com base nos valores da Evapotranspiração de Referência (ET_o) e no Coeficiente de Cultura (K_c).

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).

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).

De acordo com Pereira et al. (2002), a escolha de um método para se estimar a evapotranspiração depende de uma série de fatores, em que um deles é a disponibilidade de dados meteorológicos, visto que os métodos mais complexos que exigem grande número de variáveis somente têm aplicabilidade quando há disponibilidade de todos os dados necessários.

2.1.1 Fatores que influenciam na evapotranspiração

A evapotranspiração é função dos elementos meteorológicos, do solo e da planta (LEMON, et al., 1957). Quando a cobertura do solo é completa e não há restrição hídrica, a ETo é condicionada principalmente pelos elementos meteorológicos (PENMAN, 1956).

Os fatores meteorológicos têm influência direta nos requerimentos d'água pelas culturas, como afirma Klar (1991) o clima é o fator que mais afeta a perda de água de uma cultura. As condições de solo, doenças, pragas, a própria cultura e suas características de crescimento, além das práticas agrícolas, também influenciam a transferência de água para a atmosfera.

A evapotranspiração depende da demanda evaporativa da atmosfera, determinada por quatro componentes meteorológicas: radiação solar, vento, umidade e temperatura do ar (MATZENAUER, 1992). A importância relativa da radiação líquida, da umidade relativa do ar e da velocidade do vento na Eto é da ordem de 80:6:14, respectivamente, dependendo do local e das condições meteorológicas vigentes (MUKAMMAL e BRUCE, 1960).

No caso de não se dispor de dados de radiação solar incidente, pode-se lançar mão de estimativas a partir de dados de insolação, considerando-se ainda, valores de fotoperíodo e dados de radiação no topo da atmosfera, tendo conhecimento dos coeficientes de Angström (a e b) (SMITH, 1991).

Segundo Allen et al. (1998), na ausência de dados de radiação solar, esse elemento pode ser obtido a partir da diferença de temperatura. Portanto, a diferença entre temperatura máxima e mínima é um bom indicador da fração de radiação no topo da atmosfera que alcança a superfície da terra.

2.1.2 Determinação da Evapotranspiração

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

Burman et al. (1983) revisaram vários métodos de determinação da evapotranspiração, adotados em diversas partes do mundo. Estes autores classificaram os métodos em dois grandes grupos: o primeiro grupo inclui os

métodos onde a evapotranspiração potencial pode ser determinada a partir de medidas diretas, como ocorrem com os lisímetros. No segundo grupo estão os métodos determinados através de dados climáticos, também chamados de métodos indiretos, nos quais a evapotranspiração de referência é estimada por fórmulas empíricas, ou através de equipamentos como tanque de classe A e evaporímetro.

A determinação da ETo através dos métodos diretos demanda equipamentos específicos, usualmente lisímetros, que é considerado um método exato e direto. No entanto, possui custo elevado e demanda tempo, além de necessitar de experimentos cuidadosamente planejados (KUMAR et al., 2008). A aplicação dos métodos diretos tem se restringido a instituições de pesquisa com a finalidade de calibração dos métodos indiretos.

Devido às dificuldades de determinação da evapotranspiração de referência mediante medições diretas em condições reais, têm sido largamente utilizados métodos indiretos, possibilitando resultados satisfatórios (MARQUELLI et al., 1986).

A Comissão Internacional de Irrigação e Drenagem (ICID) e a Organização das Nações Unidas para a Agricultura e Alimentação (FAO), consideram o método de Penman-Monteith como padrão no cálculo da evapotranspiração de referência, a partir de dados meteorológicos e na avaliação de outros métodos (SMITH, 1991).

Vários métodos de estimativa da evapotranspiração têm sido desenvolvidos e testados, os quais vão desde métodos simples, que requerem apenas dados de temperatura mensal (Thornthwaite, 1948), até métodos baseados em processos físicos, que requerem vários dados de entrada, como o modelo de PM FAO-56 (ALLEN et al., 1998).

Havendo a indisponibilidade de dados de entrada, para o método Penman-Monteith, justifica-se a utilização de métodos alternativos. Verifica-se, na maioria dos trabalhos presentes na literatura, que os métodos mais estudados são: Thornthwaite, Hargreaves, Blaney-Criddle, Priestley-Taylor, Turc, Makkink, Linacre, Hamon, Holdridge, Radiação Solar, Jensen-Haise, Tanque de Classe A e Penman-Monteith.

Na Tabela 1 são visualizados vários métodos, os elementos meteorológicos necessários para estimar, variáveis auxiliares do cálculo e observações.

Tabela 1 - Métodos de estimativa de evapotranspiração mais utilizados conforme bibliografias citadas. Adaptado de Carvalho et al. (2001).

Método	Elementos meteorológicos de entrada	Variáveis auxiliares de entrada	Observações
Penman (PEN)	Tx, Tn, T, UR, v, n, P, Rs, Rn	DJ, Lat	Conhecido também por Penman Original
Thornthwaite (TW)	Tmn, Tm, T	Lat	Estimativa da ETp, em escala mensal (mm mês ⁻¹). Utilizando-se T, pode-se estimar a ETp ou ETo, em escala diária, desde que o resultado seja dividido pelo número de dias.
Turc (TC)	T, UR, Rs	DJ, Lat	-
Penman-Monteith-FAO (PM-FAO)	Tx, Tn, T, UR, v, n, P, Rs, Rn	DJ, Lat	Também conhecido por Penman-Mointeith
Tanque Classe A (TCA)	ECA, v, UR	Extensão da bordadura	-
Blaney-Criddle (BC)	Tm, URmín, n, v	DJ, Lat	Também conhecido por Blaney-Criddle FAO 24. Todos os dados de entrada em médias mensais. Estimativa da ETo em escala mensal (mm mês ⁻¹). Com DJ e Lat, pode-se estimar o parâmetro “p” sem uso de tabela. Ver, também, observação do método TW, para estimativa da ETo em escala diária.
Makkink (MK)	Rs, P, T	DJ Lat	Os parâmetros “s” ou “Δ”, γ e λ são estimados da mesma forma que no método PM-FAO
Hamon (HM)	T	DJ, Lat	DJ e Lat para estimativa de N (duração astronômica do dia).
Radiação Solar (RS)	T, v, UR, Rs, P	-	Também conhecido por Radiação Solar FAO 24. É uma adaptação ao método MK.
Linacre (LN)	Tm, Tpo, Tx, Tn	Lat, Alt	Trata-se de uma simplificação do método PEN. A parte (Tm-Tpo) deste método pode ser estimada em função de Alt, Tm, Tx, Tn e, ainda, pela diferença entre as temperaturas médias dos meses mais quente e mais frio.

Camargo (CAM)	T _m	DJ, Lat	É uma simplificação do método TW. Estima a ET _p em período de 10 ou 30 dias. Ver, também, observação do método TW, para estimativa da ETo em escala diária.
Jensen-Haise (JH)	R _s , T	DJ, Lat	--
Hargreaves (HG)	T, T _x , T _n	DJ, Lat	Bastante divulgado como método "Hargreaves e Samani".
Priestley-Taylor (PT)	T, P, R _n , G	DJ, Lat	É uma simplificação do método PEN. R _n e G podem seguir os mesmos procedimentos do método PM-FAO.
Holdridge (HD)	T		O parâmetro "CHO" deste método permite ajustar as estimativas em diferentes escalas de tempo (diária, mensal e anual).
Kharrufa (KF)	T	DJ, Lat	DJ e Lat para estimativa do parâmetro "p".

T_x, T_n e T: temperaturas diárias máxima, mínima e média, respectivamente; UR: umidade relativa média diária; v: velocidade do vento; n: insolação ou horas de brilho solar; P: pressão atmosférica média diária; R_s: radiação solar; R_n: saldo de radiação no sistema solo-planta-atmosfera; T_{mn}: temperatura normal (média de 30 anos) do mês ou a média mensal de vários anos com representatividade climática; T_m: temperatura média mensal observada no mês em estudo; ECA: evaporação do tanque Classe A; UR_{mín}: umidade relativa mínima; T_{po}: temperatura do ponto de orvalho; G: fluxo de calor no solo. Para os métodos que necessitam da radiação solar (R_s) e/ou saldo de radiação (R_n), quando não há a disponibilidade destes elementos medidos, estes poderão ser facilmente estimados, em função de outros elementos climáticos (T_x, T_n, T e UR), complementados com DJ (dia Juliano) e Lat (latitude). O parâmetro λ (calor latente de evaporação), presente em vários métodos, equivale a 2,45 Mj kg⁻¹, podendo, também, ser estimado em função de T. É utilizado para converter a radiação à superfície ou extraterrestre, em equivalente de evaporação.

As equações empíricas foram estabelecidas com base no ajuste por regressão das variáveis envolvidas, para algumas regiões e condições específicas, por isso devem ser usadas com cuidado. Em regiões onde o clima difere daquele onde a equação foi desenvolvida, os resultados obtidos não são satisfatórios (BERLATO e MOLION, 1981).

Para Amatya et al. (1992), nenhum método específico de estimativa de ETo tem sido adequado para todas as condições climáticas e locais, o que a pesquisa procura é aplicar o método que melhor corresponda à realidade de cada local.

2.2 Redes Neurais Artificiais (RNAs)

Redes Neurais Artificiais (RNAs) são agrupamentos de unidades de processamento (neurônios ou nós), estruturadas e interconectadas, cujo funcionamento é análogo a uma estrutura neural de organismo inteligente (MULLER e FILL, 2003). As RNAs extraem seu poder computacional da sua distribuição de estrutura maciçamente paralela e da sua habilidade de aprender/generalizar, tornando possível a resolução de problemas complexos nas mais diferentes áreas do conhecimento (HAYKIN, 2001).

As redes neurais artificiais 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).

Uma RNA possui processamento que se assemelha ao cérebro, pois: i) o conhecimento é adquirido através de um processo de aprendizagem e ii) são utilizadas forças de conexão entre os neurônios, conhecidas como pesos sinápticos, para armazenar o conhecimento adquirido (HAYKIN, 2001).

As RNAs têm sido utilizadas com sucesso para modelar relações envolvendo séries temporais complexas em várias áreas do conhecimento. Segundo

Galvão et al. (1999), em função de sua estrutura não-linear as redes conseguem captar características mais complexas dos dados, o que nem sempre é possível com a utilização das técnicas estatísticas tradicionais.

O aprendizado ou treinamento em RNAs está associado à capacidade de dar respostas coerentes para dados não apresentados a ela previamente durante o treinamento. O processamento da informação em modelos baseados em RNAs é feito por meio de estruturas neurais artificiais em que o armazenamento e o processamento da informação são realizados de maneiras paralelas e distribuídos por elementos processadores relativamente simples denominado neurônios (VALENÇA, 2005).

2.2.1 Neurônios Biológicos

O perfeito funcionamento e integração entre os diversos setores de um organismo são garantidos pelo rápido recebimento, processamento e condução dos impulsos nervosos, por meio de células altamente especializadas na captura e transmissão dos impulsos nervosos, chamados neurônios.

Os neurônios podem ser divididos em três seções: o corpo celular, os dendritos e o axônio, desempenhando, cada um deles, funções específicas, porém complementares (BRAGA et al. 2000). A função dos dendritos é captar informações provenientes do meio externo ou de outros neurônios e conduzi-las ao corpo celular. O corpo celular reúne as diferentes informações fornecidas pelos dendritos, e após processá-las gera um sinal constante que é conduzido por toda extensão do axônio. Os dendritos de outros neurônios que estiverem conectados a este axônio perceberão o sinal emitido. O ponto de contato entre a terminação axônica de um neurônio e o dendrito de outro é chamada de Sinapse.

Esta estrutura, que possui alta capacidade de aprendizado e adaptação, inspirou a criação de um sistema artificial capaz de simular o aprendizado e a generalização de uma rede neural biológica, podendo assim realizar tarefas que programas convencionais não conseguiriam (VALENÇA, 2010).

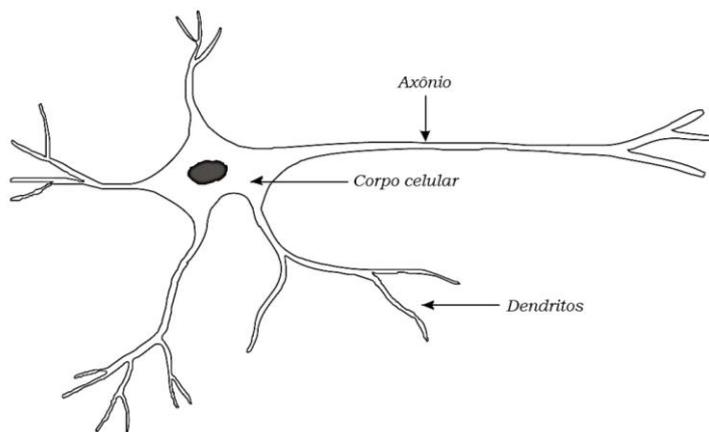


Figura 1 - Estrutura geral de um neurônio biológico

Segundo Valença (2010), um dos aspectos importantes de entendimento do funcionamento do neurônio biológico é aquele relacionado com a Lei do Tudo ou Nada. Esta lei está relacionada com a intensidade do estímulo, chamado de limiar excitatório, a partir do qual o neurônio dispara ou não o impulso nervoso. Portanto, se o estímulo for muito pequeno, sua intensidade será inferior ao limiar excitatório e não ocorrerá nenhum impulso nervoso. Por outro lado, passado esse limiar, o potencial de ação do neurônio será sempre o mesmo, qualquer que seja a intensidade do estímulo.

2.2.2 Neurônios Artificiais

Conforme Jackson (2002), rede neural é uma classe de sistemas modelados segundo o cérebro humano. Assim como o cérebro humano é constituído de milhões de neurônios conectados por sinapses, as redes neurais são formadas por um grande número de simuladores de neurônios, conectados de uma maneira similar aos neurônios do cérebro humano. A força destas conexões pode variar em resposta a estímulos, permitindo o aprendizado.

As redes neurais são modelos que simulam o comportamento dos neurônios naturais. Neste sentido, Haykin (2001) define RN como um processador que funciona de forma paralela e distribuída, constituído de unidades de processamento

simples, que armazenam o conhecimento experimental e o torna disponível para o uso.

A primeira proposta de uma representação matemática, conhecido como neurônio matemático, para representar o neurônio biológico foi feita por McCulloch e Pitts (1943), onde de forma simples representava o neurônio biológico utilizando uma regra de propagação e uma função de ativação (VALENÇA, 2010). O neurônio foi representado por n terminais de entradas ($x_1, x_2, x_3, \dots, x_n$) que representavam os dendritos e apenas um terminal de saída, o axônio, conforme Figura 2.

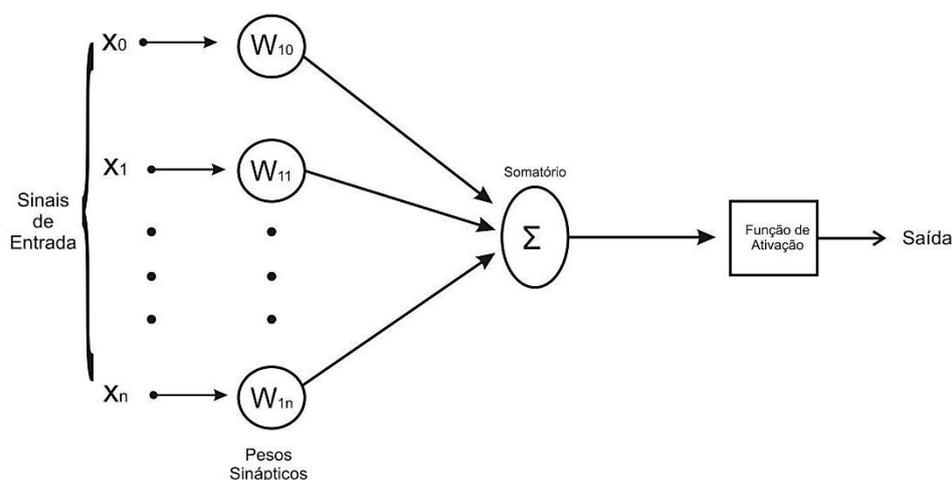


Figura 2 - Modelo de neurônio artificial

Cada neurônio é constituído pelos seguintes elementos:

Sinapses ou pesos sinápticos: formam o conjunto de elos de conexão, caracterizada por um peso. Especificamente, a função do peso é ponderar o sinal de entrada da sinapse conectada ao neurônio. As redes neurais artificiais podem apresentar também pesos adicionais, denominados de bias, que tem a função de evitar a geração de erros quando todos os dados de entradas são nulos.

Somatório: agrega os dados das entradas ponderados pelos respectivos pesos;

Função de ativação: é uma função de ordem interna, sendo uma decisão tomada pelo próprio neurônio sobre o que fazer com o valor resultante do somatório das entradas ponderadas.

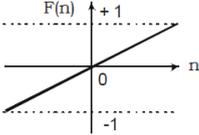
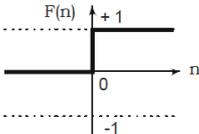
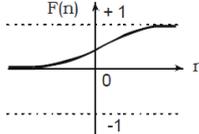
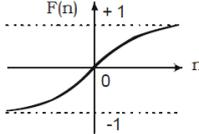
Função de Transferência: é uma função de saída ou limiar lógico. Ela controla a intensidade de ativação para obter o desempenho desejado na rede.

2.2.3 Funções de ativação e transferência

Em uma RNA, cada unidade de processamento está associada a um estado de ativação que é determinado pela função de ativação, contínuo ou discreto, que se quer representar com o modelo. A função escolhida para o estado de ativação é responsável pelo sinal a ser transmitido por um determinado neurônio aos demais a ele conectados. (VALENÇA, 2010).

Haykin (2001), afirma que as funções mais utilizadas são: linear, degrau, sigmoide logística e tangente hiperbólica. Na Tabela 2, estão dispostas as funções e suas representações gráficas.

Tabela 2 - Funções de ativação e suas representações gráficas.

Função	Equação	Representação gráfica
Linear	$f(n) = n$	
Degrau	$f(n) = \begin{cases} 1, \forall n \geq 0 \\ 0, \forall n < 0 \end{cases}$	
Sigmoide Logística	$f(n) = \frac{1}{1 + e^{-n}}$	
Tangente Hiperbólica	$f(n) = \frac{e^n - e^{-n}}{e^n + e^{-n}}$	

Segundo Silva et al (2004) as funções são descritas como:

Função linear: é a função que não limita a saída da RNA e é usada para armazenar entrada e saída de dados. Os neurônios que possuem esta função atuam como aproximadores lineares;

Função degrau: é a função utilizada para neurônios que tomam decisões binárias, limitado a saída do neurônio somente a dois valores, sendo assim, classificadora;

Função sigmoide logística: é uma função limitada que assume valores entre um limite superior e um inferior (0 e 1), sem jamais atingi-los;

Função tangente hiperbólica: é uma função limitada, definida no intervalo de -1 e +1.

As funções tangentes hiperbólicas e sigmóides logística são as mais utilizadas em redes neurais artificiais, pois apresentam diversas características favoráveis, como o fato de serem funções semi-lineares, contínuas, simétricas, deriváveis em toda sua extensão, crescente e limitada por assíntotas horizontais (REINKE, 2008).

2.2.4 Arquitetura de uma RNA

A arquitetura refere-se à maneira como os neurônios da rede estão organizados. Existem várias estruturas que diferem umas das outras em função do número de camadas e pela forma como seus neurônios interagem (VALENÇA, 2005).

Várias sugestões de arquiteturas são facilmente encontradas nas bibliografias, mas a definição dos parâmetros (algoritmo de treinamento, tipo de conexão, número de camadas e de neurônios nas camadas) não possui uma regra exata. Dessa forma, a estrutura da rede neural deve ser determinada pela análise do problema e pela experimentação.

Um fator que define diretamente a arquitetura ou topologia de uma RNA é o problema que será tratado pela rede e, neste contexto, devem ser considerados os seguintes componentes: quantidades de camadas, números de neurônios em cada camada e tipo de conexão entre os neurônios (BRAGA et al., 2000). A Figura 3 ilustra a topologia de uma RNA.

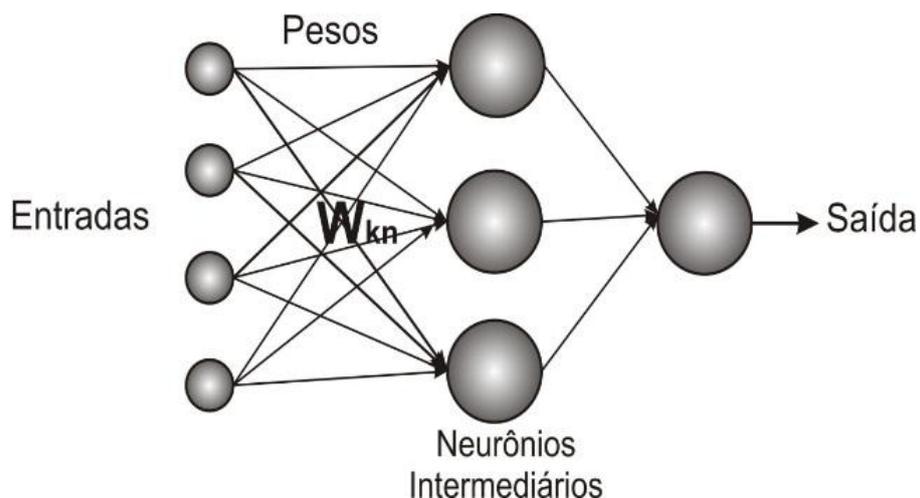


Figura 3 - Arquitetura de uma rede neural artificial

Na figura 3, podem-se observar as camadas de uma RNA, que são classificadas em:

Camada de Entrada: onde os padrões são apresentados à rede

Camadas Intermediárias ou Escondidas: onde é feita a maior parte do processamento. Através das conexões ponderadas, estas camadas podem ser consideradas como extratoras de características.

Camada de Saída: onde o resultado final é concluído e apresentado.

Segundo Silva et al (2004), entre os fatores que influenciam estes ajustes estão: número de exemplos de treinamento, complexidade da função a ser aprendida e distribuição estatística dos dados.

Conforme Reinke (2008), o projeto de construção de uma RNA deve-se seguir alguns passos básicos:

- i) definição do problema a ser estruturado;
- ii) selecionar os dados de entrada e de saída (quando necessário);
- iii) treinar a rede (definir o número de camadas escondidas, o número de neurônios, o tipo de conexão e o algoritmo de treinamento),

Caso seja realizado o treinamento com sucesso, então segue o passo iv, caso contrário, retorna-se ao passo iii e realiza novamente o treino alterando a estrutura da rede.

- iv) testar a rede
- v) validar e executar.

2.2.4.1 Tipos de arquiteturas de RNAs

Existem diferentes formas possíveis de conectar os componentes das RNA, sendo as mais conhecidas, quanto ao número de camadas, única e múltiplas camadas, e, quanto aos tipos de conexões entre os neurônios, feedforward ou acíclica e feedback ou cíclica (HAYKIN, 2001).

2.2.4.1.1 Redes Feedforward (Única Camada)

São redes neurais onde se tem uma camada de entrada e uma única camada de neurônios que é a própria camada de saída (Figura 5).

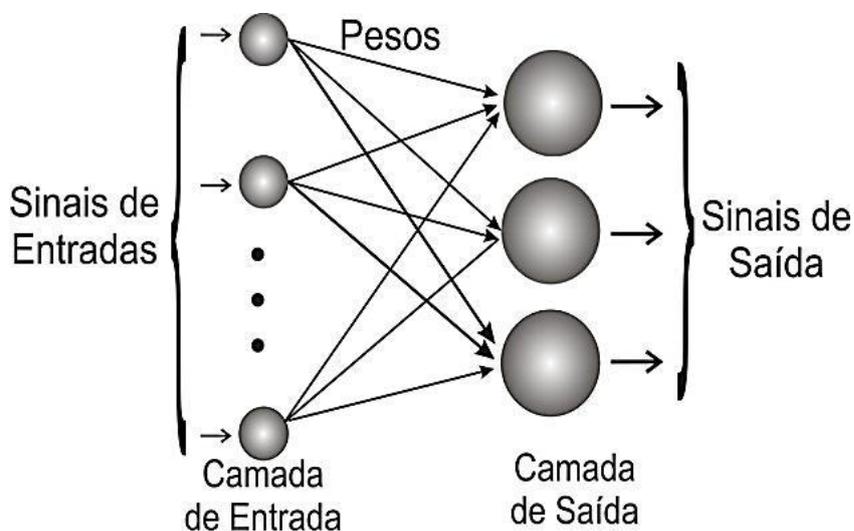


Figura 4 - Exemplo de rede neural com camada única

Suas principais aplicações são em memória associativas e no reconhecimento de padrões (WIDROW et al., 1988).

2.2.4.1.2 Redes Feedforward (Multicamadas)

Este tipo de rede distingue da anterior pela presença de uma ou mais camadas escondidas de neurônios (Figura 6). Por exemplo, os neurônios que recebem sinais de excitação do meio externo estão na camada de entrada; os neurônios que estão na saída representam a camada de saída e os neurônios intermediários estão nas camadas escondidas.

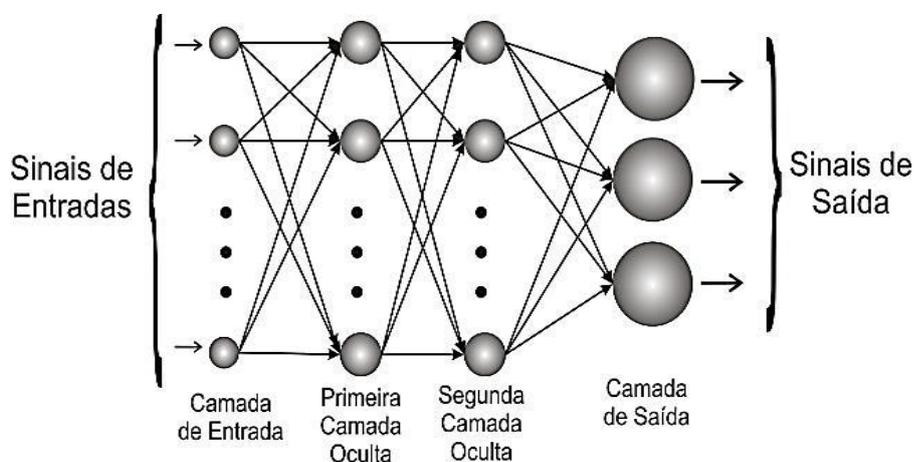


Figura 5 - Exemplo de rede neural com múltiplas camadas

A função dos neurônios da camada oculta é aumentar a capacidade de classificação e predição da rede.

