



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA



TESE DE DOUTORADO

DESENVOLVIMENTO DE MODELO EM REDES NEURAIS PARA SIMULAÇÃO
DA PRECIPITAÇÃO NA IRRIGAÇÃO POR ASPERSÃO

PAULO LOPES DE MENEZES

CAMPINA GRANDE - PB
MARÇO, 2014

PAULO LOPES DE MENEZES

**DESENVOLVIMENTO DE MODELO EM REDES NEURAIS PARA
SIMULAÇÃO DA PRECIPITAÇÃO NA IRRIGAÇÃO POR
ASPERSÃO**

Tese apresentada à Universidade Federal de
Campina Grande para obtenção do título de Doutor
em Engenharia Agrícola, Área de Concentração:
Irrigação e Drenagem.

Orientadores:

Prof. Dr. Carlos A. Vieira de Azevedo

Prof. Dr. Eduardo Eyng

CAMPINA GRANDE - PB
MARÇO, 2014



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA



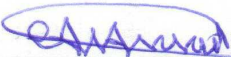
PARECER FINAL DO JULGAMENTO DA TESE

PAULO LOPES DE MENEZES

DESENVOLVIMENTO DE MODELO EM REDES NEURAIIS PARA
SIMULAÇÃO DA PRECIPITAÇÃO NA IRRIGAÇÃO POR ASPERSÃO

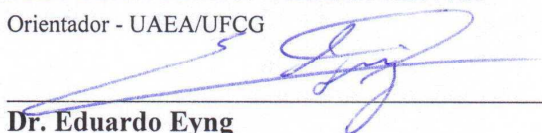
BANCA EXAMINADORA

PARECER



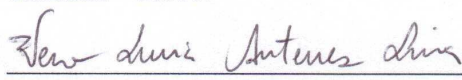
PhD. Carlos Alberto Vieira de Azevedo
Orientador - UAEA/UFCA

Aprovado




Dr. Eduardo Eyng
Orientador - UTFPR

APROVADO



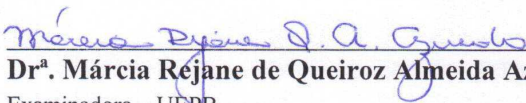
Dr^a. Vera Lúcia Antunes de Lima
Examinadora - UAEA/UFCA

Aprovado



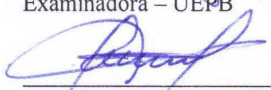
Dr. José Dantas Neto
Examinador - UAEA/UFCA

APROVADO



Dr^a. Márcia Réjane de Queiroz Almeida Azevedo
Examinadora - UEPB

APROVADO



Dr. Antonio Aprígio
Examinador - UTFPR

APROVADO

MARÇO DE 2014

AGRADECIMENTOS

A Deus, pela vida,

aos professores Dr. Carlos A. Vieira de Azevedo e Dr. Eduardo Eyng, pela oportunidade, orientações, conhecimentos transmitidos, incentivo e amizade,

aos demais professores do Programa de Pós-graduação em Engenharia Agrícola da UFCG,

à minha família, em especial a meus pais, Alvino e Maria José (*in memoriam*),

à minha esposa, Josi, e filha, Maísa, pelo incentivo, compreensão, paciência e amor.

DESENVOLVIMENTO DE MODELO EM REDES NEURAIS PARA SIMULAÇÃO DA PRECIPITAÇÃO NA IRRIGAÇÃO POR ASPERSÃO

RESUMO: A eficiência de um sistema de irrigação por aspersão depende do desempenho do aspersor, que é dependente de algumas características como diâmetro do bocal, pressão de operação, velocidade e direção do vento, disposição e espaçamento no campo. A determinação dos coeficientes de uniformidade e a eficiência dos sistemas de aspersão dependem, em geral, de ensaios em campo que envolvem tempo e recursos financeiros. Uma alternativa para reduzir custo e tempo é a utilização de simulações para estimar os valores de precipitação ou dos coeficientes de uniformidade e eficiência. Neste trabalho foi proposta e testada a aplicação de uma rede neural artificial (RNA) do tipo Perceptron Multicamadas para simular a precipitação de um aspersor cujos parâmetros de entrada são os valores de pressão de operação, velocidade do vento, direção do vento e diâmetro do bocal do aspersor. Ensaios foram feitos em campo com um aspersor operando em uma malha de 16 x 16 coletores com espaçamento de 1,5 m, e diferentes combinações de bocais, pressões e condições de vento. Uma rede neural artificial foi treinada com vista a simular e estimar os valores de precipitação para o aspersor, dentro das condições ensaiadas. O modelo RNA apresentou bons resultados na simulação da precipitação com correlação de Spearman (r_s) entre os dados obtidos em ensaio de campo e os dados simulados, apresentado valores entre 0,92 e 0,97 para dez ensaios analisados. Para a correlação entre o perfil de distribuição com os dados simulados pelo modelo RNA e os dados obtidos em ensaio de campo foram observados, para os mesmos dez ensaios, valores de coeficiente R^2 de 0,95 a 0,99. O modelo RNA mostrou-se promissor na simulação da precipitação de aspersores em sistemas de irrigação por aspersão.

Palavras-chave: aspersor, uniformidade de distribuição, modelo computacional, redes neurais artificiais.

DEVELOPING A MODEL FOR SIMULATION OF WATER DISTRIBUTION IN SPRINKLER IRRIGATION

ABSTRACT: The efficiency of a sprinkler irrigation system depends on the performance of the sprinkler head, which is dependent on certain characteristics such as nozzle diameter, operating pressure, wind speed and direction, and layout and spacing in the field. Determining the coefficients of uniformity and the efficiency of sprinkler systems usually depends on field trials requiring time and financial resources. One alternative to reduce time and expense is the use of simulations to estimate the values of water distribution or the coefficients of uniformity and efficiency. In this study, we proposed and tested the application of a multilayer perceptron-type artificial neural network (ANN) to simulate the precipitation of a sprinkler having as input parameters the values of operating pressure, wind speed, wind direction, and sprinkler nozzle diameter. Trials were performed in the field with sprinklers operating in a grid of 16 x 16 collectors with 1.5 meter spacing, with different combinations of nozzles, pressures, and wind conditions. An artificial neural network was trained to simulate and estimate the water distribution values for the sprinkler at conditions tested. The ANN model showed good results in the simulation of precipitation, with the Spearman correlation (r_s) between the data obtained in the field trial and the simulated data having values between 0.92 and 0.97 for the ten trials analyzed. For the correlation between the distribution profile with the data simulated by the ANN model and the data obtained in field trials, for the same ten trials, R^2 coefficient values of 0.95 to 0.99 were observed. The ANN model shows promise in the simulation of water distribution of sprinklers in sprinkler irrigation systems.

Keywords: sprinkler, distribution uniformity, computational model, artificial neural networks.

LISTA DE FIGURAS

Figura 1 - Neurônio Natural	28
Figura 2 - Modelo não-linear de um neurônio	29
Figura 3 - Gráfico da função logística.....	32
Figura 4 - Gráfico da Tangente Hiperbólica	32
Figura 5 - Perceptron de Múltiplas Camadas	34
Figura 6 - Fluxo de sinal do neurônio de saída j	43
Figura 7 - Fluxo de sinal do neurônio de saída k conectado ao neurônio oculto j	47
Figura 8 - Aspensor Fabrimar Modelo Pingo	52
Figura 9 - Kit de ensaio de precipitação.....	54
Figura 10 - Esquema da malha de coletores e a direção do vento.....	56
Figura 11 - Ilustração da regra de parada antecipada baseada na validação cruzada.....	62
Figura 12 - Tela de Ensaios e Coletas do programa ASPERSOFT.....	63
Figura 13 - Tela de sobreposições e coeficientes de uniformidade do ASPERSOFT.....	64
Figura 14 - Comparativo do erro SSE entre as RNA's com uma, duas, três e quatro camadas ocultas (100 menores valores de erro SSE por camada)	66
Figura 15 – Distribuição da precipitação de água do aspensor para um ensaio com 2 horas de duração, bocais 4,0 x 2,8 mm, pressão de operação de 196 kPa e vento a uma velocidade média de 0,74 m s ⁻¹ na direção 325°. A) Precipitação observada; B) Precipitação simulada pela RNA.	71
Figura 16 - Correlação entre os valores de precipitação observados e os simulados, para cinco ensaios de validação do modelo RNA com 2 horas de duração e pressão de operação de 196 kPa	73
Figura 17 - Correlação entre os valores de precipitação observados e os simulados, para dois ensaios de validação do modelo RNA com 2 horas de duração e pressão de operação de 294 kPa	74
Figura 18 - Correlação entre os valores de precipitação observados e os simulados, para três ensaios de validação do modelo RNA com 2 horas de duração e pressão de operação de 343 kPa	75
Figura 19 - Esquema da malha de coletores e orientação do eixo de referência para cálculo do perfil de distribuição	77
Figura 20 – Comparativo do perfil de distribuição do aspensor calculado com os dados de precipitação observados e dados de precipitação simulados pela RNA para ensaio com 2 horas de duração e pressão de operação de 196 kPa.....	79

Figura 21 – Comparativo do perfil de distribuição do aspersor calculado com os dados de precipitação observados e dados de precipitação simulados pela RNA para ensaio com 2 horas de duração e pressão de operação de 294 kPa.....	80
Figura 22 – Comparativo do perfil de distribuição do aspersor calculado com os dados de precipitação observados e dados de precipitação simulados pela RNA para ensaio com 2 horas de duração e pressão de operação de 343 kPa.....	81

LISTA DE TABELAS

Tabela 1 - Classificação dos valores do desempenho de sistemas de irrigação por aspersão	22
Tabela 2 - Quantidade de neurônios por camada oculta	40
Tabela 3 - Especificações técnicas do aspersor Fabrimar modelo Pingo giro completo 360 graus	53
Tabela 4 – Classificação dos quinze menores resultados de erro SSE obtidos para as redes neurais com uma, duas, três e quatro camadas ocultas	65
Tabela 5 - Classificação do erro SSE por quantidade de neurônios para topologias de rede neural com uma camada oculta	67
Tabela 6 - Testes de aderência à distribuição normal para os conjuntos de dados de teste de precipitação	69
Tabela 7 - Testes de homocedasticidade e semelhança de população entre os dados observados e simulados pelo modelo RNA	70
Tabela 8 - Valores do coeficiente de correlação de Spearman, r_s , entre os valores de precipitação observados e simulados pela rede neural para dez diferentes ensaios de teste realizados com duração de duas horas.	76
Tabela 9 - Perfil de distribuição do aspersor calculado para dados observados e simulados pela RNA para dez ensaios do conjunto de testes da RNA	78
Tabela 10 - Valores do coeficiente de determinação R^2 para a correlação linear entre o perfil de distribuição para os valores de precipitação observados e os valores de precipitação simulados pela rede neural para dez diferentes ensaios de teste realizados com duração de duas horas	82
Tabela 11 - Valores observados e simulados dos coeficientes de uniformidade de precipitação do aspersor para os dez ensaios de validação do modelo de RNA.....	84
Tabela 12 - Valores dos erros entre os coeficientes de uniformidade de precipitação do aspersor observados e os simulados, para os dez ensaios de validação do modelo de RNA.....	85

LISTA DE SIGLAS

ABNT	-	Associação Brasileira de Normas Técnicas
ADALINE	-	<i>Adaptative Linear Neuron</i>
ASAE	-	<i>American Society of Agricultural Engineers</i>
CUC	-	Coeficiente de Uniformidade de Christiansen
CUD	-	Coeficiente de Uniformidade de Distribuição
CUE	-	Coeficiente de Uniformidade Estatístico
IA	-	Inteligência Artificial
IC	-	Inteligência Computacional
ISS	-	<i>Integrated Sensor Suite</i>
MLP	-	<i>Multilayer Perceptron</i>
NBR	-	Norma Brasileira Regulamentadora
PMC	-	Perceptron de Múltiplas Camadas
RNA	-	Redes Neurais Artificiais
SNNS	-	<i>Stuttgart Neural Network Simulator</i>
SSE	-	<i>Sum of Squared Errors</i>

SUMÁRIO

RESUMO	vi
ABSTRACT	vii
LISTA DE FIGURAS	viii
LISTA DE TABELAS	x
LISTA DE SIGLAS	xi
1 INTRODUÇÃO	15
1.1 OBJETIVOS	18
1.1.1 Objetivo Geral.....	18
1.1.2 Objetivos específicos.....	18
2 REVISÃO BIBLIOGRÁFICA.....	19
2.1 Irrigação por aspersão	19
2.1.1 Uniformidade de distribuição de água dos aspersores	19
Coeficiente de Christiansen (CUC).....	20
Coeficiente de Uniformidade de Distribuição (CUD).....	21
Coeficiente de Uniformidade Estatístico (CUE)	21
2.1.2 Fatores que afetam a distribuição de água dos aspersores	23
Pressão de operação	23
Espaçamento e distribuição dos aspersores.....	23
Velocidade do vento.....	24
Altura do aspersor	25
2.2 Redes Neurais Artificiais (RNA)	25
2.2.1 O Neurônio Natural	27
2.2.2 O Neurônio Artificial	28
2.2.3 Tipos de Função de Ativação	31
2.2.4 Perceptron de Múltiplas Camadas (PMC).....	33
2.2.5 Treinamento, Aprendizado e Validação.....	35

2.2.6	Reconhecimento de Padrões.....	36
2.2.7	SNNS – Stuttgart Neural Network simulator	36
2.2.8	O programa Batchman	37
3	MATERIAL E MÉTODOS	39
3.1	Desenvolvimento do modelo de Rede Neural Artificial (RNA)	39
3.1.1	Algoritmo de Treinamento Backpropagation.....	41
3.1.2	Validação Cruzada	50
3.2	Localização do experimento.....	51
3.3	Materiais de ensaio.....	52
3.3.1	Aspersor	52
3.3.2	Pluviômetros, Hastes e Provetas	54
3.3.3	Estação agrometeorológica.....	55
3.4	Procedimento experimental.....	55
3.5	Criação, treinamento e validação da Rede Neural	57
3.5.1	Normalização dos dados.....	57
3.5.2	Construção do conjunto de dados de treinamento.....	59
3.5.3	Construção do programa computacional de criação e treinamento da RNA.....	60
3.5.4	Treinamento da Rede Neural.....	61
3.5.5	Software ASPERSOFT para cálculo de parâmetros de eficiência de Irrigação ..	63
4	RESULTADOS E DISCUSSÃO	65
4.1	A rede de melhor desempenho	65
4.2	Validação do modelo RNA	68
4.2.1	Análise e inferências sobre a distribuição dos dados de precipitação	68
4.2.2	Desempenho do modelo RNA na predição da distribuição das amostras de dados 69	
4.2.3	Desempenho do modelo RNA na simulação da precipitação do aspersor	70
4.2.4	Comparativo do perfil de distribuição do aspersor.....	76
4.2.5	Comparativo dos coeficientes de uniformidade	83
5	CONCLUSÕES.....	86

5.1	Sugestões para trabalhos futuros	87
6	REFERÊNCIAS BIBLIOGRÁFICAS	88

1 INTRODUÇÃO

Para assegurar e melhorar a produtividade das culturas tem-se utilizado a técnica da irrigação como complemento ou em substituição às precipitações naturais, de forma a garantir que suas necessidades hídricas sejam atendidas.

Muita tecnologia e ciência também são utilizadas para determinar o momento correto e a quantidade de água a ser aplicada a fim de suprir as necessidades hídricas das culturas na busca de elevados níveis de eficiência.

Entre os sistemas de irrigação existentes, a irrigação por aspersão é uma das mais empregadas por se adequar às diversidades de solo, topografia, cultura e ao tamanho de área de irrigação possibilitando, deste modo, um bom controle da lâmina de água aplicada e, portanto, da sua eficiência .

A uniformidade de aplicação da água é um dos parâmetros básicos no manejo da irrigação e resulta do desempenho do aspersor e do seu arranjo no campo podendo assumir diversas combinações de espaçamento ao longo da linha lateral e entre as linhas laterais. Para efeito da uniformidade deve-se considerar a sobreposição das precipitações sobre a área irrigada entre quatro aspersores considerando-se todos os aspersores periféricos passíveis de atingir a área e calcular a uniformidade com os totais sobrepostos em cada coletor. O CUC (Coeficiente de Uniformidade de Christiansen) é um parâmetro bastante utilizado para determinar a uniformidade de aplicação de água do sistema de irrigação.

Para reduzir custos, desperdício de água e o tempo empregado na avaliação dos sistemas de irrigação por aspersão pode-se fazer uso da simulação, quando então é possível estimar, com boa precisão, o comportamento e os resultados da irrigação, através do uso de programas computacionais os quais podem, a partir de um conjunto de

dados de campo, conhecido, fazer uma projeção dos dados para todo o sistema e em diversas configurações.

