

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ PROGRAMA DE  
PÓS-GRADUAÇÃO EM TECNOLOGIAS COMPUTACIONAIS  
PARA O AGRONEGÓCIO

JOICE WOLFRANN

**REDES NEURAS ARTIFICIAIS PARA ESTIMAR A PRECIPITAÇÃO  
NA IRRIGAÇÃO POR ASPERSÃO**

PROJETO DE DISSERTAÇÃO

MEDIANEIRA-PR

2018

JOICE WOLFRANN

## **REDES NEURAS ARTIFICIAIS PARA ESTIMAR A PRECIPITAÇÃO NA IRRIGAÇÃO POR ASPERSÃO**

Dissertação apresentada ao Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio – PPGTCA – da Universidade Tecnológica Federal do Paraná – UTFPR – Campus Medianeira, como requisito parcial para obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio / Área de Concentração: Tecnologias Computacionais Aplicadas à Produção Agrícola e Agroindústria.

Orientador: Prof. Dr. Paulo Lopes de Menezes;

Coorientadora: Prof. Dra. Silvana Ligia Vincenzi.

MEDIANEIRA-PR

2018

## Dados Internacionais de Catalogação na Publicação

**W861r**

Wolfrann, Joice

Redes neurais artificiais para estimar a precipitação na irrigação por aspersão / Joice Wolfrann - 2018

100 f. : il. ; 30 cm.

Orientador: Paulo Lopes de Menezes

Coorientadora: Silvana Ligia Vincenzi

Dissertação (Mestrado) – Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio. Medianeira, 2018.

Inclui bibliografias.

1. Interpolação.
2. [Irrigação por aspersores](#).
3. [Inteligência computacional](#).
4. Tecnologias Computacionais- Dissertações. I. Menezes, Paulo Lopes de, orient. II. Vincenzi, Silvana Ligia, coorient. III. Universidade Tecnológica Federal do Paraná. Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio. IV. Título.

CDD: 004

Biblioteca Câmpus Medianeira

Marci Lucia Nicodem Fischborn 9/1219



Ministério da Educação  
**Universidade Tecnológica Federal do Paraná**  
Campus Medianeira  
Diretoria de Pesquisa e Pós-Graduação  
Mestrado em Tecnologias Computacionais para o Agronegócio



---

## TERMO DE APROVAÇÃO

### REDES NEURAIS ARTIFICIAIS PARA ESTIMAR A PRECIPITAÇÃO NA IRRIGAÇÃO POR ASPERSÃO

Por

**JOICE WOLFRANN**

Essa dissertação foi apresentada às quinze horas e trinta minutos, do dia dois de abril de dois mil e dezoito, como requisito parcial para a obtenção do título de Mestre em Tecnologias Computacionais para o Agronegócio, Linha de Pesquisa Tecnologias Computacionais Aplicadas à Produção Agrícola, no Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio - PPGTCA, da Universidade Tecnológica Federal do Paraná. A candidata foi arguida pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

---

Prof. Dr. Paulo Lopes de Menezes (Orientador – PPGTCA)

---

Prof. Dr. Alan Gavioli (Membro Interno – PPGTCA)

---

Prof. Dr. Marcio Antonio Vilas Boas (Membro Externo – UNIOESTE)

A via original com as assinaturas encontra-se na secretaria do programa.

*“a minha filha **Sabrina Eduarda Zanini  
Martins**”*

*Dedico.*

## **AGRADECIMENTOS**

Acima de tudo agradeço a Deus que iluminou meu caminho durante essa jornada.

Ao professor Dr. Paulo Lopes de Menezes pela orientação, paciência, confiança e oportunidade de trabalhar ao meu lado, bem como o incentivador do tema da dissertação.

A professora Dr. Silvana Ligia Vincenzi pela orientação, apoio e incentivo.

A minha filha Sabrina Eduarda Zanini Martins pela paciência, amor e por estar sempre do meu lado.

Aos meus pais Romeu Wolfrann e Dirce Faganello, por me terem dado educação, valores e por me terem ensinado a andar. Ao meu irmão Alex Sandro Wolfrann pelo apoio e carinho. A família é o alicerce da vida!

Ao meu namorado Gilmar Beckers por toda paciência, carinho, amor, compreensão, e por me ajudar muitas vezes mesmo com dificuldades.

A todos os meus colegas do mestrado em Tecnologias computacionais de agronegócio da UTFPR – Medianeira, que de alguma maneira contribuíram e ajudaram. Aos amigos que estiveram dando forças e incentivo de alguma maneira.

“O ser humano vivencia a si mesmo, seus pensamentos, como algo separado do resto do universo numa espécie de ilusão de óptica de sua consciência. E essa ilusão é um tipo de prisão que nos restringe a nossos desejos pessoais, conceitos e ao afeto apenas pelas pessoas mais próximas. Nossa principal tarefa é a de nos livrarmos dessa prisão ampliando nosso círculo de compaixão para que ele abranja todos os seres vivos e toda a natureza em sua beleza. Ninguém conseguirá atingir completamente este objetivo, mas lutar pela sua realização, já é por si só parte de nossa liberação e o alicerce de nossa segurança interior.”

**Albert Einstein**

## RESUMO

WOLFRANN, Joice. Redes neurais artificiais para estimar a precipitação na irrigação por aspersão. 2018. 100f. Dissertação (Mestrado em tecnologias computacionais para o agronegócio), Universidade Tecnológica Federal do Paraná, Campus Medianeira, 2018.

Este trabalho apresenta uma abordagem teórico-conceitual do modelo de irrigação por aspersão relatando seus métodos, eficiência e manejo. Apresenta os conceitos, técnicas de aprendizado, topologias e algoritmos para treinamento das redes neurais artificiais. O objetivo da pesquisa foi construir um modelo baseado nas redes neurais artificiais capazes de estimar as precipitações de um aspersor. Foi usado o algoritmo de treinamento *backpropagation* com e sem o termo *momentum* e várias taxas de aprendizado a fim de conduzir para a escolha da melhor rede fazendo uso do software SNNS. A rede (6X459X1) com 6 neurônios na camada de entrada, 459 na camada oculta e 1 na camada de saída foi a que apresentou o menor erro (MSE) é obtida com taxa de aprendizado á 0,7 e com o uso do termo *momentum* ( $\mu=0,3$ ). As simulações apresentaram bons resultados na análise estatística, com coeficiente de determinação ( $R^2$ ) igual a 0,93 para o ajuste linear, e distribuição normal para Lilliefors. A análise por Anova refletiu homogeneidade válida e hipótese aceita para o teste de Cochran C e Bartlett. O coeficiente de Pearson resultou em uma correlação muito forte entre os resultados simulados e observados, e a comparação deu-se em torno de 0,0 a 0,29 mm de precipitação. Os testes se mostraram promissores em termos estimativos para a irrigação por aspersão.

**Palavras-chave:** ensaio de aspersor, modelagem matemática, métrica de espaço, interpolação.

## ABSTRACT

WOLFRANN, Joice. Artificial neural networks to estimate precipitation in sprinkler irrigation 2018. 100f. Dissertation (Master in Computational Technologies for Agribusiness), Federal Technological University of Paraná, Campus Medianeira, 2018.

This work presents a theoretical-conceptual approach of the sprinkler irrigation model, reporting its methods, efficiency and management. It presents the concepts, learning techniques, topologies and algorithms for the training of artificial neural networks. The objective of the research was to build a model based on artificial neural networks capable of estimating the precipitation of a sprinkler. The backpropagation training algorithm was used with and without the term momentum and several learning rates in order to lead to the choice of the best network using SNNS software. The network (6X459X1) with 6 neurons in the input layer, 459 in the hidden layer and 1 in the output layer was the one that presented the lowest error (MSE) obtained with a learning rate of 0.7 and with the use of the term moment ( $\mu = 0.3$ ). The simulations presented good results in the statistical analysis, with coefficient of determination ( $R^2$ ) equal to 0.93 for linear adjustment and normal distribution for Lilliefors. Anova's analysis reflected valid homogeneity and accepted the hypothesis for the Cochran C and Bartlett test. The Pearson coefficient resulted in a very strong correlation between the simulated and observed results, and the comparison was around 0.0 to 0.29 mm of precipitation. The tests were promising in terms of estimates for sprinkler irrigation.