Suas principais aplicações são reconhecimento de padrões, aproximadores universal de funções e em controle (NETO et al, 1999; NARENDRA e PARTHASARATHY, 1990). Neste tipo de redes, tem-se o Madaline, o Perceptron Multicamadas e o de Função Base Radial (RBF).

2.2.4.1.3 Redes Recorrentes

São redes que contém realimentação entre neurônios de camadas diferentes. Suas principais aplicações são em sistemas dinâmicos, memória

associativa, previsão e estimação, otimização e em controle. Neste tipo de redes, temos o modelo de Hopfield e o Perceptron com realimentação.

Na figura 7 pode-se observar um exemplo de estrutura de redes recorrentes.

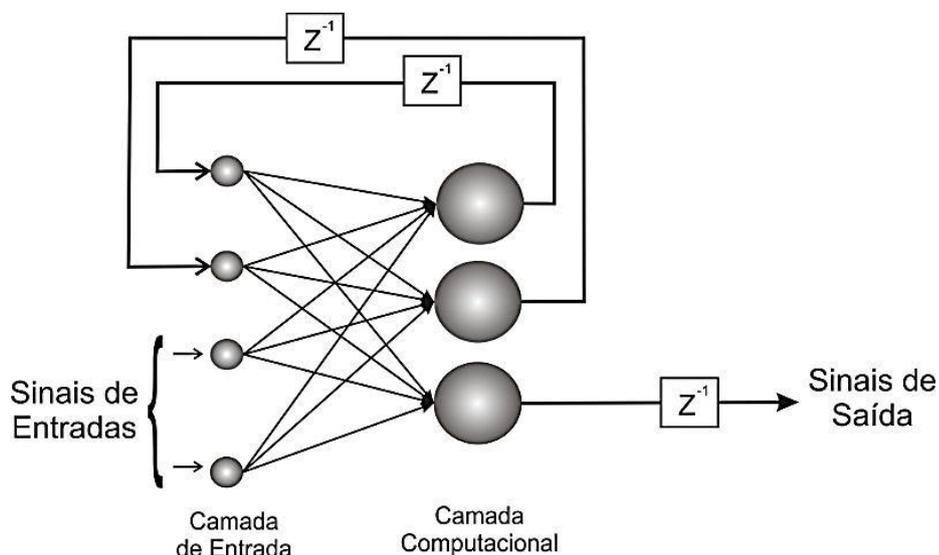


Figura 6 - Exemplo de rede neural recorrente

2.2.5 Treinamento das RNAs

O conjunto de treinamento é de extrema importância, pois corresponde aos dados que serão apresentados como entrada e utilizados para o aprendizado da RNA. Essas informações são fonte do conhecimento da rede e todas as generalizações que a mesma for capaz de realizar dependem do seu aprendizado (TAFNER et al, 1996).

Tendo em vista que a rede não é capaz de entender o mundo em seu todo, o conjunto de treinamento deve passar por processo de tratamento antes de ser apresentado à rede. O tratamento corresponde à adequação dos dados a uma linguagem compreensível, melhorando a representação do problema, além da eliminação de dados redundantes, não relevantes ou duvidados (REINKE, 2008).

A seleção dos dados de entrada deve ser estudada cautelosamente, de modo que contenha dados com qualidade e em quantidade apropriada. Em relação à quantidade, cabe salientar que se deve dar preferência a dados reais e que

possuam credibilidade; dados simulados só devem ser aplicados em situações especiais que os exijam. Além disso, a seleção das variáveis utilizadas exige atenção, pois a inclusão de uma variável pode não fazer diferença ou piorar o desempenho da rede. Quanto mais dados reais tiverem sido apresentados durante a etapa de treinamento, tanto melhores serão as respostas fornecidas pela rede (ROHN e MINE, 2003; ADELOYE e MUNARI, 2005).

Segundo Tatibana e Kaetsu (2012), de 50 a 90% do total de dados deve ser separado para o treinamento da rede neural, dados estes escolhidos aleatoriamente, a fim de que a rede "aprenda" as regras associadas ao processo. O restante dos dados só é apresentado à rede neural na fase de testes a fim de que ela possa "deduzir" corretamente o inter-relacionamento entre os dados.

2.2.6 Aprendizado da RNA

Osório e Bittencourt (2000) definiram aprendizado natural como a capacidade de se adaptar, de modificar e melhorar seu comportamento e suas respostas sendo, portanto, uma das propriedades mais importantes dos seres ditos inteligentes, sejam eles humanos ou não.

Do ponto de vista computacional, o aprendizado de máquina tenta fazer com que os programas de computador "aprendam" com os dados que eles "estudam", tal que esses programas tomem decisões diferentes baseadas nas características dos dados estudados, usando a estatística para os conceitos fundamentais, e adicionando heurística avançada da inteligência artificial aos algoritmos para alcançar os seus objetivos (GUIMARÃES, 2005; GUIMARÃES, 2001).

Em se tratando de RNA, segundo Haykin (2000), aprendizagem é um processo pelo qual os parâmetros livres (pesos sinápticos) de uma rede neural são adaptados através de um processo de estimulação pelo ambiente no qual a rede está inserida. O tipo de aprendizagem é determinado pela maneira na qual a modificação dos parâmetros ocorre.

Rohn e Mine (2003) destacaram que, para o aprendizado não é necessário um conhecimento detalhado sobre as relações entre as variáveis envolvidas no problema, contudo, as redes necessitam de uma quantidade considerável de dados

históricos para que consigam extrair satisfatoriamente as características relevantes existentes no conjunto de dados. Com o treinamento, a rede é capaz não somente de aproximar qualquer função, mas também de generalizar (validar), proporcionando saídas corretas para entradas não apresentadas anteriormente.

Conforme Rezende (2003), para um determinado conjunto de dados, o algoritmo de aprendizagem deve ser responsável pela adaptação dos parâmetros da rede, de maneira que, em um número finito de iterações, haja convergência para uma solução. O critério de convergência varia de acordo com o algoritmo e com o paradigma de aprendizado.

O aprendizado é em geral um processo gradual e iterado, onde os pesos são modificados várias vezes, pouco a pouco, seguindo-se uma regra de aprendizado que estabelece a forma como estes pesos são alterados. Cada iteração deste processo gradativo de adaptação dos pesos de uma rede neural, onde é feita uma apresentação completa do conjunto de dados, é chamada de época ou ciclo de aprendizado. Os métodos de aprendizado neural podem ser divididos em três grandes classes, segundo o grau de controle dado ao usuário: aprendizado supervisionado e não supervisionado (OSÓRIO e BITTENCOURT, 2000).

2.2.6.1 Aprendizado Supervisionado

O método supervisionado é o mais comum no treinamento das RNAs, sendo assim denominado pelo fato de as entradas e saídas desejadas serem fornecidas para a rede por meio de um supervisor externo. Tem como resultado o ajuste dos parâmetros da rede, de forma a encontrar uma ligação entre os pares de entrada e saída. A rede tem sua saída corrente comparada com a saída desejada, recebendo informações do supervisor sobre o erro da resposta atual, e a cada padrão de entrada a rede compara a resposta desejada ajustando-se os pesos das conexões para minimizar o erro (BRAGA et al., 2000).

A desvantagem do aprendizado supervisionado é que, na ausência do professor, a rede não conseguirá aprender novas estratégias para situações não cobertas pelos exemplos do treinamento da rede. Os exemplos mais conhecidos de algoritmos para aprendizado supervisionado são a regra delta (WIDROW e HOFF,

1960) e a sua generalização para redes de múltiplas camadas, o algoritmo backpropagation (RUMELHART, et al., 1986).

2.2.6.2 Aprendizado Não Supervisionado

Neste tipo de aprendizado, a rede aprende com os próprios dados de entrada (somente os exemplos de entradas são mostrados à rede), ou seja, este algoritmo não requer o conhecimento das saídas. Um exemplo de rede que utiliza esse aprendizado é a Kohonen (BRAGA et al., 2000).

A partir do momento em que a rede estabelece uma harmonia com as regularidades estatísticas da entrada de dados, desenvolve-se nela uma habilidade de formar representações internas para codificar características intrínsecas da entrada e, deste modo, criar novas classes ou grupos automaticamente. Este tipo de aprendizado só se torna possível quando existe redundância nos dados de entrada. Sem redundância seria impossível encontrar quaisquer padrões ou características dos dados de entrada (HAYKIN, 2001; BRAGA et al., 2000).

2.2.7 Redes Perceptron

A partir do modelo de neurônio artificial de McCulloch & Pitts (MCCULLOCH e PITTS, 1943), em 1957 Frank Rosenblatt (1958) propôs o perceptron como o primeiro modelo para aprendizagem supervisionada. O perceptron é a forma mais simples de uma RNA usada para classificação de padrões ditos linearmente separáveis. Basicamente, ele consiste em um único neurônio com pesos sinápticos ajustáveis e bias (HAYKIN, 2001).

Valença (2010) define que a rede perceptron é composta por uma camada de entrada onde estão as informações que alimentam a rede, uma função de pesos e uma função de saída, também conhecida como função de ativação que fornece o sinal emitido pelo neurônio da camada de saída.

Um exemplo de rede perceptron de camada única está exposto na Figura 8.

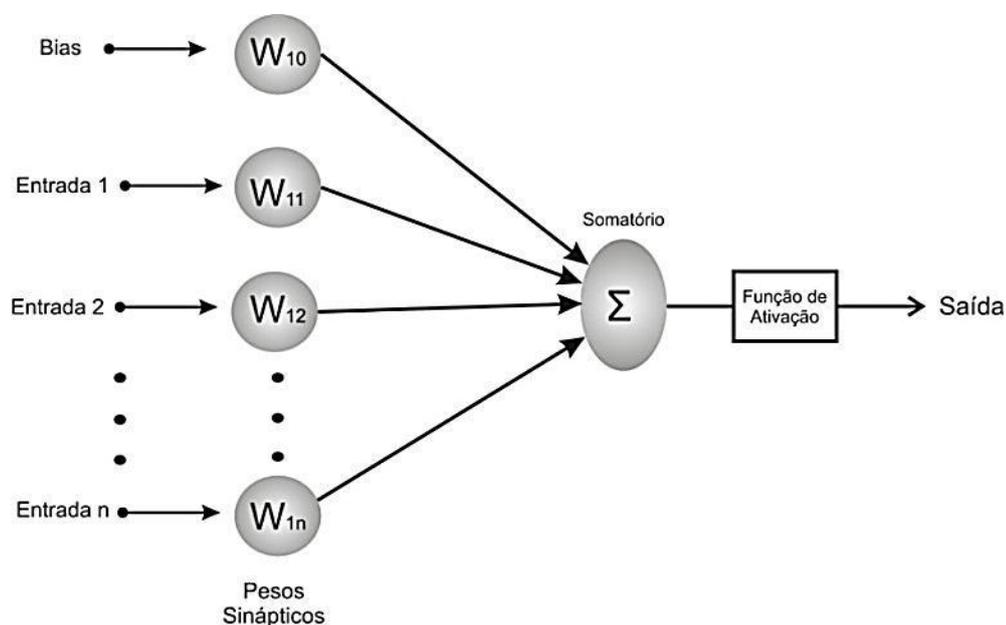


Figura 7- Estrutura de rede neural do tipo perceptron de única camada

O perceptron pode ser visto como ferramenta para reconhecimento de padrões. Reconhecer um padrão consiste em classificar este como sendo pertencente a uma única classe dentre um conjunto de classes pré-estabelecidas.

A principal limitação do perceptron é que este pode classificar somente conjunto de dados linearmente separáveis e tem como função de ativação do tipo degrau, o que fornece apenas um sinal discreto (sim ou não) (BRAGA et al., 2000).

2.2.8 Rede Perceptron de Múltiplas Camadas (MLP)

A rede perceptron de múltiplas camadas é um sistema de neurônios ligados por conexões sinápticas dividido em neurônios de entrada, que recebem estímulos do meio externo, neurônios internos ou *hidden* (ocultos) e neurônios de saída, que se comunica com o exterior (BEALE e JACKSON, 1994). O MLP foi concebido para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico.

Um exemplo de estrutura de redes neurais de múltiplas camadas está exposto na Figura 9.

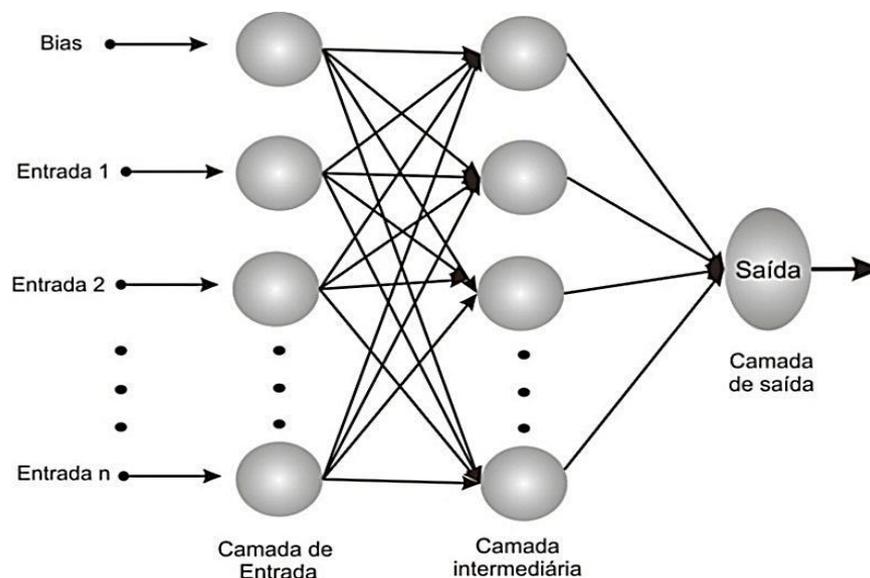


Figura 8 - Rede neural artificial multicamadas (Multilayer Perceptron)

Conforme Valença (2010) as redes MLP tradicionais apresentam as seguintes características:

Camada de entrada: cada neurônio desta camada corresponde a uma variável de entrada do problema;

Camada intermediária: é a camada responsável pela não linearidade da rede e permitem que as redes MLP sejam capazes de resolver problemas reais. Os neurônios desta camada possuem, normalmente, uma função de ativação sigmoide logística ou tangente hiperbólica.

Camada de saída: esta camada é responsável pela resposta da rede e representa a variável desejada.

As camadas intermediárias funcionam como extratoras de características, seus pesos são codificações das informações apresentadas nos padrões de entrada e permitem que a rede crie sua própria representação, mais rica e detalhada, do problema (SILVA, 1997).

A rede neural passa por um processo de treinamento a partir dos casos reais conhecidos, adquirindo, a partir daí, a sistemática necessária para executar

adequadamente o processo desejado dos dados fornecidos. Sendo assim, a rede neural é capaz de extrair regras básicas a partir de dados reais, diferindo da computação programada, onde é necessário um conjunto de regras rígidas fixadas e algoritmos.

As redes MLP são também redes de treinamento supervisionado, logo, o algoritmo backpropagation realiza a propagação recursiva dos erros (VALENÇA, 2010). Este algoritmo é baseado numa regra de aprendizagem que corrige o erro durante o treinamento (HAYKIN, 1999).

2.2.8.1 Algoritmo Backpropagation

O algoritmo de aprendizado mais conhecido para treinamento destas redes é o algoritmo backpropagation (RUMELHART e MCCLELL, 1986). Este algoritmo teve a sua origem no trabalho desenvolvido por Paul Werbos, em 1974. Entretanto, sua popularização ocorreu apenas na década de 80 através dos trabalhos de Geoffrey Hinton, David Rumelhart e Ronald Willimas (VALENÇA, 2010).

O algoritmo de treinamento consiste basicamente em dois passos: no primeiro, propagam-se os sinais no sentido progressivo (da camada de entrada para a camada de saída), calculando-se o sinal de saída e o erro. Os pesos permanecem fixos; no segundo passo, os erros são propagados recursivamente (da camada de saída para a camada de entrada) através da rede e os pesos são ajustados através da regra de ajustes de pesos.

Esses processos também são conhecidos como Passo Forward e Backward (BRAGA et al, 2000) e está representado na Figura 10.

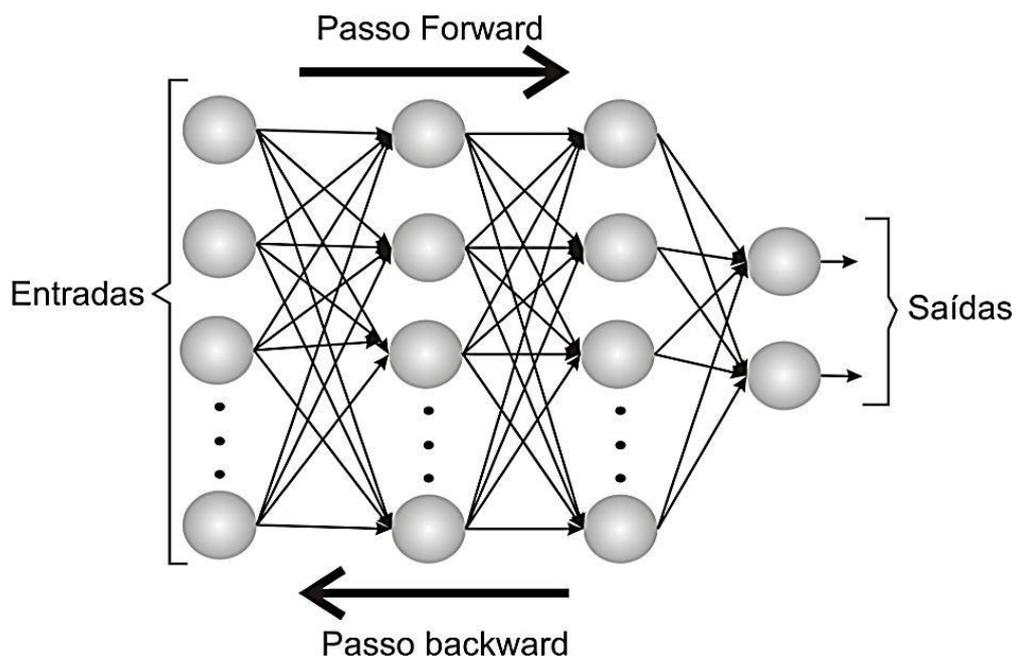


Figura 9 - Fluxo do algoritmo backpropagation

Dentre as características que norteiam o funcionamento do algoritmo de aprendizado backpropagation, um detalhe importante é a repetição (ciclos) em um determinado número de vezes (x) que o par amostra-resultado (saída) é submetida para que a rede possa, efetivamente, aprender. Estas repetições são chamadas *épocas* de treinamento (ciclos).

Na atualização dos pesos sinápticos, o algoritmo fornece uma aproximação, cujo parâmetro é um índice variando entre 0 (zero) e 1 (um), chamado de *taxa de aprendizagem*. Quanto menor for este parâmetro, menores serão as variações dos pesos sinápticos da rede, de uma iteração para a outra, e mais suave será a trajetória no espaço de pesos. Esta melhoria, entretanto, é obtida à custa de uma evolução de aprendizagem lenta. Por outro lado, caso utilize-se um parâmetro muito alto, para acelerar a aprendizagem, as grandes modificações nos pesos resultantes podem tornar a rede instável oscilatória (HAYKIN, 2001).

O Backpropagation é um algoritmo de aprendizagem eficiente e utilizado por diversos autores, porém, sua implementação normalmente exige muitos passos e, assim, um tempo de treinamento longo. Há muitos estudos, baseados em heurísticas e em técnicas de otimização, para apressar a convergência do algoritmo, com o objetivo de melhorar sua eficiência em relação ao tempo de treinamento (ANDRADE et al., 2003).

2.2.9 Modelando RNA

Para se efetuar o mapeamento do processo através de redes neurais artificiais, alguns passos devem ser seguidos para a adequada aplicação da abordagem neural (HAYKIN, 1994).

Para Valença (2010), a modelagem de uma rede neural artificial é realizada através da divisão dos dados, seleção das variáveis de entrada e saída, determinação da arquitetura de rede, treinamento e validação do desempenho.

2.2.9.1 Coleta de dados

O primeiro passo do processo de desenvolvimento de redes neurais artificiais é a coleta de dados relativos ao problema. Esta tarefa requer uma análise cuidadosa sobre o problema visando minimizar ambiguidades e erros nos dados. Além disso, os dados coletados devem ser significativos e cobrir amplamente o domínio do problema; não devem cobrir apenas as operações normais ou rotineiras, mas também as exceções e as condições nos limites do domínio do problema (VALENÇA, 2005).

2.2.9.2 Divisão dos dados

O conjunto de dados deve ser dividido em três subconjuntos independentes, isto é, um conjunto para ajustar os pesos durante o treinamento, o conjunto para validação e um conjunto para verificação (VALENÇA, 2005).

Ainda para Valença, (2005), são adotados normalmente 50% da amostra para treinamento, 25% para validação e 25% para realizar a verificação do desempenho do modelo.

É importante lembrar que, como qualquer modelagem, os conjuntos de dados utilizados para os modelos de redes neurais devem ser estatisticamente representativos da mesma amostra populacional.

2.2.9.3 Normalização dos dados

A normalização é importante para que as variáveis em intervalos diferentes tenham a mesma atenção durante o treinamento. Quando os dados não são divididos adequadamente e possuem intervalos distintos de variação para os subconjuntos a modelagem ficará prejudicada.

As variáveis devem ser normalizadas de forma que seus valores sejam proporcionais aos limites das funções de ativação usada na camada de saída. Os tipos de normalização mais utilizados são:

$$\text{Transformação linear: } y = \frac{(b-a)(x_i - x_{\min})}{x_{\max} - x_{\min}} + a$$

$$\text{Normalização estatística: } y = \frac{x_i - \bar{x}}{s}$$

$$\text{Normalização simples: } y = \frac{x_i}{x_{\max}}$$

Onde: y é o valor normalizado; x_i é o valor original; x_{\min} é o valor mínimo da variável; x_{\max} é o valor máximo da variável; \bar{x} é o valor médio da variável, a e b são os limites e s é o desvio padrão.

2.2.9.4 Determinação das variáveis de entrada

A quantidade de neurônios na camada de entrada e de saída de uma maneira geral pode-se dizer que é dada pelo problema a ser solucionado e depende do conhecimento do modelador com relação aos dados trabalhados. Entretanto, em alguns casos, as variáveis de entrada são selecionadas com base em análise estatísticas, tais como correlação, a técnica de stepwise, análise de componentes

principais e redes polinomiais. As técnicas estatísticas tradicionais conseguem captar apenas características lineares, não sendo o método mais adequado em muitas aplicações onde os fenômenos são tipicamente não lineares (VALENÇA, 2005).

Uma grande quantidade de entrada aumenta o tamanho e a complexidade da rede, que retarda o treinamento e aumenta a quantidade de dados requeridos para estimar os seus pesos. A inclusão de entradas irrelevantes pode prejudicar o processo de treinamento, tendo por resultado correlações espúrias que estão sendo modelados (VALENÇA, 2007).

2.2.9.5 Arquitetura da rede

Ao se modelar uma RNA faz-se necessário definir sua arquitetura, no qual para as redes MLP, consiste basicamente em definir a quantidade de neurônios nas camadas intermediárias.

Para Valença (2005) a quantidade de neurônios na camada intermediária é um fator importante a ser determinado, uma vez que quanto maior a quantidade de neurônio, maior será sua capacidade de mapeamento não linear da rede. Mas deve-se ter muito cuidado, pois uma quantidade excessiva de neurônios pode levar a perda da capacidade de generalização da rede, fator esse conhecido como rede superajustada (*overfitting*). Por outro lado, se este número for muito pequeno, a rede perde sua capacidade de aproximação, ficando subajustada (*underfitting*).

Nas redes multicamadas o número ótimo de neurônios na camada intermediária é obtido usando-se o processo de tentativa e erro. Portanto, uma maneira prática de se determinar o número de neurônios na camada intermediária é através do treinamento de diversas redes com diferentes quantidades de neurônios na camada intermediária. Define-se uma métrica para avaliar o erro de cada uma delas e escolhe-se a que apresentar o menor erro.

Na busca de solucionar essa questão, estudos foram realizados para determinar o número de neurônios na camada intermediária através de fórmulas empíricas. As que se destacam são: regra de Baum-Haussler e a regra de Hetcht-Nielsen.

2.2.9.6 Treinamento

O treinamento da rede neural consiste no estabelecimento dos valores dos pesos entre as conexões. Isto é equivalente a determinação dos parâmetros dos modelos estatísticos. A função erro é a função que será minimizada durante o treinamento. A função erro médio quadrático é a mais usada, mas outras funções de erros podem ser usadas (VALENÇA, 2007).

As vantagens de se usar o erro médio quadrático são relacionadas as suas características matemáticas, como: facilidade de cálculo; métrica que penaliza erros grandes e cálculo simples das derivadas parciais em relação aos pesos.

A validação cruzada utiliza um conjunto de dados que serve para informar quando devemos parar de treinar a rede neural de forma a evitar que a rede perca a sua capacidade de generalização. A validação é uma técnica que tem por objetivo evitar o treinamento em excesso.

2.2.9.7 Verificação do desempenho

O conjunto de verificação é aquele que deve ser separado para avaliar o desempenho do modelo ajustado. Este conjunto de dados não deve ser utilizado para o ajuste dos pesos nem para validade cruzada.

Segundo Valença (2005), as medidas de erros mais comumente empregados são: erro médio quadrático (EMQ), o erro médio absoluto (EMA), erro relativo percentual médio absoluto (EPMA), o erro padrão de predição (EP), coeficiente da eficiência (CE) e o coeficiente da determinação (r^2).