No contexto das simulações pode-se aplicar as Redes Neurais Artificiais (RNA) que são modelos computacionais inspirados na estrutura neural de organismos inteligentes e que adquirem conhecimento através da experiência. Uma RNA possui um grande número de elementos de processamento bem simples, inspirados no funcionamento de um neurônio do cérebro humano, além de grande quantidade de conexões entre esses elementos de processamento. A propriedade mais importante da RNA é a habilidade de aprender através de exemplos ajustando os pesos das conexões entre os neurônios chegando à condição de aprendizado quando ela consegue generalizar e dar uma resposta baseada na experiência adquirida.

Várias são as áreas de aplicação das técnicas de inteligência artificial como no sensoramento de oxigênio em veículos bicomustíveis (RICHTER, 2009), e especificamente no setor agropecuário, na caracterização de leite (NAZARIO, 2007), erosividade da chuva (MOREIRA et al., 2006), ou, ainda, classificação de soja e identificação quanto à região de plantio (GALÃO et al., 2012).

Com base no levantamento bibliográfico realizado, percebeu-se que obter os valores de precipitação de um aspersor e seu perfil de distribuição é de fundamental importância para o cálculo dos coeficientes de uniformidade, eficiência e para o correto dimensionamento do sistema de irrigação. Uma ferramenta relevante nesses estudos são os simuladores, e dentre as técnicas e modelos até o momento empregados observou-se na literatura que pouco se explorou sobre o uso de modelos de redes neurais artificiais (RNA's) na simulação da precipitação de aspersores.

Assim, o presente trabalho propôs o desenvolvimento e a utilização de um modelo de redes neurais do tipo *Perceptron de Múltiplas Camadas* (MLP, *Multilayer Perceptron*) para a simulação das lâminas precipitadas por um aspersor.

1.1 OBJETIVOS

1.1.1 Objetivo Geral

O objetivo deste trabalho foi desenvolver um modelo de redes neurais artificiais para simular a precipitação de água de aspersores aplicado na irrigação por aspersão.

1.1.2 Objetivos específicos

- Treinar e validar uma rede neural, a partir de dados observados em campo, para que esta seja capaz de simular os valores de precipitação de um aspersor.

- Fazer um comparativo entre o perfil de distribuição do aspersor para os dados observados em campo e os dados simulados pelo modelo de redes neurais.

2 REVISÃO BIBLIOGRÁFICA

2.1 Irrigação por aspersão

Na irrigação por aspersão a água é aplicada ao solo por meio de uma chuva artificial produzida pela pulverização de um jato d'água obtido pelo fluxo d'água sob pressão, através de bocais ou orifícios. Comumente, a pressão é obtida por bombeamento da água, que é assim conduzida até as estruturas de fragmentação do jato, denominadas aspersores.

Segundo Cardoso Neto (1999), este método permite o controle completo da lâmina d'água aplicada e, possibilita uma adaptação quase perfeita em praticamente toda situação possível. A flexibilidade do equipamento de aspersão faz com que tal método se adapte bem a qualquer situação topográfica sem a necessidade de grande sistematização do terreno. Como os aspersores apresentam enorme variedade de capacidade de descarga o método é aplicável a praticamente qualquer tipo de solo e cultura, tendo quase que apenas o fator econômico, como fator limitante.

2.1.1 Uniformidade de distribuição de água dos aspersores

Para se determinar a uniformidade de distribuição de água de um sistema de irrigação por aspersão é necessário que se faça a medição das precipitações geradas pelo sistema de aspersão nos pluviômetros. Conhecendo essas precipitações, pode-se calcular a uniformidade de distribuição do sistema obtendo-se um coeficiente que possa expressar a variabilidade da lâmina aplicada na superfície do solo.

Segundo Bernardo et al. (2006) os três coeficientes mais utilizados para expressar a uniformidade de aplicação de um sistema de irrigação por aspersão são o coeficiente de Christiansen, o coeficiente de uniformidade de distribuição e o coeficiente estatístico de uniformidade.

Coeficiente de Christiansen (CUC)

Proposto por J.E Christiansen, o Coeficiente de Uniformidade de Christiansen (CUC) é o mais conhecido e amplamente utilizado, apresenta uma equação que adota o desvio padrão médio permitindo a obtenção de resultados bastante confiáveis, porém ele requer a medição da precipitação em todos os pluviômetros do sistema de irrigação, o que demanda muito tempo e mão-de-obra.

O coeficiente de uniformidade de Christiansen pode ser calculado pela Equação 1:

$$CUC = \left(1 - \frac{\sum_{i=1}^N |L_i - L_m|}{N \cdot L_m} \right) \cdot 100 \quad (1)$$

Onde:

CUC - coeficiente de uniformidade de Christiansen, %;

L_i - lâmina aplicada i-ésimo coletor, mm;

L_m - lâmina média aplicada, mm ; e

N - quantidade de coletores.

Coefficiente de Uniformidade de Distribuição (CUD)

Criddle et al. (1956) introduziram outra medida da uniformidade considerando a razão entre a média do menor quartil e a lâmina média coletada, que foi denominado Coeficiente de Uniformidade de Distribuição (CUD) sendo este o coeficiente recomendado pelo serviço de Conservação do Solo dos Estados Unidos e é calculado pela Equação 2 :

$$CUD = \frac{l_q}{L_m} \cdot 100 \quad (2)$$

Onde:

l_q - média do menor quartil entre as lâminas coletadas, mm ;

L_m - lâmina média aplicada, mm.

Coefficiente de Uniformidade Estatístico (CUE)

Wilcox & Swailes (1947) propuseram um coeficiente de uniformidade utilizando o desvio-padrão como medida de dispersão:

$$CUE = 100 \cdot \left(1,0 - \sqrt{\frac{\sum_{i=1}^N (L_i - L_m)^2}{(n-1) \cdot L_m^2}} \right) = 100 \cdot \left[1 - \frac{S}{L_m} \right] = 100 - CV \quad (3)$$

Onde:

CUE - coeficiente estatístico de uniformidade, %

S - desvio-padrão das lâminas coletadas, mm

L_i - lâmina aplicada no i-ésimo coletor, mm

L_m - lâmina média aplicada, mm

n - número de coletores, e

CV - coeficiente de variação.

Os valores de desempenho de um sistema de irrigação por aspersão considerados ótimos ou ruins podem variar; Mantovani (2001) apresenta, na Tabela 1, uma classificação para os coeficientes, ao estipular faixas de valores percentuais que representam bom desempenho assim como faixas que representam desempenho razoável ou ruim para sistemas de irrigação por aspersão.

Tabela 1 - Classificação dos valores do desempenho de sistemas de irrigação por aspersão

Classificação	CUC (%)	CUE(%)	CUD(%)
Excelente	> 90	90-100	>84
Bom	80-90	80-90	68-84
Razoável	70-80	70-80	52-68
Ruim	60-70	60-70	36-52
Inaceitável	< 60	<60	<36

Fonte: Mantovani (2001)

2.1.2 Fatores que afetam a distribuição de água dos aspersores

Vários são os fatores passíveis de afetar a distribuição de água dos aspersores, entre os quais podem ser citados a pressão de operação, espaçamento e distribuição dos aspersores no campo, velocidade do vento e altura do aspersor.

Pressão de operação

Segundo Bernardo et al. (2006), pressões muito elevadas nos bocais resultam em excessiva pulverização do jato, diminuindo o alcance e causando um excesso de aplicação de água próximo ao aspersor. Uma pulverização excessiva também ocasiona um aumento na influência do vento sobre a distribuição de água. Em geral, pressões elevadas reduzem a velocidade de rotação do aspersor em relação à pressão normal de operação.

Por outro lado, a operação com pressão muito reduzida pode resultar na pulverização inadequada do jato, proporcionando aumento de precipitação na faixa perimetral da área de influência do aspersor e, hipoteticamente, resultar em menores coeficientes de uniformidade.

Espaçamento e distribuição dos aspersores

Conforme Bernardo et al. (2006) para se obter um índice de uniformidade de distribuição de água satisfatório deve haver sobreposição suficiente dos perfis de distribuição de água dos aspersores adjacentes. O grau de sobreposição depende das características do perfil de distribuição que, por sua vez, são função principalmente das

características dimensionais e operacionais do aspersor e condições de vento. A redução do espaçamento entre aspersores, comumente, aumenta os custos dos sistemas de irrigação enquanto o aumento do espaçamento para além dos espaçamentos recomendados pode levar a uma redução da uniformidade de distribuição. Em geral se utiliza no campo uma distribuição dos aspersores na forma retangular, quadrangular ou triangular.

Velocidade do vento

A velocidade do vento exerce grande influência na distribuição de água dos aspersores. Em condições de vento a superfície de precipitação sofre um desvio na forma, alongando-se na direção da ação do vento. A grandeza da distorção no perfil de distribuição é função da velocidade do vento e do diâmetro das gotas. Velocidades mais elevadas e gotas de menores dimensões favorecem a distorção do perfil, resultando em menor uniformidade.

Bernardo et al. (2006) observa que, quanto maior o período de operação dos aspersores melhor deverá ser a uniformidade de distribuição, assim como a utilização de aspersores com intensidade de aplicação reduzida deve favorecer a uniformidade de distribuição de água. Com a redução do espaçamento entre os aspersores na linha lateral e entre as linhas laterais pode haver uma compensação parcial na distorção causada pelo vento.

Dada a complexidade da interação do vento com as demais variáveis do sistema e sua relevância na eficiência dos sistemas de irrigação por aspersão, vários pesquisadores têm abordado a importância das simulações como aquela conduzida por Faria et al. (2012) que buscaram avaliar a aplicabilidade do modelo semiempírico de

Richards & Weatherhead para ensaios operando sobre diferentes condições de vento; e Oliveira et al. (2009) que avaliam a hipótese da existência de uma relação linear entre o raio de alcance de um canhão hidráulico e a velocidade do vento, que é assumida no modelo semiempírico de Richards & Weatherhead, para simulação da distribuição de água de canhões hidráulicos operando sob condições de vento.

Altura do aspersor

A altura da haste do aspersor pode favorecer a uniformidade de distribuição e deve estar adequada à altura das plantas. Em geral, um aumento na altura do aspersor melhora a uniformidade em consequência da eliminação ou redução da turbulência da água.

2.2 Redes Neurais Artificiais (RNA)

A Inteligência Artificial (IA) é uma área de pesquisa da ciência da computação dedicada a elaborar métodos e modelos que possam simular a capacidade dos organismos vivos de raciocinar, perceber, resolver problemas e tomar decisões, ações estas que caracterizam inteligência. Segundo RUSSEL & NORVIG (2004) esta área do conhecimento não apenas tenta entender senão construir entidades inteligentes.

As redes neurais são modelos computacionais inspirados no sistema nervoso dos seres vivos, principalmente o cérebro humano, e são usadas para criar sistemas de inteligência artificial. Segundo Másson (1990) o primeiro modelo formalizado de redes neurais artificiais foi proposto por McCulloch e Pitts, em 1943, criando a estrutura que

abstraía a complexidade da atividade neural e serviu de base para a maioria dos modelos desenvolvidos posteriormente.

Anos mais tarde, em 1958, foi criado o *perceptron*, que consistia em unidades sensoriais conectadas a uma única camada de neurônios de McCulloch e Pitts.

No início dos anos 60 Widrow e Hoff especificam um neurônio artificial tendo como base o modelo de McCulloch e Pitts, o qual foi chamado de ADALINE (*Adaptive Linear Neuron*).

Em 1982 foi apresentado, por John Hopfield, o modelo conexionista e no mesmo ano Kohonen descreveu uma rede neural artificial baseada na auto-organização e nas características de aprendizado adaptativo do cérebro humano.

Hinton e Seynowsky estenderam o modelo Hopfield em 1983; alguns anos mais tarde, Rumelhart et al. (1986a) aperfeiçoaram o *perceptron* criando o algoritmo de treinamento *backpropagation*, que se popularizou e foi aplicado em grande variedade de problemas.

Bufo (2000) define uma rede neural como uma técnica matemática realizada dentro de um fluxograma sequencial de cálculo projetado para obter resultados a partir da entradas de dados, independente da lei que rege esses resultados; desta forma as redes neurais artificiais oferecem recursos mesmo quando outros meios matemáticos podem ser impotentes.

Outra definição dada por Haykin (2001) é de que a RNA é um processador maciçamente e paralelamente distribuído constituído de unidades de processamento simples que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para uso.

A ideia do paradigma das redes neurais é construir um modelo formado por um grande número de unidades de processamento muito simples, chamadas neurônios,

possuindo um grande número de conexões entre eles; a transmissão das informações entre os neurônios é feita através de conexões denominadas sinapses ou pesos sinápticos.

A capacidade de aprender através de exemplos e de generalizar a informação aprendida representa, sem dúvida, atrativos importantes para a escolha da rede neural como solução.

2.2.1 O Neurônio Natural

O cérebro humano processa informações através de elementos processadores biológicos que operam em paralelo realizando suas funções de pensar e memorizar. Os neurônios são as células elementares e processadores biológicos do sistema nervoso cerebral. Segundo Kovacs (1996) o neurônio pode aparecer com diferentes formas e tamanhos no cérebro humano; são compostos por dendritos, axônios, sinapses e núcleo ou corpo celular, como ilustrado na Figura 1. A função dos axônios é transmitir as informações entre os neurônios conectados; já os dendritos recebem as informações em forma de sinais elétricos, chamados impulsos nervosos.

O corpo celular é responsável por processar as informações vindas dos dendritos e produzir um potencial de ativação que indicará se o neurônio poderá ou não disparar um impulso elétrico através do seu axônio, ou seja, transmitir ou não o impulso nervoso.

As sinapses são regiões eletroquimicamente ativas, compreendidas entre duas membranas celulares: a pré-sináptica, por onde chegam os estímulos provenientes de outra célula e a membrana pós-sináptica, que é a membrana do dendrito.

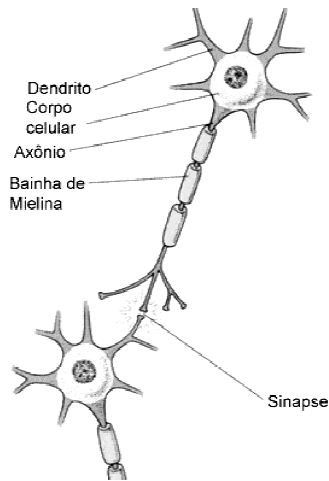


Figura 1 - Neurônio Natural
Fonte: Adaptado de FILOSOFIA À DISTÂNCIA (2007)

Na região intersináptica encontram-se os neurotransmissores; trata-se de uma substância que transfere, para a membrana dendrital, os estímulos nervosos que chegam até a sinapse; o resultado desta transferência é uma alteração no potencial elétrico da membrana pós-sináptica e, dependendo do tipo de neurotransmissor, a conexão sináptica será excitatória ou inibitória sendo que uma conexão excitatória provoca alteração no potencial da membrana que contribui para a formação de um impulso nervoso no axônio de saída, enquanto uma conexão inibitória age no sentido oposto.

2.2.2 O Neurônio Artificial

Na estrutura de uma rede neural artificial o processamento básico da informação ocorre nos neurônios artificiais que são os elementos computacionais ou unidades processadoras fundamentais da estrutura, e que são modelos bem simplificados dos neurônios biológicos (SILVA et al., 2010) .

Os neurônios artificiais utilizados nos modelos de redes neurais artificiais são não-lineares e realizam funções simples: coletar os sinais que chegam em suas entradas; ponderar e somar esses sinais; processá-los de acordo com uma função de ativação e em função desta produzir ou não uma resposta.

A Figura 2 mostra o modelo de neurônio proposto por McCulloch & Pitts (1943), denominado nodo MCP, e seus três elementos básicos: sinapses, função soma e função de ativação.

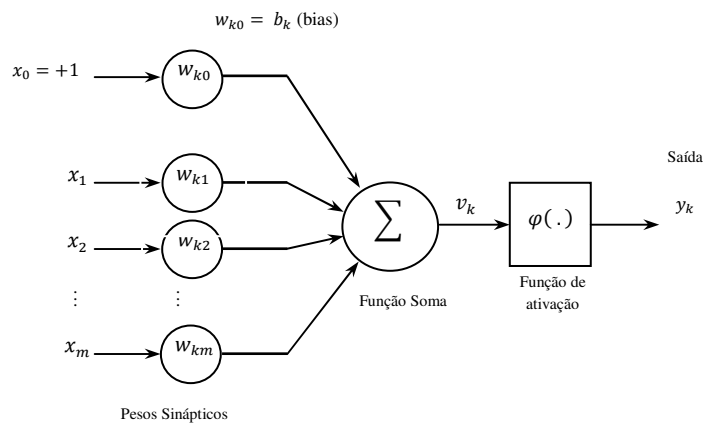


Figura 2 - Modelo não-linear de um neurônio
Fonte: Haykin (2001)

Neste modelo existe um conjunto de sinapses que fazem a ligação entre as entradas $\{x_0, x_1, x_2, \dots, x_m\}$ e o neurônio k . Cada sinapse tem seu próprio peso sináptico w ; deste modo, uma sinapse de maior eficiência, ou seja, que transmite um sinal forte, seria representada pela associação de um peso de maior valor à sua entrada.