**Keywords:** test sprinkler, modeling mathematical, space metric and interpolation.

## LISTA DE FIGURAS

Figura 1 - Métodos de irrigação.....	22
Figura 2 - Aspersion rotativo de impacto .....	25
Figura 3 - Disposição dos pluviômetros em torno do aspersion central em malha ...	32
Figura 4 - Pontos encontro da distância euclidiana.....	37
Figura 5 - Representação de um neurônio simplificada. ....	39
Figura 6 - Função de ativação degrau limiar .....	40
Figura 7 - Função de ativação logística.....	41
Figura 8 - Função de ativação tangente hiperbólica.....	41
Figura 9 - Modelo não linear de um neurônio.....	42
Figura 10 - Curva de erro MSE, generalização da rede: overfitting e underfitting .....	47
Figura 11 - Tipos de correlações lineares. ....	52
Figura 12 - Fluxograma de atividades. ....	57
Figura 13 - Reta parcial do modelo simulado.....	58
Figura 14 - Reta contendo as distâncias calculadas .....	59
Figura 15 – Menor erro MSE observado versus as épocas de treinamento.....	68
Figura 16 - Curva de treinamento da RNA pelo menor erro MSE .....	69
Figura 17 - Dispersão do teste 1 entre as amostras Observado e o Simulado .....	71
Figura 18 - Dispersão do teste 2 entre as amostras Observado e o Simulado .....	72
Figura 19 - Dispersão do teste 3 entre as amostras Observado e o Simulado .....	72
Figura 20 - Dispersão do teste 4 entre as amostras Observado e o Simulado .....	73
Figura 21 - Dispersão do teste 5 entre as amostras Observado e o Simulado .....	73
Figura 22 – Dispersão do teste 6 entre as amostras Observado e o Simulado .....	74
Figura 23 - Dispersão do teste 7 entre as amostras Observado e o Simulado .....	74
Figura 24 - Dispersão do teste 8 entre as amostras Observado e o Simulado .....	75
Figura 25 - Relação das distâncias do modelo simulado e observado do teste 1 .....	76
Figura 26 - Relação das distâncias do modelo simulado e observado do teste 2 .....	76
Figura 27 - Relação das distâncias do modelo simulado e observado do teste 3 .....	77
Figura 28 - Relação das distâncias do modelo simulado e observado do teste 4 .....	77
Figura 29 - Relação das distâncias do modelo simulado e observado do teste 5 .....	78
Figura 30 - Relação das distâncias do modelo simulado e observado do teste 6 .....	78
Figura 31 - Relação das distâncias do modelo simulado e observado do teste 7 .....	79
Figura 32 – Relação das distâncias do modelo simulado e observado do teste 8 .....	79

Figura 33 - Comparação das médias em relação às amostras .....	81
Figura 34 - Dispersão dos dados referente aos testes .....	82
Figura 35 - Análise comparativa das médias e as variâncias das amostras .....	83
Figura 36 - Independência das amostras .....	83
Figura 37 - Mapa de isolinhas do teste 1 .....	84
Figura 38 - Mapa de isolinhas do teste 2 .....	85
Figura 39 - Mapa de isolinhas do teste 3 .....	85
Figura 40 - Mapa de isolinhas do teste 4 .....	86
Figura 41 - Mapa de isolinhas do teste 5 .....	86
Figura 42 - Mapa de isolinhas do teste 6 .....	87
Figura 43 - Mapa de isolinhas do teste 7 .....	87
Figura 44 - Mapa de isolinhas do teste 8 .....	88

## LISTA DE TABELAS

Tabela 1 - Métodos de irrigação e seus subsistemas .....	23
Tabela 2 - Categorias do sistema de aspersão mecanizado.....	25
Tabela 3 - Classificação dos componentes do sistema por aspersão.....	26
Tabela 4 - Formas dos perfis de distribuição de água por Christiansen.....	31
Tabela 5 – Interpretação dos valores CUC, CUE e CUD do sistema de irrigação ....	34
Tabela 6 - Interpretação dos valores de correlação. ....	52
Tabela 7 - Topologia da rede com parâmetros e configurações específicas .....	61
Tabela 8 – Exemplo do padrão SNNS para o arquivo usado com a extensão ‘.pat’.	62
Tabela 9 - Quantidade de amostras para a execução das RNAs.....	62
Tabela 10 – Valores de $R^2$ da correlação entre os valores observados e simulados pela RNA treinada com o algoritmo <i>backpropagation</i> sem o termo <i>momentum</i> .....	66
Tabela 11 - Valores de $R^2$ da correlação entre os valores observados e simulados pela RNA treinada com o algoritmo <i>backpropagation</i> com o termo <i>momentum=0,3</i>	67
Tabela 12 – Estatística descritiva da melhor RNA. ....	70
Tabela 13 - Teste de Lilliefors (Kolmogorov-Smirnov) para as amostras resultantes da análise da RNA entre observado e o simulado .....	80
Tabela 14 - Correlação de Pearson entre o modelo observado e o simulado.....	80
Tabela 15 – Estatística da ANOVA aninhada entre dados e fatores .....	81

## LISTA DE SIGLAS

<b>ANOVA</b>	Análise De Variância
<b>JNNS</b>	Simulador de redes neurais em Java
<b>MLP</b>	Perceptron Multi-Camadas
<b>mca</b>	Metros de coluna de água
<b>MSE</b>	Erro médio quadrático
<b>r</b>	Coefficiente de Pearson
<b>R<sup>2</sup></b>	Coefficiente de determinação
<b>RNAs</b>	Redes neurais artificiais
<b>SNNS</b>	Simulator redes neurais Stuttgart

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>16</b>
1.1	PROBLEMÁTICA	17
1.2	JUSTIFICATIVA	18
1.3	OBJETIVOS GERAIS	18
1.4	OBJETIVOS ESPECÍFICOS	18
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA</b>	<b>20</b>
2.1	ESTADO DE CONHECIMENTO	20
2.2	O SOLO, ÁGUA E O CLIMA	21
2.3	IRRIGAÇÃO	22
2.3.1	A Irrigação Por Aspersão	24
2.3.1.1	Componentes de um sistema de irrigação por aspersão	25
2.3.2	Manejo Racional Da Irrigação	27
2.3.3	Eficiência Da Irrigação	28
2.3.4	Distribuição e espaçamento dos aspersores	30
2.3.5	Uniformidade de distribuição	31
2.4	UNIFORMIDADE DE APLICAÇÃO	32
2.4.1	Coeficiente de Uniformidade de Chistiansen (CUC)	33
2.4.2	Coeficiente de Uniformidade de Distribuição (CUD)	33
2.4.3	Coeficiente Estatístico de Uniformidade (CUE)	34
2.4.4	Classificação dos coeficientes CUC, CUD e CUE	34
2.5	MODELAGEM MATEMÁTICA	35
2.5.1	Medidas De Distância	36
2.5.2	Distância Euclidiana	36
2.5.3	Geometria Analítica	37
2.5.4	Interpolação espacial	38
2.6	INTELIGÊNCIA COMPUTACIONAL	38
2.6.1	Redes Neurais Artificiais	39
2.6.1.1	Processo De Aprendizagem	42
2.6.1.2	Arquitetura da Rede Neural Artificial	43
2.6.1.3	Modelo perceptron	44
2.6.1.4	Múltiplas camadas perceptron (MLP)	44
2.6.1.4.1	<i>Algoritmo de treinamento BackPropagation (Retropropagação)</i>	<i>45</i>
2.6.1.4.2	<i>Backpropagation com momentum</i>	<i>45</i>
2.6.2	Generalização	46
2.6.3	Normalização dos Dados	47
2.6.4	Treinamento da RNA	48
2.7	MÉTODOS ESTATÍSTICOS	48
2.7.1	Teste de Lilliefors (Kolmogorov-Smirnov)	49
2.7.2	Análise De Variância (ANOVA)	50
2.7.3	Coeficiente De Correlação e Determinação	51
<b>3</b>	<b>METODOLOGIA</b>	<b>54</b>
3.1	LEVANTAMENTO DE DADOS	54
3.2	AMBIENTE DE EXPERIMENTO	55
3.3	TECNOLOGIAS ENVOLVIDAS	55
3.4	FLUXOGRAMA	57
3.5	DESENVOLVIMENTO DO EXPERIMENTO	58

3.5.1	Modelagem Da Distribuição Das Distâncias Parciais Do Modelo	
	Observado .....	58
3.5.1.1	Interação .....	58
3.5.1.2	Matematização .....	59
3.5.1.3	Modelo matemático .....	59
3.5.2	Tratamento Dos Dados .....	59
3.5.3	Desenvolvimento Para Construir as Rnas Multilayer Perceptron (MPL) ..	60
3.5.4	Topologia Da Rede.....	60
3.5.5	Ajuste Dos Parâmetros e Dados Da Rede .....	61
3.5.6	Treinamento da MLP .....	63
3.5.7	Pós-processamento da RNA .....	63
3.5.8	Estatística Da Rna.....	64
<b>4</b>	<b>ANÁLISE DE RESULTADOS.....</b>	<b>65</b>
4.1	MELHOR TOPOLOGIA DA REDE .....	65
4.2	ESCOLHA DA MELHOR REDE .....	69
4.3	ESTATÍSTICA DA REDE.....	69
<b>5</b>	<b>CONSIDERAÇÕES FINAIS.....</b>	<b>89</b>
<b>6</b>	<b>TRABALHOS FUTUROS .....</b>	<b>90</b>
	<b>REFERÊNCIAS.....</b>	<b>91</b>

## 1 INTRODUÇÃO

A água e o solo são elementos fundamentais para a sustentação dos sistemas agrícolas e naturais. O solo é importante para a produção de alimentos, e a água é o componente bioquímico dos seres vivos e das várias espécies de vegetais e animais. O uso da água cresce continuamente na agricultura irrigada, demonstrando preocupação na gestão de suprimento pela quantidade do desperdício e na conservação da qualidade, que é vital para a sustentabilidade e bens de consumo para a vida humana (GOMES; BARBIERI, 2004).