O autor ainda cita que, em alguns casos de previsão, se utilizam de outros índices, no qual destaca: índice de concordância, índice de ajuste volumétrico e o índice de erro relativo do pico.

2.3 Redes Neurais e Evapotranspiração

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 e ZANETTI et al., 2007). Na Tabela 3 estão listados alguns trabalhos desenvolvidos.

Tabela 3 - Relação de pesquisas relacionadas a evapotranspiração de referência e redes neurais.

Autor	Dados de Entrada
Odhiambo et al., 2001	Radiação solar, amplitude térmica, umidade relativa do ar e velocidade do vento.
Kumar et al., 2002	Radiação solar, temperatura máxima e mínima, umidade relativa máxima e mínima e velocidade do vento.
Silva, 2002	Não revelou.
Sudheer et al., 2003	- Média da temperatura, umidade relativa, velocidade do vento e duração do brilho solar; - Média da temperatura, umidade relativa e velocidade do vento; - Média da temperatura.
Trajkovic et al. 2003	Temperatura, umidade relativa, velocidade do vento e duração do brilho solar.
Arca et al., 2004	Combinação da ETo estimada por Hargreaves-Samani e Blaney-Cridle, déficit de pressão de vapor, velocidade do vento, radiação solar extraterrestre e temperatura.
Zanetti et al., 2007	Temperatura máxima e mínima do ar, radiação solar extraterrestre e fotoperíodo máximo diário.
Zanetti et al., 2008	Latitude, longitude, altitude, temperatura média, amplitude térmica e dia do ano.

Embora tenham conseguido bons resultados, os autores que utilizaram RNAs para estimar a ETo, com exceção de SUDHEER et al. (2003), ARCA et al. (2004) e Zanetti et al. (2007), não se empenharam em reduzir ou substituir as variáveis de entrada, utilizando, em vários trabalhos, os mesmos dados climáticos

requeridos para aplicação do método de Penman-Monteith, ZANETTI et al., 2007 e 2008,

Sudheer et al. (2003) utilizaram três opções de dados de entrada para estimar a ETo, a partir de dados de temperatura média, umidade relativa, velocidade do vento, e duração do brilho solar. Na opção mais simplificada, a ETo foi estimada em função apenas da temperatura média do ar e da data correspondente à sua ocorrência. Arca et al. (2004) testaram onze combinações dos seguintes dados de entrada: ETo estimada pelo método de Hargreaves, Hargreaves-Samani e Blaney-Criddle, déficit de saturação de vapor, velocidade do vento, radiação solar extraterrestre e temperatura do ar. Na combinação mais simplificada, a ETo foi estimada em função de duas variáveis: radiação solar extraterrestre e temperatura do ar.

De acordo com Sudheer et al. (2003), a evapotranspiração pode ser estimada com sucesso usando dados limitados através da abordagem RNA. 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 ETo com a simples utilização de um termômetro de máxima e de mínima.

2.4 – Aplicativos Web

O interesse dos programadores pelo desenvolvimento para a internet já atinge um nível muito alto desde que o uso da *web* se popularizou. Isso ocorre, em grande parte, pela complexidade desses sistemas e pelo envolvimento cada vez maior de tecnologias variadas (LOBO, 2007).

O *WebService* é uma tecnologia que diz respeito a padrões de implementação de softwares distribuídos, fazendo com que aplicações consigam compartilhar facilmente informações diferentes. Segundo Ferreira (2003) os *WebService* são componentes de desenvolvimento de aplicativos, baseados em

códigos fontes abertos, que oferecem sistemas e informações pela Internet e que rodam em qualquer dispositivo de forma dinâmica, ou seja, tem como sua principal característica a interoperabilidade, possuindo a capacidade de integrar aplicações e programas distintos, inclusive quando estes mesmos são criados utilizando linguagem ou plataformas diferentes.

Os desenvolvedores de softwares e do mercado corporativo têm dado bastante atenção a *WebService*, com o advento da utilização de serviços distribuídos e disponibilizados em rede, seja ela uma local ou mundial. Com o seu uso, é possível a concepção de um sistema que agregue serviços disponibilizados em outras máquinas e servidores numa única aplicação para o usuário final (MELO e NASCIMENTO, 2007).

A evolução das tecnologias de telecomunicação teve um impacto fundamental no aparecimento de novas plataformas e, conseqüentemente, a necessidades da disponibilidade de informações. Pretende-se que a informação seja disponibilizada a qualquer hora, em qualquer lugar e para qualquer plataforma. A portabilidade da informação passa a ser um requisito essencial no âmbito da sua distribuição através da Internet (ARAUJO e ROCHA, 2004).

A mobilidade associada a informações de localização permite selecionar a informação a ser disponibilizada, de forma que o conteúdo retornado seja filtrado de acordo com a posição geográfica do usuário. O uso da tecnologia *WebService* na disponibilização de soluções visa atender estes requisitos, uma vez que ela permite que sistemas executados em diferentes ambientes se comuniquem (ARSANJANI et al., 2003).

Com o avanço da tecnologia e da capacidade de armazenagem e processamento dos sistemas computacionais, diversos modelos e técnicas quantitativas de previsão têm sido pesquisados, complementando e aprimorando as análises qualitativas por uma série de fatores, incluindo maior precisão (HARDIE, et al., 1998).

O mais interessante, é que os sistemas não precisam ser desenvolvidos na mesma linguagem, nem estarem sob a mesma plataforma ou sistema operacional. Apenas as mensagens são trocadas entre eles e que seguem com um formato padrão, que é codificado e decodificado em ambos os lados (MELO e NASCIMENTO, 2007).

2.4.1 – Linguagem de programação PHP

A linguagem Hipertext PreProcessor (PHP) foi desenvolvida em 1994 por Rasmus Lerdorf. As primeiras versões não foram disponibilizadas, sendo a primeira utilizada por outra pessoa foi em 1995. Era composto por um sistema bastante simples que interpretava alguns macros e utilitários que rodavam por trás das homepages. Em 1997 deixou de ser um projeto, e passou a receber contribuições de outras pessoas para ter uma equipe de desenvolvimento mais organizada (MUTO, 2006).

A linguagem PHP vem evoluindo ao longo de mais de dez anos, tornando-se cada vez mais estável e acessível. A partir da versão 5, pode-se utilizar recursos da orientação a objetos e com isso temos uma aplicação mais estável e robusta (SCHMITZ, 2009).

Esses endereços eletrônicos permitem uma interação com o usuário mediante formulários, parâmetros de localizador padrão de recursos (URL), conexões (links), entre outros, e que retornam páginas criadas em tempo real. O PHP pode ser utilizado na maioria dos sistemas operacionais, como Linux, variantes Unix (Solaris OpenBSD) e Microsoft Windows. Ele também é suportado pela maioria dos servidores *Web* atuais, incluindo Apache, Microsoft Information Server (IIS), Personal *Web* Server e muitos outros (MORAZ, 2005).

É uma linguagem de programação baseada na linguagem C que é processada no servidor, ou seja, aquela que é executada no servidor *web* antes da página ser enviada através da internet ao cliente. As páginas que executam no servidor podem realizar acessos a banco de dados, conexões de rede, e outras tarefas para criar a página final que será vista pelo cliente (ALVAREZ, 2009).

A diferença de PHP com relação a linguagens semelhantes a javascript é que o código PHP seja executado no servidor, sendo enviado para o cliente apenas HTML puro (ROCHA, 2007).

Na Figura 11, pode-se observar o processamento realizado por um aplicativo *web* desenvolvido na linguagem de programação PHP.

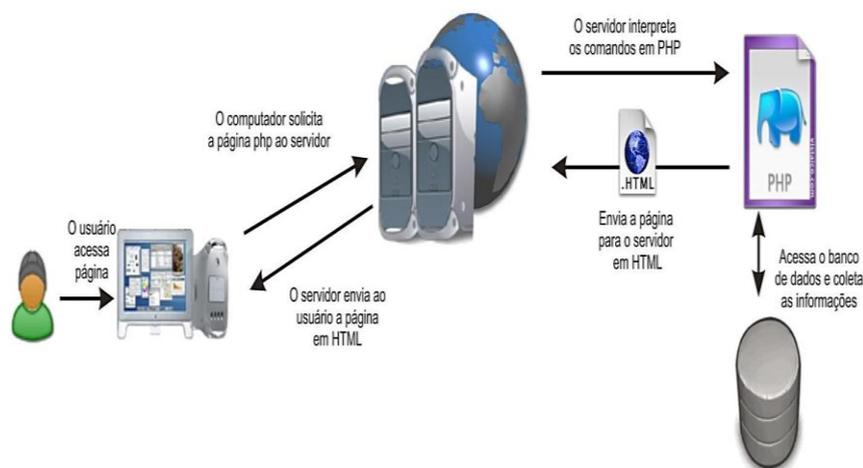


Figura 10 - Diagrama de funcionamento da linguagem de programação PHP

Possivelmente a mais forte e mais significativa característica do PHP seja seu suporte a uma ampla variedade de sistemas de gerenciamento de bancos de dados (PHP GROUP, 2009), além de possuir capacidade de extensibilidade e oferecer aos usuários finais uma infraestrutura sólida para diversos bancos de dados e protocolos. Outra característica chave do PHP é o suporte, a sintaxe para orientação a objetos que é bem mais consistente, melhorando assim o desempenho e o desenvolvimento de aplicações complexas (PHP GROUP, 2008).

Conforme Meloni (2000), o PHP é uma linguagem flexível, rápida e simples em seus requerimentos e poderoso em suas saídas. Dessa forma, com o PHP, tem a liberdade de escolher o sistema operacional e o servidor *Web* que desejar utilizar ou programação orientada a objetos (POO), ou ainda, uma mistura de ambas. Mesmo sem todos os recursos da POO, muitas bibliotecas de código e grandes aplicações são escritas somente nesse tipo de código (DALL'OGGIO, 2009).

Segundo Maziero (2001), o PHP oferece soluções simples para a construção de *sites* dinâmicos e usa em seu conceito várias características importantes, tais como, compatibilidade a multi-plataformas, suporte a banco de dados, linguagem simples e interface com formulários. Juntamente com o PHP deve ser usado o HTML (*Hyper Text Markup Language* - Linguagem de Marcação de Hipertexto), que não é nada mais do que textos escritos com marcas da linguagem (códigos indicando ao *browser* o que deve ser realizado).

Centenas de servidores em todo o mundo têm acesso ao PHP, garantindo que a sua aplicação possa ser utilizada na maioria deles. Com isso, pode-se desenvolver a aplicação *web* com segurança, e após o término do desenvolvimento, pode-se transferir para a internet sem problemas (SCHMITZ, 2009). Conforme Dall'Oglio (2009), o PHP é uma linguagem amplamente utilizada nas aplicações *web* da atualidade.

2.4.2 - Linguagem de programação HTML

O *Hypertext Markup Language (HTML)* foi desenvolvido em 1992 por Tim Berners Lee e Robert Caillau no CERN, correspondendo a uma implementação de SGML (*Standard Generalized Markup Language*). Originalmente o HTML definia estritamente a estrutura lógica de um documento, e não a sua aparência física. Mas com a pressão dos utilizadores, as versões posteriores do HTML foram forçadas a fornecer cada vez mais controles da aparência do documento (COSTA, 2007).

A linguagem HTML é considerada o padrão da *web* para armazenamento e distribuição de documentos eletrônicos, na forma de hipermídia. O HTML pode ser definido como um formato de texto com marcações (tags) utilizado para apresentar conteúdo no navegador. Uma vez que é uma linguagem bastante simples, com apenas alguns “comandos”, o HTML rapidamente tornou-se popular para apresentar documentos formatados (RODRIGUES, 2007).

O HTML destaca-se entre as demais linguagens existentes no mercado pela sua ampla facilidade de manipular e estruturar páginas *Web*. Além disso, foi o primeiro código que surgiu para a programação de páginas *web* e aplicações para a internet. Apesar da aparência sofisticada, as páginas produzidas em HTML não passam de documentos de texto simples, que podem ser produzidos usando somente em um editor, como o Bloco de notas do Windows (BHON, 2004).

Com a linguagem HTML pode-se programar aplicativos acessíveis por qualquer computador independente de sua arquitetura ou sistema operacional. Além disso, o HTML pode ser facilmente associado a outras linguagens de programação preparadas para produção de *scripts* mais complexos, como o PHP (BOULIC, 2001).

Devido às limitações do HTML1.0, muitas extensões foram criadas nos últimos anos. Além das extensões do HTML, em si, um conjunto considerável de tecnologias foi criado para dar apoio às aplicações *web*, tal como Javascript, Java, CGI, ASP, JSP, PHP, XML, CSS, dentre outras (RODRIGUES, 2007).

2.4.3 - Linguagem de programação *Javascript*

O Javascript surgiu com o nome de LiveScript, uma linguagem de criação de scripts elaborada especificamente para a Netscape Navigator. A Netscape, em conjunto com a Sun, mudou o nome para JavaScript. Atualmente, o JavaScript, é uma linguagem de programação orientada a objetos (KAUFMAN et al., 1997).

JavaScript é uma linguagem de *script* utilizada na criação de páginas *web* interativas. Esta linguagem está, como em PHP, embutida dentro de códigos HTML, porém atua de uma forma diferente. A linguagem HTML serve para traduzir ao *browser* todos os componentes de uma página, como caixas de texto, botões, estilos de fonte, etc. (VANDER, 2005).

Ainda segundo Vander (2005), a linguagem JavaScript trata esses componentes interativamente dependendo de ações de usuários. Nesta linguagem é usado o paradigma de orientação a objetos, sendo que cada um dos componentes supracitados são tratados como objetos. Pode-se, portanto, utilizar métodos para alterar esses objetos ou criar eventos de acordo com sua situação, como por exemplo, ao ser acionado um botão da página.

2.4.4 – Banco de Dados

Apesar do termo “banco de dados” parecer um tanto quanto técnico para a maioria das pessoas, trata-se de um conceito amplamente conhecido e empregado por quase toda a população mundial. De fato, a grande maioria das pessoas hoje tem acesso a equipamentos, cujas funções, são de armazenamento de informações (FERRARI, 2007).

Tudo isso remete ao conceito de banco de dados, ou seja, um local no qual é possível armazenar informações, para consulta ou utilização, quando necessário, independente do aplicativo que se deseja usar para o armazenamento e manipulação das informações, todos os bancos de dados são constituídos por três elementos básicos: campos, registros e tabelas (FERRARI, 2007).

O banco de dados, segundo Guimarães (2001), é um recurso valioso que tem levado ao desenvolvimento de uma enorme gama de conceitos e técnicas para o eficiente gerenciamento de informações.

Banco de dados nada mais é que um conjunto de dados integrados, que tem por objetivo atender a uma comunidade de usuários (HEUSER, 2000). Neste sistema protótipo, a ferramenta de banco de dados usada é o MySQL, por ser uma ferramenta de caráter livre, de fácil aprendizado, prática e ao qual o PHP tem suporte.

Através de comandos de programação em PHP, é possível ter acesso a bases de dados no MySQL, sendo permitido a pesquisa dos mesmos e até inserções e deleções de informações nas tabelas, conforme necessário (NIEDERAUER, 2004).

2.4.4.1 - Banco de dados relacional

O modelo relacional para gerência de bancos de dados (SGBD) é um modelo de dados baseados em lógicas de predicados e na teoria de conjuntos (FERRARI, 2007).

Historicamente, ele é o sucessor do modelo hierárquico e do modelo em rede. Estas arquiteturas antigas são até utilizadas em alguns Centros de Dados com alto volume de dados, em que a migração é inviabilizada pelo custo que ela demandaria; existem ainda os novos modelos baseados em orientações ao objeto, que, na maior parte das vezes, são encontradas como kits de construção de SGBD, ao invés de um SGBD propriamente dito (FERRARI, 2007).

O modelo relacional foi o primeiro modelo de banco de dados formal. Somente depois, seus antecessores, os bancos de dados hierárquicos e em rede,

passaram a ser também descritos em linguagem formal (ELMASRI e NAVATHE, 2005).

O modelo relacional foi inventado pelo Dr. Ted Codd e posteriormente mantido e aprimorado por Chris Date e Hugh Darwen como um modelo geral de dados. No terceiro Manifesto (1995), eles mostraram como o modelo relacional pode ser estendido com características de orientação ao objeto sem comprometer os seus princípios fundamentais (FERRARI, 2007).

A linguagem padrão para os bancos de dados relacionais são apenas vagamente remanescente do modelo matemático. Atualmente ela é adotada, apesar de suas restrições, porque é antiga e muito mais popular que qualquer outra linguagem de banco de dados (NIEDERAUER, 2008).

O modelo relacional permite ao projetista criar um modelo lógico consistente da informação a ser armazenada. Este modelo lógico pode ser refinado através de um processo de normalização. Um banco de dados construído puramente baseado no modelo relacional estará inteiramente normalizado. O plano de acesso, outras implementações e detalhes de operações são tratados pelo sistema DBMS, e não devem ser refletidos no modelo lógico (FERRARI, 2007).

Para Ferreira (2003), o sucesso dos sistemas de banco de dados relacionais pode ser atribuído a vários fatores. O modelo relacional é de fácil compreensão e possui uma fundamentação teórica forte. Além disso, foi adotada a linguagem de consultas padronizadas ANSISQL que é completamente integrada aos sistemas de banco de dados.

Desde o lançamento do System/R da IBM em 1980, os sistemas de banco de dados relacionais vêm dominando o segmento de gerenciamento de dados. Nos dias de hoje há diversos produtos comerciais de banco de dados relacionais tais como IBM DB2, Oracle, Informix, Microsoft Access, Microsoft SQL Server, Borland Interbase, MySQL e PostgreSQL (RODRIGUES, 2007).

2.4.4.2 - SQLite

SQLite é um banco de dados de código aberto utilizado amplamente na aplicação de software com armazenamento de dados simples e de forma

sistemática, sendo adotado também em software de dispositivo embutido. O que faz com que seja popular é a combinação do mecanismo de base de dados e uma interface para uma biblioteca única, bem como a capacidade de armazenar todos os dados num ficheiro único. Sua funcionalidade está entre MySQL e PostgreSQL, no entanto, ele é mais rápido que os dois bancos de dados (NEWMAN, 2005).

É um banco de dados integrado, em vez de executar de forma independente como um processo autônomo, simbioticamente convive dentro do aplicativo que serve dentro de seu espaço de processo. Seu código está interligado, ou incorporado, como parte do programa que o hospeda. Para um observador externo, ele nunca seria evidente que tal programa tinha um sistema de gerenciamento de banco de dados relacional (RDBMS) a bordo.

O SQLite tem uma arquitetura elegante, modular que leva algumas abordagens bastante originais para a gestão de banco de dados relacional. É constituída por oito módulos separados agrupados em três subsistemas principais (OWENS, 2006).

Na Figura 12, pode-se observar os módulos e suas divisões estruturais.

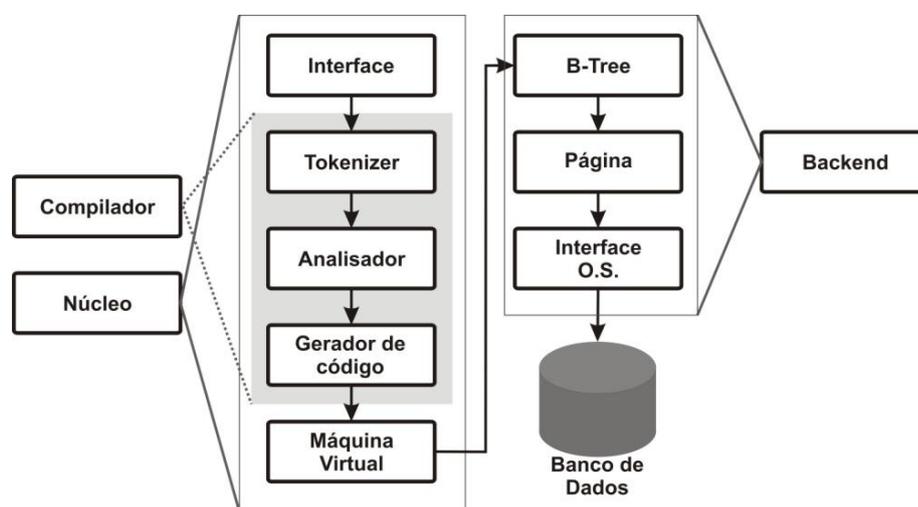


Figura 11 - Estrutura de banco de dados SQLite

Na figura 13 estão ilustradas as diferenças entre as aplicações com outro banco de dados e o SQLite, conforme defini Kreibich (2010).

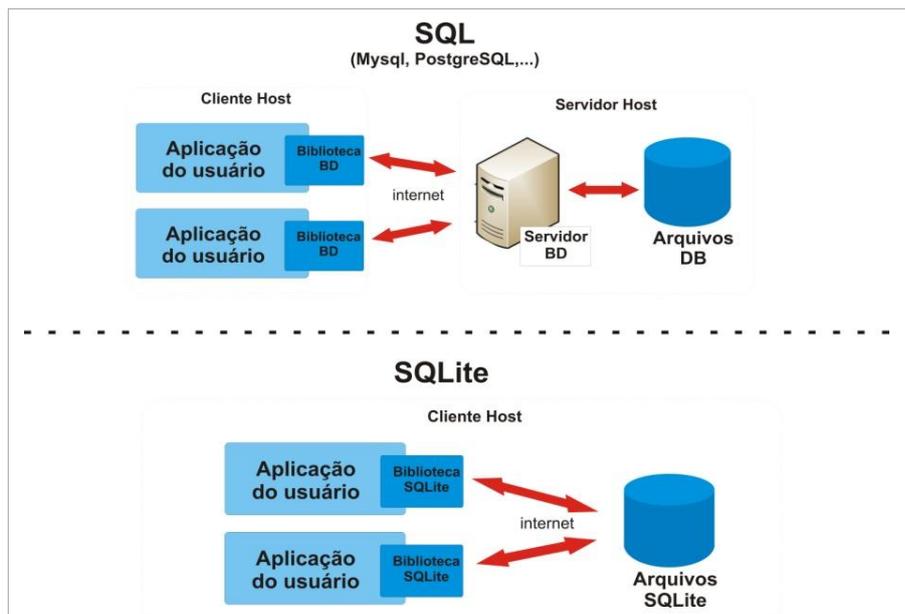


Figura 12 - Comparação entre as estruturas de funcionamento de banco de dados SQL e SQLite

A estrutura do SQLite permite seu funcionamento sem precisar de um servidor dedicado, o que facilita o acesso e a mobilidade do aplicativo. (KREIBICH, 2010).

Ainda segundo Owens (2006), o banco de dados SQLite possui as seguintes características: i) não necessita configurar servidor; ii) portabilidade; iii) compacto; iv) estrutura simplificada; v) flexibilidade; vi) licença liberada e vii) confiança.

Outra característica importante é que o SQLite utiliza de baixa memória de armazenamento, sendo um dos pontos predominantes que permite aos usuários configurar um mecanismo de banco em um ambiente de operação com memória ativa limitada, como telefones celulares, PDAs e MP3 players. Por isso de sua ampla utilização em aplicações que envolvem dispositivos móveis (NEWMAN, 2005).

2.5 – Tecnologia Móvel

As novidades tecnológicas progredem rapidamente e o futuro da computação móvel está se tornando cada vez mais promissor. Os dispositivos móveis estão cada vez mais eficientes, especialmente com a chegada dos *Smartphones*, que possuem

recursos inteligentes integrados. Um dos objetivos é melhorar a mobilidade e usabilidade sem perder o desempenho, pois esses aparelhos vêm adquirindo mais capacidade de processamento e de armazenamento. Além disso, com mais recursos de conectividade, são capazes de proporcionar altas taxas de transferência de dados, podendo transferir mídias em tempo real (LEE et al., 2005).

Conforme Rovadosky et al (2012), a evolução tecnológica é interessante, como visto com os computadores, que eram lentos e pesados, hoje possuem vários núcleos de processamento, produzindo a agilidade necessária. Com os dispositivos móveis, o caminho da evolução tende a ser o mesmo.

Por outro lado, o acesso à Internet Móvel se dá através de uma grande diversidade de dispositivos. Além dos celulares, há outros produtos com especificações técnicas e conceitos de usabilidade distintos, tais como PDA e *Smartphones* (DUDA et al., 2001).

Ao longo dos anos, a quantidade de telefones celulares vem aumentando cada vez mais. Atualmente, o celular é o produto de consumo mais utilizado no mundo, sendo a quantidade existente correspondente à metade da população mundial (3,3 bilhões – 2007). Acredita-se que até o final de 2013 este número chegará a 5,6 bilhões (PEREIRA e SILVA, 2009).

Os autores ainda citam que, em 2009, a quantidade de celulares na internet (3.000.000.000) atinge mais que o dobro de computadores com acesso à internet. Existindo um mercado tão promissor, não restam dúvidas que inovações nesta área são inevitáveis.

2.5.1 – Dispositivos móveis

Nos últimos anos, os dispositivos computacionais e as tecnologias têm evoluído rapidamente de um conceito estático (sem mobilidade) para um contexto móvel. Tem-se percebido, no dia-a-dia das pessoas, uma maior adoção de dispositivos móveis do que dispositivos não móveis (FERREIRA, 2004).

Os dispositivos móveis são divididos em gerações, a primeira delas a 1G, destinadas aos aparelhos analógicos, baseava-se em protocolos comunicação permitindo apenas a comunicação por voz. Já na segunda geração, 2G, além da

comunicação por voz, os celulares começaram a transmitir dados digitais, a acessar a internet e enviar mensagem. E finalmente na terceira geração, 3G, esses dispositivos, passam a maiores taxas de transmissão, em centenas de Kbps, oferecendo maior qualidade na transmissão de voz e suporte em diversos conteúdos de multimídias como a transferência de vídeos, imagens músicas e jogos, além da grande capacidade de comunicação de dados. (FERRARI, 2011).