Um sinal de entrada x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} . Diferentemente do neurônio biológico, o peso sináptico de um neurônio artificial pode assumir um valor positivo ou negativo. Na primeira etapa do processamento cada entrada é multiplicada pelo peso de sinapse correspondente, gerando entradas ponderadas (HAYKIN, 2001).

O corpo do neurônio se constitui de uma função soma (*combinador linear* Σ), representada pela soma ponderada dos valores recebidos pelo neurônio através das sinapses e somados ao valor do *bias* que é aplicado externamente e tem o efeito de aumentar ou diminuir o valor da saída (u_k) do corpo do neurônio. Este valor gerado no corpo do neurônio (u_k) passa por uma função de ativação $\varphi(\cdot)$, que atua restringindo a amplitude de saída do neurônio e gerando um valor de saída (y_k), valor este que representa o valor líquido de saída do neurônio e será transmitido ao neurônio subsequente simulando o fluxo de impulsos no cérebro.

Em termos matemáticos o neurônio k pode ser descrito pelo seguinte par de equações:

$$v_k = \sum_{j=0}^m w_{kj} \cdot x_j + b_k \quad (4)$$

e,

$$y_k = \varphi(v_k) \quad (5)$$

Onde:

v_k – campo local induzido do neurônio;

y_k – sinal de saída do neurônio k ;

$x_0, x_1, x_2, \dots, x_m$ – sinais de entrada;

$w_{k1}, w_{k2}, w_{k3}, \dots, w_{km}$ – pesos sinápticos do neurônio k ;

b_k – bias aplicado ao neurônio k ;

$\varphi(\cdot)$ – função de ativação.

2.2.3 Tipos de Função de Ativação

A função de ativação $\varphi(v)$ determina o valor de saída do neurônio e podem ser identificados três tipos básicos de função de ativação:

- **Função de Limiar**, ou função degrau, que gera saídas com valores 0 ou 1 e define uma característica de saída “tudo ou nada” para o neurônio e pode ser expressa pela Equação 6 :

$$\varphi(v) = \begin{cases} 0, & \text{se } v < 0; \\ 1, & \text{se } v \geq 0; \end{cases} \quad (6)$$

- **Função Sigmoid**, é a forma mais utilizada de função de ativação de redes neurais artificiais, por exibir um balanceamento adequado entre comportamento linear e não linear. Um exemplo de função sigmoide é a função logística definida por:

$$\varphi(v) = \frac{1}{1+e^{-av}} \quad (7)$$

Na qual a é o parâmetro que define a inclinação da função; ela assume o intervalo contínuo entre 0 e 1 e é diferenciável em todo o seu domínio, apresentando um gráfico como ilustrado na Figura 3:




Figura 3 - Gráfico da função logística

Em alguns casos se deseja que a função de ativação de um neurônio assuma um intervalo maior estendendo-se de -1 a 1, em que se pode utilizar uma função do tipo tangente hiperbólica, definida pela Equação 8:

$$\varphi(v) = \tanh(v) \quad (8)$$

e que apresenta um gráfico com ordenadas de -1 a 1, como ilustrado na Figura 4:




Figura 4 - Gráfico da Tangente Hiperbólica

2.2.4 Perceptron de Múltiplas Camadas (PMC)

Uma típica rede neural é composta por um conjunto de nós que constituem a camada de entrada, uma ou mais camadas ocultas que realizam o processamento e uma camada de saída.

A topologia apresentada na Figura 5 é um exemplo de uma típica rede Perceptron de Múltiplas Camadas (PMC) completamente conectada, ou seja, cada neurônio de uma determinada camada está conectado com todos os neurônios/nós da camada seguinte. O sinal é recebido pelos nós da camada de entrada na forma de estímulos gerados pelo ambiente externo e se propaga ao longo da rede, da esquerda para a direita, até atingir os nós da camada de saída produzindo a resposta da rede. Este fluxo de sinal da esquerda para a direita passando por todas as camadas, leva este tipo de conexão a também ser chamado de *feedforward*.

O processamento realizado por cada neurônio é definido pela combinação dos processamentos realizados pelos neurônios da camada anterior que estão conectados a ele.

Segundo Haykin (2001) as redes PMC são mais poderosas que as redes sem camadas escondidas pois podem tratar dados que não são linearmente separáveis e a precisão da resposta obtida pela rede depende da quantidade de camadas ocultas e da quantidade de neurônios utilizados em cada uma dessas camadas.

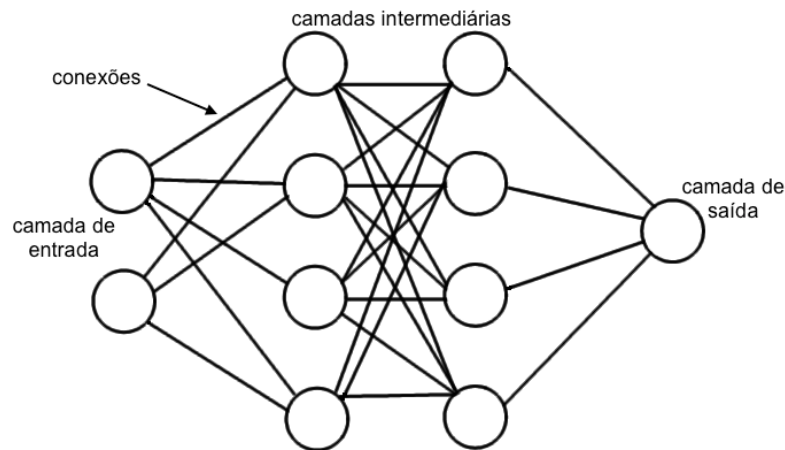


Figura 5 - Perceptron de Múltiplas Camadas

Fonte: Adaptado de redes neurais – Conceito (2012)

As camadas de um *perceptron* podem ser assim descritas:

- **Camada de Entrada:** são os nós por onde os sinais de entrada são apresentados à rede, numa relação de um nó para cada variável de entrada;
- **Camadas Intermediárias ou Ocultas:** onde é feita a maior parte do processamento; através das conexões ponderadas cada nó agrega seu peso ao valor da entrada atribuindo sua importância em relação aos demais nós na resposta final;
- **Camada de Saída:** são os nós nos quais o resultado final é apresentado, na relação de um nó para cada variável resposta.

Através da rede passam dois tipos de sinais, sendo o primeiro chamado sinal função, que é recebido pelos nós da camada de entrada e se propaga ao longo da rede, sendo processado em cada neurônio intermediário na forma de uma função das entradas,

ponderadas pelos pesos a elas associados até que alcancem os nós de saída, produzindo a resposta da rede; o segundo tipo é um sinal de erro originado na camada de saída da rede, contendo uma medida de erro entre o resultado encontrado e o resultado desejado, e que se propaga para trás, no sentido oposto à rede, sendo útil para o algoritmo de aprendizagem.

2.2.5 Treinamento, Aprendizado e Validação

Depois de especificada a arquitetura da rede neural, torna-se necessário definir o algoritmo de treinamento da rede. Basicamente, o treinamento da rede neural consiste em um problema de minimização não linear sem restrições, em que os pesos sinápticos da rede são iterativamente modificados para minimizar o erro médio quadrático entre a resposta desejada e o resultado obtido no neurônio de saída.

As formas de aprendizagem podem ser separadas em dois modelos:

Aprendizado supervisionado: é a forma mais comum de treinamento e é assim denominado pois existe um algoritmo supervisor que dirige o processo de treinamento fornecendo à rede os valores de entrada e a respectiva saída desejada e medindo o valor do erro na resposta da rede. Enquadram-se, neste modelo de aprendizagem, a regra delta e sua generalização em redes de múltiplas camadas usando o algoritmo *backpropagation*.

Aprendizado não supervisionado: assim chamado porque neste modelo não existe a figura do supervisor controlando o processo de aprendizagem e monitorando os erros gerados. Ao contrário do aprendizado supervisionado, onde no treinamento são apresentados pares de entrada e saída, neste modelo apenas os padrões de entrada são apresentados para a rede. Um método bastante popular para este modelo é o

aprendizado Hebbiano, apresentado por Hebb (1949) que propõe o ajuste do peso de uma conexão sináptica baseado no sincronismo entre os níveis de atividades das entradas e saídas. Quando há sincronismo na atividade de dois neurônios conectados por uma sinapse, ocorrerá o fortalecimento desta sinapse, senão esta sinapse será enfraquecida podendo chegar a ser eliminada.

Em todos os casos o critério de parada do treinamento exige considerar a capacidade de generalização da rede. Espera-se que a rede se torne bem treinada de modo que aprenda o suficiente sobre o passado, para generalizar no futuro. Um treinamento prolongado demais pode levar a um indesejável sobreajuste da rede (*overfitting*), especialmente no caso da disponibilidade de poucos pares de entrada e saída para o conjunto de treinamento.

2.2.6 Reconhecimento de Padrões

No reconhecimento de padrões a rede neural utiliza o conjunto de pesos resultantes do treinamento para dar suas respostas. Nesta fase são apresentados, à rede, valores de entrada sem valores de saída associados que deverão ser calculados pela rede. Se o treinamento foi eficiente e o padrão foi aprendido, o valor de saída deverá ser igual ou muito próximo do esperado.

2.2.7 SNNS – Stuttgart Neural Network simulator

Segundo UNIVERSITY OF TÜBINGEN (2013) O SNNS é um software simulador de redes neurais bastante utilizado por pesquisadores e cientistas da

computação, desenvolvido a partir de 1989, no Instituto de Sistemas Paralelos e Distribuídos de Alta Performance da Universidade de Stuttgart, e mantido pela Universidade de Tübingen, da Alemanha. É distribuído como Software Livre e licenciado de maneira semelhante a GNU – General Public License. Tem o seu núcleo simulador escrito na linguagem de programação C e inclui as principais arquiteturas de RNA e algoritmos de aprendizagem os quais podem ter suas funcionalidades estendidas através da criação de novas funções de ativação, de saída e algoritmos de aprendizado personalizados.

O SSNS é composto de quatro componentes principais: núcleo simulador, interface gráfica do usuário, interface *batchman* para execução de comandos em lote e o compilador de redes, chamado *snns2c*.

Embora o SNNS possua uma interface gráfica, às vezes pode ser interessante dispensá-la e fazer uso da sua poderosa interface de modo texto, em que se obtém, a partir da linha de comandos, grande flexibilidade na criação e simulação de RNA's, sendo possível criar arquivos para processamento de comandos em lotes, cuja sequência de comandos do SNNS pode ser armazenada dentro de um arquivo e executados pelo programa chamado *batchman*, automatizando todo o processo ou parte dele, executando uma lógica programada pelo usuário.

2.2.8 O programa Batchman

De acordo com a UNIVERSITY OF TÜBINGEN (2013) o programa *batchman* faz parte do SNNS atuando como interface extra entre o usuário e o núcleo simulador permitindo a execução de tarefas através de scripts criados pelo usuário. A estrutura e os comandos dos scripts são muito similares àqueles observados nas linguagens de

programação tradicionais trabalhando com variáveis que suportam diversos tipos de dados como números inteiros, números reais, valores lógicos verdadeiro ou falso e cadeias de caracteres. Além das variáveis que podem ser criadas pelo usuário existe, no *batchman*, um conjunto de variáveis do próprio sistema que são predefinidas e estão disponíveis para o usuário em tempo de execução e somente para leitura, não podendo ser alteradas; entre elas se destacam a variável que armazena a quantidade de épocas que o algoritmo de treinamento da RNA foi executado, denominada CYCLES, e a variável SSE (*Sum of Squared Error*), que armazena o valor atualizado do erro entre a resposta desejada e a resposta dada pela rede em determinado instante.

O *batchman* possui estruturas de controle condicionais e de repetição que, de maneira análoga às linguagens de programação, permitem criar uma ordem de execução de comandos que serão executados, repetidos ou ignorados até que as variáveis de interesse assumam os valores esperados. Desta forma é possível programar para que o *batchman* crie, treine e teste diversas topologias de rede neural e selecione aquela que melhor satisfaça aos critérios definidos pelo programador que, geralmente, é obter uma rede neural que apresente a resposta mais próxima do esperado e pode ser medido através da variável SSE.

3 MATERIAL E MÉTODOS

3.1 Desenvolvimento do modelo de Rede Neural Artificial (RNA)

A RNA, rede neural artificial implementada foi do tipo Perceptron de Múltiplas Camadas com o algoritmo de treinamento *Backpropagation* o qual, após cada iteração, realimenta os pesos das sinapses para reduzir o valor da função de erro.

Se por um lado é relativamente fácil determinar a quantidade de entradas e saídas de uma rede neural por outro não há como determinar, *a priori*, a quantidade de camadas ocultas e tampouco a quantidade de neurônios em cada camada oculta da rede neural que resolva determinado problema. Desta forma, a escolha de uma rede neural se dá através da criação, treinamento e validação de diversas topologias e da escolha daquela cuja resposta mais se aproxime do valor esperado.

Neste trabalho a quantidade de neurônios da camada de entrada foi fixada em quatro, correspondentes as variáveis de entrada: pressão, diâmetro do bocal, velocidade do vento e sua direção; para a camada de saída foi fixada a quantidade de 256 neurônios, sendo um para cada pluviômetro utilizado no ensaio.

Foram testadas as quantidades de uma, duas, três e quatro camadas ocultas. Para topologia com uma camada oculta foram testadas todas as redes com até 500 neurônios e para as topologias de duas, três e quatro camadas, foram testados pelo menos 10.000 neurônios distribuídos igualmente pelas camadas de cada topologia. A Tabela 2 mostra quantos neurônios foram testados em cada camada de cada topologia, podendo ser observado, por exemplo, que para a topologia com quatro camadas ocultas foram testadas 10^4 combinações, ou seja, 10000 redes.

Tabela 2 - Quantidade de neurônios por camada oculta

Topologia	Quantidade de neurônios por camada oculta				Total de Redes
	Camada 1	Camada 2	Camada 3	Camada 4	
1 camada oculta	500				500
2 camadas ocultas	100	100			10000
3 camadas ocultas	22	22	22		10648
4 camadas ocultas	10	10	10	10	10000
TOTAL GERAL					31148

Fonte: Autoria própria

Observa-se, na Tabela 2, que foi testado o total de 31148 redes neurais candidatas para, dentre elas, se selecionar a de melhor desempenho.

A rede foi escolhida pelo critério da comparação da soma dos erros quadrados (*SSE - Sum of Squared Errors*), ou seja, aquela que apresentou o menor valor SSE foi a selecionada. A quantidade de épocas, que corresponde à quantidade de vezes em que o conjunto completo de treinamento é apresentado à rede, e encerra um ciclo, não foi um parâmetro decisivo para a escolha. Cada vez em que um valor mínimo de erro era determinado para uma rede candidata, o algoritmo de treinamento armazenava os parâmetros da rede, marcava-os como sendo aqueles os parâmetros para os quais a rede apresentava o melhor desempenho e continuava treinando-a por mais 1000 épocas a fim de verificar se ela apresentaria melhor resultado no futuro. Pode-se, então, afirmar que a rede de melhor desempenho não seria melhorada, mesmo que o treinamento continuasse por mais 1000 épocas de treinamento. Para todos os treinamentos o parâmetro taxa de aprendizagem (η) não foi variado sendo adotado o valor predefinido heurísticamente como 0,02 conforme SILVA et al. (2010).

3.1.1 Algoritmo de Treinamento Backpropagation

Vários métodos para treinamento supervisionado de RNA são propostos; entretanto, o algoritmo mais popularmente usado é o algoritmo *backpropagation* (retropropagação).

A aplicação do algoritmo *backpropagation* requer a escolha de um conjunto de parâmetros, tais como número de iterações do algoritmo, critério de parada, pesos iniciais e taxa de aprendizado cuja influência pode ser decisiva para a capacidade de generalização da rede.