A natureza está fortemente ligada com o solo e o clima, as alterações que ocorrem por troca de reações do ecossistema podem tanto prejudicar como beneficiar uma determinada cultura. A precipitação fluvial é um dos fenômenos físicos decorrentes da variabilidade climática que exerce grande influência no controle hidrológico e na qualidade do meio ambiente (BORGES; THEBALDI, 2016), sendo a precipitação na meteorologia um atributo climático que determina a queda de água por algum fenômeno que relaciona períodos de seca ou chuva (SANTOS; GALVANI, 2014).

A irrigação é uma aplicação artificial da água para que a terra tenha fins de produção agrícola, agregada com as etapas de preparo do solo, germinação, crescimento da raiz, utilização de nutrientes, crescimento da planta, rebrota, rendimento e qualidade da produção (TESTEZLAF, 2017).

O método de irrigação é diferenciado pela maneira ou local no solo onde a água vai ser disponibilizada, portanto, deve-se selecionar o sistema mais adequado para cada condição e objetivos da produção (TESTEZLAF, 2011). A irrigação por aspersão, a qual é foco deste estudo, é um tipo de aplicação caracterizada pela divisão de um ou mais jatos de água em uma grande quantidade de gotas pelo ar, que caem em forma de chuva artificial. O ensaio radial se baseia no fato do método de irrigação ser adicionado em uma única reta, diferente do ensaio em malha que se refere ao modelo total realizado em campo.

A agricultura irrigada tem sido uma importante atividade na macroeconomia, e no crescimento da cadeia de produção, pois quanto mais acrescentar o trabalho técnico para o cultivo (utilização de adubos, defensivos químicos, irrigação, implementos agrícolas) maior é a contribuição da agricultura ao mercado interno e

externo (VANZELA; ANDRADE, 2002). Junto ao crescimento, desenvolvimento tecnológico e metodologias de manejo, a irrigação tem se tornado um sinônimo de produção, modernidade e garantia para a qualidade dos produtos (LÉO; HERNANDEZ, 2001).

As redes neurais artificiais (RNAs) são modelos matemáticos que se assemelham às estruturas neurais biológicas e tem a capacidade de aprender com a experiência. O aprendizado de uma rede neural é um processo pelo qual os parâmetros são adaptados através dos estímulos do meio onde ela está inserida, na fase de treinamento, até obter a resposta desejada (HAYKIN, 2001). O Algoritmo de treinamento *backpropagation* se baseia no fato de fazer uma retropropagação dos erros para realizar os ajustes dos pesos nas suas camadas intermediárias e assim ter uma resposta próxima ou igual à desejada.

A pesquisa construiu um modelo em redes neurais artificiais (RNA) capaz de estimar a precipitação de um aspersor em um ensaio radial. E com base de análises estatísticas verificarem a eficiência do modelo comparando os valores simulados e os observados.

## 1.1 PROBLEMÁTICA

Em um sistema de irrigação se não for acompanhado o funcionamento e feitas as devidas medições de eficiência a operação do sistema pode ser tornar cara, pois poderá haver desperdício de água e energia. Realizar ensaios completos de irrigação pode ser custoso (caro) e depende de mobilizar pessoal em campo, o que é trabalhoso. Então, há de se estudar formas de fazer avaliações da eficiência dos sistemas de irrigação de maneira mais barata e ainda assim confiáveis. Com estas observações resume-se a problemática deste trabalho: É possível prever a precipitação de um aspersor em um ensaio radial por meio de um modelo baseado nas redes neurais?

A proposta do trabalho é avaliar o desempenho das redes neurais artificiais como simulador dos dados de aspersão a fim de dispensar ensaios completos, fazendo ensaios parciais, que serão complementados com simulações.

## 1.2 JUSTIFICATIVA

A irrigação é uma prática agrícola que visa suprir a deficiência de água de forma total ou parcial nas plantas. Desenvolvida para melhorar o pacote tecnológico de produtor rural, tornando terras sem produtividade em campos sustentáveis (ANA, 2017). O objetivo dessa técnica é uma crescente produção de alimentos para amenizar a fome do mundo e assim obter um aumento na economia do país (SILVA; SILVA; PIRES, 2014).

De acordo com Bernardo (2009) para que a área aplicada fique uniformemente até atingir a necessidade satisfatória é importante verificar a distribuição de água e o espaçamento entre os aspersores. Existem vários fatores no aspersor que podem afetar direta e indiretamente essa uniformidade, como: bocal, pressão de operação, e outros fatores como superposição e vento.

Diminuir os custos da avaliação do desempenho de aspersores, através do uso de simulações para complementar os ensaios observados no campo é objeto de vários estudos (PRADO; COLOMBO, 2010).

## 1.3 OBJETIVOS GERAIS

Construir um modelo em redes neurais capaz de estimar e simular a precipitação de aspersores em ensaios radiais.

## 1.4 OBJETIVOS ESPECÍFICOS

A pesquisa tem como objetivo descrever as seguintes etapas:

- a) Desenvolver um algoritmo computacional que seja capaz de criar um conjunto de RNA;
- b) Selecionar dentro deste conjunto aquela rede que obtiver o menor erro MSE.

- c) Avaliar através de métodos estatísticos a eficácia e normalidade da simulação do ensaio radial pela RNA.

## 2 FUNDAMENTAÇÃO TEÓRICA

O presente capítulo tem um breve embasamento inicial explicando em tópicos os conceitos sobre o solo, água e clima, de como funciona uma irrigação, manejo e tipos existentes. Destaca sobre o método de irrigação por aspersão que é o tema abordado pela pesquisa e referencia sobre os conceitos dos coeficientes de uniformidade CUC, CUD e CUE.

Outro tópico aborda sobre as redes neurais artificiais seu processo de aprendizagem, arquitetura da rede, modelo de MLP de Perceptron e o algoritmo *backPropagation* e o termo *momentum*.

A análise estatística resume-se na análise descritiva, Anova, coeficiente de correlação Pearson e Lilliefors (Kolmogorov-Smirnov).

### 2.1 ESTADO DE CONHECIMENTO

As RNAs têm sido usadas para solucionar uma variedade de problemas entre eles aqueles que se adequam a predição, reconhecimento de padrões, modelagens, processamento de dados e análises. O advento de *Deep Learning* também é uma forma eficiente de construir modelos para a extração de informações complexas, sendo bastante aplicada e testada com problemas de reconhecimento de imagens, fala e objetos. Outra evolução é o uso de redes convolucionais que alcançaram grandes avanços na representação e processamento de imagens, voz, vídeos (LECUN; BENGIO; HINTON, 2015).

Redes neurais por convolução são técnicas amplamente utilizadas para tal tarefa, por ser considerado o estado-de-conhecimento nesse contexto e pela alta disponibilidade de implementações com código aberto, bem como por serem constantemente aprimoradas durante os últimos anos. Dentre os trabalhos desenvolvidos com similaridade nesta área se observa o de Menezes et al. (2015) com o modelo em RNAs para a simulação da precipitação na irrigação por aspersão, no qual foram desenvolvidos os ensaios de malha em campo e a comparação com os modelos simulados, onde se observou um resultado promissor no uso da RNA

aplicadas na irrigação. Grandes partes das pesquisas que contribuem para o modelo de irrigação por aspersão mencionam o estudo do perfil de aspersores a partir de ensaios na distribuição de água (PRADO; COLOMBO, 2010).

Entre outras pesquisas relacionadas à área, no trabalho de Faria et al. (2009) relata sobre a simulação da uniformidade da irrigação de sistemas convencionais de aspersão operando sobre diferentes condições de vento, com o objetivo de usar a modelagem matemática e a uniformidade de aplicação de água para realizar simulações, a fim de verificar a distribuição espacial de água aplicada pelo canhão (PLONA-RL250), operando em diversas situações de vento.