Conforme Gomes et al. (2011), com a evolução da tecnologia móvel, os dispositivos móveis tornaram-se uma importante fonte de transmissão e recepção de informações, gerando a necessidade de sistemas operacionais mais robustos e uma considerável demanda para o desenvolvimento de serviços e aplicações.

2.5.2 - Android

O Android é uma plataforma para tecnologia móvel completa, envolvendo um pacote com programas para celulares, já com um sistema operacional, middlewaer, aplicativos e interface do usuário.

Segundo Pereira e Silva (2009), o Android é uma plataforma destinada à tecnologia móvel, sendo o primeiro projeto de plataforma open source para dispositivos móveis em conjunto com o Open Handset Alliance (OHA).

Android foi construído com a intenção de permitir aos desenvolvedores criar aplicações móveis que possam tirar total proveito do que um aparelho portátil possa oferecer.

Segundo Lecheta (2009) a plataforma é baseada no sistema operacional Linux, e possui diversas características que o diferencia, como: diversos componentes, variada disponibilidade de bibliotecas e interface gráfica além de disponibilizar ferramentas para a criação de aplicativos.

O Android tem como objetivos principais: i) a oportunidade de personalização das aplicações e componentes presentes em seu sistema, por ser de código aberto e gratuito, e ii) a possibilidade de desenvolvimento rápido e moderno de aplicações corporativas, uma vez que sua plataforma é moderna e flexível. (PROJECT, 2008; LECHETA, 2009).

A arquitetura da plataforma Android é constituída por várias camadas, que também é chamada de pilha de software, sendo que cada camada possui programas que suportam funções específicas no sistema operacional (GOOGLE, 2010). As camadas são: Kernel, Bibliotecas, runtime, framework e aplicativos, conforme observa-se na Figura 14.

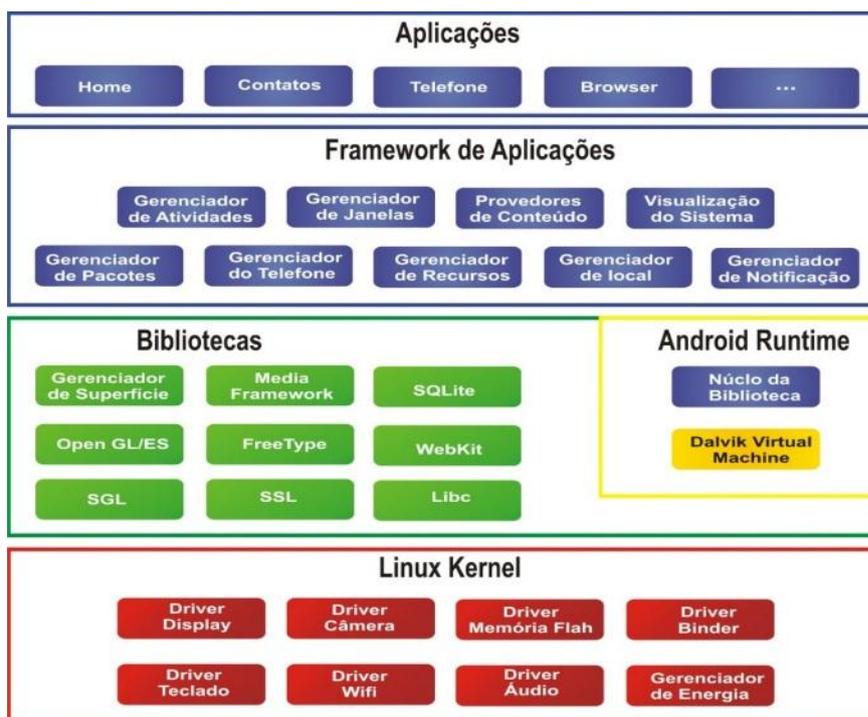


Figura 13 - Arquitetura da plataforma Android

Para Silva (2009), cada camada tem suas características, sendo que:

Linux Kernel: O Android utiliza o kernel do Linux 2.6, que é responsável pelos serviço de segurança, gerenciamento de memória, processos, rede e drivers, sendo capaz de acessar todas as funcionalidades do dispositivo.

Bibliotecas: é a camada responsável pela biblioteca de códigos de funções e rotinas. O Android possui um conjunto de bibliotecas, disponíveis para a criação de seus aplicativos, sendo elas: System C Library, Media Libraries, Surface Manager, Lib Webcore, SGL, 3D libraries, Freetype e SQLite. Tais bibliotecas permitem a manipulação de vídeos, imagens, sons, animações, banco de dados, dentre outras funções.

RunTime: é a camada responsável pela máquina virtual. Uma aplicação Android é interpretada de maneira análoga ao byte-code Java, com a diferença que o Android gera códigos Dalvik Executáveis (.dex), e não os byte-code (.class) do Java, tais código são interpretados pela Máquina Virtual Dalvik (MVD).

Framework de Aplicação: é a camada que fornece componentes que auxiliam na implementação dos programas, permitindo a criação de listas, grades, caixas de texto, botões, etc. Alguns componentes que se destacam são: i) O provedor de conteúdo, que gerencia o acesso aos dados realizados pelos aplicativos; ii) gerenciador de notificações, que habilita os aplicativos a exibirem informações e avisos na barra de status do aparelho, assim como a reagirem às notificações recebidas; iii) gerenciador de atividades, que gerencia o ciclo de vida das aplicações e permite sua execução em segundo plano.

A série histórica foi constituída por dados horários dos períodos de 2008 a 2012, sendo eles: código da estação no INMET, data, hora em UTM, temperatura instantânea (°C), temperatura máxima (°C), temperatura mínima (°C), umidade instantânea (%), umidade máxima (%), umidade mínima (%), ponto de orvalho instantâneo (°C), ponto de orvalho máximo (°C), ponto de orvalho mínimo (°C), pressão atmosférica instantânea (hPa), pressão atmosférica máxima (hPa), pressão atmosférica mínima (hPa), velocidade do vento (m/s), direção do vento (°), rajada de vento (m/s), radiação solar líquida (kJ/m²) e precipitação (mm).

3.2 Estimativa da Evapotranspiração de Referência

A evapotranspiração de referência utilizada como padrão foi estimada pelo método de Penman-Monteith com base na equação 1:

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

Em que: ET_o – evapotranspiração de referência (mm.d⁻¹); Δ - declividade da curva de pressão de vapor na saturação versus temperatura do ar (kPa°C⁻¹); R_n – saldo de radiação na superfície do cultivo (MJ m⁻²d⁻¹); G – densidade de fluxo de calor no solo (MJ m⁻²d⁻¹); y - constante psicrométrica (kPa°C⁻¹); U_2 – velocidade do vento a 2 metros de altura (m s⁻¹); e_s – pressão de vapor na saturação (kPa); e_a – pressão de vapor atual (kPa); T_{med} – temperatura média do ar tomada a 2m de altura (°C).

Para fins de comparação, foram estimadas a evapotranspiração de referência através de outros métodos, sendo eles: Priestley e Taylor, Tanner e Pelton, Makkink, Jensen-Haise, Hargreaves-Samani, Camargo, Benevides-Lopes e Turc.

A equação 2 empregada no método de Priestley-Taylor desenvolvido na Austrália, tem a seguinte forma (Jensen et al., 1990; Allen, 2000):

$$ET_o = 1,26 \frac{\Delta}{\Delta + y} \frac{(Q^* - G)}{2,45} \quad (2)$$

Sendo que: Δ - tangente à curva de saturação para a temperatura do ar ($\text{hPa}^\circ\text{C}^{-1}$); Q^* - balanço de radiação ou saldo de radiação ($\text{MJm}^{-2}\text{d}^{-1}$); G - densidade de fluxo de calor no solo ($\text{MJm}^{-2}\text{d}^{-1}$).

A estimativa pelo método de Tanner e Pelton foi realizado através da equação 3:

$$ET_o = \frac{1,12 Q^*}{2,45} - 0,11 \quad (3)$$

Em que: Q^* - balanço de radiação ou saldo de radiação ($\text{MJm}^{-2}\text{d}^{-1}$);

O método de Makkink utiliza a radiação solar global e é definido através da equação 4:

$$ET_o = 0,61 \frac{\Delta}{\Delta + y} \frac{K \downarrow}{2,45} - 0,12 \quad (4)$$

Onde: Δ - tangente à curva de saturação para a temperatura do ar ($\text{hPa}^\circ\text{C}^{-1}$); y - constante psicrométrica ($\text{hPa}^\circ\text{C}^{-1}$); $K \downarrow$ - radiação solar global ($\text{MJm}^{-2}\text{d}^{-1}$).

As estimativas pelo método de Jensen-Haise foram obtidas através da equação 5:

$$ET_o = \frac{K \downarrow}{2,45} (0,0252 T + 0,078) \quad (5)$$

Em que: $K \downarrow$ - radiação solar global ($\text{MJm}^{-2}\text{d}^{-1}$); T - temperatura média diária do ar ($^\circ\text{C}$).

O método Hargreaves-Samani requer apenas dados de temperaturas, tendo sua simbologia adaptada para as utilizadas no trabalho. É determinada através da equação 6:

$$ET_o = 0,0023 K_o \downarrow (T_{max} - T_{min})^{0,5} \cdot (T_{med} + 17,8) \quad (6)$$

Onde: $K_o \downarrow$ - radiação solar na ausência da atmosfera ($\text{MJm}^{-2}\text{d}^{-1}$); T_{\max} - temperatura máxima do ar ($^{\circ}\text{C}$); T_{\min} - temperatura mínima do ar ($^{\circ}\text{C}$); T - temperatura média diária do ar ($^{\circ}\text{C}$).

O método de Camargo (1971) foi definido através da equação 7:

$$ET_o = 0,01 \left(\frac{K_o \downarrow}{2,45} \right) T \quad (7)$$

Onde: $K_o \downarrow$ - radiação solar na ausência da atmosfera ($\text{MJm}^{-2}\text{d}^{-1}$); T - temperatura média diária do ar ($^{\circ}\text{C}$).

Os valores da ET_o estimados pelo método de Benevides-Lopes foram obtidos através da equação 8:

$$ET_o = 1,21 \cdot 10^{\left[\frac{7,5T}{(237,5+T)} \right]} \cdot (1 - 0,01 UR) + 0,21 T - 2,3 \quad (8)$$

Em que: T - temperatura média diária do ar ($^{\circ}\text{C}$); UR - umidade relativa do ar (%);

O método de Turc utilizada os dados de temperatura e radiação solar global, determinando a ET_o através da equação 9:

$$ET_o = 0,013 [T_{\max} (T_{\max} + 15)^{-1}] (50 + 23,8 K \downarrow) \quad (9)$$

Sendo que: T_{\max} - temperatura máxima do ar ($^{\circ}\text{C}$); $K \downarrow$ - radiação solar global ($\text{MJm}^{-2}\text{d}^{-1}$);

3.3 Arquitetura e modelagem das Redes Neurais Artificiais

Neste trabalho foram utilizadas as Redes Neurais Artificiais do tipo Perceptron de Múltiplas Camadas (MLP) com o algoritmo de treinamento backpropagation com otimização de Levenberg-Marquardt, sendo considerada uma rede de aprendizado supervisionado.

Para a realização do treinamento das redes, foi utilizada a série climática obtidas no INMET e os dados de espacialização de cada estação, conforme Tabela 4.

Tabela 4 - Estações meteorológicas de observação de superfície do Instituto Nacional de Meteorologia instalada no Estado do Rio Grande do Sul.

Cidade	Latitude (°)	Longitude (°)	Altitude (m)
Alegrete	-29,7116	-55,5261	121
Bagé	-31,3478	-54,0133	230
Bento Gonçalves	-29,1672	-51,5347	640
Caçapava do Sul	-30,5477	-53,4675	450
Camaquã	-30,8106	-51,8347	108
Canela	-29,3688	-50,8274	830
Canguçu	-31,4058	-52,7011	464
Chuí	-33,7418	-53,3714	26
Cruz Alta	-28,6036	-53,6736	432
Dom Pedrito	-30,9925	-54,8153	170
Erechim	-27,6603	-52,3064	765
Frederico Westphalen	-27,3956	-53,4294	490
Jaguarão	-32,5542	-53,3764	47
Lagoa Vermelha	-28,2219	-51,5122	842
Mostardas	-31,2478	-50,9057	10
Palmeira das Missões	-27,9199	-53,3174	642
Passo Fundo	-28,2294	-52,4039	684
Porto Alegre	-30,0500	-51,1666	46,97
Quarai	-30,3686	-56,4372	124
Rio Grande	-32,0333	-52,1000	2,46
Rio Pardo	-29,8733	-52,3825	111
Santa Maria	-29,7000	-53,7000	95
Santa Rosa	-27,8901	-54,4797	276
Santana do Livramento	-30,8333	-55,6000	328
Santiago	-29,1914	-54,8856	394
Santo Augusto	-27,8500	-53,7833	550
São Borja	-28,6494	-56,0156	83
São Gabriel	-30,3414	-54,3108	126
São José dos Ausentes	-28,7514	-50,0583	1000
São Luiz Gonzaga	-28,4172	-54,9625	245
Soledade	-28,8536	-52,5417	667
Torres	-29,3503	-49,7331	4,5
Tramandaí	-30,0097	-50,1353	1
Uruguaiana	-29,8425	-57,0825	62,31
Vacaria	-28,5136	-50,8828	986

O banco de dados possui registros horários para cada variável, e por se tratar de estimativas diárias, os valores foram agrupados por dia e posteriormente avaliados e filtrados os períodos com falha ou erros de registros.

As variáveis utilizadas do banco de dados foram: latitude ($^{\circ}$), longitude ($^{\circ}$), altitude (m), dia do ano (dia), temperatura máxima diária ($^{\circ}\text{C}$), temperatura mínima diária ($^{\circ}\text{C}$), umidade relativa do ar média diária (%), velocidade do vento ($\text{m}\cdot\text{s}^{-1}$), radiação solar líquida diária ($\text{MJm}^{-2}\text{d}^{-1}$) e ocorrência de precipitação (sim ou não). Além das entradas disponíveis, foram estimadas as variáveis: radiação solar global incidente diária ($\text{MJm}^{-2}\text{d}^{-1}$), duração de brilho solar diário (h) e déficit de saturação do ar (kPa).

A radiação solar global incidente foi estimada através da equação 10.

$$K_o \downarrow = 37,6 \cdot \left(\frac{d}{D}\right)^2 \cdot \left| \left(\frac{\pi}{180}\right) \cdot Hn \cdot \text{sen}(\emptyset) \cdot \text{sen}(\delta) + \text{sen}(Hn) \cdot \cos(\emptyset) \cdot \cos(\delta) \right| \quad (10)$$

Em que $\left(\frac{d}{D}\right)^2$ é a relação entre a distância média e real entre a Terra e o Sol, obtido através da equação 11.

$$\left(\frac{d}{D}\right)^2 = 1,00011 + 0,034221 \cdot \cos(X) + 0,00128 \cdot \text{sen}(X) + 0,000719 \cos^2(X) + 0,000077 \text{sen}(2X) \quad (11)$$

Sendo que X é uma variável simplificada e é definida pela equação 12.

$$X = \frac{2\pi \cdot (n - 1)}{365} \quad (12)$$

Para efeito de cálculo, Hn é ângulo horário do nascer do sol, \emptyset é a latitude em graus, δ é ângulo de inclinação em relação ao sol e n é o dia de ordem no ano (1 a 366).

Para determinação do fotoperíodo em horas, foi utilizada a equação 13.

$$N = \frac{2}{15} \cdot Hn \quad (13)$$

O déficit de saturação do ar é definido com a diferença entre a pressão de saturação e a pressão real do vapor d'água, sendo determinado através da equação 14.

$$\Delta e = e - e_s \quad (14)$$

Em que e_s é a pressão de saturação; e é pressão real. Para sua determinação foram utilizadas as equações 15 e 16.

$$e_s = 6,108.10^{\left(\frac{7,5.T}{237,5+T}\right)} \quad (15)$$

$$e = \frac{UR.e_s}{100} \quad (16)$$

Em que T é a temperatura média em °C e UR é a umidade relativa diária.

Na ocorrência de precipitação foram utilizados os valores 1 para os dias que foram registrados a incidência de chuva e 0 para dias sem precipitação. Estes valores são baseados na programação binária, no qual corresponde 1 para sim e 0 para não (ou nulo).

Os dados de entradas foram normalização através da transformação linear, descrita na equação 17:

$$y = \frac{(b - a)(x_i - x_{min})}{x_{max} - x_{min}} + a \quad (17)$$

Sendo que: a e b são limites de normalização, adotado -1 e 1 respectivamente, x_i são os valor a serem normalizados, x_{min} é o valor mínimo do banco de dados e x_{max} é o valor máximo dos dados.

Os valores de evapotranspiração de referência estimados pelo método de Penman-Monteith foram calculados para cada estação e data do banco de dados. Estes valores foram definidos como saída padrão para todas as redes modeladas e treinadas.

Para obter o melhor modelo de rede neural artificial para estimar a evapotranspiração de referência, foram estruturadas diferentes arquiteturas de rede,

alterando as variáveis de entradas, número de neurônios na camada oculta e função de ativação.

Foi definida apenas uma camada intermediária, pois conforme Kumar et al. (2002), uma camada escondida é suficiente para representar a relação não linear entre os elementos climáticos e a correspondente ETo.

Os modelos de redes foram determinados pelas variáveis de entradas e identificados por “ANN”. Na Tabela 5 estão dispostos os 10 (dez) modelos definidos.

Tabela 5 - Modelos de arquiteturas de redes neurais e suas variáveis de entrada.

Modelo	Entrada	Variáveis												
		Lat	Lon	Alt	DA	T _{min}	T _{max}	UR	VV	Rg	P	Ro	N	Δe
		(°)	(°)	(m)	(dia)	(°C)	(°C)	(%)	(m.s ⁻¹)	(MJm ⁻² d ⁻¹)	(s/n)	(MJm ⁻² d ⁻¹)	(h)	(kPa)
ANN1	7	●	●	●	●	●	●	●						
ANN2	8	●	●	●	●	●	●	●	●					
ANN3	9	●	●	●	●	●	●	●	●	●				
ANN4	9	●	●	●	●	●	●	●	●			●		
ANN5	10	●	●	●	●	●	●	●	●	●				●
ANN6	10	●	●	●	●	●	●	●	●			●	●	
ANN7	11	●	●	●	●	●	●	●	●	●				●
ANN8	11	●	●	●	●	●	●	●	●			●	●	●
ANN9	12	●	●	●	●	●	●	●	●	●	●			●
ANN10	12	●	●	●	●	●	●	●	●		●	●	●	●

Lat – latitude; Lon - longitude; Alt - altitude; DA - dia do ano; T_{min} - temperatura mínima diária; T_{max} - temperatura máxima diária; UR - umidade relativa do ar média diária; VV - velocidade do vento; Rg - radiação solar líquida diária; P - ocorrência de precipitação; Ro - radiação global incidente diária; N - duração de brilho solar diário e Δe - déficit de saturação do ar.

Todos os modelos neurais configurados basearam-se no modelo de Haykin (2001), com pesos sinápticos, camada intermediária com variação no número de neurônios.

As variações utilizadas no trabalho podem ser observadas no esquema estrutural ilustrado na Figura 16.

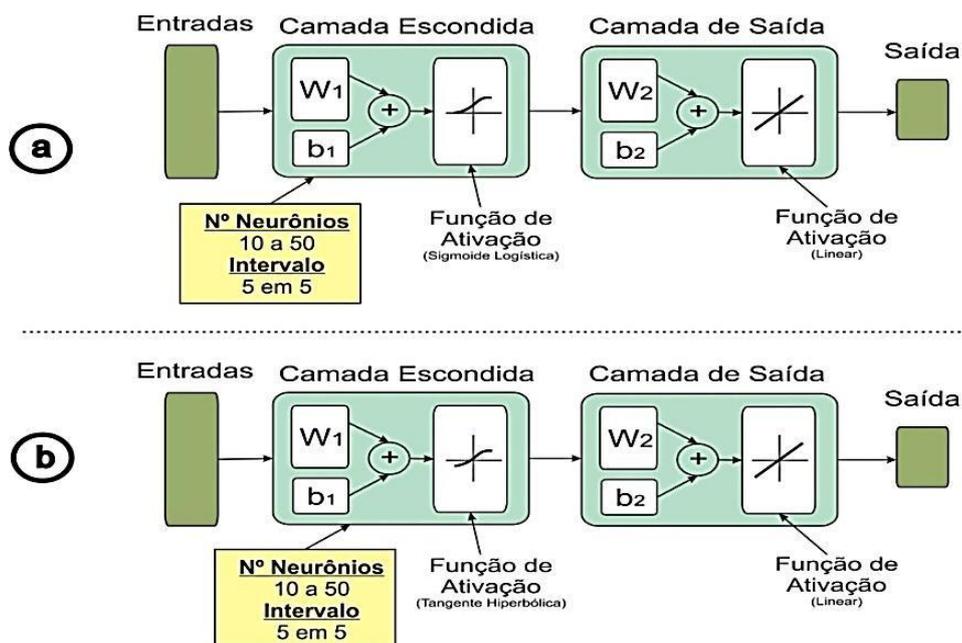


Figura 15 - Arquitetura de redes com função de ativação sigmoide logística (a) e tangente hiperbólica (b)

Para cada modelo de rede foram testadas diferentes arquiteturas, variando o número de neurônios na camada intermediária entre 10 e 50, com intervalo de 5 por rede. Além dos neurônios, foram utilizadas duas funções de ativação, tangente hiperbólica e sigmoide logística na camada escondida.

Foram definidos 10 modelos de redes neurais artificiais, com 9 arquiteturas, relacionadas ao número de neurônios na camada intermediária, e testada com funções ativação tangente e sigmoide, totalizando 180 redes testadas e validadas.

3.4 Método Computacional

Para determinação dos algoritmos de treinamento a serem implementados no sistema, foram realizados os treino, testes e validação através da ferramenta Neural Network Toolbox do aplicativo Simulink Matlab® R2011b.

Os dados diários das estações foram agrupados em planilha eletrônica, obtendo-se um conjunto com 35.775 observações diárias. Destes, foram derivados dois subconjunto: o primeiro, com 80% das observações, serviu para treinar a rede e

o segundo, com 20% dos dados, foi utilizado para testar e validar o seu desempenho. As linhas do arquivo contendo os dados de treinamento e teste foram submetidas a uma aleatorização visando eliminar qualquer influência do ordenamento dos dados no referido processo.

3.5 Avaliação dos modelos

A análise dos dados foi realizada através da regressão linear ($y = a + bx$) onde x representa os valores de evapotranspiração estimados pelo Método de Penman-Monteith e y representa os valores estimados.

Para a avaliação entre os valores de evapotranspiração estimadas e padrão de Penman-Monteith, foi utilizado os seguintes índices: erro médio, erro médio quadrático, raiz quadrada do erro médio, coeficiente de determinação, índice de concordância, coeficiente de correlação e índice de desempenhos. Segundo Valença (2005), esses são os índices mais utilizados para avaliação de desempenho de redes neurais.

Foi calculado o erro médio (ME) entre os valores da evapotranspiração através da equação 18:

$$ME = \frac{\sum_{i=1}^n (E_i - O_i)}{n} \quad (18)$$

Sendo E_i é o valor de evapotranspiração de referência estimada, O_i é o valor padrão determinado por Penman-Monteith e n o número observações.

Para a determinação do erro médio quadrático, utilizou-se a equação 19:

$$MSE = \frac{\sum_{i=1}^n (E_i - O_i)^2}{n} \quad (19)$$

Onde E_i é o valor de evapotranspiração de referência estimada, O_i é o valor padrão determinado por Penman-Monteith e n o número observações.

A determinação da raiz quadrada do erro médio aplicou-se a equação 20:

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (E_i - O_i)^2}{n}} \quad (20)$$

Sendo que E_i é o valor de evapotranspiração de referência estimada, O_i é o valor padrão determinado por Penman-Monteith e n o número de observações.

Outra forma de obter explicações sobre a estimação é através da relação entre os valores médios. Esta relação foi obtida através da equação 21:

$$RR = \frac{\bar{E}}{\bar{O}} \quad (21)$$

Onde \bar{E} é a média dos valores estimados e \bar{O} é a média dos valores observados. Quando o valor da relação for superior a 1 exprime que houve, em média, superestimação dos valores de evapotranspiração.

O coeficiente de correlação (r) permite quantificar o grau de associação entre as duas variáveis envolvidas na análise (SCHNEIDER, 1998), sendo seu campo de variação entre -1 e 1 e quanto maior o seu valor absoluto maior o grau de associação entre os valores observados e os valores estimados.

O coeficiente de correlação (r) pode ser estimado por:

$$r = \frac{\sum_{i=1}^n (E_i - E) \cdot (O_i - O)}{\sqrt{[\sum_{i=1}^n (E_i - E)^2] \cdot [\sum_{i=1}^n (O_i - O)^2]}} \quad (22)$$

Onde E_i são os valores estimados pela rede, O_i os valores de evapotranspiração de Penman-Monteith, E a média dos valores das redes e O a média dos valores de Penman-Monteith.

O índice de concordância (c) fornece o grau de exatidão entre as variáveis envolvidas, uma vez que está relacionada a diferença entre os valores estimados em relação aos valores observados, sendo seu campo de variação de 0 (nenhuma concordância) a 1 concordância perfeita (WILLMONT, 1981).

O índice de concordância pode ser calculado pela expressão:

$$c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - E| + |O_i - O|)^2} \quad (23)$$

Onde E_i são os valores estimados, O_i os valores observados e O a média dos valores observados.

Conhecendo-se esses indicadores foi determinado o índice de desempenho ID, que segundo Camargo e Sentelhas (1997), pode ser calculado por:

$$ID = r \cdot c \quad (24)$$

Onde, r é o coeficiente de correlação e c é o índice de concordância.

O índice ID tem a finalidade de avaliar o desempenho do método proposto, considerando as seguintes classes de interpretação (Tabela 6), de acordo com Costa (2004).