Neste algoritmo os pesos iniciais das conexões sinápticas são inicialmente aleatorizados dentro de um intervalo predefinido, sendo o intervalo de $[-1,1]$ amplamente utilizado. Os valores de entrada são apresentados na camada de entrada que os repassa para os neurônios da primeira camada oculta e que, de acordo com os seus pesos, ajustam os valores recebidos e os encaminham para a camada seguinte, até que o valor resposta chegue à camada de saída. De posse do valor desejado e com o valor que chega na camada de saída o algoritmo calcula o valor do erro que servirá de base para a retropropagação em que os pesos das conexões e limiares serão reajustados desde a camada de saída até a camada de entrada, procurando minimizar o erro obtido.

Há dois casos diferentes a serem tratados em relação ao cálculo do erro (e), sendo o primeiro para um neurônio de saída e no segundo caso um neurônio de camada oculta.

Caso 1: O neurônio j é um nó de saída:

De acordo com Haykin (2001) o sinal de erro no neurônio de saída j , na n -ésima iteração, corresponde à análise do n -ésimo par de exemplos (dados de entrada – saída) apresentados à rede e seu valor é a diferença entre a resposta atual $y_j(n)$ e a desejada $d_j(n)$ conforme a equação abaixo:

$$e_j(n) = d_j(n) - y_j(n) \quad (9)$$

O erro calculado em relação a todos os M nós de saída pode ser obtido da seguinte maneira (Equação 10):

$$E(n) = \frac{1}{2} \sum_{j=1}^M e_j^2(n) \quad (10)$$

A função objetivo que se deseja minimizar é dada pela Equação 11.

$$E_{med} = \frac{1}{N} \sum_{n=1}^N E(n) \quad (11)$$

Em que N representa o número total de padrões (exemplos) contidos no conjunto de treinamento.

Considerando a Figura 6, que representa o neurônio j sendo alimentado por um conjunto de sinais produzidos por uma camada de neurônios anterior, sendo cada sinal associado a um peso sináptico $w_{ji}(n)$, o nível de atividade do neurônio j pode ser expresso pela Equação 12.




Figura 6 - Fluxo de sinal do neurônio de saída j
 Fonte: Adaptado de Haykin (2001)

$$v_j(n) = \sum_{i=0}^m w_{ji}(n) \cdot y_i(n) \quad (12)$$

Onde m é a quantidade de entradas aplicadas ao neurônio j e o peso sináptico w_{j0} corresponde ao bias b_j do neurônio.

Desta forma, a resposta produzida pelo neurônio j na iteração n é:

$$y_j(n) = \varphi_j(v_j(n)) \quad (13)$$

Onde φ é uma função contínua e diferenciável como, por exemplo, uma função sigmoideal.

O algoritmo backpropagation se baseia no ajuste dos pesos sinápticos proporcionalmente à redução do erro $E(n)$; assim, de acordo com a regra da cadeia do cálculo, pode-se escrever a Equação 14.

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = \frac{\partial E(n)}{\partial e_j(n)} \frac{\partial e_j(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} \frac{\partial v_j(n)}{\partial w_{ji}(n)} \quad (14)$$

Diferenciando a Equação 14 em relação a $e_j(n)$, tem-se:

$$\frac{\partial E(n)}{\partial e_j(n)} = e_j(n) \quad (15)$$

Diferenciando a Equação 15 em relação a $y_j(n)$, obtém-se:

$$\frac{\partial e_j(n)}{\partial y_j(n)} = -1 \quad (16)$$

A seguir tem-se, diferenciando a Equação 16, em relação a $v_j(n)$:

$$\frac{\partial y_j(n)}{\partial v_j(n)} = \varphi'_j(v_j(n)) \quad (17)$$

Finalmente, diferenciando a Equação 12 em relação a $w_{ji}(n)$, tem-se:

$$\frac{\partial v_j(n)}{\partial w_{ji}(n)} = y_i(n) \quad (18)$$

Fazendo a substituição das Equações de 15 a 18 na Equação 14:

$$\frac{\partial E(n)}{\partial w_{ji}(n)} = -e_j(n) \varphi'_j(v_j(n)) y_j(n) \quad (19)$$

A correção dos pesos sinápticos, Δw_{ji} é definida pela regra delta, como:

$$\Delta w_{ji}(n) = -\eta \frac{\partial E(n)}{\partial w_{ji}(n)} \quad (20)$$

Onde η é a taxa de aprendizagem e o uso do sinal negativo se deve ao fato do aprendizado ser efetuado no sentido do decréscimo do gradiente de erro.

Substituindo a Equação 19 na Equação 20, tem-se:

$$\Delta w_{ji}(n) = \eta \delta_j(n) y_i(n) \quad (21)$$

A Equação 21 é conhecida como regra delta e nela o gradiente local $\delta_j(n)$ é definido por:

$$\delta_j(n) = \frac{\partial E(n)}{\partial v_j(n)} = e_j(n) \varphi'_j(v_j(n)) \quad (22)$$

Nota-se que o fator-chave para o cálculo do ajuste de pesos $\Delta w_{ji}(n)$ é o sinal de erro $e_j(n)$ caso em que, como ele é um neurônio de saída, o cálculo é fácil, pois a resposta desejada é conhecida.

Caso 2: O neurônio j é um nó de saída:

Segundo Haykin (2001) quando o neurônio em questão é de uma camada oculta, não há uma resposta desejada especificada para ele e o erro deve ser calculado a partir de sinais vindos de todos os neurônios da camada seguinte, que estão conectados a ele. Neste caso, para o neurônio oculto j, pode-se redefinir o gradiente local $\delta_j(n)$ a partir da Equação 22; substituindo nela a Equação 17, tem-se:

$$\delta_j(n) = -\frac{\partial E(n)}{\partial y_j(n)} \frac{\partial y_j(n)}{\partial v_j(n)} = -\frac{\partial E(n)}{\partial y_j(n)} \varphi'_j(v_j(n)) \quad (23)$$

A Figura 7 mostra o cenário no qual está o neurônio oculto j em relação a um neurônio k pertencente à camada de saída; neste caso pode-se proceder ao cálculo do erro, segundo a Equação 24 :




Figura 7 - Fluxo de sinal do neurônio de saída k conectado ao neurônio oculto j
 Fonte: Adaptado de Haykin (2001)

$$E(n) = \frac{1}{2} \sum_k e_k^2(n) \quad (24)$$

Diferenciando a Equação 24 em relação ao sinal $y_j(n)$ tem-se:

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k \frac{\partial e_k(n)}{\partial y_j(n)} \quad (25)$$

Aplica-se, a seguir, a regra de cadeias na Equação 25:

$$\frac{\partial E(n)}{\partial y_j(n)} = \sum_k e_k(n) \frac{\partial e_k(n)}{\partial v_k(n)} \frac{\partial v_k(n)}{\partial y_j(n)} \quad (26)$$

Já que o neurônio k está na última camada, seu valor de erro pode ser calculado como base na resposta desejada; então:

$$e_k(n) = d_k(n) - y_k(n) = d_k(n) - \varphi_k(v_k(n)) \quad (27)$$

Diferenciando a Equação 27 em relação a $v_k(n)$:

$$\frac{\partial e_k(n)}{\partial v_k(n)} = -\varphi'_k(v_k(n)) \quad (28)$$

Pela Figura 7 nota-se que o campo local induzido para o neurônio k é:

$$v_k(n) = \sum_{j=0}^m w_{kj}(n)y_j(n) \quad (29)$$

sendo m o total de entradas aplicadas ao neurônio k exceto o bias.

Diferenciando a Equação 29 em relação a $y_j(n)$ obtém-se:

$$\frac{\partial v_k(n)}{\partial y_j(n)} = w_{kj}(n) \quad (30)$$

Utilizando as Equações de 28 a 30 na Equação 26, obtém-se a derivada parcial desejada:

$$\frac{\partial E(n)}{\partial y_j(n)} = - \sum_k e_k(n) \varphi'_k(v_k(n)) w_{kj}(n) = - \sum_k \delta_k(n) w_{kj}(n) \quad (31)$$

Finalmente, a fórmula de retropropagação é obtida aplicando-se a Equação 31 na Equação 23, e é definida por:

$$\delta_j(n) = \varphi'_j(v_j(n)) \sum_k \delta_k(n) w_{kj}(n) \quad (32)$$

A parcela $\varphi'_j(v_j(n))$ do cálculo do gradiente local $\delta_j(n)$ presente na Equação 32 depende apenas da função de ativação associada ao neurônio oculto j , enquanto o somatório sobre k (neurônio de saída) é feito sobre dois conjuntos de termos: o termo $\delta_k(n)w_{kj}$ em função dos sinais de erro $e_k(n)$ de todos os neurônios da camada à direita do neurônio j que estão diretamente conectados a ele e o termo $w_{kj}(n)$, ou seja, os pesos sinápticos dessas conexões.

Ainda segundo Haykin (2001) a taxa de aprendizagem (η) presente na Equação 20 regula as variações dos pesos sinápticos da rede entre as iterações. Quanto menor for este parâmetro menores também serão as variações dos pesos sinápticos e mais suave será a trajetória do modelo rumo à minimização do erro porém mais lento será o processo de treinamento da rede. Aumentando a taxa de aprendizagem para valores muito altos, visando acelerar o treinamento, as modificações nos pesos da rede serão

grandes e existe um grande risco da rede se tornar instável. Um valor de referência para a taxa de aprendizagem é 0,02 (SILVA et al., 2010).

Para aumentar a taxa de aprendizagem evitando o risco de instabilidade, RUMELHART et al. (1986) mostraram a inclusão de uma constante de momento (α) na regra delta da Equação 21; a equação resultante, chamada *Regra Delta Generalizada*, é mostrada na Equação 33.

$$\Delta w_{ji}(n) = \alpha \Delta w_{ji}(n - 1) + \eta \delta_j(n) y_i(n) \quad (33)$$

3.1.2 Validação Cruzada

O processo de aprendizagem de uma rede neural se resume a uma escolha de pesos e limiares em que para cada par de entrada e saída que lhe for apresentado durante o treinamento, gere a resposta o mais próximo possível da resposta desejada. Existirão, sem dúvida, diversas topologias de rede possíveis e dentre elas deverá ser selecionada a melhor, de acordo com certo critério.

Uma ferramenta bastante conhecida e muito utilizada como critério para selecionar a “melhor” rede, é a validação cruzada que consiste em dividir aleatoriamente o conjunto de dados em um conjunto de treinamento e em um conjunto de teste. O conjunto de treinamento é então dividido em dois subconjuntos:

- Subconjunto de estimação: usado para selecionar o modelo;
- Subconjunto de validação: usado para testar ou validar o modelo.

Os dois subconjuntos são utilizados pelo algoritmo de treinamento, em que, a cada iteração de ajuste dos pesos sinápticos e limiares, denominado *época* de treinamento, utiliza o subconjunto de dados de validação para medir, naquela iteração, a

diferença ou erro entre a resposta da rede e a resposta desejada. Com base nesta medição de erro o algoritmo decide se interrompe o treinamento ou lhe dá sequência em busca de um resultado melhor.

Após o treinamento da rede, e já com os pesos sinápticos e limiares ajustados na fase de treinamento, torna-se necessário avaliar se a rede selecionada não está excessivamente ajustada ao conjunto de treinamento (subconjunto de estimação e subconjunto de validação) o que é feito com o conjunto de testes, que consiste da porção de dados que não foram utilizados no treinamento da rede e serve para avaliar se a rede não foi excessivamente treinada e se ela é capaz de gerar respostas satisfatórias para dados de entrada até então por ela desconhecidos. Assim, através do conjunto de testes é possível avaliar se a rede possui bom grau de generalização.

3.2 Localização do experimento

A pesquisa foi desenvolvida no município de Medianeira localizado na região Oeste do Estado do Paraná, cuja economia se baseia na agropecuária, indústria e serviços. A área do município tem 328,733 km² e altitude em relação ao nível do mar, de 402 m. O índice pluviométrico do município é de 1880 mm ano⁻¹. O clima predominante é classificado como subtropical úmido (Classificação climática de Köppen-Geiger: Cfa) com verões quentes e temperatura média anual de 21 °C .

O experimento foi instalado em uma propriedade rural, localizada a 12 km do centro urbano, na linha Ouro Verde, nas coordenadas geográficas Latitude 25°12'19.26"S, Longitude 54°3'27.93"O e altitude de 360 m.

3.3 Materiais de ensaio

3.3.1 Aspersor

Utilizou-se um aspersor da marca Fabrimar, modelo Pingo (Figura 8), que trabalha nas pressões recomendadas pelo fabricante de 196; 245; 294 e 343 kPa e vazões que variam de 0,38 a 1,86 m³ h⁻¹ ajustadas por nove combinações de bocais com diâmetros de: 2,4; 2,6; 2,8; 3,0; 3,2; 3,4; 3,6; 3,8 e 4,0 mm identificados por cores. O diâmetro irrigado do aspersor varia de 20 a 24 m, segundo dados do fabricante.



Figura 8 - Aspersor Fabrimar Modelo Pingo

Fonte: FABRIMAR IRRIGAÇÃO (2012)

A Tabela 3 mostra as possíveis configurações de diâmetro do bocal, pressão, vazão, diâmetro irrigado e espaçamentos recomendados para o aspersor utilizado na realização do experimento deste trabalho.

Tabela 3 - Especificações técnicas do aspersor Fabrimar modelo Pingo giro completo 360 graus

	Pressão na base (mca)	Vazão total m ³ h ⁻¹	Diâmetro irrigado (m)	Espaçamento máx. recomendado	
				Aspersor x Linha (m x m)	Intensidade de Precipitação (mm h ⁻¹)
Combinação de bocais (mm x mm)	2,6	0,70	20,0	12x12	4,9
	X	0,77	20,0	12x12	5,3
	2,4	0,84	20,5	12x15	5,8
		0,90	21,0	15x15	6,3
	2,8	0,76	20,0	12x12	5,3
	X	0,85	20,5	12x12	5,9
	2,4	0,94	21,0	12x15	6,5
		1,01	21,5	15x15	7,0
	3,0	0,89	20,5	12x12	6,2
	X	1,00	21,0	12x15	6,9
	2,6	1,10	21,5	15x15	6,1
		1,17	22,0	15x15	6,5
	3,2	0,96	21,0	12x12	6,7
	x	1,07	21,5	12x15	7,5
	2,6	1,18	22,0	15x15	6,6
		1,27	22,5	15x15	7,1
	3,4	1,05	22,0	12x12	7,3
	X	1,17	22,5	12x15	6,5
	2,6	1,25	23,0	15x15	7,0
		1,34	23,5	15x15	5,9
	3,6	1,17	22,0	12x15	6,5
	X	1,30	22,5	12x15	7,2
	2,8	1,41	23,0	15x15	7,9
		1,51	23,5	15x15	6,7
	3,8	1,26	22,0	12x15	7,0
	x	1,39	22,5	15x15	7,7
	2,8	1,51	23,0	15x15	6,7
		1,64	23,5	15x15	7,3
4,0	1,31	22,5	12x15	7,3	
X	1,46	23,0	15x15	6,5	
2,8	1,59	23,5	15x15	7,1	
	1,70	24,0	15x15	7,6	
4,0	1,44	22,5	12x15	8,0	
X	1,58	23,0	15x15	7,0	
3,2	1,73	23,5	15x15	7,7	
	1,86	24,0	15x15	8,3	

Fonte: FABRIMAR – IRRIGAÇÃO (2012)

3.3.2 Pluviômetros, Hastes e Provetas

Foram utilizados dois kits de ensaio de precipitação, ilustrados na Figura 9, destinados aos ensaios de uniformidade de distribuição de água em sistemas de irrigação por aspersão que, em conjunto, compunham:

- Coletores: conjunto de 300 pluviômetros confeccionados em plástico de engenharia para a coleta da água;
- Provetas: conjunto de 10 provetas confeccionadas em termoplástico transparente, estabilizado, graduadas em milímetros. Específica para área da boca do coletor para a leitura direta em milímetros de lâmina de água. Escala de 0,5 mm;
- Hastes: dois estojos confeccionados em lona plástica com alça e protetor no fundo, contendo 300 hastes de alumínio estrutural (varetas cilíndricas) para fixar no solo e sustentar, por encaixe, os coletores, a fim de mantê-los a aproximadamente 0,70 m de altura do solo.



Figura 9 - Kit de ensaio de precipitação
Fonte: FABRIMAR IRRIGAÇÃO (2012)

3.3.3 Estação agrometeorológica

Para a coleta de dados de velocidade e direção do vento foi utilizada a estação agrometeorológica Davis VantageVue, equipada com datalogger e um conjunto de sensores integrados (*ISS - Integrated Sensor Suite*) composto de coletor de chuva, sensores de temperatura interna e externa, sensores de umidade e anemômetro. A estação tem a capacidade de trabalhar alimentada por energia elétrica e, na sua falta, por baterias, e armazena os dados em uma frequência configurada na sua console de monitoramento e configuração. Neste trabalho foi utilizada a configuração que registra os dados meteorológicos periodicamente em intervalos de 5 minutos.