## 2.2 O SOLO, ÁGUA E O CLIMA

O solo é constituído de partículas sólidas, líquidas e gasosas de origem mineral e orgânica, está estruturado em camadas denominadas horizonte e sujeito a constantes transformações nos processos de adição, remoção, translocação de natureza química, física e biológica (MENDONÇA, 2006). A umidade do solo influencia diretamente no volume de água armazenado e sua resistência na forma de compactação do solo (BERNARDO, 2009).

A água é o meio de transporte básico para levar os nutrientes essenciais que constituem o solo até as raízes da planta, desta forma as plantas utilizam parte na absorção de partículas sólidas (orgânicas e minerais) e a outra sofre o processo de escoamento superficial que retorna a atmosfera no processo de evaporação (GILLES et al., 2009). A água é responsável pela constituição do metabolismo vegetal das plantas e reação fotossintética, pois se ocorrer desidratação dos tecidos vegetais devido à falta de fotossíntese, acarreta na morte da planta. A eficiência do uso da água é importante para a sobrevivência de plantas em condições de baixa disponibilidade hídrica e proporcional a uma produtividade com qualidade e eficiência (PIMENTEL, 2004).

O clima na meteorologia é uma descrição estática que designa as condições do estado atmosférico em determinada região, com base em descrições climatológicas (calor, precipitação pluvial, umidade relativa, luminosidade, fotoperiodismo e sazonalidade) (PEREIRA; ANGELOCCI; SENTELHAS, 2007). A

precipitação pluvial é um atributo climático que determina a queda de água por algum fenômeno, e que exerce grande influência no controle hidrológico e na qualidade do meio ambiente (BORGES; THEBALDI, 2016) relacionado com períodos de seca ou chuva (SANTOS; GALVANI, 2014).

Estatisticamente, quando os valores das precipitações se encontram fora da variabilidade climatológica e o índice de chuva está acima ou abaixo é importante que haja intervenção por técnicas de irrigação ou escoamento, que contribua para obter benefícios ao meio agrícola (SANTOS; GALVANI, 2014) e com toda a cadeia de produção relacionada (plantio, colheita, transporte, armazenagem e comercialização) (PEREIRA; ANGELOCCI; SENTELHAS, 2007).

### 2.3 IRRIGAÇÃO

A irrigação é uma prática em aplicar a água artificialmente nas plantas, objetivando fornecer a quantidade adequada para a sua sobrevivência. Aliada com outras operações agrícolas tais como adubação, mecanização, controle de pragas e doenças contribui para o aumento da produtividade (ANA, 2017).

Os principais métodos de irrigação vistos na Figura 1, são empregados em lavouras e plantações, e empregados conforme a forma de aplicação da água. Constituem basicamente em: de superfície, por aspersão ou chuva artificial, localizada e subsuperfície.



**Figura 1 - Métodos de irrigação**  
Fonte: Retirada de Testezlaf (2017).

Subdivididos em subsistemas como mostra a Tabela 1, do qual operam com distintos conjuntos de equipamentos, acessórios, formas de manejo e operações.

**Tabela 1 - Métodos de irrigação e seus subsistemas**

<b>Método</b>	<b>Sistemas</b>
Superfície	Sulcos; Inundação;
Aspersão	Convencional com linhas laterais ou em malha; mangueiras perfuradas; carretel; enrolador; pivô central.
Localizada	Gotejamento; Microaspersão;
Subsuperfície	Gotejamento Subterrâneo; Subirrigação.

**Fonte: ANA (2017).**

O método por superfície ou irrigação por gravidade, é dividido em sulcos (a água é aplicada pela inundação parcial, podendo ser conduzida por tubulações até o ponto de aplicação) e inundação (a distribuição da água se dá pela gravidade através da superfície do solo) (BERNARDO, 2009). Por aspersão são lançados jatos de água ao ar, sobre a pressão dos aspersores ou orifícios que caem sobre a cultura em forma de chuva (ANA, 2017).

Para o método localizado (microirrigação) a água é aplicada ao solo sobre uma frequência de baixo ou alto volume para que a umidade fique ideal para a planta, as formas de distribuição deste método podem ser por meio de emissores pontuais (gotejadores), lineares (tubo poroso) ou superficiais (microaspersores) (SOUZA; ANDRADE; SILVA, 2005).

No método de subsuperfície ou subirrigação a área deve ser plana ou nivelada de maneira que o lençol freático é mantido a certa profundidade, permitindo um fluxo adequado à zona radicular da cultura (ANDRADE; BRITO, 2010). Na subirrigação por gotejamento subterrâneo as linhas são enterradas no solo para que a água atinja as raízes. O método de subsuperfície de elevação do lençol freático é empregado por áreas de impedimento, que permite saturar o solo deixando próximas as raízes. Em ambientes protegidos usa o princípio da aplicação de água diretamente as raízes das culturas (TESTEZLAF, 2017).

### 2.3.1 A Irrigação Por Aspersão

BERNARDO (2009, p.361) define a irrigação por aspersão como sendo:

Um método em que a água é aspergida sobre a superfície do terreno, assemelhando-se a uma chuva, por causa do fracionamento do jato de água em gotas, devido a sua passagem sobre pressão de pequenos orifícios e bocais.

É classificado como aquele que opera sobre uma tabulação com aspersores instalados em seu comprimento ou lateral, e sistemas que operam a partir de um aspersor sobre alta pressão ou vazão (TESTEZLAF, 2017). Podendo ser dividido pelas seguintes categorias (BERNARDO, 2009):

- a) Sistema de aspersão móvel:
  - I. Sistema com movimentação manual: sistema de aspersão portátil, semi portátil, canhão hidráulico portátil, mangueira;
  - II. Sistemas com movimentação mecânica: sistema de aspersão sobre rodas, com deslocamento longitudinal e lateral; pivô central; auto propelido com canhão hidráulico;
- b) Sistema de aspersão fixo: fixo portátil, fixo permanente e em malha;

O sistema convencional portátil é caracterizado por poder movimentar o equipamento de um lado para o outro, conforme a necessidade da irrigação, a disposição dos equipamentos e a abrangência da área irrigada. O sistema semi portátil dispõe de uma linha principal enterrada com hidrantes dispostos na superfície e em cada ponto de mudança nas linhas laterais. No sistema convencional permanente as tubulações são fixas e não movidas, dessa forma classificasse por cobrir toda uma área totalmente permanente ou parcialmente no qual as canalizações são portáteis (BISCARO, 2009).

O sistema de aspersão mecanizado tem como objetivo irrigar grandes áreas, para que ocorra a movimentação o equipamento é montado sobre rodas, e dividido em três categorias, apresentadas na Tabela 2.

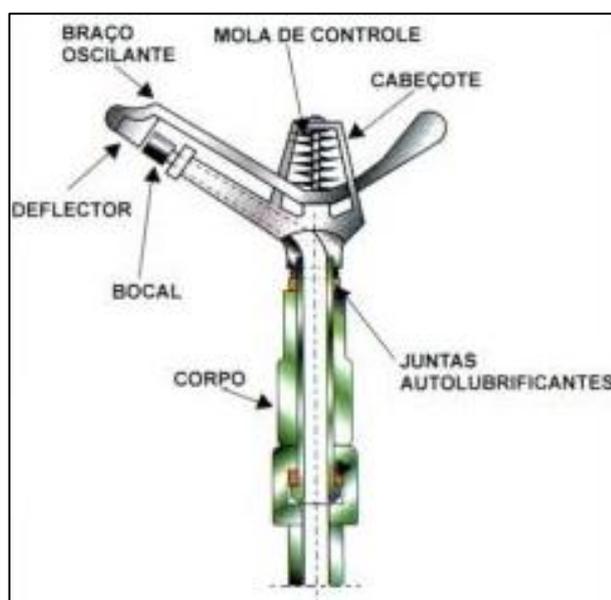
**Tabela 2 - Categorias do sistema de aspersão mecanizado**

<b>Categoria</b>	<b>Descrição</b>
Linha lateral móvel	Composto por uma linha lateral que deslocasse á fonte fornecedora de água pode ser tubulações ou canal de água;
Auto propelido	Movimentado por energia hidráulica e possui um aspersor do tipo canhão, montado em uma plataforma de rodas, com carretel que contém mangueira enrolada, considerada um sistema de médio porte;
Pivô central	Contém uma linha lateral suspensa por torres de sustentação dotadas de rodas e motores, e que gira em torno de um ponto central, denominado pivô.

**Fonte: Adaptado de Stone (2016) e Biscaro (2009).**

### 2.3.1.1 Componentes de um sistema de irrigação por aspersão

O aspersor é o responsável pela pulverização do jato de água (aspersor rotativo demonstrado na Figura 2), sendo a pressão responsável pela formação das gotículas em formato de chuva.