Tabela 6 - Classificação do índice de desempenho. (COSTA, 2004)

Classes	Valores de ID	Desempenho
1	> 0.85	Ótimo
2	0.76 a 0.85	Muito Bom
3	0.66 a 0.75	Bom
4	0.61 a 0.65	Regular
5	0.51 a 0.60	Fraco
6	0.41 a 0.50	Muito Fraco
7	< 0.41	Péssimo

3.6 - Sistema web

Para o desenvolvimento do sistema foram utilizadas ferramentas livres, ou seja, aplicativos e sistemas operacionais gratuitos. O servidor web foi implementado em ambiente Linux Ubuntu 12.04 .

Para o desenvolvimento do aplicativo *web* foram utilizadas as linguagens de programação PHP e JavaScript, integrados na linguagem padrão HTML5. O

JavaScript foi utilizado para melhorar o desempenho das funções internas e dos cálculos matemáticos. Com a linguagem PHP foram realizadas a correspondência entre o aplicativo e o banco de dados.

A programação foi realizada no software Eclipse IDE, open-source para ambiente Linux. Este aplicativo possui interface para programação em diversas linguagens e plug-ins que auxiliam no desenvolvimento e rotinas.

3.7 - Aplicativo Móvel

O aplicativo da plataforma Android foi realizado utilizando a linguagem HTML5 e CSS3, com framework JQUERY MOBILE, ambas as ferramentas livres com aplicações web e mobile.

A implementação foi realizada para Android 2.2 considerando que as versões superiores não terão dificuldade de acesso. Foi utilizado o emulador SDK Android Virtual Device, configurado para tela 4.7" (720x1280 hpdi), Android 2.2 – API Level 8, memória 512 Mb e memória de armazenamento 32 Mb. Na Figura 17 pode-se observar o emulador utilizado.



Figura 16 - Emulador SDK Android

O aplicativo Eclipse IDE possui plug-ins para aplicações Android e máquina virtual inclusa, possibilitando a programação e manipulação dos códigos.

A compilação do código foi realizada através do software PhoneGap, disponível através do link www.phonegap.com.

4 RESULTADOS

Nesta secção estão dispostos os resultados obtidos na estimativa de evapotranspiração de referência pelos métodos empíricos conhecidos e pelas redes neurais com diferentes arquiteturas. Também são apresentados os procedimentos e programação utilizada no desenvolvimento do sistema NeuroEvap (sistema *web* e *mobile*) e a comparação final de seu desempenho.

4.1 Comparação entre métodos de estimativas

Foram estimados os valores de evapotranspiração de referência (ET_o) com os modelos empíricos: Priestley e Taylor, Tanner e Pelton, Makkink, Jensen-Haise, Hargreaves-Samani, Camargo, Benevides-Lopes e Turc. Posteriormente, comparou-se o modelo padrão de Penman-Monteith, cujo valor médio calculado foi de 3,933 mm.dia⁻¹. Pode-se observar os resultados na Tabela 7.

Tabela 7 - Valores da média, desvio padrão, erro médio (ME), erro médio quadrático (MSE), raiz do erro médio quadrático (RMSE), relação média entre os valores estimados e observados (RR) e coeficiente de determinação (R²).

Método	Média (mm.dia ⁻¹)	Desvio Padrão (mm.dia ⁻¹)	ME (mm.dia ⁻¹)	MSE (mm.dia ⁻¹)	RMSE (mm.dia ⁻¹)	RR	R ²
Priestley e Taylor	3,857	1,626	-0,075	0,465	0,682	0,981	0,828
Tanner e Pelton	5,233	1,987	1,300	2,721	1,649	1,331	0,746
Makkink	3,513	1,374	-0,420	0,545	0,738	0,893	0,847
Jensen-Haise	4,982	2,362	1,050	2,160	1,470	1,267	0,895
Hargreaves-Samani	3,380	1,776	-0,553	0,805	0,897	0,859	0,844
Camargo	2,733	1,203	-1,200	2,393	1,547	0,695	0,602
Benevides-Lopes	3,082	1,678	-0,851	1,729	1,315	0,784	0,656
Turc	4,525	1,633	0,592	0,743	0,862	1,150	0,853

Na tabela 7, pode-se observar a variação entre os dados estimados pelos métodos empíricos, sendo que as médias variam entre 2,733 mm.dia⁻¹ e 5,233 mm.dia⁻¹, para Camargo e Tanner e Pelton respectivamente. Os dois modelos consequentemente apresentam os maiores erro médio absoluto, erro médio quadrático e raiz do erro médio quadrático.

Corroborando com os resultados, os autores Silva et al (2011) e Conceição e Mandelli (2005), verificaram que o método de Camargo apresentou baixo desempenho além de subestimar os valores de evapotranspiração.

O método de Priestley e Taylor apresentou média de 3,857 mm.dia⁻¹, menor erro médio (-0,075 mmdia⁻¹) e 0,828 de coeficiente de determinação. Este modelo foi que mais se aproximou do valor médio determinado pela ETO Penman-Monteith.

A relação entre os valores estimados e observados (RR) é utilizada para exprimir a variação na estimativa. Conforme nota-se na Tabela 7, o método de Priestley e Taylor apresentou valor de RR igual a 0,981, sendo o modelo que mais se aproximou de 1. Ainda analisando este fator, pode-se observar que os métodos de Tanner e Pelton, Jensen-Haise e Turc superestimaram os valores de evapotranspiração de referência.

Na Tabela 8 são apresentados os resultados da avaliação de desempenhos dos modelos quando comparados com Penman-Monteith.

Tabela 8 - Coeficiente de correlação (r), índice de concordância (c), índice de desempenho (ID) e classificação para os métodos empíricos propostos.

Método	r	c	ID	Desempenho
Priestley e Taylor	0.910	0.908	0.826	Muito Bom
Tanner e Pelton	0.864	0.571	0.493	Muito Fraco
Makkink	0.920	0.873	0.803	Muito Bom
Jensen-Haise	0.946	0.729	0.690	Bom
Hargreaves-Samani	0.919	0.855	0.785	Muito Bom
Camargo	0.776	0.377	0.293	Muito Fraco
Benevides-Lopes	0.810	0.668	0.541	Fraco
Turc	0.924	0.853	0.788	Muito Bom

Conforme nota-se na tabela 8, o método de Priestley e Taylor apresentou desempenho muito bom e índice de desempenho de 0,826, destacando-se entre os modelos de estimativas para o período e área de estudo. Conforme Silva et al (2011), o método apresentou melhor índice de desempenhos, além de apresentar um coeficiente de determinação (R^2) de 0,876. Ainda segundo os autores Junior et. al. (2012), dentre os métodos avaliados, verificou-se que o melhor desempenho foi obtido com o método de Priestley-Taylor, com base nos valores do erro médio e no coeficiente de desempenho (0,87).

Para Vescove e Turco (2005), quando comparado o modelo de Makkink com Penman-Monteith, obteve coeficiente de determinação (R^2) de 0,887 e concluiu que o modelo subestima a ETo em todo seu período estudo.

4.2 Desempenho das redes neurais artificiais

Foram definidos 10 modelos conforme suas variáveis de entrada e posteriormente alternadas a arquitetura das redes. Foram testadas e validadas 180 redes, sendo que para cada modelo foi selecionada a arquitetura que apresentou melhor resultado. Os resultados obtidos para cada teste estão disponíveis nos apêndices.

Outro fator importante na definição dos modelos foi a distribuição espacial, no qual foram incorporadas as variáveis latitude, longitude, altitude e dia do ano, definidas como entrada padrão em todas as redes, com o objetivo de explorar os efeitos espaciais das estações.

Assim como Zanetti et al (2007), as coordenadas geográficas de cada estação auxilia na obtenção de modelos aptos a extrapolações espaciais. A temperatura também foi utilizada com padrão em todas as redes, assim como definido por Jin et al (2008) e Huo et al (2012), no qual afirmam que a temperatura, como variável de entrada, é um fator importante para melhorar a estimativa de ETo.

Considerou-se apenas a arquitetura que apresentou melhor resultado em cada modelo, realizando a análise estatística, conforme listadas nas Tabela 9.

Tabela 9 - Melhor arquitetura de rede para cada modelo, média, desvio padrão, erro médio (ME), erro médio quadrático (MSE), raiz do erro médio quadrático (RMSE), relação média entre os valores estimados e observados (RR) e coeficiente de determinação (R²).

Modelo	Função de Ativação	Entradas	Arquitetura	Média	Desvio Padrão	ME	MSE	RMSE	RR	R ²
ANN1	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} e UR	7-50-1	3,9359	1,4355	0,0032	0,3450	0,5874	1,0008	0,8560
ANN2	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR e VV	8-45-1	3,9274	1,4523	-0,0053	0,2825	0,5315	0,9986	0,8821
ANN3	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV e R _g	9-40-1	3,9328	1,5476	-0,0000	0,0000	0,0003	1,0000	1,0000
ANN4	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV e R _o	9-50-1	3,9272	1,4488	-0,0056	0,2831	0,5320	0,9986	0,8818
ANN5	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV, R _g e N	10-50-1	3,9328	1,5476	-0,0000	0,0000	0,0007	1,0000	1,0000
ANN6	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV, R _o e N	10-50-1	3,9275	1,4522	-0,0052	0,2756	0,5249	0,9987	0,8850
ANN7	Tangente Hiperbólica	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV, R _g , N e Δe	11-50-1	3,9327	1,5476	-0,0000	0,0000	0,0005	1,0000	1,0000
ANN8	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV, R _o , N e Δe	11-50-1	3,9354	1,4586	0,0027	0,2886	0,5373	1,0007	0,8795
ANN9	Sigmoide Logística	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV, R _g , N, Δe e P	12-50-1	3,9328	1,5476	0,0000	0,0000	0,0007	1,0000	1,0000
ANN10	Tangente Hiperbólica	Lat, Lon, Alt, DA, T _{min} , T _{max} , UR, VV, R _o , N, Δe e P	12-45-1	3,925	1,452	-0,008	0,290	0,538	0,998	0,879

Lat – latitude (°); Lon – longitude (°); Alt – altitude (m); DA – dia do ano (dia); T_{min} – temperatura mínima do ar (°C); T_{max} - temperatura máxima do ar (°C); UR – umidade relativa do ar média diária (°C); VV – velocidade do vento (m.s⁻¹); R_g – radiação solar global (MJm⁻²dia⁻¹); R_o – radiação global incidente (MJm⁻²dia⁻¹); N – fotoperíodo (h); Δe- déficit de saturação de vapor de água (hPa); P – ocorrência de precipitação.

Com base nas tabelas 9, pode-se observar que os resultados obtidos pelas redes neurais artificiais foram melhores do que os alcançados pelos métodos empíricos anteriores. Verificam-se menores valores de erro médio (EM) entre -0,008 e 0,0032 mm/dia, com média da raiz quadrada do quadrado do erro médio (RMSE) entre 0,0003 e 0,5874 mm/dia. Os autores Sobrinho et al (2011), ao comparar modelos de redes neurais e método empíricos, também afirmam que as RNAs apresentam desempenhos superiores e baixo erro médio quadrático, afixando entre 0,016 e 0,496%.

Quando analisado a relação média entre os dados observados e estimados, pode-se observar que todos os modelos estão com valores próximos a 1, apresentando baixa subestimação nos modelos ANN2, ANN4, ANN6 e ANN10, mas sem muito desvio.

Notou-se que para os dados estimados nas RNA com radiação solar diária como variável de entrada apresentaram erro médio tendendo a zero, resultando em coeficiente de determinação (R^2) de 1,00. Dessa forma, pode-se afirmar que os modelos ANN3, ANN5, ANN7 e ANN9 estimam com melhor precisão a ETo. A Tabela 10 apresenta os valores de desempenhos dos modelos, considerando que mesmo possuindo arquiteturas semelhantes, as variáveis de entradas alteram para cada modelo (conforme observado na Tabela 9).

Tabela 10 - Melhor arquitetura de rede para cada modelo, coeficiente de correlação (r), índice de concordância (c), índice de desempenho (Id) e classificação.

Modelo	Função de Ativação	Arquitetura	R	C	Id	Desempenho
ANN1	Sigmoide Logística	7-50-1	0,9252	0,9226	0,8535	Ótimo
ANN2	Sigmoide Logística	8-45-1	0,9392	0,9373	0,8803	Ótimo
ANN3	Sigmoide Logística	9-40-1	1,0000	1,0000	1,0000	Ótimo
ANN4	Sigmoide Logística	9-50-1	0,9391	0,9370	0,8799	Ótimo
ANN5	Sigmoide Logística	10-50-1	1,0000	1,0000	1,0000	Ótimo
ANN6	Sigmoide Logística	10-50-1	0,9407	0,9388	0,8832	Ótimo
ANN7	Tangente Hiperbólica	11-50-1	1,0000	1,0000	1,0000	Ótimo
ANN8	Sigmoide Logística	11-50-1	0,9378	0,9362	0,8780	Ótimo
ANN9	Sigmoide Logística	12-50-1	1,0000	1,0000	1,0000	Ótimo
ANN10	Tangente Hiperbólica	12-45-1	0,938	0,936	0,877	Ótimo

Considerando o índice de desempenho (Id), nota-se que todos os modelos apresentaram valores entre 0,8535 a 1,00, sendo que o modelo ANN1 apresentou o menor desempenho. Esse fator pode estar relacionado no baixo número de variáveis de entrada. Para Zanetti et al (2008), ao realizar a estimativa utilizando apenas temperatura, amplitude térmica e dados locais, determinaram um índice de desempenho de 0,88, afirmando que a grande vantagem desse modelo é utilização de poucas variáveis, necessitando apenas um termômetro de máxima e mínima para a determinação.

Todos os modelos foram classificados como ótimo, de acordo com a proposta de classificação de Camargo e Sentelhas (1997). Pode-se ressaltar, no entanto, que as redes ANN3, ANN5, ANN7 e ANN9 são mais recomendadas por obter índice de desempenho igual a 1.

A característica em comum dentre os modelos com melhores coeficientes de correlação e índice de desempenho, é a radiação solar líquida diária como variável de entrada, no qual pode explicar o aperfeiçoamento no aprendizado das redes. Segundo Pereira et al.(2002), a radiação solar é uma das principais variáveis meteorológicas que afeta na determinação da evapotranspiração na planta.

Ainda segundo os autores Medeiros et al (1998), os métodos que incorporam a radiação solar e temperatura do ar em sua estrutura possuem uma melhor estimativa da evapotranspiração.

Dentre os modelos sem radiação solar, destaca-se a rede ANN6, apresentando índice de desempenho 0,8832. Segundo Zanetti et al (2007), quando estimado com as mesmas variáveis de entrada, obteve desempenho ótimo com índice 0,875 para estimar evapotranspiração em Viçosa (MG) e Campo dos Goytacaces (SP).

A seguir, na Figura 18, são apresentadas as relações entre os dados padrões de Penman-Monteith e os estimados pelas redes neurais artificiais.

Com base na Figura 18, observa-se um bom ajuste entre os valores observados e estimados para a evapotranspiração de referência. As redes apresentaram boa capacidade preditiva, com R^2 de 0,856 e 1,0.

Ainda na Figura 18, notou-se que os modelos ANN1, ANN2, ANN4, ANN6, ANN8 e ANN10 apresentaram maior dispersão nos valores em torno da relação 1:1, mas não afetou no índice de determinação (R^3), que variou entre 0,856 a 0,885.

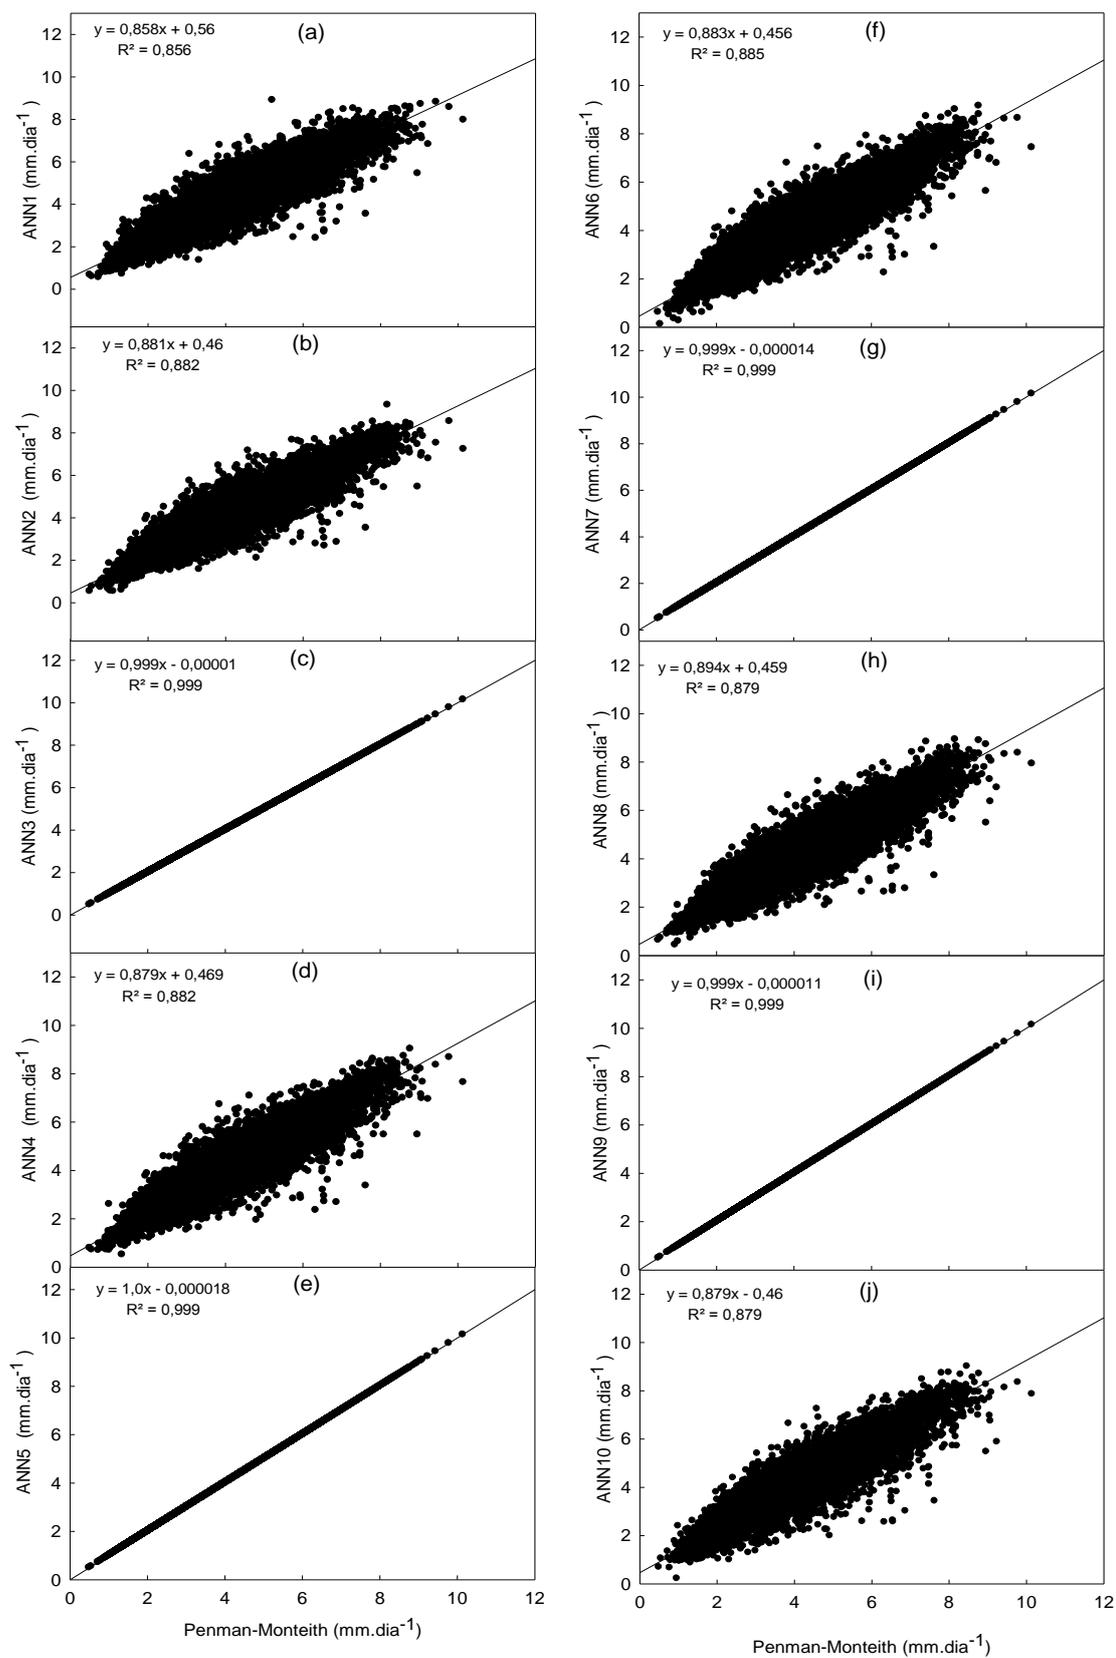


Figura 17 - Comparação entre os valores de evapotranspiração de Penman-Monteith e os modelos de redes neurais ANN1 (a), ANN2 (b), ANN3 (c), ANN4 (d), ANN5 (e), ANN6 (f), ANN7 (g), ANN8 (h), ANN9 (i) e ANN10 (j)

4.3 Sistema NeuroEvap

O NeuroEvap foi desenvolvido com diferentes ferramentas para cada utilização. A primeira aplicação do sistema é em versão web para consulta, apenas para realizar o cálculo sem opção de armazenamento. O segundo módulo do sistema em versão web, é destinado a usuários cadastrados, no qual são armazenados os cálculos em banco de dados. Esta segunda aplicação foi desenvolvida utilizando alguns recursos do framework JQuery Mobile que possibilita um visual adaptável para acesso através de dispositivos móveis.

A última aplicação desenvolvida é para mobile e sem acesso a internet, onde neste caso é uma ferramenta de cálculo direto, sem possibilidade de armazenamento.

Estes módulos diferentes foram desenvolvidos com o intuito de atender o maior número de usuários e para diferentes dispositivos de consulta.

4.3.1 Algoritmo para programação NeuroEvap

A programação do sistema NeuroEvap foi desenvolvida com dois padrões de entrada de dados. Estas opções foram estipuladas devido a necessidade e disponibilidade de dados de cada usuário do sistema, visto que em muitos casos, é difícil de obter os valores de radiação solar líquida diária.

A primeira opção refere-se a usuários que possuem dados: altitude, latitude, longitude, data, temperatura mínima, temperatura máxima, umidade relativa do ar e velocidade do vento. Para a determinação da evapotranspiração de referência será utilizado o modelo de redes neurais ANN6 com arquitetura 10-50-1, sendo 10(dez) variáveis de entrada, 50 (cinquenta) neurônios na camada intermediária e 1 (uma) saída. Como função de ativação de entrada, utilizou-se a sigmoide logística e função linear de saída.

Este modelo foi definido através da análise de desempenho, no qual entre as redes testadas sem entrada de radiação solar líquida diária, apresentou índice de 0,8832, classificado como ótimo. Além dos dados disponibilizados pelo operador do

sistema, a rede utiliza como entrada a radiação solar global incidente e fotoperíodo, sendo ambos estimados pelo sistema.

Para a segunda opção de cálculo da evapotranspiração, é necessário que o usuário possua os seguintes dados: latitude, longitude, data, temperatura mínima, temperatura máxima, umidade relativa do ar, velocidade do vento e radiação solar líquida diária.

Este modelo será gerado através da rede ANN3 com arquitetura 9-40-1, sendo 9 (nove) variáveis de entrada, 40 (quarenta) neurônios na camada escondida e 1 (uma) saída. A função de ativação de entrada foi sigmoide logística e função linear para a saída.

O modelo ANN3 apresentou melhor desempenho entre os comparados com entrada de radiação solar líquida diária, com índice de 1,0 e classificado como ótimo. Este modelo diferenciou-se dos demais por apresentar menor erro médio quadrático (0,0003). Outro fator, foi o número de variáveis de entrada, no qual auxilia no desempenho e agilidade do sistema.

Em cada algoritmo de programação foram utilizados os valores das bias e pesos sinápticos calculados na simulação de cada rede através do toolbox Neuraltools® do software Matlab® 2011.

4.3.2 NeuroEvap – Sistema Web

Para o desenvolvimento do sistema NeuroEvap foram utilizadas as linguagens de programação PHP, javascript e HTML5, com banco de dados SQLite local. O servidor foi configurado no sistema operacional Ubuntu Linux.

O NeuroEvap caracteriza-se por ser um sistema de tecnologia da informação e comunicação com baixo custo de desenvolvimento e implementação, sendo desenvolvido com ferramentas e linguagens de programação livres e/ou open source

Conforme Neto et. al. (2013), os sistemas de tecnologia e informação quando voltados a atividades rurais, destacam-se pela potencialidade de reforçar atividades existentes e explorar novas oportunidades.

O sistema web está incorporado ao site do projeto no endereço www.neuroevap.webnode.com, conforme Figura 19.



Figura 18 - Visualização da página inicial do projeto NeuroEvap

A versão web consta de duas formas de acesso: i) versão consulta rápida e ii) versão usuário. A primeira é para realizar a estimativa direto no site. O usuário escolhe o modelo de cálculo conforme os dados climáticos disponíveis. A segunda versão é para usuários cadastrados, no qual são registrados os cálculos realizados em banco de dados SQLite que posteriormente poderão ser consultados.

Estas duas versões foram definidas para suprir a necessidade de cada usuário e disponibilizar uma ferramenta de estimativa para todos os usuários do sistema e para usuários cadastrados.

4.3.2.1 Versão Consulta Rápida

Conforme já definido, esta versão disponibiliza a versão para consulta em tela, sem registro dos dados. É destinado para usuários não cadastrados e pode ser acessado diretamente através do link <http://neuroevap.webnode.com/consulta-rapida> (Figura 20).