3.4 Procedimento experimental

O aspersor foi instalado a 1,25 m da superfície do solo com o bocal de saída de água a uma distância vertical de 0,60 m dos coletores, conforme recomendações da ABNT (1999).

A pressão de operação para cada teste foi controlada utilizando-se um manômetro do tipo bourdon, tipo vertical com glicerina e escala de pressão até 10 kgf cm⁻² (981 kPa), acoplado na base do aspersor e outro com escala de pressão de até 7 kgf cm⁻² (686 kPa) na entrada da linha principal em que a regulagem da pressão era controlada através de registro de gaveta. Adicionalmente foi instalado um hidrômetro junto à entrada da linha principal para medição do volume de água aplicada durante cada ensaio, e, conseqüentemente a determinação da vazão.

O total de 256 pluviômetros foi instalado a partir do centro da área irrigada, conforme a Figura 10, seguindo espaçamentos regulares de 1,5 x 1,5 m nas duas direções coordenadas; a área de irrigação destinada ao aspersor foi de 24 x 24 m.

A velocidade e a direção do vento foram registradas automaticamente pela estação agrometeorológica em intervalos regulares de 5 minutos, estando a mesma localizada a 2 m de altura em relação ao solo e a uma distância de 25 m da área de irrigação. Os dados foram registrados em planilhas, na forma de uma matriz, denominada “A”, com tamanho 16 x 16. Na Figura 10 pode-se observar o sistema de coordenadas (X,Y) adotado nos ensaios, e a notação do registro do ângulo Φ , que descreve a direção predominante do vento em relação às linhas de coletores de água utilizados nos ensaios de campo.

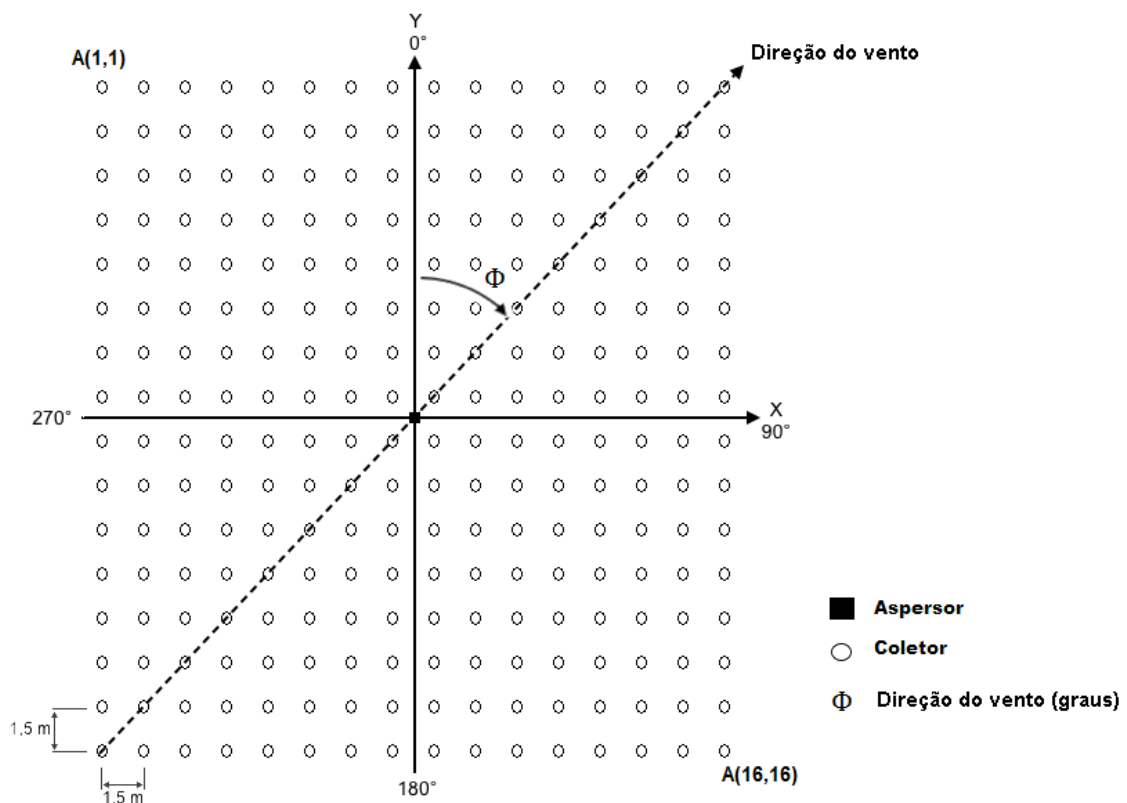


Figura 10 - Esquema da malha de coletores e a direção do vento
 Fonte: Autoria própria

Foram realizados 108 ensaios, cada um com duração de duas horas em operação e aproximadamente 50 minutos para coleta e registro dos dados na planilha e preparação do ambiente para o próximo ensaio.

Os parâmetros de cada ensaio foram definidos de forma a abranger todas as combinações especificadas no catálogo do fabricante (Tabela 3). Foram testadas as nove combinações de bocais nas quatro pressões sugeridas (196; 245; 294 e 343 kPa). Uma vez que a quantidade de amostras necessárias para o treinamento de uma rede neural é desconhecida e que quanto maior a quantidade delas há uma possibilidade maior de sucesso no treinamento da rede, optou-se por executar três ensaios para cada combinação não se tratando, entretanto, de três repetições, visto que as variáveis direção e velocidade do vento variavam em todos os ensaios; assim, totalizaram 108 ensaios.

Os ensaios foram realizados nas condições naturais de velocidade e direção do vento, evitando-se as velocidades acima de 2 m s^{-1} .

A rotina de ensaio permitia realizar três ensaios por dia, com início às 08:00 horas e encerramento às 18:00 horas.

3.5 Criação, treinamento e validação da Rede Neural

3.5.1 Normalização dos dados

Como as amplitudes das variáveis de entrada e saída da rede neural podem ser bastante diferentes, é imprescindível que se faça um tratamento prévio sobre esses dados, a fim de normalizá-los a uma mesma amplitude antes de processá-los com a rede neural. Desta forma, e quando em escalas diferentes, o valor de uma determinada variável não será mais significativa do que outra, quando processada. Sem este pré-

processamento ocorrerá que uma variável, tomando-se por exemplo a direção predominante do vento, que assume valores de 0 a 360°, torne-se mais significativa e afete com maior importância o resultado, que uma variável que assuma valores no intervalo entre 0 e 15 mm, por exemplo, dos volumes de precipitação.

Adota-se, como prática comum, a normalização linear, expressa pela Equação 34, em que todos os dados serão tratados de forma que fiquem dentro de um intervalo $[y_{min}; y_{max}]$.

$$f(x) = y = (y_{max} - y_{min}) \cdot \frac{(x - x_{min})}{x_{max} - x_{min}} + y_{min} \quad (34)$$

Neste trabalho os dados foram normalizados no intervalo $[y_{min}; y_{max}] = [0; 1]$ determinando-se, através da Equação 34, uma equação de normalização a ser aplicada a cada variável.

Como a seção transversal dos bocais utilizados tinha como valor mínimo 5,0 mm e máximo 7,20 mm, tem-se, aplicando a equação 34, a seguinte equação de normalização:

$$f(x) = \left(\frac{x - 5,0}{2,2} \right) \quad (35)$$

A pressão de operação do sistema operou dentro do intervalo $[2,0 ; 3,5]$ kgf cm⁻², equivalente a $[196 ; 343]$ kPa, e foi normalizada pela equação:

$$f(x) = \left(\frac{x - 2,0}{1,5} \right) \quad (36)$$

A velocidade do vento sob a qual os ensaios foram realizados foi registrada no intervalo $[0 ; 1,65]$ m s⁻¹ e foi normalizada pela equação:

$$f(x) = \left(\frac{x}{1,65} \right) \quad (37)$$

A direção do vento foi registrada no intervalo $[10 ; 347,5]$ graus e foi normalizada pela equação:

$$f(x) = \left(\frac{x - 10}{337,5} \right) \quad (38)$$

Os valores de precipitação observados ao longo de todos os ensaios estiveram no intervalo de $[0 ; 15,5]$ mm e foram normalizados pela equação:

$$f(x) = \left(\frac{x}{15,5} \right) \quad (39)$$

3.5.2 Construção do conjunto de dados de treinamento

Treinar uma rede neural significa encontrar os pesos de suas conexões que tendam a minimizar o erro entre o valor encontrado pela rede e o valor esperado. A validação cruzada é uma técnica bastante comum para avaliar a capacidade de generalização de um modelo, através do particionamento do conjunto total de dados em

subconjuntos menores em que alguns desses serão utilizados para estimar os parâmetros do modelo e o restante dos subconjuntos será utilizado para validar e testar o modelo.

De acordo com SILVA et al. (2010) uma estratégia muito comum para a realização do particionamento desses subconjuntos é dividir os dados em um conjunto maior, frequentemente 60 a 90%, para treinar a rede neural e estimar seus parâmetros e o conjunto de dados restante, e menor, para testar o modelo.

Neste trabalho o conjunto de dados relativo aos 108 ensaios, seguindo a estratégia de treinamento e a validação cruzada, foi normalizado e dividido aleatoriamente em três subconjuntos: subconjunto de dados de treinamento composto de 76 ensaios, subconjunto de dados de validação composto de 22 ensaios e subconjunto de dados de teste composto de 10 ensaios utilizados para a discussão dos resultados.

Para ser processado pela rede neural, cada subconjunto foi armazenado em um arquivo distinto, sendo que neste arquivo os dados de cada ensaio, que na planilha de coletas se apresentavam em forma matricial, foram reorganizados de maneira que ficassem representados em apenas uma linha com seus valores separados por um espaço em branco. Organizados desta forma, a rede neural pôde trabalhar interpretando que cada linha que lhe era apresentada, representava também todos os dados de um ensaio, em particular.

3.5.3 Construção do programa computacional de criação e treinamento da RNA

Para automatizar a parametrização, criação, treinamento e validação das topologias de rede deste trabalho, haja vista que foram avaliadas milhares de topologias de redes candidatas, e escolhida a de melhor resultado, foram desenvolvidos quatro programas, apresentados no anexo 1, que foram executados pelo *batchman*, que faz parte do software de simulação de redes neurais SNNS. Para acelerar o processamento

os quatro programas rodavam em paralelo e cada um tinha, como objetivo, criar, treinar e validar topologias de rede neural com determinada quantidade de camadas ocultas. Neste trabalho foram avaliadas e utilizadas redes neurais com uma, duas, três e quatro camadas ocultas, o que demandou aproximadamente 190 horas de processamento computacional.

3.5.4 Treinamento da Rede Neural

A rede foi treinada utilizando-se os dados do conjunto de validação, composto de 76 ensaios.

No treinamento da rede neural especial atenção deve ser tomada para evitar um treinamento excessivo (*overfitting*) da mesma. Ao atingir o treinamento excessivo, a rede perde a capacidade de generalização, ou seja, torna-se capaz de prever apenas o conjunto de dados do treinamento ficando deficiente na capacidade de prever dados novos. Utilizou-se, para monitorar e evitar o treinamento excessivo, o conjunto de dados de validação que, neste trabalho, foi composto de 22 ensaios. A cada iteração de treinamento o erro na resposta da rede ao conjunto de validação foi medido; o esperado era que este erro diminuísse progressivamente e seu aumento indicaria que a rede estaria recebendo excesso de treinamento e ficando ajustada demais ao conjunto de treinamento, sinal de que o treinamento deveria ser encerrado.

O método utilizado neste trabalho é citado por Haykin (2001) como *método de treinamento com parada antecipada*, o qual, baseado no comportamento da curva de erro da amostra de treinamento e da curva de erro da amostra de validação, define o momento (*época*) de encerrar o treinamento da rede. Este método é baseado na observação de que a curva de treinamento, conforme pode ser vista na Figura 11, se

inicia com alto valor e vai decrescendo rapidamente até certo ponto, quando muda o comportamento e tende a se estabilizar a medida em que os ciclos de treinamento ocorrem. De forma diferente, a curva do erro de validação inicia com alto valor e, na medida em que a rede vai sendo treinada, este valor vai decrescendo até certo valor mínimo a partir do qual o valor volta a crescer conforme o treinamento continua. O *treinamento com parada antecipada* sugere que o ponto mínimo na curva de erro de validação seja usado como critério para encerrar a sessão de treinamento.

A medida deste erro também é um importante critério de escolha da rede, ou seja, a melhor rede é aquela que dá o menor erro para o conjunto de validação.




Figura 11 - Ilustração da regra de parada antecipada baseada na validação cruzada
Fonte: Autoria própria

3.5.5 Software ASPERSOFT para cálculo de parâmetros de eficiência de Irrigação

Como ferramenta de suporte a este trabalho foi desenvolvido e utilizado o programa ASPERSOFT com um banco de dados com todas as informações dos ensaios realizados, Figura 12. O software foi desenvolvido em Java FX®, possibilitando o armazenamento em seu banco de dados dos registros dos diversos parâmetros dos ensaios de precipitação e a partir dessas informações realizar os cálculos do perfil de distribuição, sobreposição de precipitação para os espaçamentos de 12x12; 12x15; 12x18; 12x24; 15x15; 18x18; 18x24; 18x30; 24x24; 24x30 e 30x30, sendo ainda possível obter, para cada espaçamento, os parâmetros de avaliação da uniformidade de distribuição da água CUC, CUD e CUE e os parâmetros estatísticos: desvio padrão, média do 1º quartil e coeficiente de variação, como observado na Figura 13.

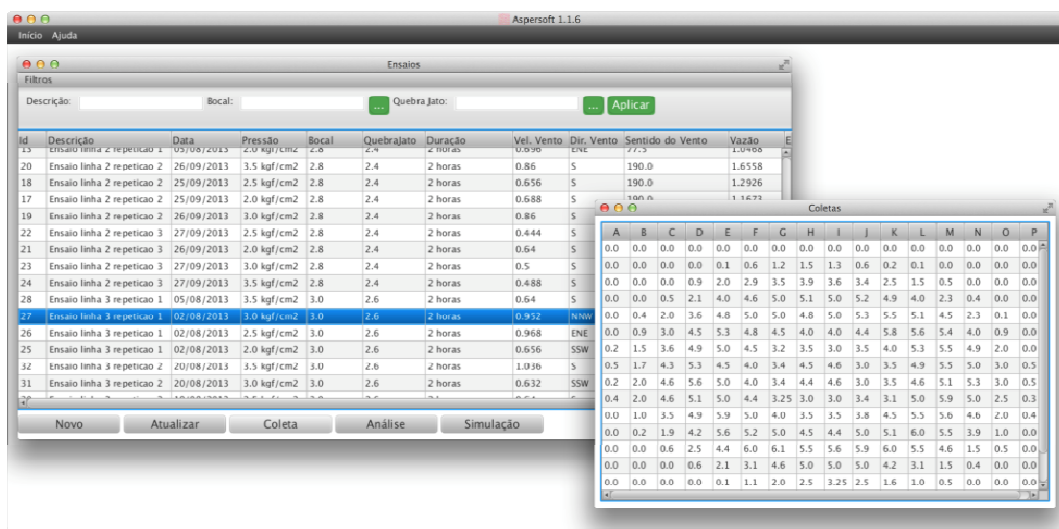


Figura 12 - Tela de Ensaio e Coletas do programa ASPERSOFT
Fonte: Autoria Própria

No software foi incluída a rede neural produto deste trabalho, que pode ser alimentada com os valores de secção do bocal, direção e velocidade do vento e a pressão de operação e obter as precipitações simuladas pela rede neural.