**Figura 2 - Aspersor rotativo de impacto**  
**Fonte: Silva (2014).**

O aspersor necessita de outros componentes que operem em conjunto, tais quais:

- Moto bomba: responsável pela captação de água e sucção. Pode ser do tipo eixo horizontal, centrífuga ou turbina (usado para poços profundos),

os principais tipos de motores o elétrico, a diesel e a gasolina (BERNARDO, 2009);

- b) Tubulação: responsável pela condução da água desde a moto bomba até os aspersores. Constituída por linhas secundárias (laterais), linhas de derivação, linha principal, linha de recalque e linha de sucção (BISCARO, 2009);
- c) Acessórios: registro, manômetro, curvas, cotovelo, niple, tampão, tê, cruzeta, redução, braçadeira, válvulas (retenção, pé, derivação), pé de suporte, tripé e tubo de subida. Sendo estes os mais comuns (BERNARDO, 2009).

A escolha dos critérios para a classificação de um aspersor é detalhada na Tabela 3, responsável pelo mecanismo de movimento e fragmentos do jato de água na distribuição do solo (TESTEZLAF, 2017).

**Tabela 3 - Classificação dos componentes do sistema por aspersão**

<b>Classificação</b>	<b>Descrição</b>
Sistema de rotação	Rotativos ou estacionários;
Ângulo de inclinação do jato com a horizontal	Na maioria a inclinação padrão é 30 <sup>o</sup> , para uso em subcopa inclinação de 4 <sup>o</sup> á 6 <sup>o</sup> ;
Número de bocais	Apresentam um ou mais bocais, caracterizado por bocais de diferentes diâmetros em milímetros.
Tipo de movimentação	Aspersor pode girar de forma contrária, devido à movimentação da palheta. Definido em quatro grupos:
Relação ao tamanho da pressão do serviço	I. Aspersores de pressão de serviço muito baixa; II. Pressão de serviço baixa; III. Pressão de serviço média; IV. Aspersores gigantes ou canhão hidráulico.

**Fonte: Ajustado de Biscaro (2009) e Bernardo (2009).**

Uma boa uniformidade sobre a área irrigada condiz com uma adequada superposição entre os perfis de distribuição, sendo o vento um fator que acarreta muito no prejuízo na formação das gotas, pois quanto maior a sua velocidade, menor é o diâmetro das gotas e menor é o poder de aplicação. A distribuição do jato

de água nos aspersores varia de bocal e tipo, pois a bocais de longo alcance e com vazão proporcional a superfície a ser irrigada. A pressão e diâmetro do bocal são responsáveis pela pulverização do jato da água, em casos de pressão muito alta ocorrerão excessos, e sendo baixa a pulverização pode ocorrer de forma inadequada.

Em relação ao tamanho e pressão de serviço dos aspersores apresentados na Tabela 3, explicasse que os aspersores de pressão muito baixa possuem um raio pequeno de ação. Com a pressão variando de 4 a 10 mca (metros de coluna de água) aplicado mais em jardins. Aspersores de pressão baixa possuem alcance de 6 a 12m e pressão de 10 e 20 mca. Usados em irrigação de sub copa de pomares e pequenas áreas. Os aspersores de médio porte possuem um raio de ação entre 12 e 36m e pressão de 20 e 40 mca. Encontrado em vários tipos de culturas e solo. Já os aspersores gigantes trabalham de médio e longo alcance entre raio de ação 40 a 80 mca e pressão de 30 e 60m, operando mais em irrigações de pastagens, cana de açúcar e sistemas autopropelidos (BERNARDO, 2009).

Os aspersores rotativos apresentam o movimento de rotação em três formas: a por reação, impacto ou engrenagens. O movimento de reação ou impulsão é o processo no qual o impulso é originado pela força de dois ou mais jatos horizontais, criado por bocais direcionados a sentidos opostos. O movimento por impacto baseia-se na força do choque entre o defletor e o braço oscilante, como o braço fica conectado a uma mola, criasse o movimento de rotação. E no movimento de engrenagens a água passa por dentro de uma turbina que movimenta um conjunto de engrenagens e rotaciona a parte superior do equipamento até o local de aplicação da água (TESTEZLAF, 2017).

### 2.3.2 Manejo Racional Da Irrigação

Boas práticas de manejo condiz em obter aspectos propícios para a economia de água, como a melhor seleção do método que se adapta aos aspectos climáticos, da cultura, solo, topografia, energia, disponibilidade de água, mão de obra e custo da implementação (CALHEIROS et al., 2009). A fim de evitar falhas, é

importante desenvolver um planejamento no qual o sistema de irrigação será aplicado, bem como na instalação, operação, manutenção e manejo (BERNARDO, 2009). Esses aspectos são importantes para avaliar uma irrigação com eficiência, e quantificar a condição física, química e biológica do solo. Como o controle da planta em sua sensibilidade, estresse hídrico, estágio de desenvolvimento, suscetibilidade e déficit hídrico (PIRES et al., 2008).

A fonte de água do qual abastece o sistema de irrigação também é fator que pode acarretar na destruição dos equipamentos, pois podem conter quantidades de matérias sólidas suspensas e danificar os bocais. Devido a isso é necessário instalar um sistema de filtragem a fim de retirar as partículas e propiciar um manejo adequado à irrigação. Porém outros fatores podem influenciar no desgaste abrasivo dos bocais como a densidade, pressão de funcionamento, tipo de material, vazão, ângulo de impacto das partículas sólidas e diversidades do campo (SANDRI; MATSURA; TESTEZLAF, 2003).

O conhecimento do usuário e treinamentos de técnicos é um fator importante para o sucesso do projeto de irrigação, pois necessitam de etapas para os processos básicos de operações em planejamento, construção, manutenção, viabilidade e dimensionamento a fim obter um aumento de produtividade, maior eficiência no uso de fertilizantes e geração na escala de produção (BERNARDO, 2009).

### 2.3.3 Eficiência Da Irrigação

A eficiência no uso da água é uma forma de analisar as diferentes condições da disponibilidade, buscando aumentar o rendimento quantitativo das culturas para obter um melhoramento em relação da biomassa e produção agrícola (DANTAS JUNIOR; CHAVES, 2014). A eficiência de aplicação ( $E_a$ ) é a medida entre a relação do volume de água disponível para a cultura e o volume aplicado sobre o emissor ( $V_a$ ), visto na Equação 1 (FRIZZONE, 2013):

$$E_a = (V_s / V_a) * 100 \quad (1)$$

Onde:  $V_s$  é a lâmina média aplicada.

Planejamento, uso racional dos recursos hídricos, manejo da água e gestão de melhoria da produção são aspectos importantes à eficiência da produção agrícola irrigada (CONCEIÇÃO, 2005).

Porém conta com alguns aspectos negativos decorrentes da perda por percolação, evaporação, arrastamento do vento por um vazamento no sistema de irrigação e relação com a lâmina de aplicação, que consiste na lâmina mínima e média total sobre a área aplicada. A perda por percolação é relacionada com o coeficiente de uniformidade do sistema, de forma que, quanto maior o valor do coeficiente, menor é a redução. A perda por evaporação e arrastamento do vento é ocasionada pelo aumento da temperatura do ar, velocidade do vento, fracionamento do jato, pressão da operação do aspersor e redução da umidade do ar. Um parâmetro que reflete estas perdas é calculado na Equação 2 (BERNARDO, 2009):

$$E_{Ap} = (LMc * S1 * S2) / (Qa * Ti * 36) \quad (2)$$

Onde:

$E_{Ap}$ : é eficiência da aplicação em %;

$LMc$ : lâmina média coletada;

$Qa$ : vazão média do aspersor;

$Ti$ : tempo de irrigação;

$S1$ : espaçamento entre aspersores em metros;

$S2$ : espaçamento entre laterais em metros;

A Equação 3, determina a perda por evaporação e arrastamento do vento (PV).

$$PV = 100 - E_{ap} \quad (3)$$

A Equação 4 é definida para avaliar a eficiência de irrigação por aspersão ( $E_{Apa}$ ).

$$E_{Apa} = E_{Dpa} * E_{Ap} \quad (4)$$

No qual: EAp<sub>a</sub> é a eficiência da aplicação, pa % da área irrigada;

EDpa: eficiência da distribuição;

EAp: eficiência da aplicação em decimal.

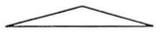
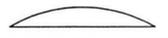
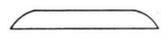
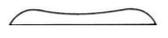
Em conjunto com os avanços tecnológicos se torna favorável verificar a eficiência através do monitoramento de imagens por satélites (que contribui com melhorias de grandes áreas irrigadas, com possibilidade de extrair índices de vegetação do local, para a estimativa de evapotranspiração da planta), criação de sensores (umidade), dossel, comunicação com sistemas inteligentes de irrigação e mecanismos de alta entrega em eficiência da água e nutrientes. Essas práticas inovadoras contribuem para uma melhor utilização dos recursos hídricos, redução de encargos ambientais, e elenca uma maior produtividade ao produtor (LEVIDOW et al., 2014).