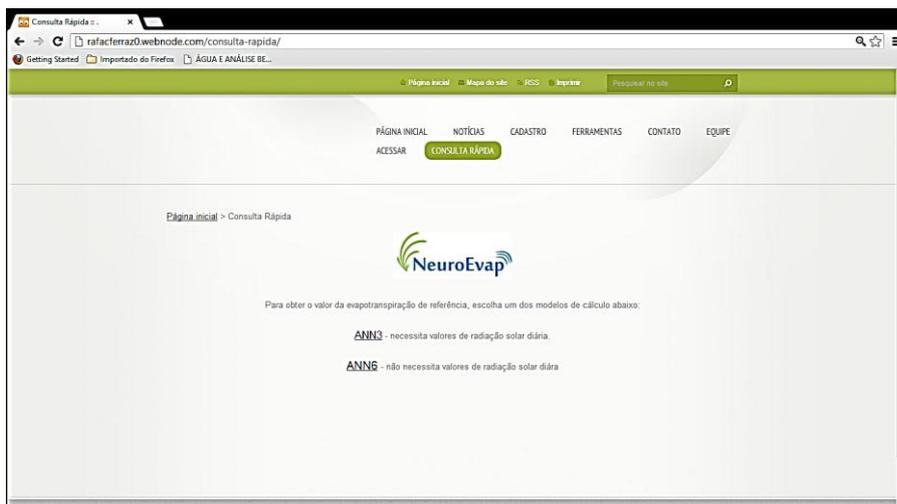


Figura 19 - Visualização da página de acesso a consulta rápida

São disponibilizados os dois modelos de cálculos, sendo nomeados ANN3 e ANN6, conforme observado na Figura 20. Estes modelos foram estruturados conforme definido no algoritmo de programação.

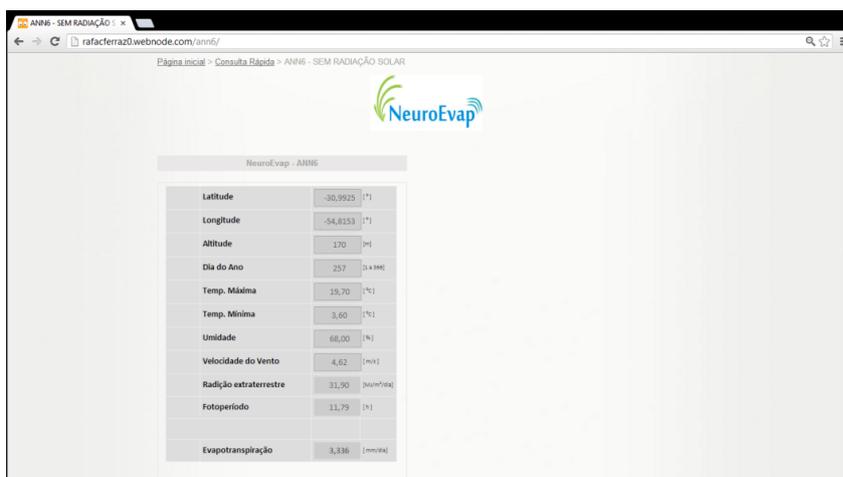
Foram utilizadas as linguagens HTML e javascript para a confecção destes modelos e são calculadas de forma dinâmica. Ao escolherem ao modelo ANN3, o usuário será direcionado a página de estimativa, conforme Figura 21.

NeuroExp - ANN3	
Latitude	-30,9922 (°)
Longitude	-54,8135 (°)
Altitude	170 (m)
Dia do Ano	257 (1/4/196)
Temp. Máxima	19,7 (°C)
Temp. Mínima	3,6 (°C)
Umidade	68 (%)
Velocidade do Vento	4,621 (m/s)
Radiação Solar	23,0912 (kWh/m²/dia)
Evapotranspiração (Eto)	3,324 (mm/dia)

Figura 20 - Visualização da página de estimativa do modelo ANN3

Nesta página será disposto um formulário no qual são inseridos os dados locais e climáticos, e automaticamente é estimado o valor de evapotranspiração de referência em $\text{mm}\cdot\text{dia}^{-1}$. Cabe salientar que as unidades de medidas deverão ser as mesmas que estão descritas no formulário.

O modelo ANN6 também é direcionado para uma página de formulário, conforme a Figura 22.



NeuroEvap - ANN6	
Latitude	-30,9925 [°]
Longitude	-54,8153 [°]
Altitude	170 [m]
Dia do Ano	257 [d x 366]
Temp. Máxima	19,70 [°C]
Temp. Mínima	3,60 [°C]
Umidade	68,00 [%]
Velocidade do Vento	4,62 [m/s]
Radiação extraterrestre	31,90 [kWh/m²/dia]
Fotoperíodo	11,79 [h]
Evapotranspiração	3,336 [mm/dia]

Figura 21 - Visualização da página de estimativa do modelo ANN6

O modelo ANN6 é utilizado quando o usuário não possui a informação de radiação solar diária. Sendo assim, o modelo utiliza-se dos dados de radiação solar extraterrestre e fotoperíodo. Estes dois valores são calculados pelo sistema automaticamente a partir da inserção da posição geográfica e dados meteorológicos (temperatura máxima e mínima, umidade relativa do ar e velocidade do vento).

4.3.2.2 Versão Usuário

Esta versão se difere da anterior em questões de programação e recursos. A plataforma foi realizada na linguagem PHP, javascript e HTML, com banco de dados SQLite para armazenamento. O PHP foi utilizado na programação de acesso, registro em banco de dados e visualização dos dados cadastrados. Os cálculos de

estimativas foram programados em javascript e a estruturação do site foi em HTML5. A estrutura do sistema pode ser visualizada na Figura 23.

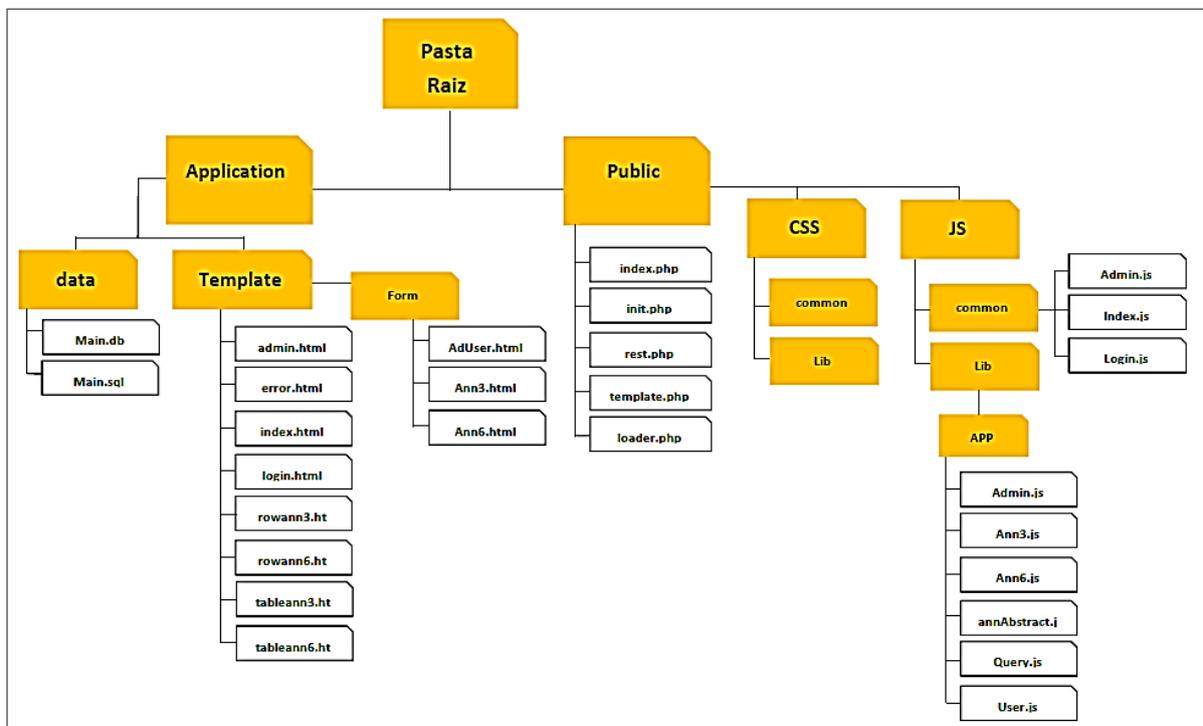


Figura 22 - Arquitetura de funcionamento do sistema NeuroEvap

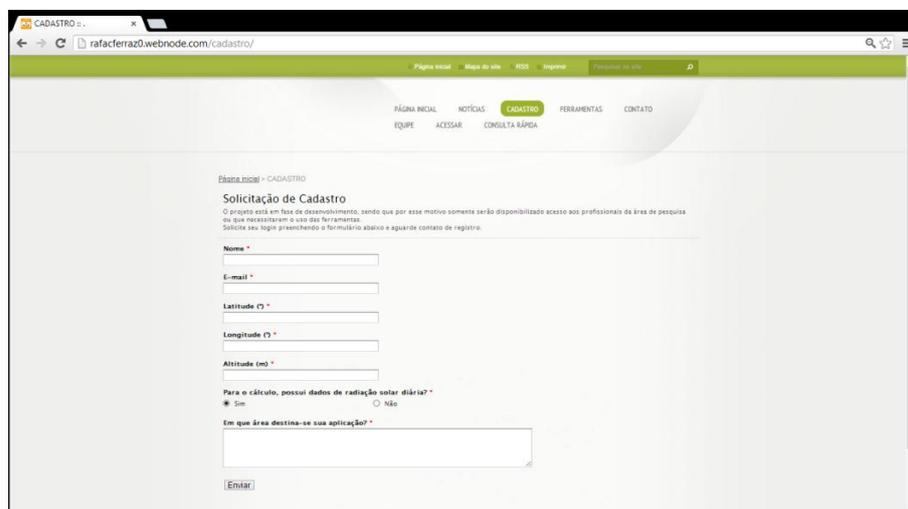
Conforme demonstrado na Figura 23, o sistema é separado por pastas no diretório central. Na pasta “Application” está localizado o banco de dados (pasta data) e os arquivos relacionados ao layout e formulários. No diretório “Public” estão localizadas as bibliotecas de estilo CSS, as implementações em javascript e PHP.

Os arquivos ann3.js e ann6.js são responsáveis pelo cálculo de cada modelo de rede, sendo os seus valores registrados no banco de dados através da implementação Query.js.

Os cálculos de normalização dos dados de entrada, conversão de data em dia do ano, NET1, NET2 e normalização da variável de saída, estão implementados no arquivo AnnAbstract.js pelo fato de serem comuns a ambas as redes.

Este formato de sistema é disponibilizado apenas para usuários cadastrados ao sistema, necessitando realizar a solicitação através do link

<http://www.neuroevap.webnode.com/cadastro>, assim como demonstrado na Figura 24.



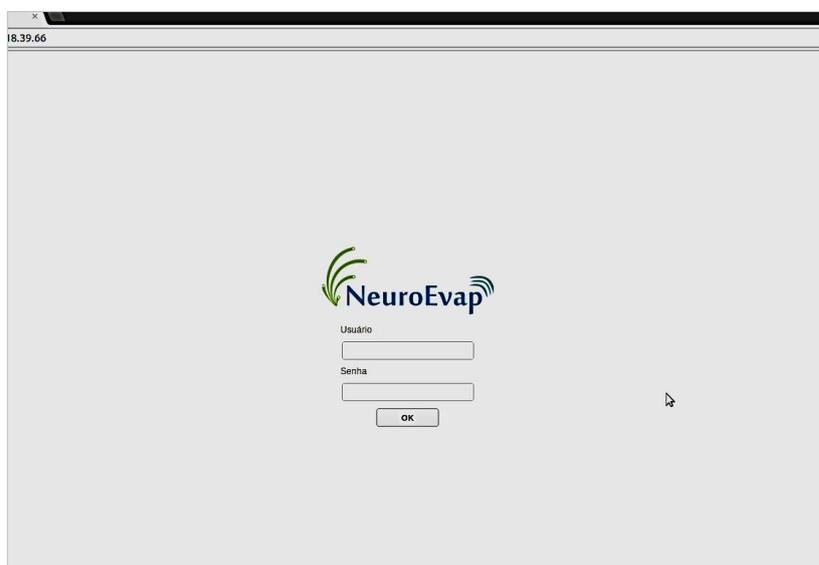
The screenshot shows a web browser window with the URL <http://www.neuroevap.webnode.com/cadastro/>. The page title is "Solicitação de Cadastro". The form includes the following fields and options:

- Nome *
- E-mail *
- Latitude (°) *
- Longitude (°) *
- Altitude (m) *
- Para o cálculo, possui dados de radiação solar diária? *
 - Sim
 - Não
- Em que área destina-se sua aplicação? *

An "Enviar" button is located at the bottom of the form.

Figura 23 - Formulário de solicitação de cadastro de acesso ao sistema NeuroEvap

A solicitação de cadastro é realizada através de um formulário de contato no qual os dados inseridos são encaminhados ao administrador do sistema. Esta solicitação é analisada e posteriormente são reencaminhados os dados de acesso ao usuário. A Figura 25 demonstra a forma de acesso através do login.



The screenshot shows the login page of the NeuroEvap system. The page features the NeuroEvap logo at the top center. Below the logo, there are two input fields labeled "Usuário" and "Senha". An "OK" button is positioned below the "Senha" field. The page is displayed in a browser window with the address bar showing "18.39.66".

Figura 24 - Acesso ao sistema NeuroEvap

Após acesso, são disponibilizadas as opções de cálculo e consulta, no qual o usuário pode realizar através dos dois modelos definidos no algoritmo, devendo o usuário selecionar conforme as disponibilidades de dados. A Figura 26 ilustra as opções do sistema.



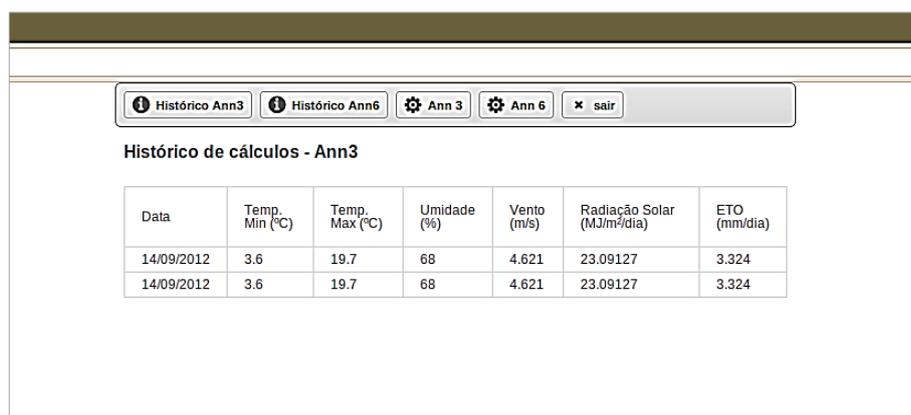
Figura 25 - Página de opções de cálculo e consulta do sistema NeuroEvap

As estimativas são realizadas apenas com inserção dos dados climáticos, pois os dados geográficos estão incorporados automaticamente, conforme informado no cadastro. Um exemplo de utilização pode ser visualizado na Figura 27.

Ann3	
Data	14/09/2012
Temp. máxima (°C)	19.7
Temp. mínima (°C)	3.6
Umidade (%)	68
Vento (m/s)	4.621
Radiação Solar (MJ/m²/dia)	23.09127
ETo (mm/dia):	3.324
<input type="button" value="calcular"/>	

Figura 26 - Estimativa realizada pelo modelo ANN3

Ao clicar em calcular será apresentado o valor da evapotranspiração de referência, e o mesmo será registrado no banco de dados. Posteriormente poderão ser consultados todos os registros realizados pelo usuário através da opção *histórico* incluído no cabeçalho do sistema (Figura 28).



Histórico de cálculos - Ann3

Data	Temp. Min (°C)	Temp. Max (°C)	Umidade (%)	Vento (m/s)	Radiação Solar (MJ/m ² /dia)	ETO (mm/dia)
14/09/2012	3.6	19.7	68	4.621	23.09127	3.324
14/09/2012	3.6	19.7	68	4.621	23.09127	3.324

Figura 27 - Visualização de históricos de lançamentos pelo modelo ANN3

O histórico informa os dados climáticos, a data e o resultado gerado pelo modelo escolhido. Estes valores são disponibilizados em ordem crescente pela data.

4.3.2.3 Banco de Dados

Por ser um banco de dados SQLite não foi necessário a configuração de servidor, ou seja, foi estruturado e programado diretamente na pasta de aplicação do sistema web, possibilitando futuras aplicações em dispositivos móveis, como sistema local. Segundo Jeon et al (2012), o SQLite é um mecanismo de banco de dados de pequeno porte muito utilizado principalmente para sistemas com implementação em dispositivos embutidos.

O banco de dados foi nomeado como *neuro.db* com arquitetura de funcionamento definida conforme a Figura 29.

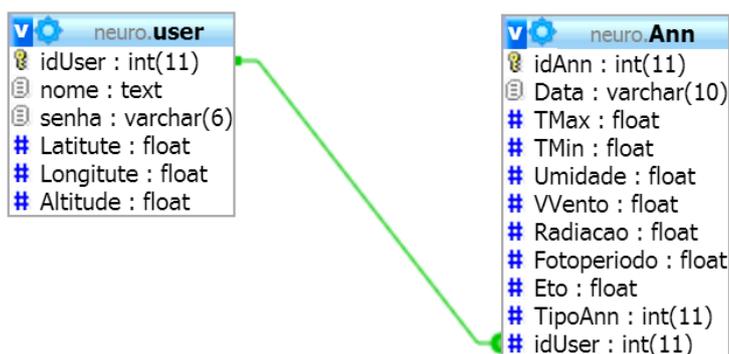


Figura 28 - Estrutura do banco de dados “neuro.db”

O banco é composto por duas tabelas de dados, sendo elas: user e Ann. Esta arquitetura definida visa otimizar o sistema, relacionando as tabelas entre si. Na tabela *user* estão registrados os registros dos usuários que possuem acesso ao sistema. Os dados são: nome, senha, altitude, longitude e altitude. Os dados geográficos inseridos referem-se ao ponto no qual o usuário deseja estimar a evapotranspiração.

A tabela *Ann* armazena os dados cadastrados pelos usuários no sistema. Esta tabela está relacionada ao *user* através da coluna *idUser*, no qual defini de qual usuário é o registro do banco. Nesta tabela são registrados os dados de data, temperatura máxima e mínima, umidade relativa do ar, velocidade do vento, radiação, fotoperíodo, evapotranspiração estimada e tipo de ann.

A coluna *tipoAnn* registra qual algoritmo que foi utilizado para o cálculo, ou seja, ann3 e ann6, conforme definido no algoritmo de cálculo.

4.3.3 NeuroEvap – Mobile

Para os dispositivos móveis, foram desenvolvidas duas formas de aplicação para atender as necessidades dos usuários e a configuração de seus aparelhos.

A primeira é destinada a usuários sem acesso a internet, no qual foi desenvolvida uma ferramenta de consulta rápida sem armazenamento dos dados.

O aplicativo foi desenvolvido para dispositivos com mínimo sistema operacional Android versão 2.2. Na Figura 30 é possível visualizar a página inicial do NeuroEvap mobile.

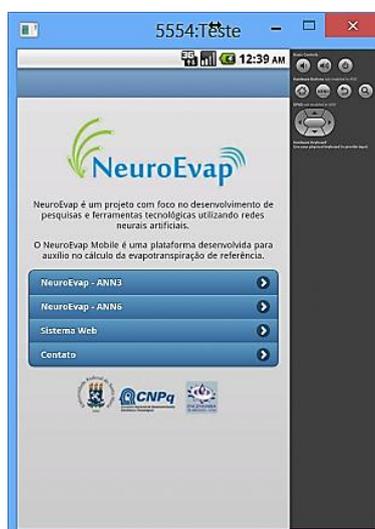


Figura 29 - Página inicial do sistema NeuroEvap Mobile

Na versão mobile também há possibilidade de realizar o cálculo pelos dois modelos de redes, definidos como ANN3 e ANN6, conforme pode-se observar na Figura 31.

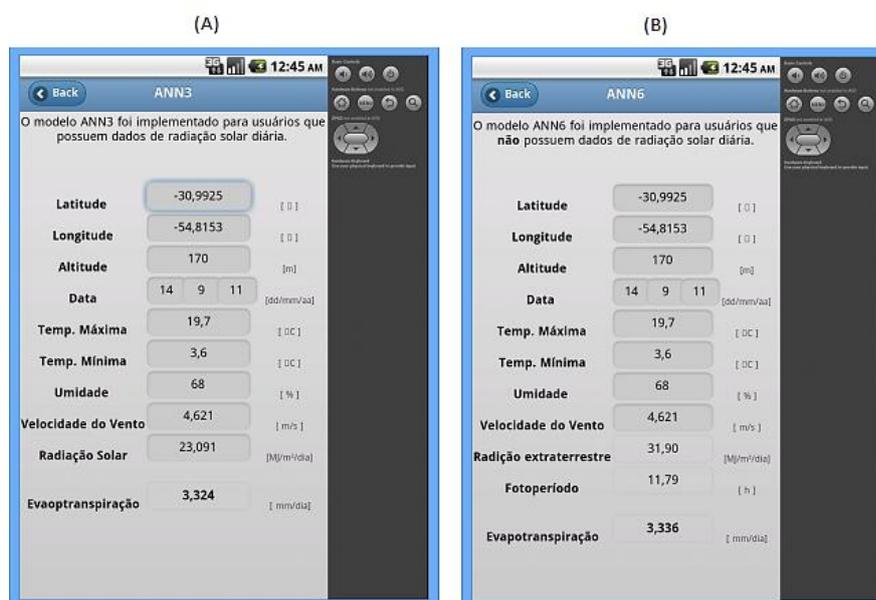


Figura 30 - Visualização do modelo ANN3 (A) e modelo ANN6 (B)

A segunda versão para dispositivos móveis necessita de acesso a internet, no qual o usuário é direcionado para o sistema web (<http://200.18.39.66>), sendo que o mesmo é redimensionado para o tamanho de tela.

4.4 Resultados NeuroEvap

Para validação do sistema web e mobile, foram lançados os valores de entrada para as coordenadas da estação de Santa Maria. Os dados comparados obtiveram os seguintes desempenhos, conforme Tabela 11.

Tabela 11 - Valores de evapotranspiração de referência em mm.dia^{-1} para Santa Maria/RS estimado pelo método de Penman-Monteith e pelos NeuroEvap (modelos ANN3 e ANN6).

Data	Penman-Monteith (mm.dia^{-1})	NeuroEvap	
		ANN3 (mm.dia^{-1})	ANN6 (mm.dia^{-1})
20/05/2009	1,818	1,818	1,880
20/12/2010	2,552	2,552	2,943
05/12/2010	4,952	4,952	4,784
30/03/2009	3,431	3,428	3,740
28/01/2010	3,387	3,387	3,849
28/08/2009	3,457	3,456	3,311
04/02/2009	4,833	4,830	4,820
14/03/2009	4,043	4,036	3,556
29/12/2010	5,922	5,923	5,503
09/06/2010	1,701	1,699	1,501
04/08/2010	1,577	1,577	1,318
16/04/2009	2,980	2,980	2,996
17/01/2009	5,128	5,125	5,281
23/10/2008	1,732	1,730	1,612
16/09/2008	2,166	2,163	2,702
08/12/2011	6,598	6,599	6,434
17/06/2011	1,652	1,655	2,637
04/05/2009	2,463	2,462	2,423
08/10/2011	2,419	2,419	2,914
29/11/2008	4,826	4,828	5,863
07/03/2010	4,134	4,134	3,933
<i>Média</i>	3,418	3,417	3,524
<i>Desvio Padrão</i>	1,514	1,514	1,476
<i>R²</i>	-----	1	0,924

Para realizar a comparação, utilizou-se datas em diferentes períodos com o intuito de verificação dos efeitos da estimação em estações climáticas diferentes.

Observa-se, ao comparar os resultados da Tabela 11, que os modelos de redes neurais possuem capacidade de predição de evapotranspiração de referência, onde apresentaram índice de determinação (R^2) 1,0 para o modelo ANN3 e 0,94 para rede Ann6. Estes resultados demonstram, principalmente, a qualidade dos algoritmos implementados em versão web e mobile, permitindo realizar estimativas de evapotranspiração de referência através de uma ferramenta livre e com poucas variáveis de entrada.

5 CONCLUSÃO

Com base neste trabalho, pôde-se concluir que:

As redes neurais artificiais apresentam ótimos resultados nas estimativas de evapotranspiração de referência para a área de estudo.

Os modelos definidos apresentaram ótimo desempenho, principalmente quando inserido as informações de radiação solar diária como variável de entrada.

A espacialização dos dados através dos dados geográficos como variáveis de entrada, demonstrou que há possibilidade de trabalhar os efeitos sazonais causados pela localização do ponto de estimativa e permite estimar para locais dentro da área de estudo.

O sistema NeuroEvap, desenvolvido em plataforma web e mobile, apresenta-se como uma inovação na área de estimativa de evapotranspiração de referência no Rio Grande do Sul, demonstrando as possibilidades de aplicações da redes neurais artificiais. Estas aplicações podem ser destacadas pela fácil utilização e pela mobilidade.