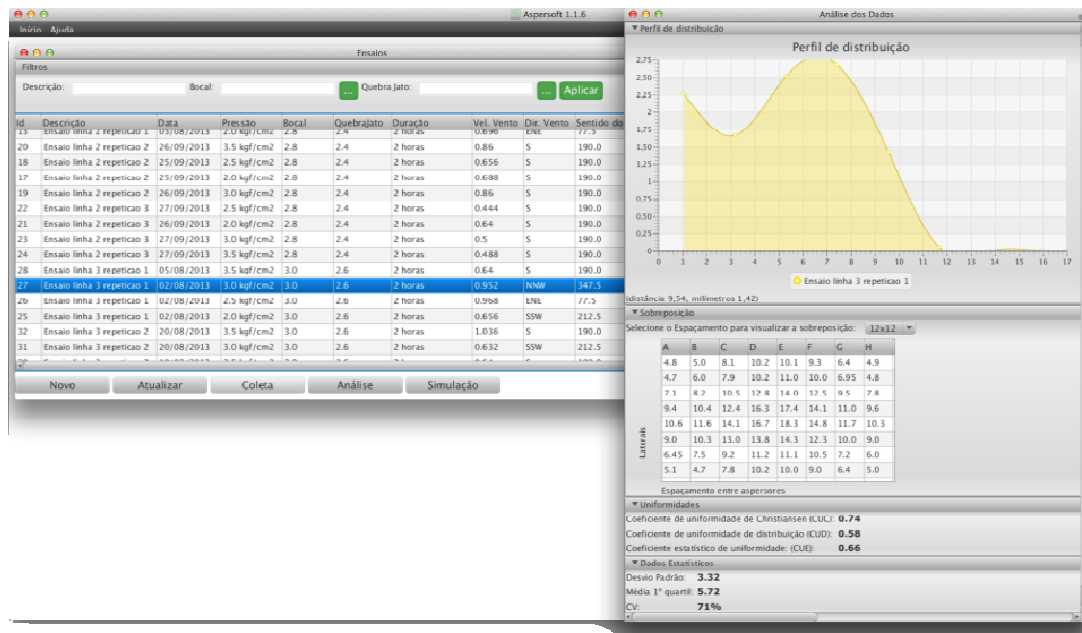


Figura 13 - Tela de sobreposições e coeficientes de uniformidade do ASPERSOFT
Fonte: Autoria própria

4 RESULTADOS E DISCUSSÃO

4.1 A rede de melhor desempenho

Foram testadas 31148 redes neurais e selecionada aquela que produziu o melhor resultado, isto é, o menor valor de erro SSE. A Tabela 4 mostra a classificação dos quinze menores erros obtidos e também o maior erro para cada uma das topologias testadas (uma, duas, três e quatro camadas ocultas). Observou-se, para os dados deste trabalho, que a topologia com apenas uma camada oculta se mostrou melhor, ou seja, com o menor erro SSE, e, na medida em que aumenta a quantidade de camadas ocultas este indicador piora.

Tabela 4 – Classificação dos quinze menores resultados de erro SSE obtidos para as redes neurais com uma, duas, três e quatro camadas ocultas

CLASSIFICAÇÃO	ERRO SSE			
	1 CAMADA	2 CAMADAS	3 CAMADAS	4 CAMADAS
1	7,958807	9,583435	12,165959	15,169821
2	8,034795	9,622751	12,430941	15,362198
3	8,150610	9,671642	12,503036	16,803764
4	8,165284	9,716320	12,686063	18,644808
5	8,169233	10,070355	12,822331	19,260088
6	8,297061	10,165201	12,942290	19,328934
7	8,315094	10,175529	13,077940	19,420382
8	8,316446	10,636321	13,184516	19,424723
9	8,337774	10,686354	13,226684	19,477280
10	8,344623	10,729122	13,239070	19,987125
11	8,362608	10,863175	13,261174	20,080833
12	8,392083	10,957334	13,283604	20,131428
13	8,401917	11,002492	13,285940	20,246361
14	8,417866	11,036373	13,374914	20,265135
15	8,441094	11,036393	13,433792	20,300486
...
ÚLTIMO	29,780346	461,123444	30,787025	68,327126

Fonte: Autoria própria

A Figura 14, construída com um conjunto maior dos dados da Tabela 4, mostra a tendência observada de que, quanto maior o número de camadas maior também o valor

do erro SSE. Esta tendência indica que, pela natureza dos dados discutidos neste trabalho, uma camada oculta é o suficiente para modelá-los e que, aumentando a quantidade de camadas da rede e tornando-a mais complexa, esta perde eficiência na minimização do erro.




Figura 14 - Comparativo do erro SSE entre as RNA's com uma, duas, três e quatro camadas ocultas (100 menores valores de erro SSE por camada)
 Fonte: Autoria própria

A Tabela 5 mostra a classificação com os quinze melhores resultados do erro SSE identificando a quantidade de neurônios presentes na camada oculta da rede. Observa-se que o menor erro SSE, no valor de 7,958807, ocorreu na topologia de rede composta de 280 neurônios na camada oculta; observou-se também, entre os quinze menores erros, que todas as redes tinham pelo menos 205 neurônios dando indícios de que quantidades menores de neurônios não são interessantes para os dados em questão.

Tabela 5 - Classificação do erro SSE por quantidade de neurônios para topologias de rede neural com uma camada oculta

Classificação	Qtde de neurônios na camada oculta	SSE
1	280	7,958807
2	465	8,034795
3	432	8,150610
4	436	8,165284
5	289	8,169233
6	252	8,297061
7	315	8,315094
8	452	8,316446
9	404	8,337774
10	345	8,344623
11	422	8,362608
12	449	8,392083
13	475	8,401917
14	355	8,417866
15	205	8,441094

Fonte: Autoria própria

Em relação à escolha da rede neural que apresente o melhor desempenho conclui-se que, considerando os quatro neurônios da camada de entrada correspondentes as variáveis pressão, velocidade do vento, direção do vento e diâmetro do bocal, mais 280 neurônios na camada oculta, discutidos acima, e 256 na camada de saída, correspondentes aos 256 pluviômetros dos ensaios, ficou definida a rede de topologia 4x280x256 neurônios para modelar os dados do presente trabalho, por ela apresentar o menor valor de erro SSE quando comparada com as demais topologias testadas.

4.2 Validação do modelo RNA

A avaliação de que o desempenho do modelo baseado em rede neural selecionado se comporta de maneira suficientemente satisfatória em relação aos objetivos do estudo, foi realizada comparando-se as respostas do modelo com os valores observados nos ensaios de campo, quando ambos foram submetidos às mesmas condições de entrada.

A resposta desejada é a predição dos valores de precipitação do aspersor cujo desempenho foi medido pela correlação entre os valores simulados e os observados. Fez-se, também, um estudo comparativo entre o perfil de distribuição do aspersor para os dados simulados e o perfil de distribuição para os dados observados.

4.2.1 Análise e inferências sobre a distribuição dos dados de precipitação

Na Tabela 6 são apresentados os valores de *p-valor* referentes aos testes de normalidade de Kolmogorov-Smirnov e Shapiro-Wilk, para os dados de precipitação dos dez ensaios utilizados na validação do modelo RNA.

Considerando 5% de significância ($\alpha = 0,05$) e que *p-valor* ficou abaixo de 0,05 para todos os ensaios, tanto no teste Kolmogorov-Smirnov quando no teste Shapiro-Wilk, rejeita-se a hipótese de que os dados de precipitação seguem uma distribuição normal. A não normalidade dos dados é consequência da alta frequência de valores igual a zero observados nos pluviômetros mais afastados do aspersor. Considerando que a normalidade dos dados não pode ser assumida, os testes seguintes foram baseados em métodos estatísticos não paramétricos.

Tabela 6 - Testes de aderência à distribuição normal para os conjuntos de dados de teste de precipitação

	Teste Kolmogorov-Smirnov			Teste Shapiro-Wilk		
	Estatística	p-value	Normal	Estatística	p-value	Normal
Ensaio 56	0,175	$3,33 \times 10^{-21}$	N	0,855	$9,16 \times 10^{-15}$	N
Ensaio 15	0,230	$3,33 \times 10^{-21}$	N	0,782	$3,66 \times 10^{-18}$	N
Ensaio 13	0,270	$3,33 \times 10^{-21}$	N	0,709	$7,68 \times 10^{-21}$	N
Ensaio 55	0,155	$3,33 \times 10^{-21}$	N	0,881	$2,75 \times 10^{-13}$	N
Ensaio 100	0,201	$3,33 \times 10^{-21}$	N	0,836	$9,35 \times 10^{-16}$	N
Ensaio 88	0,190	$3,33 \times 10^{-21}$	N	0,831	$5,08 \times 10^{-16}$	N
Ensaio 41	0,176	$3,33 \times 10^{-21}$	N	0,873	$8,91 \times 10^{-14}$	N
Ensaio 93	0,215	$3,33 \times 10^{-21}$	N	0,834	$7,33 \times 10^{-16}$	N
Ensaio 89	0,232	$3,33 \times 10^{-21}$	N	0,837	$9,89 \times 10^{-16}$	N
Ensaio 85	0,208	$3,33 \times 10^{-21}$	N	0,837	$9,93 \times 10^{-16}$	N

Fonte: Autoria própria

4.2.2 Desempenho do modelo RNA na predição da distribuição das amostras de dados

Para cada ensaio, do total de dez, foi feito um comparativo de variâncias entre os dados observados em campo e os dados simulados pelo modelo RNA, para medir o quanto elas eram homogêneas entre os dois conjuntos de dados. O teste utilizado para medir a homogeneidade das variâncias (homocedasticidade) foi o teste de Levene que é indicado quando os dados não seguem uma distribuição normal. Observa-se, pela Tabela 7, que a 5% de significância o teste de Levene aceita a hipótese de homogeneidade entre os dados observados e simulados com p-valor > 0,05 para sete dos dez ensaios e no teste de Wilcoxon-Mann-Whitney, utilizado para indicar se as medidas de posição de duas amostras são iguais indicando se os dois conjuntos de dados em teste vêm de populações semelhantes, a Tabela 7 mostra que com nível de significância $\alpha = 0,05$ em oito dos dez ensaios os dados reais e simulados vêm de populações semelhantes (ou da mesma população).

Tabela 7 - Testes de homocedasticidade e semelhança de população entre os dados observados e simulados pelo modelo RNA

	Teste		Teste	
	Wilcoxon-Mann-Whitney		de Levene	
	W	p-valor	F	p-valor
Ensaio 56	36025	0,050	0,1945	0,659
Ensaio 15	30225,5	0,121	0,0035	0,953
Ensaio 13	28634,5	0,011*	0,2155	0,643
Ensaio 55	28407,5	0,009*	10,247	0,001*
Ensaio 100	30547	0,183	89,603	0,003*
Ensaio 88	31969,5	0,629	0,3833	0,536
Ensaio 41	32537	0,889	0,2075	0,649
Ensaio 93	31605	0,478	0,5733	0,449
Ensaio 89	28674,5	0,014*	3,0639	0,081
Ensaio 85	32374	0,811	0,8904	0,346

*Rejeita a 5% de significância

Fonte: Autoria própria

Os resultados desses testes foram considerados satisfatórios, visto que, a partir dos mesmos pode-se dizer que o modelo RNA fez previsões bastante acertadas acerca das populações e da distribuição dos dados de precipitação.

4.2.3 Desempenho do modelo RNA na simulação da precipitação do aspensor

O desempenho da RNA na simulação da precipitação do aspensor foi avaliado através do coeficiente de correlação de postos de Spearman, que é uma medida de correlação não-paramétrica, simbolizado por r_s (ou ρ).

A Figura 15A e 15B apresenta, respectivamente, a precipitação de água do aspensor observada no ensaio de campo e a respectiva precipitação simulada pela rede neural para o ensaio número 93 com 2 horas de duração, combinação de bocais 4,0 x 2,8 mm, operando a uma pressão de 196 kPa, com vento soprando a uma velocidade média de $0,74 \text{ m s}^{-1}$ na direção 325° .


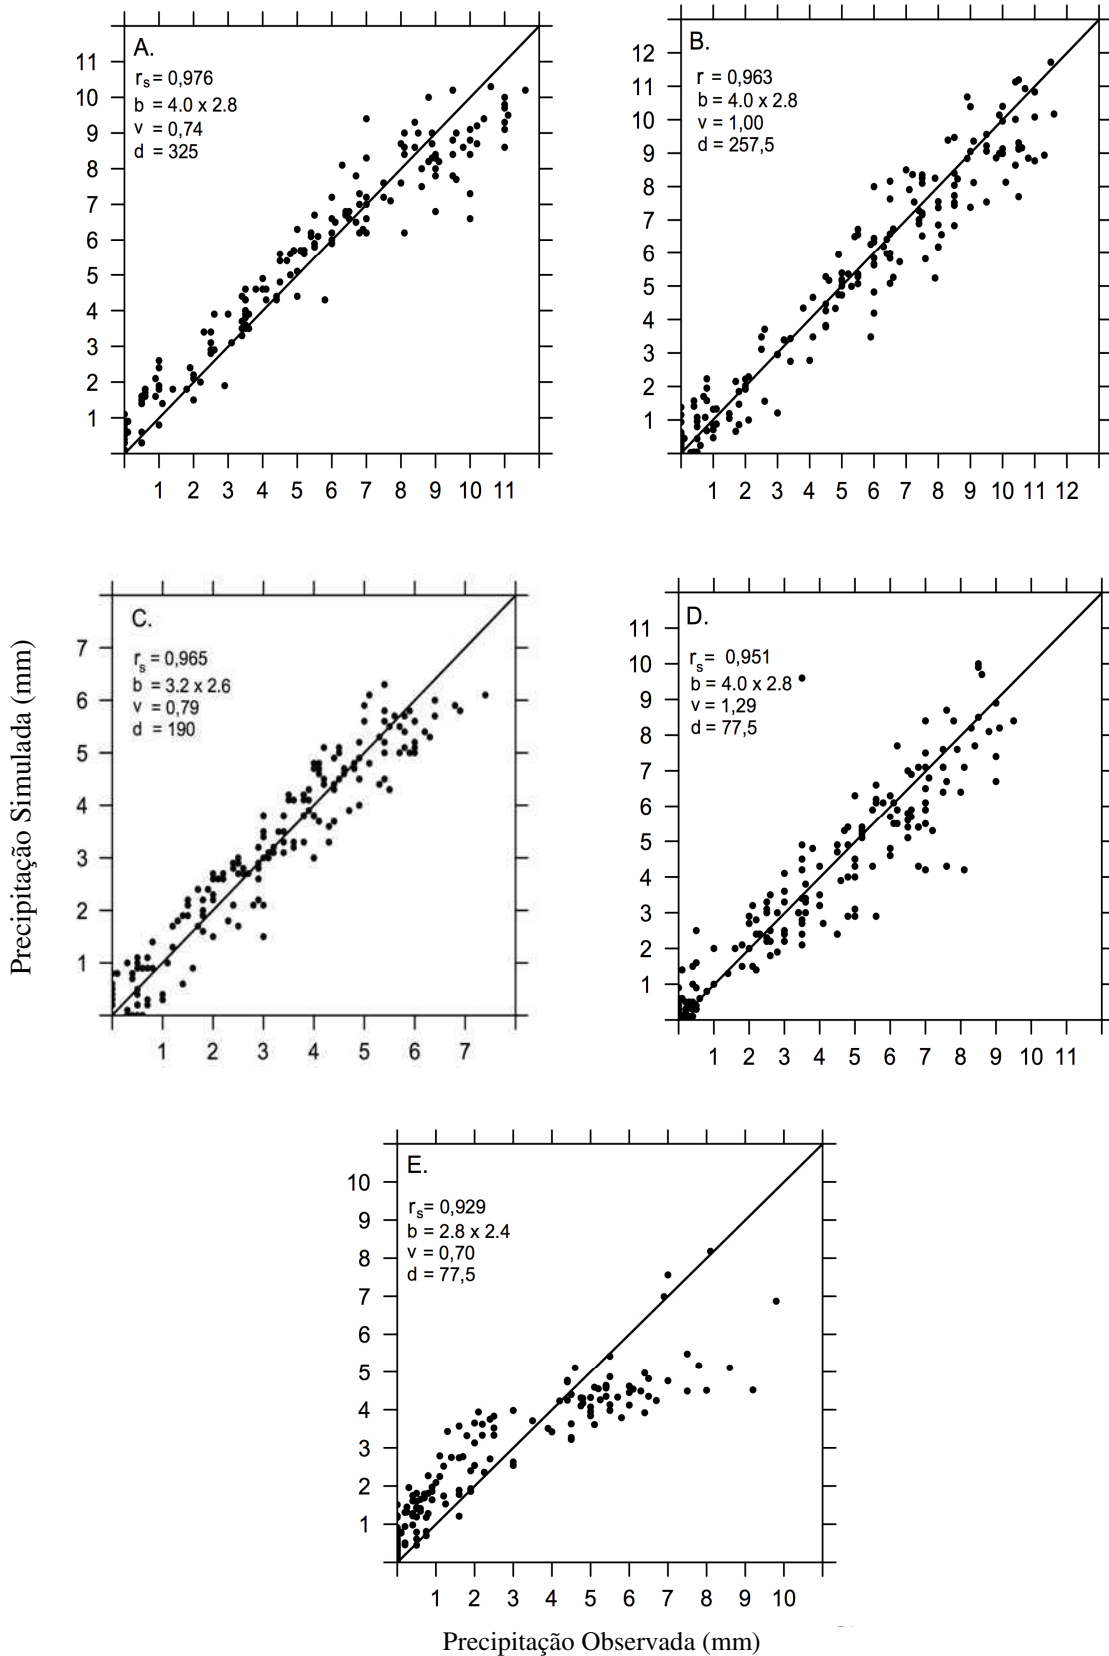


Figura 15 – Distribuição da precipitação de água do aspersor para um ensaio com 2 horas de duração, bocais 4,0 x 2,8 mm, pressão de operação de 196 kPa e vento a uma velocidade média de $0,74 \text{ m s}^{-1}$ na direção 325° . A) Precipitação observada; B) Precipitação simulada pela RNA.