#### 2.3.4 Distribuição e espaçamento dos aspersores

Há normas que padronizam a curva de distribuição de água do aspersor. A pesquisa aborda o método em malha e radial. No método completo em campo (malha) o aspersor é posicionado na posição central em um malha de coletores. Já no radial são instalados ao longo de uma reta que é definida a partir do centro do aspersor. Cada aspersor gera uma curva de distribuição de água que varia no tamanho do bocal, pressão de operação, ângulo, saída do jato de água e vários estudos dos métodos de uniformidade de distribuição da água (FARIA, 2011).

A Tabela 4 mostra as formas de perfis de distribuição de água de Christiansen, do qual os perfis A e B são característicos em aspersores com dois ou mais bocais, para o C e D sendo característico de aspersores que trabalham com um único bocal e no E para pressões inferiores.

**Tabela 4 - Formas dos perfis de distribuição de água por Christiansen**

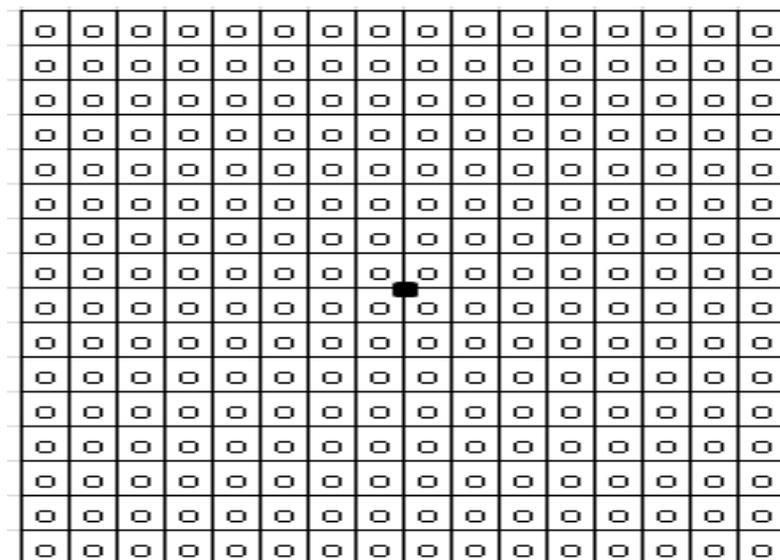
Perfil	Forma	Recomendação do espaçamento (% diâmetro molhado em metros)		
		Quadrado	Triângulo equilátero	Retângulo
A		50	50	40x60 a 65
B		55	66	40x60
C		60	65	40x60 a 65
D		40	70 a 75	40x70 a 75
E		40	80	40x80

Fonte: Adaptado de Faria (2011).

A maioria dos aspersores aplica a água em forma circular, necessitando certa superposição até obter a disposição e espaçamento adequado para atingir a uniformidade desejada. A disposição dos aspersores no campo normalmente é representada no formato de triângulo, retângulo, quadrado e triângulo equilátero. Mas dependendo da distribuição, maior é o espaçamento entre as linhas lateral e menor entre os aspersores. O raio do alcance do espaçamento é variado em metros (BERNARDO, 2009).

### 2.3.5 Uniformidade de distribuição

O teste de uniformidade consiste em colocar os pluviômetros em uma malha de pontos em torno do aspersor, como é visto na Figura 3. Quando este é simulado com somente com um aspersor, a sobreposição com diferentes espaçamentos podem ser simulados.



**Figura 3 - Disposição dos pluviômetros em torno do aspersor central em malha**

**Fonte: Adaptado de Bernardo (2009).**

O ponto central destacado em preto (Figura 3) é o aspersor, e ao seu redor os círculos representam os pluviômetros com a distribuição fixa.

## 2.4 UNIFORMIDADE DE APLICAÇÃO

Segundo BERNARDO (2009) a uniformidade de aplicação consiste em colocar os aspersores em uma malha de pontos ou em uma linha lateral, para indicar problemas na distribuição da irrigação. Para realizar os testes de uniformidades é importante obter as características do aspersor tais como: marca, diâmetro dos bocais e condições de operação (altura de elevação, pressão de operação, duração e hora do teste, vazão, velocidade e direção do vento).

A determinação da uniformidade é um fator importante para o diagnóstico do funcionamento do sistema, em que verifica o nível de eficiência e o tipo de lâmina que é aplicado para corrigir a distribuição a fim fornecer um melhor desenvolvimento da cultura (RODRIGUES et al., 2013).

A avaliação de um sistema de irrigação por aspersão pode ser feita pelo coeficiente de uniformidade, que reflete na qualidade da fração de água aspergida e determina a uniformidade de distribuição da água (MARTINS; RODRIGUES; REIS, 2013).

### 2.4.1 Coeficiente de Uniformidade de Chistiansen (CUC)

Christiansen (1942) foi o primeiro pesquisador a estudar a uniformidade de distribuição da água para aspersores rotativos, determinando o efeito da pressão de serviço, espaçamento, rotação e velocidade do vento sobre a distribuição da água. Adotou o desvio médio absoluto como medida de dispersão, calculando o CUC pela equação 5 (MARTINS; RODRIGUES; REIS, 2013):

$$CUC = 100\left(1 - \sum_{i=1}^n \frac{|X_i - X_m|}{nx}\right) \quad (5)$$

Onde:

$x_i$ : = precipitação observada nos coletores, em mm;

$X_m$ : média das precipitações, em mm;

$n$ = número de coletores.

Caso os dados das precipitações apresentem uma distribuição normal, se usa a Equação 6:

$$CUC = \left(\frac{lm}{Lm}\right) * 100 \quad (6)$$

Onde:

$L_m$  é a média de 50% das precipitações com valores menores, ou seja, a média da mediana.

### 2.4.2 Coeficiente de Uniformidade de Distribuição (CUD)

O coeficiente de uniformidade de distribuição (CUD) foi apresentado por Keller e Karmeli (1975), e sua distribuição é baseada na razão de 25% das vazões mínimas e com vazões médias dos emissores descritas na Equação 7:

$$CUD = \left(\frac{X_q}{X_m}\right) \quad (7)$$

Logo:

$x_q$ : média de 25% do total de coletores com as menores precipitações em mm.

$x_m$ : média das precipitações.

#### 2.4.3 Coeficiente Estatístico de Uniformidade (CUE)

O coeficiente de uniformidade estatístico (CUE) é usado para o dimensionamento e avaliação em campo, possui variações na uniformidade devida a fatores construtivos hidráulicos, obtido pela Equação 8 (MARTINS; RODRIGUES; REIS, 2013).

$$CUE = 1 - \left( \frac{Sd}{x_{med}} \right) * 100 \quad (8)$$

Em que:

Sd: é o desvio padrão das precipitações calculado;

Xmed: média das precipitações em mm.

#### 2.4.4 Classificação dos coeficientes CUC, CUD e CUE

O desempenho dos sistemas de irrigação por aspersão convencional obtém a classificação em função dos coeficientes CUC, CUD e CUE. A classificação da Tabela 5 mostra que quanto maior for o valor, melhor é a uniformidade de aplicação.

**Tabela 5 – Interpretação dos valores CUC, CUE e CUD do sistema de irrigação**

Classificação	CUC (%)	CUE (%)	CUD (%)
Excelente	>90	90-100	>84
Bom	80-90	80-90	64-84
Razoável	70-80	70-80	52-68
Ruim	60-70	60-70	36-52
Inaceitável	<60	<60	<36

Fonte: Adaptado de Martins et al. (2011).

A falta de uniformidade pode estar atribuída á falta de manutenção dos sistemas, o que ocasiona má distribuição de água que afeta na queda da produtividade.

## 2.5 MODELAGEM MATEMÁTICA

A matemática pode ser definida como a ciência que tem por um objeto, medida por suas propriedades e grandezas, quantidade do espaço, estruturas e variações estatísticas, conhecida também por aritmética (trabalha com números e regras de operação) e geometria (dividida em geometria plana, espacial e analítica) (DAVIS; HERSH, 1995). Para o ensaio radial é importante conhecer os pontos sobre o plano geométrico, do qual contribui para explorar o modelo trivial.

De acordo com Burak (2010) a modelagem matemática é um plano matemático com a perspectiva de obter algo novo, inexplorável, abordada por um conjunto de procedimentos e fenômenos, a fim de interligar a realidade com a matemática, presentes no cotidiano do ser para ajudar nas predições e tomar decisões, desenvolvida em duas premissas: Na primeira verifica o interesse do grupo de objetos envolvidos, e na segunda os dados são coletados de acordo com os grupos interessados.