REFERÊNCIAS BIBLIOGRÁFIAS

- ADELOYE, A. J.; MUNARI, A. de; NArtificial neural network based generalized storage-yield-reliability models using the Levenberg-Marquardt algorithm. **Journal of Hidrology**. P. 1-16, 2005.
- ALLEN, R. G.; PEREIRA, L. S.; RAES, D.; SMITH, M. **Crop evapotranspiration - guidelines for computing crop water requirements**. Rome: FAO, 1998. 300p. Irrigation and Drainage Paper: 56.
- ALVAREZ, M. A. **Introdução à programação em PHP**. Publicado em 14 Jul. 2004. Disponível em <<http://www.criarweb.com/artigos/70.php>>. Acesso em 12 jan. 2009.
- AMATYA, D. M.; SKAGGS, R. W.; GREGORY, J. D. **Comparison of methods for estimating potential evapotranspiration**. St. Joseph: ASABE, 1992. 27 p.
- ANDRADE. M. C. de; NETO, A. R.; ROSA, R. R.; SAWANT, H. S.; FERNANDES, F. C. R. Spatiotemporal Patterns Estimation Using a Multilayer Perceptron Neural Network in a Solar Physics Application. Learning and Nonlinear Models – **Revista da Sociedade Brasileira de Redes Neurais**, v.1, n.2, p. 159-167, 2003.
- ARAÚJO, M.A.; ROCHA, J. G. **Web Services na Informática Geográfica**. Universidade do Minho. Braga, 2004.
- 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. Acessado em 22 Jul. 2001.
- ARSANJANI, A., HAILPERN, B., MARTIN, J.; TARR, P., **Web Services: Promises and Compromises**, *ACM Queue*, New York, NY, USA, v.1, n.1, p. 48-58, 2003.
- AZEVEDO, B. M. **Evapotranspiração de referência obtida com a razão de Bowen, lisímetro de pesagem e equação de Penman-Monteith utilizando sistemas automáticos**. 1999. 81 f. Tese (Doutorado em Agronomia) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 1999.
- AZEVEDO, F. G. B. de; JÚNIOR, H. D. S.; LACERDA, F. F. Estatística e modelagem In: CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, XIV.2005, Campinas. **Anais ...**, Campinas-SP, 2005. p. 29-30.
- BACK. A. J. Variação da evapotranspiração de referência calculada em diferentes intervalos de tempo. **Engenharia Agrícola**, v.27, n.1, p.139-145, 2007.
- BARROS, V. R. et al. Avaliação da evapotranspiração de referência na região de Seropédica, Rio de Janeiro, utilizando lisímetro de pesagem e modelos matemáticos

Revista Brasileira de Ciências Agrárias, Recife, v. 4, n. 2, p. 198-203, abr./jun. 2009.

BEALE, R; JACKSON, T. **Neural Computing**: an introduction. Bristol: Adam Hilger, 1990

BERLATO, M. A; MOLLION, L.C.B. **Evaporação e Evapotranspiração**. Porto Alegre: IPAGRO, 1981. 85p. (IPAGRO, Boletim Técnico, 7).

BERLATO, M.A. & MOLLION, L.C.B. **Evaporação e evapotranspiração**. Boletim Técnico. Porto Alegre: Instituto de Pesquisas Agronômicas – Departamento de Pesquisa. Secretaria da Agricultura, 1981. 95p.

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

BHON, Daniela. **Sites Dinâmicos com Dreamweaver: PHP & MySQL**. Editora Visual Books. Florianópolis - SC, 2004

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

BOULIC, Welling, Luke; **PHP e MySQL: desenvolvimento Web**. Rio de Janeiro: Campus, 2001.

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

BURMAN, R. D. et al. **Water requirements**. IN: JENSEN, M. E. ed. Design and operation of farm irrigation systems. St Joseph: ASAE, 1983. Cap6, 189-232 p.

CAMARGO, A. P.; CAMARGO, M. B. P. Uma revisão analítica da evapotranspiração potencial. **Bragantia**, Campinas, v. 59, n. 2, p. 125-137, 2000

CAMARGO, A. P.; SENTELHAS, P. B.; Avaliação do desempenho de diferentes métodos de estimativas de evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v.5 , n.1 , p. 89-97, 1997.

CARMO, D. S. **Tutorial sobre o novo MySQL 4**. In: Br.Linux.Org, 2005 Disponível em <www.brlinuxsecurity.com.br/tutoriais>. Acesso em 05 jan 2012.

CARVALHO, L.G; RIOS, G. F. A.; MIRANDA, W. L.; NETO, P. C. Evapotranspiração de referência: uma abordagem atual de diferentes métodos de estimativa. **Pesquisa Agropecuária Tropical**. v.41, n. 3, Goiânia. 2011.

CONCEIÇÃO, M. A. F.; MANDELLI, F.; Comparação entre métodos de estimativa da evapotranspiração de referência em Bento Gonçalves, RS. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 13, n. 2, p.303-307, 2005.

COSTA, Carlos J., **Desenvolvimento para Web**, Lisboa, Portugal. Editora Lusocredito, 2007.131p.

DALL'OGGIO, P. **PHP: Programando com orientação a objetos**. São Paulo, SP. Novatec Editora. 2009.

DANTAS, R. T. Determinação da Constante Térmica (R), na Estimativa da vapotranspiração Máxima do Arroz (*Oryza sativa* L). In: IX CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, 9.,1995, Campina Grande. **Anais...** Campina Grande: Sociedade Brasileira de Agrometeorologia, 1995. p. 102-105

DUDA, S.; SCHIßL, M.; HESS, J. M. **Mobile Usability**. Mobile Economy, 2001.

EBERHART, R.; DOBBINS, R. **Neural Networks PC Tools - A Practical Guide**. Academic Press, San Diego, 1990.

ELMASRI, Ramez; NAVATHE, Shamkant B. **Sistemas de banco de dados**. São Paulo: Pearson Addison Wesley, 2005.

FAO Irrigation and Drainage **Paper 56. Crop Evapotranspiration** – Guidelines for Computing Crop Water Requirements. ALLEN, R. G, PEREIRA, L.S., RAES, D., SMITH, M>, 1998. Food and Agriculture Organization of the United Nations, Rome, 1998, 309p.

FERRARI, Fabrício A.; **Crie banco de dados MySQL**, São Paulo, Digerati Books, 2007, 128p

FERRARI, G. **Sistemas operacionais de celular**. Disponível em <<http://www.sosestudante.com/informatica/sistema-operacional-de-celular.html>>. Acessado em 26 de fevereiro de 2011.

FERREIRA, C. L. **Framework para gerenciar dados de interação do usuário em ambiente hipermídia de aprendizagem**. Dissertação de mestrado. UFSC, Florianópolis, 2003.

FERREIRA, D. de S. **Usabilidade de dispositivos móveis** 2004,23 f. Monografia (especialização em Informática) – Universidade Federal de Campinas, 2004.

FRONZA, D. **Consumo de água da cultura de estévia (*Stevia rebaudiana*) estimado por microlisímetro automático**. 2002. 127f. Tese (Doutorado Agronomia) Universidade de São Paulo, Piracicaba, 2002.

GALVÃO, C. O.; et al. **Sistemas inteligentes: Aplicações a recursos hídricos e ciências ambientais**. Porto Alegre: UFRGS/ABRH, 1999. 246p.

GOMES, F.de J. L.; SOUZA, M. T. F.; ARAÚJO, M. L. **Desenvolvimento de Aplicações para Plataforma Google Android**. Escola Regional de Computação dos Estados do Ceará, Maranhão e Piauí (ERCEMAPI), disponível em www.die.ufpi.br/ercemapi2011/minicursos/MC3.pdf, acessado em 09.12.2011.

GROSSBERG, S. Adaptive pattern classification and universal recording: I. Parallel development and coding of neural detectors. **Biological Cybernetics**, v23, p.121-134, 1976.

GUIMARÃES, A. M. **Aplicação de computação evolucionária na mineração de dados físico-químicos da água e do solo**, 2005. Tese. 127p. (Doutorado em

Agronomia – Energia na Agricultura), Universidade Estadual Paulista – UNESP, Botucatu, 2005.

GUIMARÃES, A. M.; VRIESMANN, L. M.; TOMASI, A. L. B.; CANTERI, M. G.; MATHIAS, I. M. Aplicação de Técnicas de Data Mining na obtenção de padrões de características físico-químicas do solo em função de sua produtividade. In: X Encontro Anual de Iniciação Científica e I Encontro de Pesquisa da UEPG, **Anais...**, Ponta Grossa: Editora UEPG, v.1. p.292 – 293, 2001.

HARDIE, B.G.S.; FADER, P.;S.; WISNIEWSKI, M. An empirical comparasion of new product trial forecasting methods. **International Journal of Forecasting**. n.17, p. 209-229, 1998.

HARGREAVES, G. H., AND SAMANI, Z. Reference crop evapotranspiration from temperature. **Appl. Eng. Agric.**, p. 96–99. 2005.

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

HAYKIN, S. **Neural Networks**: a comprehensive foundation. New York, Macmillan College Publishing Company. 1994.

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

HEUSER, C. A. **Projeto de banco de dados**. 3. ed. Porto Alegre: Sagra Luzzatto, 2000. 204 p.

HOPFIELD, J.J. Neural networks and physical systems with emergent collective computational abilities. **Proceedings of the National Academy Science of the United Estates of America**, *Washington*, v.79, p.2554-2558, 1982.

HUO, Z.; FENG, S.; KANG, S.; DAI, X. Neurais artificiais modelos de rede de evapotranspiração de referência em uma área árida do noroeste da China. **Journal of Arid Environments**, v. 82, p 81-90, 2012.

JABLOUN, M. de; SAHLI, A. Evaluation of FAO-56 methodology for estimating reference evapotranspiration using limited climatic data application to Tunisia. **Agricultural Water Management**, Amsterdam, v. 95, n. 6, p. 707-715, 2008.

JACKSON, J. **Data Mining**: A Conceptual Overview. Communications of the Association for Information Systems, v. 8, p. 267-296, 2002.

JAIN, S. K.; NAYAK, P. C. K.; SUDHEER P. Models for estimating evapotranspiration using artificial neural networks, and their physical interpretation. **Hydrological Processes**. v.22, n. 13, p. 2225 – 2234, 2008.

JEAN, S.; BANG, J.; BYUN, K.; LEE, S. A recovery method of deleted record for SQLite database. **Personal and Ubiquitous Computing**. v.16, n. 6, p. 707-715, 2012.

KAUFMAN, Sanders; PERKINS, Jeff; FLEET, Diana: traduzido por Vandenberg Dantas de Souza. **Teach Yourself ActiveX Programming in 21 Days**. Rio de Janeiro: Campus, 1997. 703p.

KLAR, A. E. **Irrigação**: frequência e quantidade de aplicação. São Paulo: Nobel, 1991. 156 p.

KOHONEN, T. An introduction to neural network. **Neural Networks**, v.1, n.1, p.3-16, 1988.

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

KREIBICH, J.A. **Using SQLite**. O'Reilly, 2ª edição, 2010. 530p.

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.

LECHETA, R. R. **Google Android**: Aprenda a criar aplicações para dispositivos móveis com o Android SDK. Editora Novatec, 2009.

LEE, V.; SCHNEIDER, H; SCHELL, R. **Aplicações móveis**: arquitetura, projeto e desenvolvimento. São Paulo: Pearson Education do Brasil, 2005.

LEMON, E.R.; GLASSER, A.M.; SATTERWHITE, L.E. Some aspects of the relationship of soil, plant and meteorological factor to evapotranspiration. **Soil Sc. Soc. Amer. Proc.**, 21. 1957, pp.464-468.

LIN, W. C. et al. A hierarchical multiple view approach to three-dimensional object recognition. **IEEE Trans. On Neural Networks**, v.2, p. 84-92, 1991.

LOBO, Edson Junior Rodrigues. **Criação de sites em PHP**. São Paulo: Digerati Books, 2007. 96p.

LÓPEZ-URREA, R. et al. Testing evapotranspiration equations using lysimeter observations in a semiarid climate. **Agricultural Water Management**, Amsterdam, v. 85, n. 1, p. 15-26, 2006.

MARQUELLI, W. A. **Manejo da irrigação de hortaliças**. Brasília: CNPH/EMBRAPA, jan. 1986. (Circular Técnica, 2).

MATZENAUER, R. Evapotranspiração de plantas cultivadas e coeficientes de cultura. In: BERGAMASCHI, H. (Coord.). **Agrometeorologia aplicada à irrigação**. Porto Alegre: UFRGS, 1992. cap. 3, p. 31-39

MAZIERO, E. **Introdução a PHP**. Curitiba: PUC-PR, 2001. Disponível em: <<http://www.ppgia.pucpr.br/~maziero/ensino/lisu>>. Acesso em: 23 jul. 2012.

MCCULLOCH, W.S.; PITTS, W.A. logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, Elmsford, v.5, p.115-133, 1943

MEDEIROS, A. T. **Estimativa da evapotranspiração de referência a partir da equação de Penman-Monteith, de medidas lisimétricas e de equações empíricas em Paraipaba, CE**. 2002. 103 f. Tese (Doutorado em Agronomia) – Escola Superior Luiz de Queiroz, Piracicaba, 2002.

MEDEIROS, A. T. **Estimativa da evapotranspiração de referência através do programa REF-ET, para duas localidades do Nordeste**. Fortaleza, 1996. 95 p. Dissertação (Mestrado em Engenharia Agrícola) Universidade Federal do Ceará.1996.

MEDEIROS, L. F. de. **Redes neurais em delphi**. Florianópolis: Visual Books Editora, 2003, 115p

MEDEIROS, S. L. P., MANFRONI, P. A., BIANCHI, C. Avaliação de métodos de estimativa da Evapotranspiração de referência para a região mesoclimática de Santa Maria-RS. **Revista Brasileira de Agrometeorologia**, Santa Maria, V. 6, n.1, p. 105-109, 1998.

MELO, Alexandre A., NASCIMENTO, Maurício G.F.; **PHP Profissional: aprenda a desenvolver sistemas profissionais orientados a objetos com padrões de projetos**. São Paulo, Novatec, 2007, 464p

MELONI, J. C. **PHP essentials**. Roseville: Prima Publishing, 2000. 363 p

MENDONÇA, J. C.; SOUSA, E. F.; BERNARDO, S.; DIAS, G. P.; GRIPPA, S. Comparação entre métodos de estimativa da evapotranspiração de referência (ET_o) na região Norte Fluminense, RJ. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.7, n.2, p.275-279, 2003

MINSKY, M. L., PAPERT, S. A. **Perceptrons**, Cambridge, MA: MIT Press, 1969.

MORAZ, Eduardo. **Treinamento avançado em PHP 5.0**. São Paulo: Digirati Books, 2005. 189p.

MUKAMMAL, E.I.; BRUCE, J.P. Evaporation measurements by pan and atmometer. S.I., **Association of Scientific Hydrology**, p. 408-20, 1960.

MULLER, M; FILL, H. D. Redes Neurais aplicadas na propagação de vazões. In: SIMPOSIO BRASILEIRO DE RECURSOS HÍDRICOS, 15. Curitiba. **Anais....** Curitiba: ABRH, 2003.

MUTO, C. A. **PHP & MySQL: Guia Introdutório**. 3ª edição. São Paulo: Brasport, 2006. 412p.

MYSQL AB. **Manual de referência do Mysql 4.1**. Tradução do manual oficial. Disponível em: <<http://dev.mysql.com/doc/mysql/en>>. Acesso em: 25 mar. 2012

NAKASHIMA, G. Y. **Apostila do curso de Inteligência Artificial da Universidade do Sagrado Coração (USC) – Bauru**. [199-?].

NARENDA, K. S.; PARTHASARATHY, K. Identification and control of dynamical systems using neural networks. **IEEE Transactions on Neural Networks**, v. 1, p4-27, 1990

NETO, J. F.; SODRÉ, E.; CARVALHO, M. A. Jr. Monitoração da segurança estática do sistema sul-sudeste através da tecnologia de redes neurais. *IV Congresso Brasileiro de Redes Neurais*, 1999 São José dos Campos, **Anais...** p. 182-87, 1999.

NETO, M. de C.; PINTO, P. A.; COELHO, J. P. **Tecnologias de informação e comunicação e a agricultura**. SIG – Sociedade Industrial Gráfica, 1 Edição, Porto-Portugal, 104 p. 2005.

NEWMAN, C. **SQLite**. Macmillan Computer Pub, 2005. 313p.

NIEDERAUER, J. **Desenvolvendo Websites com PHP: Aprenda a criar Websites dinâmicos e interativos com PHP e bancos de dados**, 2004, 272p.

NIEDERAUER, J. **Integrando PHP5 com MySQL**. São Paulo: Novatec, 2ª edição, 2008, 104p.

NIEDERAUER, J. **PHP para quem conhece PHP**. São Paulo, Novatec, 2006, 480p.

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.

OSÓRIO, F. S.; BITTENCOURT, J. R. **Sistemas Inteligentes baseados em Redes Neurais Artificiais aplicados ao Processamento de Imagens**, In: I Workshop de inteligência artificial, 2000, apostila-seminário, Santa Cruz do Sul, UNISC – Universidade de Santa Cruz do Sul - Departamento de Informática, 2000.

OWENS, M. **The definitive guide to SQLite**. Apress, 2006. 425p.

PENMAN, H. L. Evaporation: an introductory survey. **Journal Agriculture Science**, Neth, v 4, p. 9-29, 1956.

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

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C.; FOLEGATTI, M.V.; NOVA, N. A. V.; MAGGIOTTO, S. R.; PEREIRA, F. A. C. Substantiation of the day FAO-56 reference evapotranspiration with data from automatic and conventional weather stations. **Revista Brasileira de Agrometeorologia**, v.10, n.2, p.251, 2002.

PEREIRA, C. O., SILVA, L. da S. **Android para desenvolvedores**. Rio de Janeiro: Braspot, 2009, p. 223.

PEREIRA, F. A. C. **Desempenho do modelo de Penman-Monteith e de dois evaporímetros na estimativa da evapotranspiração de referência (ET_o) em relação a um lisímitre de pesagem**. Piracicaba, 1998. 87p. Tese (doutorado) – Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo. 1998.

PHP GROUP. **PHP hypertext preprocessor**. Disponível em: <<http://www.php.net>>. Acesso em: 21 jan. 2012.

PROJECT, A. O. S. **Android open source**. 2008. Disponível em: <<http://source.android.com>>. Acessado em 18/06/2012.

REINKE, M. **Utilização de redes neurais artificiais aplicadas a mapeamento hidrogeológicos**, 2008. Dissertação (Mestrado em Geologia), Universidade do Vale do Rio dos Sinos. São Leopoldo, 2008.

REVISTA DROPS. **Realidade aumentada**: das telas de ficção a sua webcam. Passo Fundo, v. 25, 2010.

REZENDE, S. O. **Sistemas Inteligentes**: Fundamentos e aplicações. Barueri, SP. Editora Manole. 2003.

RIBEIRO, L. N. **Rede Neural com retropropagação: uma aplicação na classificação de imagens de satélite**. 2003. Dissertação. 131p. (Mestrado em Estatística), Departamento de Computação e Estatística, Universidade Federal do Mato Grosso do Sul - UFMS, Campo Grande, 2003.

RICH, E. ; KNIGHT, K. **Inteligência Artificial**. Makron Books do Brasil Editora Ltda. São Paulo. p. 560-608. 1993.

ROCHA, A. A. da. **PHP-ASP-JSP**: Desenvolvendo Websites Dinâmicos. In: na RedeMundial Corpiration. São Paulo, 2007. Disponível em <www.naredemundial.com.br/livro>. Acesso em 16 jun. 2012.

ROHN, M. da C; Mine, M. R. M. Uma aplicação das redes neurais artificiais à previsão de chuvas de curtíssimo prazo. In: SIMPÓCIO BRASILEIRO DE RECURSOS HÍDRICOS, 15. Curitiba. **Anais...** Curitiba: ABRH, 2003.

ROSENBLATT, F. The Perceptron: A probabilistic model for information storage and organization in the brain. **Psychological Review**, v.65, 1958.

ROVADOSKY, D. S; PAVAN, W; DALBOSCO J.; CERVI, C. R. Uma ferramenta de realidade aumentada usando dispositivo móvel com sistema operacional Android. **Revista Brasileira de Computação Aplicada**. v. 4, n. 1, p. 25-37. 2012.

RUMELHART, D. E., HILTON, G. E. WILLIAMS, R. J. **Learning Representation by Back-Propagation Error**. Nature, 1986.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Internal Representation by Error Propagation**, in Parellel Distributed Processing. MIT Press, Cambridge, 1986.

SCHMITZ, D. P.. **Desenvolvendo sistemas com Flex e PHP**. São Paulo, SP. Novatec Editora, 2009.

SEDIYAMA, G. C. Estimativa da evapotranspiração: histórico, evolução e análise crítica. **Revista Brasileira de Agrometeorologia**, Santa Maria, v. 4, n. 1, p. 1-7, 1996

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; RAMOS, R.;SOUZA, L.; RODRIGUES, D.; MENDES, J. SIG – **Uma plataforma para introdução de técnicas emergentes no planejamento urbano regional e de transportes: uma ferramenta 3D para análise ambiental urbana: avaliação multicritério, redes neurais artificiais.** São Carlos: Editora dos Autores, 2004. 221p.

SILVA, L. E. P. **Utilização da plataforma Android no desenvolvimento de um aplicativo para o cálculo do Balanço Hídrico Climatológico**,2002. Monografia (Bacharel em Sistema de Informação) Universidade Estadual de Mato Grosso do Sul, 2009.

SILVA, V. J. da; CARVALHO, H. de P.; DA SILVA, C. R. CAMARGO, R.; TEODORO, R. E. F. Desempenho de diferentes métodos de estimativa da evapotranspiração de referência diária em Uberlândia, MG. **Journal Bioscience**, Uberlândia, v. 27, n. 1, p. 95-101. 2011

SMAGT, P. P.; KROSE, B. J. A. **A real-time learning neural robot controller.** Proc. Of the 1991 Internacional Conference on Artificial Neural Networks, Espoo, Finland, p.351-356, 1991.

SMITH, M. **Report on the expert consultation on procedures for revision of FAO guidelines for prediction of crop water requeriments:** Rome: FAO, 1991. 54 p.

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, p. 197-203, 2011.

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.

TAFNER, M. A; XEREZ, M.; RODRIGUES FILHO, I. **Redes neurais artificiais: introdução e princípios de neurocomputação.** Blumenau: Editora Eko, 1996. 199p.

TATIBANA, C. Y.; KAETSU, D. Y. **Introdução a redes neurais artificiais.** Departamento de informática – Universidade Estadual de Maringá – PR. Acessado em 05 de agosto de 2012, disponível em <http://www.din.uem.br/ia/neurais>

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

TURCO, J. E. P.; BARBOSA, J. C. Avaliação de duas estações meteorológicas automatizadas, para estimativa diária da evapotranspiração de referência obtida pelo método Peanman-Monteith. **Irriga**, v.13, n.13, p.339-354, 2008.

ULLMAN, L. **PHP and MySQL for dynamic web sites.** Berkeley, CA. Ed. Peachpit Press. 2003.

VALENÇA, M. J.S. **Aplicando redes neurais: um guia completo.** Olinda, PE: Livro Rápido, 2005. 284p.

VALENÇA, M. J.S. **Fundamentos das redes neurais: Exemplos em JAVA**. 2ed. Olinda, PE: Livro Rápido, 2010. 386p.

VALENÇA, M. J.S. Prevendo com redes neurais o Estado da arte, 2005, IN: XVI Simpósio Brasileiro de Recursos Hídricos. **Anais...** João Pessoa, 2005.

VANDER VEER, Emily A.. **JavaScript for dummies**. Hoboken, EUA: Ed. Wiley, 2005. 358 p.

VESCOVE, H. V., TURCO, J. E. P., Comparação de três métodos de estimativa da evapotranspiração de referência para a região de Araraquara – SP. **Revista Engenharia agrícola**, v. 25, p. 713 -721, 2005.

WASSERMAN P. D. **Neural computing: theory and practice**. New York: Van Nostrand Reinhold, 1989

WIDROW, B.; HOFF, M.E. **Adaptive switching circuits**. In: *IRE WESCON Convention Record* . New York: IRE Press, 1960. p.96-104

WILLMOTT, C. J. On the validation of model. **Physical Geography**, v.2, n.2, p.184-194, 1981.

WINDROW, B. ; WINTER, R. G. ; BAXTER, R. A. Layered neural nets for pattern recognition. **IEEE Trans. On Acoustics, Speech, and Signal Processing**, v.36, p.1109-1117, 1988.

XU, C,Y.; CHEN, D. Comparison of seven models for estimation of evapotranspiration and groundwater recharge using lysimeter measurement data in Germany. **Hydrological Processes**, Chichester, v. 19, n. 18, p. 3717- 3734, 2005.

YODER, R. E.; ODHIAMBO, L. O.; WRIGHT, W. C. Evaluation of methods for estimating daily reference crop evapotranspiration at a site in the humid Southeast United States. **Applied Engineering in Agriculture**, St. Joseph, v. 21, n. 2, p. 197-202, 2005.

ZANETTI, S. S.; SOUSA, E. F. CARVALHO, D. F.; BERNARDO, S. Estimaco da evapotranspiraco de referncia no Estado do Rio de Janeiro usando redes neurais artificiais. **Revista Brasileira de Engenharia Agrcola e Ambiental**, v.12, n.2, p.174-180, 2008.