O gráfico da Figura 16A mostra a dispersão entre os dados observados e os simulados para o Ensaio 93, cuja distribuição da precipitação é mostrada na Figura 15. Observou-se que há forte correlação entre os dois conjuntos de dados, indicada pelo coeficiente de relação de Spearman $r_s = 0,974$, que dá indícios de um bom desempenho do modelo RNA na predição dessas precipitações.

O estudo de correlações de Spearman foi feito também para os demais nove conjuntos de dados reservados para teste do modelo RNA, dados estes que não fizeram parte das etapas de treinamento e estimação dos parâmetros do modelo RNA; da Figura 16 à Figura 18 são apresentados os valores de correlação entre o conjunto de dados do ensaio de campo e os simulados pela RNA com os respectivos coeficientes de Spearman r_s medindo a força da correlação entre os dados observados e os simulados.




r_s = coeficiente de correlação; b = combinação de bocais (mm x mm); v = velocidade do vento ($m s^{-1}$); d = direção do vento (graus)

Figura 16 - Correlação entre os valores de precipitação observados e os simulados, para cinco ensaios de validação do modelo RNA com 2 horas de duração e pressão de operação de 196 kPa



r_s = coeficiente de correlação; b = combinação de bocais (mm x mm);
 v = velocidade do vento ($m s^{-1}$); d = direção do vento (graus)

Figura 17 - Correlação entre os valores de precipitação observados e os simulados, para dois ensaios de validação do modelo RNA com 2 horas de duração e pressão de operação de 294 kPa



r_s = coeficiente de correlação; b = combinação de bocais (mm x mm);
 v = velocidade do vento ($m\ s^{-1}$); d = direção do vento (graus)

Figura 18 - Correlação entre os valores de precipitação observados e os simulados, para três ensaios de validação do modelo RNA com 2 horas de duração e pressão de operação de 343 kPa

São mostrados, na Tabela 8, os coeficientes de correlação r_s para os dez ensaios que foram utilizados para validar o modelo. Para todos os ensaios de teste observou-se uma correlação muito forte, com coeficientes r_s variando entre 0,929 e 0,976, sinal de que o modelo RNA fez previsões de valores muito próximos daqueles observados nos ensaios reais.

Tabela 8 - Valores do coeficiente de correlação de Spearman, r_s , entre os valores de precipitação observados e simulados pela rede neural para dez diferentes ensaios de teste realizados com duração de duas horas.

Nº DO ENSAIO	BOCAL (mm)	PRESSÃO (kPa)	VENTO		r_s
			VEL. (m s ⁻¹)	DIR (graus)	
13	2,8 X 2,4	196	0,70	76,50	0,929
15	2,8 X 2,4	294	0,18	95,16	0,965
41	3,2 X 2,6	196	0,79	116,76	0,965
55	3,4 X 2,6	294	0,87	139,26	0,974
56	3,4 X 2,6	343	0,33	245,70	0,956
85	4,0 X 2,8	196	1,00	214,86	0,963
88	4,0 X 2,8	343	1,23	246,60	0,952
89	4,0 X 2,8	196	1,29	94,92	0,951
93	4,0 X 2,8	196	0,75	271,80	0,976
100	4,0 X 3,2	343	0,34	152,28	0,967

4.2.4 Comparativo do perfil de distribuição do aspersor

Uma comparação foi feita entre o perfil radial de distribuição do aspersor calculado sobre os dados de precipitação observados e os dados de precipitação simulados pelo modelo RNA, para constatar e medir o quanto os dados simulados conseguiriam reproduzir o perfil de distribuição de água do aspersor.

Para compor o gráfico do perfil de distribuição, que apresenta os valores precipitados ao longo do raio de alcance do aspersor, foram considerados os valores

médios da lâmina coletada nos quatro raios diagonais que partem do aspersor e estão representados pelas linhas tracejadas da Figura 19. Cada raio abrigou oito coletores, o primeiro a uma distância de 1,06 m do aspersor e os demais nas distâncias de 3,18; 5,30; 7,42; 9,54; 11,66; 13,78 e 15,90 m, respectivamente. Para efeito de cálculo e apresentação gráfica utilizou-se a representação dos dados em apenas um raio, com os valores médios.




Figura 19 - Esquema da malha de coletores e orientação do eixo de referência para cálculo do perfil de distribuição

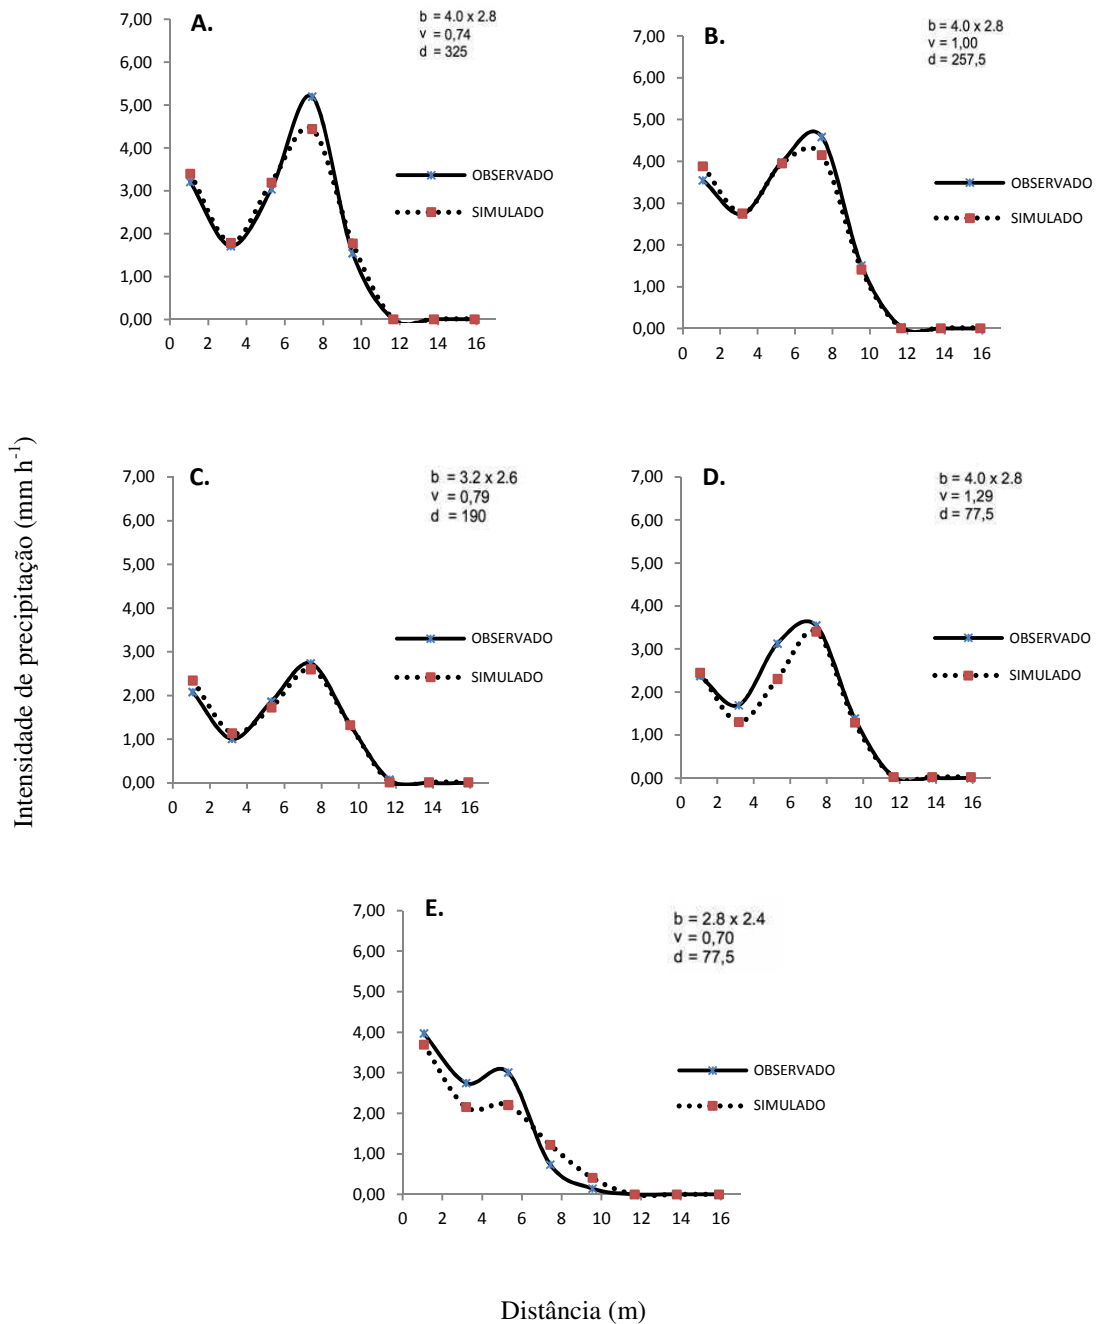
A Tabela 9 apresenta os valores da intensidade de precipitação observados nos dez ensaios.

Tabela 9 - Perfil de distribuição do aspersor calculado para dados observados e simulados pela RNA para dez ensaios do conjunto de testes da RNA

Distancia (m)	INTENSIDADE DE PRECIPITAÇÃO (mm h ⁻¹)									
	ENSAIO 13		ENSAIO 15		ENSAIO41		ENSAIO55		ENSAIO56	
	OBS.	SIMUL.	OBS.	SIMUL.	OBS.	SIMUL.	OBS.	SIMUL.	OBS.	SIMUL.
1,06	3,98	3,70	5,10	4,15	2,08	2,35	2,35	2,69	3,65	3,21
3,18	2,75	2,16	3,21	3,33	1,01	1,14	1,61	2,07	2,93	2,27
5,30	3,01	2,21	3,76	3,60	1,86	1,73	2,51	2,90	3,94	3,19
7,42	0,74	1,23	1,89	2,08	2,74	2,60	3,03	3,43	4,38	4,21
9,54	0,14	0,41	0,41	0,66	1,33	1,32	1,76	1,84	2,90	2,69
11,66	0,00	0,00	0,00	0,01	0,08	0,02	0,16	0,03	0,18	0,01
13,78	0,00	0,00	0,00	0,01	0,00	0,02	0,00	0,03	0,00	0,01
15,90	0,00	0,00	0,00	0,01	0,00	0,02	0,00	0,03	0,00	0,01
Distancia (m)	INTENSIDADE DE PRECIPITAÇÃO (mm h ⁻¹)									
	ENSAIO85		ENSAIO88		ENSAIO89		ENSAIO93		ENSAIO100	
	OBS.	SIMUL.	OBS.	SIMUL.	OBS.	SIMUL.	OBS.	SIMUL.	OBS.	SIMUL.
1,06	3,55	3,89	4,55	4,78	2,38	2,45	3,21	3,40	4,68	4,25
3,18	2,74	2,76	4,68	5,17	1,69	1,31	1,71	1,79	4,33	4,15
5,30	3,99	3,96	5,61	5,81	3,13	2,31	3,04	3,20	5,95	5,51
7,42	4,59	4,16	4,64	4,85	3,55	3,41	5,20	4,45	5,75	5,55
9,54	1,51	1,42	2,15	2,11	1,39	1,29	1,55	1,78	2,41	2,97
11,66	0,04	0,01	0,15	0,02	0,03	0,03	0,00	0,01	0,08	0,07
13,78	0,00	0,01	0,00	0,02	0,00	0,03	0,00	0,01	0,00	0,07
15,90	0,00	0,01	0,00	0,02	0,00	0,03	0,00	0,01	0,00	0,07

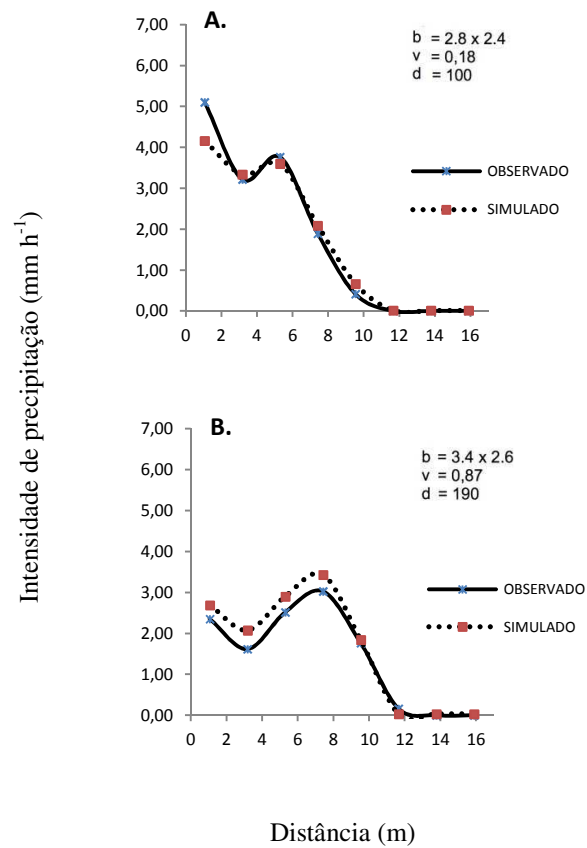
Os gráficos do perfil de distribuição para cada ensaio são apresentados da Figura 20 até a Figura 22.

A Figura 20 mostra a relação entre o perfil de distribuição com os dados observados e os simulados para os cinco ensaios realizados com pressão de operação de 196 kPa, na Figura 21 são mostrados os resultados para os dois ensaios realizados com pressão de operação de 294 kPa e, na Figura 22, são mostrados os resultados para os dois ensaios realizados com pressão de operação de 343 kPa.



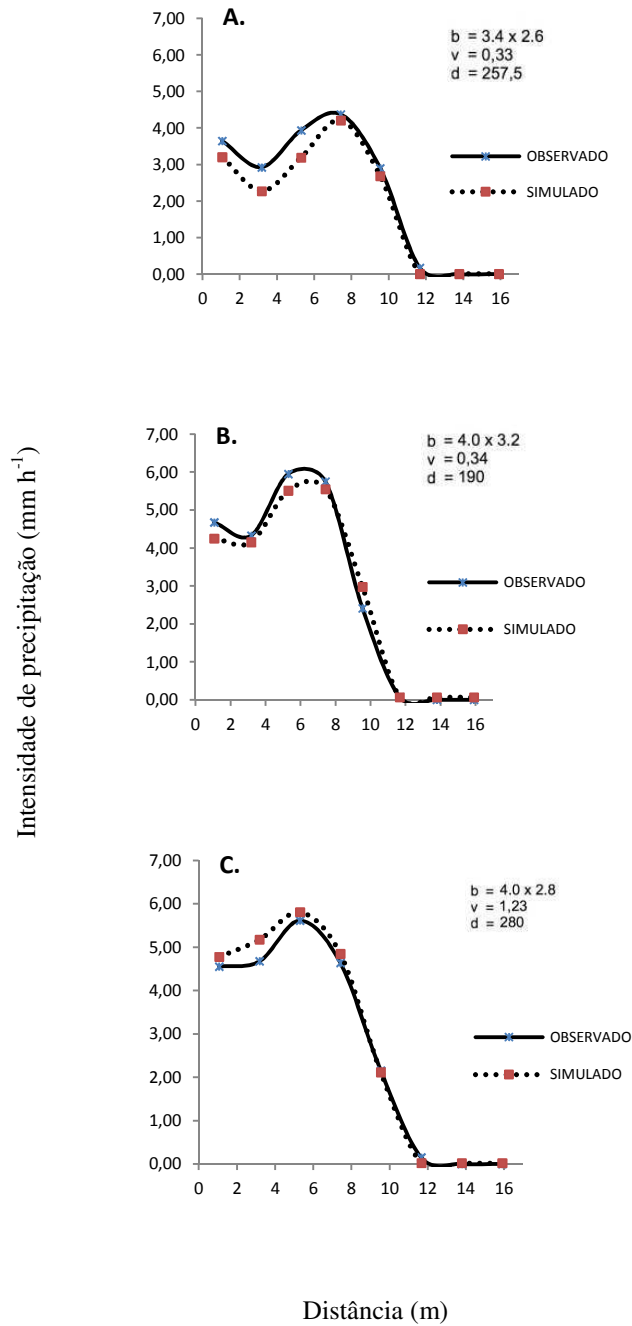
r_s = coeficiente de correlação; b = combinação de bocais (mm x mm); v = velocidade do vento (m s⁻¹); d = direção do vento (graus)

Figura 20 – Comparativo do perfil de distribuição do aspersor calculado com os dados de precipitação observados e dados de precipitação simulados pela RNA para ensaio com 2 horas de duração e pressão de operação de 196 kPa.



r_s = coeficiente de correlação; b = combinação de bocais (mm x mm);
 v = velocidade do vento (m s^{-1}); d = direção do vento (graus)

Figura 21 – Comparativo do perfil de distribuição do aspersor calculado com os dados de precipitação observados e dados de precipitação simulados pela RNA para ensaio com 2 horas de duração e pressão de operação de 294 kPa



r_s = coeficiente de correlação; b = combinação de bocais (mm x mm);
 v = velocidade do vento (m s^{-1}); d = direção do vento (graus)

Figura 22 – Comparativo do perfil de distribuição do aspersor calculado com os dados de precipitação observados e dados de precipitação simulados pela RNA para ensaio com 2 horas de duração e pressão de operação de 343 kPa

Observou-se que os perfis de distribuição com os dados simulados pelo modelo quando comparados com os perfis calculados com os dados observados nos ensaios experimentais se mostraram bastante próximos, e que o modelo reproduziu, com boa precisão, as diferentes características de curvas geradas pelas diferentes combinações de parâmetros do sistema. Assumindo que os dados dos perfis de distribuição provêm de uma distribuição normal, foi possível calcular os respectivos coeficientes de correlação linear de Pearson e, a partir deles, calcular os coeficientes de determinação R^2 , ilustrados na Tabela 10, cujos valores foram utilizados para medir o quanto dos dados observados pode ser explicado pelo modelo RNA e estimar a sua qualidade.