A arte da modelagem matemática é subdividida em três etapas:

- a) Interação é o processo de reconhecimento da situação e do problema, na familiarização do assunto.
- b) Matematização é a etapa mais complexa, onde se faz as hipóteses e a resolução do problema em termos matemáticos.
- c) Modelo matemático está é a etapa de interpretação e validação da solução do modelo usual (KLÜBER; BURAK, 2008).

### 2.5.1 Medidas De Distância

Para Witten, Frank e Hall (2005) um ambiente de aprendizagem cada instância é comparado com uma métrica de distância e usado para definir uma nova classe que classifica qual método é melhor para encontrar o seu devido espaço. A função da distância métrica constitui de quatro propriedades (GOTELLI; ELLISON, 2004):

1. **Positividade:** a medida da distância  $d$  é sempre positiva se dois pontos ( $x_1$  e  $x_2$ ) não são idênticos ( $d(x, y) \geq 0$ ).
2. **Simétrica:** a medida  $d(x_1, x_2) = d(x_2, x_1)$ .
3. **Desigualdade triangular:** a medida  $d(x, z) \leq d(x, y) + d(y, z)$  para todos os objetos  $x$ ,  $y$  e  $z$ .
4. **Nula para pontos coincidentes:** a distância mínima é igual a Zero. Duas amostras  $x_1$  e  $x_2$  são idênticas, sendo a distância  $d = 0$ .

A análise de agrupamento define a similaridade entre as instâncias no experimento e a distância métrica para cada elemento amostrado, dessa forma verifica a possível semelhança entre os casos observados. Nas técnicas de agrupamento a medida de similaridade mais conhecida é a da distância euclidiana (GUIMARÃES et al., 2013).

### 2.5.2 Distância Euclidiana

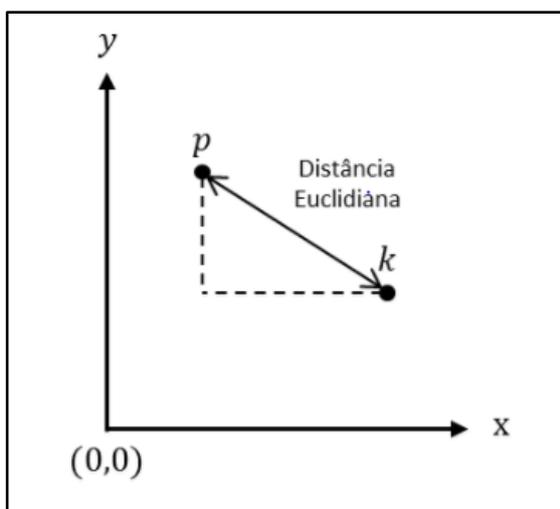
É a distância entre dois pontos ( $x = [x_1, x_2, \dots, x_n]$  e  $y = [y_1, y_2, \dots, y_n]$ ) ou mais dimensões que servem para definir um espaço métrico. Suas bases na aplicação do teorema de Pitágoras define que a distância euclidiana torna-se o comprimento da hipotenusa do triângulo, definida na Equação 9. (MONTEIRO et al., 2010).

$$d_{xy} = \sqrt{\sum_{i=1}^p (x_i - y_i)^2} \quad (9)$$

Em que:

$d_{xy}$ : distância do ponto x em relação ao y.

O comprimento da métrica euclidiana no segmento da reta (p) e (k) na Figura 4 é que une os pontos.



**Figura 4 - Pontos encontro da distância euclidiana**

Fonte: Adaptado de Linden (2009).

### 2.5.3 Geometria Analítica

A geometria analítica é o estudo das coordenadas, geometria cartesiana e princípios da álgebra, que através da representação de pontos em uma reta, curvas no plano e superfícies no espaço tratam dos problemas geométricos através de equações. Para obter os pontos é necessário descobrir as coordenadas x e y, e traçar um eixo entre as paralelas para que forme um triângulo retângulo ABC do qual é aplicando o teorema de Pitágoras para descobrir o valor da hipotenusa (igual à soma dos quadrados dos seus catetos) (SMITH et al., 2001).

$$d_{AB} = \sqrt{\Delta x^2 + \Delta y^2} \quad (10)$$

Em que:

$\Delta x$  : (XA-XB) e  $\Delta y$ : (YA-YB).

A equação 10 determina a fórmula para esboçar um plano cartesiano de forma que os pontos em uma reta vertical e horizontal correspondem ao eixo das abscissas A  $(x, 0)$  e o das ordenadas B  $(0, y)$ , sendo possível construir um triângulo retângulo que possui o segmento na reta (A, B) para a obtenção da hipotenusa dos seus catetos e coordenadas para bissetriz dos quadrantes  $(x, x)$ ,  $(y, y)$ ,  $(x, -x)$ , se o ponto é equidistante e enxerga o segmento das extremidades sobre o ângulo reto (MENDOZA, 2005).

#### 2.5.4 Interpolação espacial

A interpolação ou estimativa de um ponto é o processo de determinar valores desconhecidos ou não amostrados por meio do ajuste de funções matemáticas, com base em um conjunto de valores conhecidos (MOLIN; AMARAL; COLAÇO, 2015). A qualidade de uma interpolação depende muito da amostra e distribuição espacial dos pontos amostrais (YAMAMOTO; LANDIM, 2013).

A interpolação linear permite determinar por aproximação, um valor desconhecido que se encontra entre dois valores. Utiliza uma função linear  $p(x)$  para representar, e se aproximar da suposta função  $f(x)$ . Para interpolar os dados espaciais é necessário construir uma malha da qual todos os pontos amostrais preencheram os espaços não amostrados (MAZZINI; SCHETTINI, 2009).

## 2.6 INTELIGÊNCIA COMPUTACIONAL

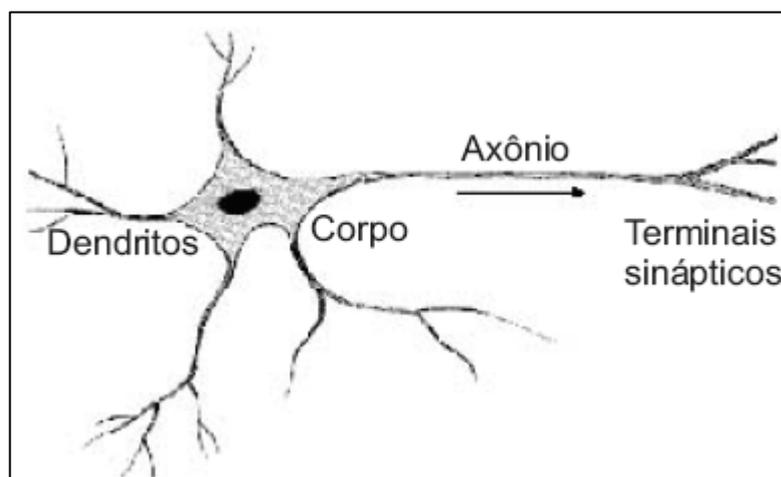
A pesquisa refere-se ao estudo das redes neurais artificiais, com uma abordagem geral sobre o assunto, focando no modelo de perceptron de múltiplas camadas com o algoritmo de *backPropagation* e seu termo *momentum*.

## 2.6.1 Redes Neurais Artificiais

Segundo HAYKIN (2001, p. 28), uma Rede Neural pode ser definida como:

Uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular ou função de interesse; a rede normalmente é implementada utilizando-se componentes eletrônicos ou simulada por programação digital. Para alcançarem um bom desempenho, as redes neurais empregam uma interligação maciça de células computacionais simples denominadas neurônios ou unidades de processamento.

O cérebro humano é composto por bilhões de neurônios, todas as funções e movimentos do organismo são gerados por essas pequenas células, os neurônios. A Figura 5 demonstra como os neurônios são conectados uns com os outros pelas sinapses que são pontos de contatos por onde há a passagem de neurotransmissores. Os dendritos são responsáveis pela captação de informações do ambiente e transmitem ao corpo do neurônio. O corpo celular processa as informações e envia ao axônio no qual distribuem as informações processadas para outros neurônios ou células do corpo (FERNEDA, 2006).



**Figura 5 - Representação de um neurônio simplificada.**  
Fonte: Ferneda (2006).

As RNAs diferenciam-se pela arquitetura e pela forma em que os pesos são associados às conexões durante o processo de aprendizado. A arquitetura de uma RNA restringe o tipo de problema no qual a rede pode ser utilizada, definida pelo

número de camadas (uma ou múltiplas), número de nós em cada camada, tipo de conexão entre os nós (*feedforward* ou *feedback*) e a topologia (HAYKIN, 2001).