APÊNDICES

APÊNDICE 1 – Valores estatísticos obtidos para o modelo de redes neurais ANN1 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoides Logística	10	3.932	1.414	0.910	0.828	0.000	0.411	0.641	1.000	0.906	0.825
	15	3.928	1.424	0.920	0.846	-0.005	0.369	0.608	0.999	0.916	0.843
	20	3.916	1.414	0.920	0.846	-0.017	0.368	0.607	0.996	0.916	0.843
	25	3.930	1.429	0.921	0.848	-0.003	0.364	0.603	0.999	0.918	0.845
	30	3.923	1.423	0.921	0.848	-0.010	0.363	0.603	0.997	0.918	0.845
	35	3.937	1.425	0.923	0.851	0.004	0.356	0.596	1.001	0.920	0.849
	40	3.934	1.429	0.923	0.851	0.002	0.357	0.597	1.000	0.920	0.848
	45	3.942	1.429	0.923	0.853	0.009	0.353	0.594	1.002	0.920	0.850
	50	3.936	1.435	0.925	0.856	0.003	0.345	0.587	1.001	0.923	0.854
Tangente Hiperbólica	10	3.933	1.414	0.916	0.839	0.000	0.385	0.621	1.000	0.912	0.836
	15	3.933	1.426	0.921	0.847	0.000	0.366	0.605	1.000	0.917	0.844
	20	3.927	1.423	0.919	0.845	-0.006	0.371	0.609	0.998	0.916	0.842
	25	3.934	1.432	0.922	0.849	0.001	0.361	0.601	1.000	0.919	0.847
	30	3.929	1.433	0.922	0.850	-0.004	0.358	0.598	0.999	0.919	0.848
	35	3.934	1.424	0.920	0.847	0.001	0.367	0.605	1.000	0.917	0.844
	40	3.941	1.428	0.923	0.853	0.008	0.352	0.594	1.002	0.921	0.850
	45	3.940	1.424	0.922	0.849	0.007	0.361	0.601	1.002	0.918	0.846
	50	3.946	1.418	0.919	0.844	0.014	0.375	0.612	1.003	0.915	0.840

APÊNDICE 2 – Valores estatísticos obtidos para o modelo de redes neurais ANN2 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoides Logística	10	3.935	1.448	0.928	0.861	0.002	0.332	0.576	1.000	0.926	0.860
	15	3.918	1.436	0.933	0.871	-0.015	0.309	0.556	0.996	0.931	0.868
	20	3.934	1.450	0.936	0.876	0.001	0.296	0.544	1.000	0.934	0.875
	25	3.936	1.450	0.935	0.874	0.003	0.301	0.548	1.001	0.933	0.873
	30	3.922	1.435	0.935	0.875	-0.010	0.300	0.548	0.997	0.933	0.872
	35	3.933	1.447	0.934	0.872	0.000	0.306	0.553	1.000	0.932	0.870
	40	3.938	1.444	0.938	0.879	0.005	0.290	0.539	1.001	0.935	0.877
	45	3.927	1.452	0.939	0.882	-0.005	0.282	0.531	0.999	0.937	0.880
	50	3.942	1.453	0.938	0.880	0.010	0.288	0.537	1.002	0.936	0.878
Tangente Hiperbólica	10	3.931	1.433	0.929	0.863	-0.002	0.328	0.572	1.000	0.926	0.861
	15	3.930	1.444	0.933	0.870	-0.003	0.311	0.557	0.999	0.931	0.868
	20	3.943	1.446	0.933	0.870	0.011	0.312	0.558	1.003	0.930	0.868
	25	3.926	1.440	0.934	0.873	-0.007	0.304	0.552	0.998	0.932	0.871
	30	3.939	1.450	0.934	0.872	0.007	0.307	0.554	1.002	0.932	0.870
	35	3.940	1.441	0.935	0.874	0.007	0.301	0.549	1.002	0.933	0.872
	40	3.935	1.441	0.936	0.876	0.002	0.297	0.545	1.001	0.933	0.874
	45	3.937	1.457	0.938	0.880	0.004	0.287	0.536	1.001	0.936	0.878
	50	3.932	1.455	0.938	0.879	-0.001	0.289	0.537	1.000	0.936	0.878

APÊNDICE 3 – Valores estatísticos obtidos para o modelo de redes neurais ANN3 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.933	1.547	1.000	1.000	0.000	0.000	0.007	1.000	1.000	1.000
	15	3.933	1.548	1.000	1.000	0.000	0.000	0.006	1.000	1.000	1.000
	20	3.933	1.548	1.000	1.000	0.000	0.000	0.003	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	30	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	40	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	45	3.932	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
Tangente Hiperbólica	50	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	10	3.933	1.548	1.000	1.000	0.000	0.000	0.009	1.000	1.000	1.000
	15	3.933	1.548	1.000	1.000	0.000	0.000	0.006	1.000	1.000	1.000
	20	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.003	1.000	1.000	1.000
	30	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.004	1.000	1.000	1.000
	40	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
45	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000	
50	3.933	1.548	1.000	1.000	0.000	0.000	0.005	1.000	1.000	1.000	

APÊNDICE 4 – Valores estatísticos obtidos para o modelo de redes neurais ANN4 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.934	1.438	0.930	0.864	0.001	0.325	0.571	1.000	0.927	0.862
	15	3.933	1.446	0.935	0.874	0.000	0.302	0.549	1.000	0.933	0.872
	20	3.929	1.445	0.933	0.871	-0.004	0.309	0.556	0.999	0.931	0.869
	25	3.927	1.446	0.936	0.875	-0.006	0.298	0.546	0.999	0.933	0.873
	30	3.924	1.447	0.936	0.875	-0.009	0.299	0.547	0.998	0.933	0.873
	35	3.934	1.449	0.937	0.878	0.001	0.293	0.541	1.000	0.935	0.876
	40	3.928	1.451	0.938	0.880	-0.004	0.286	0.535	0.999	0.936	0.879
	45	3.925	1.447	0.937	0.878	-0.007	0.293	0.542	0.998	0.935	0.876
	50	3.927	1.449	0.939	0.882	-0.006	0.283	0.532	0.999	0.937	0.880
Tangente Hiperbólica	10	3.926	1.432	0.932	0.868	-0.007	0.315	0.561	0.998	0.929	0.866
	15	3.932	1.444	0.935	0.874	0.000	0.301	0.549	1.000	0.933	0.872
	20	3.928	1.450	0.935	0.874	-0.005	0.301	0.549	0.999	0.933	0.872
	25	3.929	1.462	0.936	0.876	-0.003	0.297	0.545	0.999	0.934	0.875
	30	3.936	1.447	0.933	0.870	0.003	0.311	0.557	1.001	0.931	0.868
	35	3.931	1.452	0.936	0.876	-0.002	0.297	0.545	1.000	0.934	0.874
	40	3.920	1.442	0.937	0.879	-0.013	0.291	0.539	0.997	0.935	0.876
	45	3.936	1.449	0.936	0.876	0.004	0.297	0.545	1.001	0.934	0.874
	50	3.919	1.440	0.938	0.880	-0.014	0.288	0.537	0.996	0.936	0.878

APÊNDICE 5 – Valores estatísticos obtidos para o modelo de redes neurais ANN5 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.933	1.548	1.000	1.000	0.000	0.000	0.004	1.000	1.000	1.000
	15	3.933	1.547	1.000	1.000	0.000	0.000	0.022	1.000	1.000	1.000
	20	3.933	1.548	1.000	1.000	0.000	0.000	0.004	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	30	3.932	1.548	1.000	1.000	0.000	0.000	0.008	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	40	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	45	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	50	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
Tangente Hiperbólica	10	3.933	1.548	1.000	1.000	0.000	0.000	0.007	1.000	1.000	1.000
	15	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	20	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	30	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	40	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	45	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	50	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000

APÊNDICE 6 – Valores estatísticos obtidos para o modelo de redes neurais ANN6 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.927	1.438	0.929	0.864	-0.006	0.327	0.572	0.999	0.927	0.861
	15	3.933	1.445	0.934	0.872	0.001	0.307	0.554	1.000	0.931	0.870
	20	3.945	1.440	0.932	0.869	0.012	0.314	0.560	1.003	0.930	0.867
	25	3.923	1.443	0.938	0.879	-0.010	0.290	0.539	0.997	0.935	0.877
	30	3.933	1.456	0.938	0.880	0.000	0.288	0.537	1.000	0.936	0.878
	35	3.927	1.450	0.936	0.877	-0.006	0.296	0.544	0.999	0.934	0.875
	40	3.934	1.444	0.932	0.868	0.002	0.315	0.561	1.000	0.930	0.866
	45	3.922	1.454	0.938	0.880	-0.011	0.288	0.537	0.997	0.936	0.878
	50	3.928	1.452	0.941	0.885	-0.005	0.276	0.525	0.999	0.939	0.883
Tangente Hiperbólica	10	3.929	1.441	0.930	0.865	-0.004	0.322	0.568	0.999	0.928	0.863
	15	3.931	1.438	0.931	0.867	-0.002	0.319	0.565	0.999	0.929	0.865
	20	3.931	1.449	0.936	0.877	-0.002	0.295	0.543	0.999	0.934	0.875
	25	3.933	1.457	0.938	0.879	0.001	0.289	0.537	1.000	0.936	0.878
	30	3.928	1.457	0.939	0.881	-0.004	0.284	0.533	0.999	0.937	0.880
	35	3.932	1.450	0.936	0.876	-0.001	0.297	0.545	1.000	0.934	0.874
	40	3.928	1.449	0.939	0.881	-0.005	0.285	0.534	0.999	0.937	0.879
	45	3.929	1.456	0.939	0.882	-0.004	0.283	0.532	0.999	0.937	0.880
	50	3.932	1.449	0.938	0.879	-0.001	0.290	0.538	1.000	0.936	0.877

APÊNDICE 7 – Valores estatísticos obtidos para o modelo de redes neurais ANN7 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.933	1.548	1.000	1.000	0.000	0.000	0.003	1.000	1.000	1.000
	15	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	20	3.933	1.547	1.000	1.000	0.000	0.000	0.010	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	30	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	40	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	45	3.933	1.548	1.000	1.000	0.000	0.000	0.003	1.000	1.000	1.000
	50	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
Tangente Hiperbólica	10	3.932	1.547	1.000	1.000	0.000	0.000	0.020	1.000	1.000	1.000
	15	3.933	1.548	1.000	1.000	0.000	0.000	0.008	1.000	1.000	1.000
	20	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.010	1.000	1.000	1.000
	30	3.933	1.547	1.000	1.000	0.000	0.000	0.003	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	40	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	45	3.933	1.548	1.000	1.000	0.000	0.000	0.000	1.000	1.000	1.000
	50	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000

APÊNDICE 8 – Valores estatísticos obtidos para o modelo de redes neurais ANN8 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.941	1.446	0.934	0.873	0.008	0.304	0.551	1.002	0.932	0.871
	15	3.940	1.439	0.934	0.872	0.008	0.306	0.553	1.002	0.931	0.870
	20	3.927	1.442	0.935	0.874	-0.006	0.302	0.549	0.999	0.933	0.872
	25	3.942	1.431	0.933	0.870	0.009	0.311	0.557	1.002	0.930	0.868
	30	3.931	1.445	0.935	0.874	-0.001	0.303	0.550	1.000	0.932	0.872
	35	3.934	1.453	0.935	0.874	0.001	0.303	0.550	1.000	0.933	0.872
	40	3.925	1.441	0.937	0.878	-0.008	0.293	0.541	0.998	0.934	0.876
	45	3.935	1.450	0.933	0.871	0.002	0.308	0.555	1.001	0.931	0.869
	50	3.935	1.459	0.938	0.880	0.003	0.289	0.537	1.001	0.936	0.878
Tangente Hiperbólica	10	3.936	1.446	0.933	0.871	0.003	0.308	0.555	1.001	0.931	0.869
	15	3.933	1.443	0.934	0.873	0.000	0.304	0.551	1.000	0.932	0.871
	20	3.920	1.424	0.931	0.867	-0.013	0.318	0.564	0.997	0.928	0.864
	25	3.936	1.450	0.936	0.876	0.004	0.296	0.544	1.001	0.934	0.875
	30	3.934	1.448	0.935	0.875	0.001	0.300	0.548	1.000	0.933	0.873
	35	3.936	1.453	0.937	0.879	0.004	0.291	0.539	1.001	0.935	0.877
	40	3.941	1.449	0.937	0.878	0.009	0.291	0.540	1.002	0.935	0.876
	45	3.924	1.450	0.937	0.877	-0.009	0.295	0.543	0.998	0.935	0.875
	50	3.927	1.443	0.934	0.873	-0.006	0.304	0.551	0.998	0.932	0.871

APÊNDICE 9 – Valores estatísticos obtidos para o modelo de redes neurais ANN9 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.933	1.548	1.000	1.000	0.000	0.000	0.006	1.000	1.000	1.000
	15	3.933	1.548	1.000	1.000	0.000	0.000	0.004	1.000	1.000	1.000
	20	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	30	3.933	1.548	1.000	1.000	0.000	0.000	0.004	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	40	3.933	1.548	1.000	1.000	0.000	0.000	0.002	1.000	1.000	1.000
	45	3.933	1.548	1.000	1.000	0.000	0.000	0.003	1.000	1.000	1.000
	50	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
Tangente Hiperbólica	10	3.933	1.548	1.000	1.000	0.000	0.000	0.004	1.000	1.000	1.000
	15	3.933	1.548	1.000	1.000	0.000	0.000	0.007	1.000	1.000	1.000
	20	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	25	3.933	1.548	1.000	1.000	0.000	0.000	0.004	1.000	1.000	1.000
	30	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	35	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	40	3.933	1.547	1.000	1.000	0.000	0.000	0.005	1.000	1.000	1.000
	45	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000
	50	3.933	1.548	1.000	1.000	0.000	0.000	0.001	1.000	1.000	1.000

APÊNDICE 10 – Valores estatísticos obtidos para o modelo de redes neurais ANN10 com cada número de neurônios escondidos.

Função de Ativação	Neurônios Escondidos	Média	Desvio Padrão	r	R ²	ME	MSE	RMSE	RR	C	Id
Sigmoide Logística	10	3.928	1.438	0.933	0.871	-0.005	0.308	0.555	0.999	0.931	0.869
	15	3.931	1.443	0.935	0.875	-0.001	0.300	0.548	1.000	0.933	0.872
	20	3.908	1.435	0.934	0.872	-0.025	0.308	0.555	0.994	0.931	0.869
	25	3.927	1.456	0.937	0.878	-0.006	0.293	0.541	0.999	0.935	0.876
	30	3.929	1.449	0.938	0.880	-0.004	0.288	0.537	0.999	0.936	0.878
	35	3.927	1.458	0.940	0.883	-0.006	0.280	0.529	0.999	0.938	0.882
	40	3.956	1.455	0.937	0.877	0.023	0.294	0.543	1.006	0.935	0.876
	45	3.925	1.452	0.938	0.879	-0.008	0.290	0.538	0.998	0.936	0.877
	50	3.923	1.444	0.938	0.879	-0.009	0.289	0.538	0.998	0.935	0.877
Tangente Hiperbólica	10	3.942	1.453	0.933	0.870	0.009	0.312	0.559	1.002	0.931	0.868
	15	3.936	1.452	0.936	0.875	0.003	0.298	0.546	1.001	0.934	0.874
	20	3.928	1.451	0.936	0.875	-0.005	0.299	0.546	0.999	0.934	0.874
	25	3.928	1.453	0.938	0.880	-0.005	0.288	0.537	0.999	0.936	0.878
	30	3.926	1.452	0.937	0.878	-0.007	0.293	0.541	0.998	0.935	0.876
	35	3.918	1.451	0.936	0.877	-0.015	0.295	0.543	0.996	0.934	0.875
	40	3.927	1.450	0.937	0.878	-0.006	0.291	0.540	0.999	0.935	0.877
	45	3.929	1.461	0.942	0.887	-0.004	0.271	0.521	0.999	0.940	0.885
	50	3.961	1.459	0.936	0.876	0.028	0.298	0.546	1.007	0.934	0.874

APÊNDICE 11 – Matriz de pesos e bias do modelo de rede ANN3.

PESOS w1									BIA 1	PESO W2	BIA 2
-0,03	-0,02	0,02	0,00	0,61	0,50	-0,14	1,03	-0,44	0,41	2,12	7,7927
3,08	1,29	2,13	-0,11	3,09	0,88	-2,83	1,65	-1,32	-1,82	0,00	
-3,13	-1,43	3,24	2,06	-2,91	3,20	-1,40	-0,08	2,90	6,46	0,00	
0,60	8,67	-4,58	1,69	-3,32	0,95	-4,13	-1,67	2,42	-5,34	0,00	
0,02	0,05	-0,07	0,04	-0,75	-0,11	1,46	2,87	-1,24	-4,14	0,36	
3,49	3,97	5,25	9,34	-2,51	0,47	-6,26	-0,30	-2,24	1,41	0,00	
-6,01	-1,58	5,58	-3,55	4,06	6,19	1,49	0,91	-4,89	2,84	0,00	
-4,22	-2,82	-0,56	-1,74	1,00	3,16	-0,99	1,46	1,85	4,03	0,00	
4,71	1,89	-0,21	-2,07	-1,27	1,84	-2,21	2,87	1,50	-2,74	0,00	
-0,08	-0,46	0,09	0,18	1,68	-3,05	5,95	-2,27	2,52	-4,39	0,01	
0,23	1,58	12,99	6,53	-1,64	-0,63	7,08	7,90	1,05	-1,61	0,00	
0,00	0,00	0,00	0,00	-0,44	-0,41	-0,92	2,83	-0,70	4,77	-3,94	
0,00	-0,02	0,01	0,01	-0,52	-0,52	1,34	0,93	-0,31	0,66	-1,43	
0,03	-0,15	0,10	0,05	-0,77	-1,32	3,41	1,86	0,49	1,26	0,08	
5,42	1,66	-7,75	0,77	-4,54	4,28	-2,79	-4,34	6,83	-0,96	0,00	
0,01	0,00	0,00	0,00	-0,86	-0,75	0,38	-0,96	-0,30	1,65	-3,07	
2,23	-1,08	1,44	3,07	0,09	-0,58	9,12	-6,87	8,55	-6,12	0,00	
-1,77	-0,65	-0,62	-0,60	-3,86	2,98	-0,92	3,50	1,28	2,92	0,00	
2,36	-1,53	-3,77	0,00	0,31	-2,78	0,38	1,16	3,73	1,74	0,00	
-3,25	-0,50	2,51	0,78	0,44	7,35	-11,74	3,56	-9,08	4,97	0,00	
1,39	1,25	-1,44	2,22	0,09	-1,76	-3,10	-2,47	2,29	0,70	0,00	
-4,05	-2,21	1,95	0,58	-3,41	4,81	3,09	3,65	2,38	0,24	0,00	
-3,13	-1,65	2,44	-6,42	1,44	3,65	2,23	3,47	-4,03	3,19	0,00	
0,00	0,00	0,01	0,01	0,59	0,53	0,08	-1,33	-0,48	-2,74	-3,32	

Continuação...

2,10	3,30	-1,63	-0,12	-0,14	2,68	-1,21	-4,79	-4,48	2,71	0,02
1,99	3,33	0,50	-2,23	-2,46	3,87	-1,48	-3,84	-0,63	0,17	0,00
0,98	0,30	-1,20	-2,50	-1,66	1,08	-0,63	0,57	2,53	3,30	0,00
-0,04	-0,01	-0,01	-0,03	-0,53	-0,67	-0,33	2,53	-1,06	1,84	-0,31
1,51	-0,27	0,17	-0,15	6,14	-7,59	0,82	0,71	-1,59	-0,60	0,00
-2,95	-2,09	3,02	-2,03	-4,18	-1,89	1,12	-3,00	3,68	-1,85	0,00
1,85	1,49	1,88	0,74	4,78	-1,09	-0,05	0,36	1,67	2,89	0,00
-0,62	0,45	-0,91	-0,13	0,31	2,72	-3,36	-2,60	-2,33	-5,43	-0,01
-5,50	4,74	4,67	-1,41	3,64	4,24	5,81	-4,72	2,19	-4,05	0,00
0,00	0,00	-0,01	0,00	0,31	0,28	0,93	0,88	-0,33	-2,12	-3,92
-4,15	2,75	-1,46	-1,13	2,18	-5,55	3,61	-1,66	3,10	-4,12	0,00
-0,05	-0,02	0,03	-0,01	0,39	0,33	-0,95	1,26	-0,79	0,51	-1,12
1,69	-2,38	-0,59	-0,44	1,72	-3,26	-0,11	-5,48	-2,66	4,03	0,06
-2,03	-10,55	7,32	3,86	-3,58	-2,59	1,67	2,16	-0,73	1,25	0,00
-1,39	-2,87	4,86	2,56	3,46	-1,64	-3,28	4,24	-5,37	2,61	0,00
0,00	0,00	-0,01	-0,01	0,37	0,34	-0,56	-2,91	-0,33	-5,24	-5,20

APÊNDICE 12 – Matriz de pesos e bias do modelo de rede ANN6.

PESOS w1										BIA 1	PESO w2	BIA 2
6,53	12,81	-1,24	1,25	-7,07	9,14	-8,48	-33,37	-77,57	74,58	-14,12	0,02	-1,80
-0,76	0,26	-1,30	-0,04	-0,10	0,45	0,03	-0,58	-0,44	0,62	-2,72	3,38	
-10,03	-6,35	2,59	0,99	-5,01	2,07	-0,09	2,67	-9,40	9,29	10,01	0,09	
-4,12	-1,85	1,01	-1,41	0,88	-0,67	-1,99	0,64	47,05	-37,54	-12,08	0,23	
0,96	-1,13	3,99	-0,12	0,08	-0,01	-1,51	0,28	1,80	-2,39	4,15	0,97	
0,02	0,29	-0,54	-0,38	0,22	0,33	-1,31	-1,27	14,18	-13,76	-2,57	-2,34	
1,43	-1,29	-5,40	-0,25	1,55	-3,98	6,02	7,37	-0,99	4,66	0,95	-0,03	
1,95	-1,03	1,86	-0,64	-12,62	8,02	-17,86	-7,17	-45,05	45,66	12,72	0,04	
0,67	10,70	3,69	-0,34	2,02	0,29	9,32	-10,94	-6,88	8,63	-5,97	-0,06	
-2,72	-2,59	1,00	2,58	-3,41	-0,32	0,62	2,58	-1,20	1,34	3,62	-0,08	
-1,22	-8,78	-1,33	9,82	0,46	-0,47	0,35	3,80	80,32	-89,41	-13,49	0,06	
-1,41	1,64	-0,20	-3,66	2,46	-0,16	-2,20	-0,94	23,03	-21,91	-4,88	0,25	
-6,10	-5,93	2,54	0,09	-9,05	1,25	5,52	-16,93	25,66	-26,65	-18,07	0,03	
-28,69	15,49	-4,65	-59,38	8,45	45,18	-31,69	59,78	376,33	-359,06	-83,14	-0,03	
-0,02	-0,23	0,23	0,30	-1,77	1,69	-2,33	-2,88	1,14	1,54	0,45	-0,58	
6,69	13,83	-1,78	-6,77	29,97	23,61	-13,67	-32,76	95,04	-99,31	-31,99	0,00	
0,15	0,09	0,12	0,33	-2,27	2,29	-1,51	-1,50	2,22	-1,08	-0,09	1,08	
-2,10	13,32	2,66	0,68	10,44	2,60	14,95	-7,76	-25,20	21,29	-6,77	0,02	
-6,71	-5,22	1,67	-4,54	4,12	-4,41	0,53	-3,32	7,48	-10,66	-5,75	0,07	
-8,32	3,54	-2,69	3,99	1,26	-0,62	6,23	-0,48	-9,46	9,96	1,53	-0,07	
0,19	-0,18	0,46	0,17	-0,28	-0,25	1,57	1,83	-15,55	15,07	2,77	-2,10	
0,16	0,32	-1,17	-3,68	-4,67	-0,62	2,04	0,94	11,58	-9,21	-0,97	0,16	
0,19	0,10	2,41	-0,21	15,83	10,00	7,14	-4,80	4,65	-12,11	-9,97	-0,03	
0,05	-9,80	-10,91	-0,20	-15,43	13,05	-3,69	-12,04	-20,04	20,01	-8,64	-0,04	
8,51	0,70	-3,51	12,78	-0,25	2,57	-8,18	-2,80	-65,65	68,42	1,81	-0,04	
0,35	-0,82	0,52	-0,51	-3,62	1,21	1,69	2,12	4,47	-3,76	-0,39	-0,48	

Continuação...

-14,36	-4,61	10,24	68,67	8,18	-12,89	71,37	13,24	28,51	-10,10	-17,96	0,00
-5,16	-18,50	18,55	-9,58	-14,81	-2,64	-3,48	-15,08	-20,49	33,77	3,09	-0,02
2,16	1,58	-2,53	-1,71	-5,54	-1,26	-3,96	-6,78	-2,17	-4,65	0,24	0,09
-7,73	-12,58	9,56	15,62	-15,95	5,49	-4,90	24,72	51,85	-55,40	14,48	0,03
15,26	5,24	3,92	1,45	-3,18	4,61	-1,42	0,19	5,28	-6,57	2,82	0,07
-1,11	-0,66	0,42	0,60	-2,72	-6,00	-12,53	1,16	-17,55	27,56	6,03	-0,06
-7,72	-24,66	-106,47	32,73	17,64	-1,79	-110,68	-12,72	-15,62	4,27	0,96	0,00
-2,28	2,87	3,48	5,17	-12,05	8,10	-4,00	0,62	17,71	-14,52	-1,96	-0,05
7,17	-11,14	-0,73	12,40	-8,96	5,55	-2,89	-1,65	7,73	-1,31	6,59	0,03
-3,18	2,44	-1,26	9,45	-3,16	-7,78	2,15	0,34	19,22	-12,01	5,84	-0,04
-1,81	-1,72	1,55	-0,14	0,52	0,37	-2,22	2,63	12,08	-14,53	-1,65	0,42
0,31	-0,64	0,51	0,28	-6,40	6,06	1,98	-1,72	-3,32	3,40	0,84	0,39
-41,29	16,04	57,61	-10,21	53,62	68,03	67,07	-46,46	91,39	-102,63	-52,74	0,00
13,42	6,05	-7,17	-24,97	21,98	-2,47	-9,91	6,13	-197,22	253,31	50,74	0,00
10,00	40,57	-25,02	-41,47	17,17	-75,08	36,78	24,18	57,56	-86,42	-21,38	0,00
19,79	28,70	-14,80	-13,13	-21,71	-22,70	-15,00	32,02	8,65	-17,09	5,90	0,01
0,72	0,20	0,28	0,25	1,38	-1,58	0,96	2,59	-1,03	0,70	3,20	1,70
-2,95	3,42	-17,75	13,81	-5,08	7,14	-2,10	3,45	44,96	-61,05	-9,01	-0,02
-35,09	-47,18	72,78	58,76	-10,87	-12,62	-90,17	-46,22	-22,08	62,33	62,39	0,01
-2,28	-0,87	0,50	-0,47	-2,45	-1,07	2,06	-3,72	5,95	-7,22	0,79	-0,32
0,15	-4,74	5,10	-6,03	2,06	-0,67	-7,32	-3,16	-6,03	14,12	5,69	0,07
0,07	-6,84	-15,75	7,56	-3,79	1,34	-3,00	-0,65	3,26	2,52	-14,29	0,04
-3,63	0,69	10,89	2,14	4,89	-8,92	12,92	18,92	-7,48	10,31	22,53	0,04
0,48	0,88	-0,57	0,03	2,82	-2,22	-0,81	1,73	0,22	0,55	0,29	1,02