Tabela 10 - Valores do coeficiente de determinação R^2 para a correlação linear entre o perfil de distribuição para os valores de precipitação observados e os valores de precipitação simulados pela rede neural para dez diferentes ensaios de teste realizados com duração de duas horas

Nº DO ENSAIO	BOCAL (mm)	PRESSÃO (kPa)	VENTO		R^2
			VEL. (m s ⁻¹)	DIR (graus)	
13	2,8 X 2,4	196	0,70	76,50	0,953
15	2,8 X 2,4	294	0,18	95,16	0,976
41	3,2 X 2,6	196	0,79	116,76	0,984
55	3,4 X 2,6	294	0,87	139,26	0,992
56	3,4 X 2,6	343	0,33	245,70	0,984
85	4,0 X 2,8	196	1,00	214,86	0,988
88	4,0 X 2,8	343	1,23	246,60	0,998
89	4,0 X 2,8	196	1,29	94,92	0,962
93	4,0 X 2,8	196	0,75	271,80	0,977
100	4,0 X 3,2	343	0,34	152,28	0,989

Fonte: Autoria própria

Observou-se, para o perfil de distribuição do aspersor, um bom ajuste entre os dados observados e os simulados, a regressão linear aponta forte correlação entre o perfil de distribuição do aspersor para os dados observados e o perfil de distribuição para os dados simulados pelo modelo RNA proposto, apresentando coeficiente de

determinação R^2 no valor de 0,953 para o pior caso, o ensaio 13 e 0,998 no melhor caso, conforme pode ser observado na Tabela 10.

4.2.5 Comparativo dos coeficientes de uniformidade

Foram feitos estudos comparativos entre os valores dos coeficientes de uniformidade CUC, CUD e CUE calculados com os dados de precipitação observados e os dados de precipitação simulados pelo modelo RNA, para constatar o quanto os dados simulados conseguiriam reproduzir a variabilidade da uniformidade de distribuição de água do aspersor observada no campo.

Foram calculados os valores dos três coeficientes para os espaçamentos sobrepostos de 12x12, 12x15 e 15x15 para os dez ensaios utilizados na validação do modelo. A Tabela 11 mostra os valores obtidos.

Tabela 11 - Valores observados e simulados dos coeficientes de uniformidade de precipitação do aspersor para os dez ensaios de validação do modelo de RNA

ENSAIO	CUC						CUD						CUE					
	ESPAÇAMENTOS						ESPAÇAMENTOS						ESPAÇAMENTOS					
	12x12		12x15		15x15		12x12		12x15		15x15		12x12		12x15		15x15	
	OBS.	SIM.	OBS.	SIM.	OBS.	SIM.	OBS.	SIM.	OBS.	SIM.	OBS.	SIM.	OBS.	SIM.	OBS.	SIM.	OBS.	SIM.
13	0,76	0,89	0,61	0,81	0,52	0,78	0,64	0,83	0,39	0,73	0,28	0,59	0,69	0,86	0,50	0,76	0,44	0,70
15	0,81	0,88	0,73	0,84	0,72	0,81	0,72	0,80	0,61	0,76	0,50	0,63	0,76	0,85	0,64	0,79	0,64	0,75
41	0,66	0,70	0,62	0,66	0,53	0,81	0,49	0,56	0,40	0,46	0,37	0,63	0,54	0,59	0,56	0,60	0,45	0,75
55	0,73	0,74	0,72	0,71	0,66	0,66	0,59	0,59	0,53	0,53	0,49	0,54	0,65	0,66	0,67	0,67	0,60	0,61
56	0,75	0,70	0,74	0,67	0,69	0,59	0,60	0,54	0,56	0,47	0,56	0,48	0,67	0,60	0,69	0,61	0,65	0,54
85	0,66	0,68	0,65	0,69	0,64	0,68	0,48	0,52	0,50	0,55	0,52	0,61	0,61	0,64	0,60	0,64	0,55	0,61
88	0,76	0,76	0,76	0,77	0,76	0,78	0,58	0,59	0,63	0,65	0,64	0,69	0,71	0,71	0,70	0,72	0,70	0,71
89	0,62	0,63	0,60	0,58	0,58	0,53	0,42	0,48	0,43	0,40	0,43	0,40	0,55	0,63	0,55	0,53	0,49	0,43
93	0,64	0,67	0,59	0,65	0,53	0,61	0,41	0,47	0,41	0,45	0,40	0,46	0,54	0,59	0,53	0,60	0,43	0,52
100	0,73	0,75	0,73	0,75	0,71	0,74	0,54	0,58	0,56	0,59	0,60	0,62	0,67	0,68	0,69	0,71	0,64	0,69

A partir dos valores dos coeficientes de uniformidade apresentados na Tabela 11 foi calculado o percentual de erro dos dados obtidos a partir do modelo RNA, representado pela diferença entre o valor do coeficiente com os dados observados e o coeficiente com os dados simulados pelo modelo RNA; a Tabela 12 mostra os valores encontrados.

Tabela 12 - Valores dos erros entre os coeficientes de uniformidade de precipitação do aspersor observados e os simulados, para os dez ensaios de validação do modelo de RNA

ENSAIO	CUC			CUD			CUE		
	ESPAÇAMENTOS			ESPAÇAMENTOS			ESPAÇAMENTOS		
	12x12	12x15	15x15	12x12	12x15	15x15	12x12	12x15	15x15
	ERRO (%)	ERRO (%)	ERRO (%)	ERRO (%)	ERRO (%)	ERRO (%)	ERRO (%)	ERRO (%)	ERRO (%)
13	17,2	32,8	48,8	29,4	89,7	108,1	24,9	50,7	58,4
15	9,3	15,7	12,0	11,3	24,6	26,5	11,4	22,9	17,1
41	5,6	6,1	52,1	13,6	16,5	70,3	9,1	6,4	64,1
55	1,8	-0,4	1,1	-0,5	0,6	9,8	1,4	0,7	2,2
56	-7,4	-9,9	-14,4	-9,5	-14,9	-13,1	-10,2	-12,0	-16,6
85	2,9	6,3	6,9	8,5	10,6	18,3	4,6	6,7	11,1
88	0,0	1,8	2,1	2,8	4,2	6,8	0,7	3,1	1,0
89	1,3	-2,3	-8,0	13,1	-5,9	-7,3	14,6	-2,2	-11,3
93	4,5	10,4	14,6	13,3	9,6	14,3	9,1	13,7	20,5
100	3,0	2,6	4,7	6,8	5,6	3,4	2,3	3,5	6,5

Observou-se que os maiores erros foram encontrados nos ensaios 13 e 15, o que já era esperado, considerando que os valores de correlação para da precipitação mostrados na Tabela 8 já demonstravam que estes dois ensaios tinham a maior diferença entre os dados reais e os simulados.

Para os outros oito ensaios, os resultados foram considerados satisfatórios; constatou-se menor diferença entre os valores dos coeficientes reforçando os indícios de que o modelo conseguiu um bom ajuste para os dados destes ensaios.

5 CONCLUSÕES

Os resultados do presente trabalho levam às seguintes conclusões.

1. O modelo de Rede Neural Artificial (RNA) desenvolvido para simular a precipitação do aspersor foi do tipo Perceptron Multicamadas (MCP). Apresentou como melhor topologia aquela composta de 4 neurônios na camada de entrada, uma camada oculta composta de 280 neurônios e a camada de saída composta de 256 neurônios, cujo treinamento baseado no algoritmo *backpropagation* se estendeu até a época 9487, com erro de validação $SSE=7,958807$.

2. Para os dez ensaios de campo utilizados em sua validação, o modelo RNA alcançou desempenho muito bom na predição da precipitação do aspersor, com coeficientes de correlação r_s variando entre 0,929 e 0,976.

3. Na comparação entre o perfil de distribuição do aspersor com os dados simulados pelo modelo RNA e os dados observados em campo, constatou-se, para os mesmos dez ensaios, que o pior caso apresentou correlação com R^2 de 0,953.

4. A comparação entre os valores dos coeficientes de uniformidade CUC, CUD e CUE com os dados simulados pelo modelo RNA e os observados em campo, reforçou os indícios de que o modelo conseguiu um bom ajuste para os dados de precipitação do aspersor.

5. A topologia de RNA selecionada e testada neste trabalho, alcançou bom desempenho na predição da precipitação do aspersor mostrando o potencial de uso desses modelos em simulações de irrigação. O desempenho obtido foi, em parte, devido à grande capacidade de ajuste apresentado pelo algoritmo de aprendizagem *backpropagation*.

5.1 Sugestões para trabalhos futuros

1. Embora a modelagem obtida tenha apresentado bons resultados, alterações nos dados de entrada e parâmetros da rede podem trazer melhorias.

2. Testar o ajuste de uma rede neural com menor quantidade de dados.

3. O emprego de RNA para operação e controle do sistema de irrigação pode ser explorado, atribuindo-lhe, por exemplo, a função de aumentar ou diminuir o tempo de aplicação, de acordo com as condições de vento ou umidade do solo a fim de buscar alta eficiência do sistema.

4. Outras técnicas de Inteligência Computacional (IC) como Algoritmos Genéticos, Lógica Fuzzy e Máquinas de Vetor Suporte, podem ser aplicadas de forma isolada ou em conjunto com a utilização do modelo redes neurais na simulação de sistemas de irrigação.

6 REFERÊNCIAS BIBLIOGRÁFICAS

ABELÉM, A. J. G. **Redes Neurais Artificiais Na Previsão De Séries Temporais**, publicação Dissertação de Mestrado pela Universidade Católica do Rio de Janeiro, RJ, Brasil, 197 p., 1994.

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS - ABNT. **Aspersores para irrigação: avaliação da distribuição de água - método de ensaio**. 1985. 9 p. (ASAE, NBR 8989)

BERNARDO, S; SOARES, A. A; MANTOVANI, E.C. **Manual de Irrigação**. 8^a.ed. Viçosa: Ed. UFV, Viçosa, MG, Brasil, 625p., 2006.

BUFO, M. J. **Aplicação de rede neural artificial como auxiliar na predição do desempenho de um landfarming**. 2000. 192 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas.

CARDOSO NETO, A. **A irrigação e drenagem de áreas rurais; Uma visão geral**. ANA – Superintendência de Informações Hidrológicas da Agencia Nacional de Águas, 1999.

CRIDDLE, W.D.; DAVIS, S.; PAIR, C.H.; SHOCKLEY, D.G. **Methods for Evaluating Irrigation Systems**. Washington DC: Soil Conservation Service - USDA,1956. 24p. Agricultural Handbook, 82

FABRIMAR – IRRIGAÇÃO. Disponível em <<http://www.fabrimar.com.br>> . Acesso em: 02 set. 2012.

FARIA, L. C.; BESKOW, S.; COLOMBO, A.; OLIVEIRA, H.F.E; **Modelagem dos efeitos do vento na uniformidade da irrigação por aspersão: Aspersores de tamanho médio**. Revista Brasileira de Engenharia Agrícola e Ambiental v.16, n.2, p.133-141, 2012.

FILOSOFIA A DISTÂNCIA. Disponível em < <http://www.filosofiaadistancia.com.br> >. Acesso em: 03 set. 2012.

GALÃO, O F.; BORSATO, D; PINTO, J P., VISENTAINER, J. V., CARRÃO-PANIZZI, M. C. **Artificial neural networks in the classification and identification of soybean cultivars by planting region.** Journal of the Brazilian Chemical Society, 22(1), 142-147, 2011.

HAYKIN, S. **Redes Neurais:Princípios e Prática.** 2.ed. Porto Alegre: Editora Bookman, 2001.

HEBB, D. O. **The Organization of Behavior: A Neuropsychological Theory,** New York; Wiley, 1949.

KOVÁCS, Z. L. **Redes Neurais Artificiais Fundamentos e Aplicações,** Edição Acadêmica, São Paulo, 1996.

MANTOVANI, E. C. **Avalia: Programa de Avaliação da Irrigação por Aspersão e Localizada.** Viçosa, MG: UFV, 2001.

MÁSSON, Egill; WANG, Yih-Jeou. **Introduction to Computation and Learning in Artificial Neural Networks.** European Journal of Operational Research, North-Holand, 47, 1990. p. 1 - 28.

McCulloch, W.S.; Pitts, W. **A logical calculus of the ideas immanent in nervous activity.** Bulletin of Mathematical Biophysics, vol. 5, pp. 115-133. 1943.

MOREIRA, M. C.; CECILIO, R. A.; PINTO, F. A. C.; PRUSKI, F. **F. Desenvolvimento e análise de uma rede neural artificial para estimativa da erosividade da chuva para o Estado de São Paulo.** Rev. Bras. Ciênc. Solo [online]. vol.30, n.6, 2006

NAZARIO, S. L. S. **Caracterização do leite utilizando técnicas de ultra-som e redes neurais**. Dissertação de mestrado (engenharia elétrica), Universidade Estadual Paulista, Ilha Solteira, 2007.

OLIVEIRA, H. F. E.; COLOMBO, A.; FARIA, L. C. **Modelagem dos efeitos do vento sobre as dimensões do alcance do jato de um canhão hidráulico**. Revista Brasileira de Engenharia Agrícola e Ambiental v.13, p.818-824, 2009.

RICHTER, T. **Arquitetura de sistema inteligente para sensoriamento virtual de oxigênio em veículos bicompostíveis**. Dissertação de mestrado (engenharia elétrica), Universidade de São Paulo, São Carlos, 2009.

REDES NEURAIS – CONCEITO. Disponível em: <<http://www.solv.com.br/prof/redeneural/>>. Acesso em: 21 set. 2012.

RUMELHART, D. E.; MCCLELLAND, J. L.; WILLIAMS, R.J. **Learning representations of back-propagation errors**. Nature (London), vol 323, p533-536, 1986.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. **Learning internal representations by error propagation**. In: Parallel Distributed Processing, vol. 1, chapter 8. MIT Press, Cambridge, Massachusetts, USA. 1986a.

RUSSEL, J.J.; NORVIG, P. **Inteligência artificial un enfoque moderno - Segunda edición**. Pearson Educación, Madrid, 2004

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo; Artliber, 2010.

UNIVERSITY OF TÜBINGEN. **SNNS - User Manual, Version 4,2**. Tübingen, Alemanha. Disponível em: <<http://www.ra.cs.uni-tuebingen.de/downloads/SNNS/SNNSv4.2.Manual.pdf>>. Acesso em 18 nov. 2013.

WILCOX, J.C.; SWAILES, G.E. **Uniformity of water distribution by some under tree orchard sprinklers.** Scientific Agriculture, Ottawa, v.27, n.11,1947