O neurônio artificial apresentado por HAYKIN (2001) é uma unidade de processamento fundamental para uma RNA. A Figura 9 apresenta o modelo de um neurônio, no qual são identificados os seguintes elementos básicos:

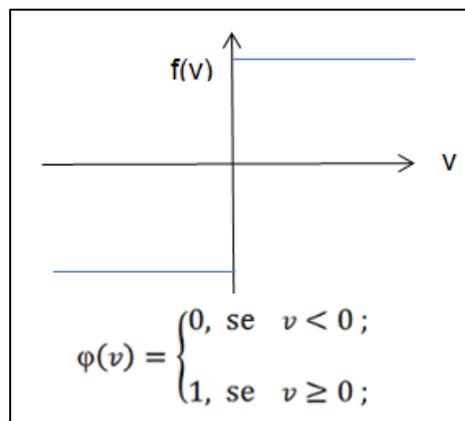
- a) Um conjunto de sinapses ou elos de conexão, cada representado por um peso;  
Sinais de entrada ( $X_1, X_2, \dots, X_n$ ), pesos sinápticos ( $w_1, w_2, \dots, w_n$ );
- b) Somador, definido para somar os sinais de entrada, como calcula a Equação 11;

$$\sum \{(X_1 * W_1) + (X_2 * W_2) + (X_n * W_n)\} \quad (11)$$

- c) A função de ativação restringe a amplitude da saída de um neurônio, referida por um intervalo permissível do sinal de saída e um valor finito.

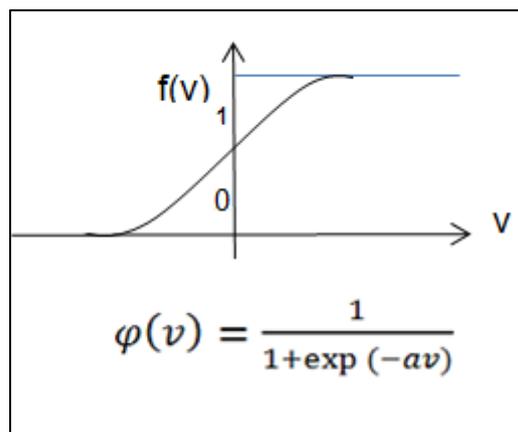
Tipos:

- I. Degrau: Figura 6) se o valor for  $v < 0$  ou  $v = 1$ ;



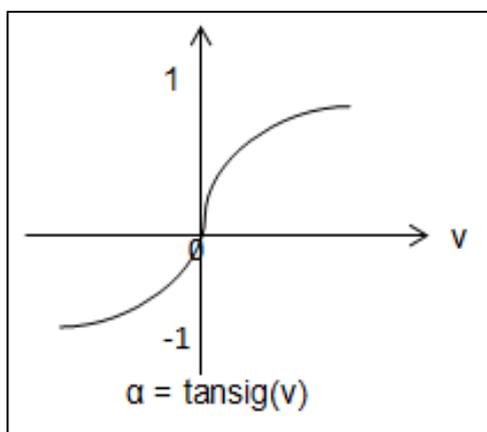
**Figura 6 - Função de ativação degrau limiar**  
Fonte: Adaptado de Lima, Pinheiro e Santos (2016).

- II. Sigmoide: Logística representada na Figura 7 (gera valores de 0 a 1);



**Figura 7 - Função de ativação logística**  
 Fonte: Adaptado de Lima, Pinheiro e Santos (2016).

III. Hiperbólica: Observada na Figura 8 (valores de -1 até +1).



**Figura 8 - Função de ativação tangente hiperbólica**  
 Fonte: Adaptado de Lima, Pinheiro e Santos (2016).

A Figura 9 apresenta a constante representada por  $(b_k)$ , que é o *bias*. Tem o efeito de realizar a ponderação, ou seja, ele aumenta ou diminui a entrada da função de ativação e dependendo se o valor for positivo ou negativo apresenta um valor fixo para o neurônio (GOLDSCHMIDT, 2010).

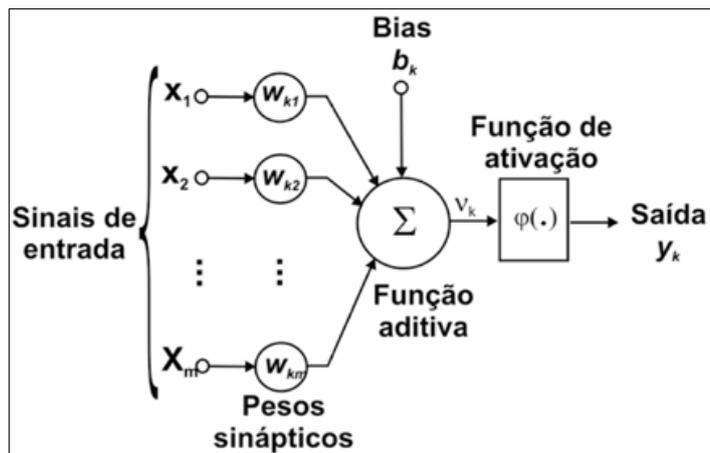


Figura 9 - Modelo não linear de um neurônio.  
Fonte: HAYKIN (2001).

### 2.6.1.1 Processo De Aprendizagem

Para HAYKIN (2001) o processo de aprendizagem de uma RNA é um procedimento pelo qual os parâmetros livres são adaptados através de um processo de estimulação do ambiente que está inserido, do qual implica em uma sequência de eventos, sofre modificações nos parâmetros e responde de acordo com o novo ambiente, oriunda das diversas modificações ocorridas na sua estrutura interna. Uma RNA pode ter o processo de treinamento que pode ser subdividido em três tipos de aprendizados:

- a) Aprendizado supervisionado: onde é fornecida a resposta desejada e são adaptados os pesos;
- b) Aprendizado Semi-supervisionado: onde a rede aprende através de resultados do tipo sucesso e insucesso, mesmo informando o resultado esperado a rede não tem um parâmetro de como proceder;
- c) Aprendizado não supervisionado: não há saída esperada, os dados de entrada são fornecidos e a rede consegue rearranjar até obter uma saída satisfatória.

A maioria das RNAs trabalha com o tipo de treinamento supervisionado, no qual os pesos são ajustados por meio de algum algoritmo de aprendizagem a cada iteração, que é conhecido como ciclo ou época. Quando o treinamento alcança um

nível satisfatório é resultado de que obteve parâmetros adaptáveis nos seus pesos e bias (MENDEL; MCLAREN, 1970).

#### 2.6.1.2 Arquitetura da Rede Neural Artificial

A RNA é formada por atributos semelhantes aos do sistema biológico, com capacidade de aprendizado e generalização. A topologia no formato de rede recorrente (onde há presença de realimentação de informações, por estrutura capaz de representar grande variedade de comportamentos dinâmicos) e não recorrentes (não possuem realimentação das saídas para as suas entradas) (GOLDSCHMIDT, 2010). HAYKIN (2001) associa uma RNA a um grafo direcionado, onde cada nó representa um neurônio e as arestas entradas ou saídas do neurônio.

GOLDSCHMIDT (2010) classifica a arquitetura da RNA da seguinte forma:

a) Em relação ao número de camadas:

- I. Redes de única camada: possuem apenas uma camada de neurônios artificiais;
- II. Redes de múltiplas camadas: possuem mais de uma camada com elementos.

b) Tipo de conexões:

- I. Redes *feedForward* (acíclicas ou não recorrentes): produz diretamente a saída e não há retorno do sinal para camadas anteriores;
- II. Redes *feedBack* (cíclicas ou recorrentes): há retorno do sinal em sentido contrário ao fluxo de processamento normal da rede;
- III. Redes com recorrência auto associativa: a saída de cada neurônio serve como entrada para os outros processadores.

c) Tipo de conectividade:

- I. Redes parcialmente conectadas: neurônios em que uma camada não se conecta com todos da camada seguinte;
- II. Redes completamente conectadas: todos os neurônios se conectam com a camada seguinte.

### 2.6.1.3 Modelo perceptron

O perceptron foi proposto por Rosenblat em 1958 sendo o primeiro modelo de aprendizagem supervisionado nas redes neurais, foi construído em cima do modelo de McCulloch-Pits. É a forma mais simples para a classificação de padrões linearmente separáveis (CASTRO, 2001) que consiste em um neurônio com pesos sinápticos ajustáveis, utiliza a função de ativação degrau e é *feedForward* pois tem uma polarização (bias) (GOLDSCHMIDT, 2010).

### 2.6.1.4 Múltiplas camadas perceptron (MLP)

HAYKIN (2001) destaca o desenvolvimento de redes *feedForward* de múltiplas camadas, conhecidas também como *Multilayer Perceptrons* (MLP), estas apresentam três características:

- a) O modelo que cada neurônio inclui uma função de ativação;
- b) A rede contém uma ou mais camadas ocultas;
- c) A rede tem um alto grau de conectividade.

Para a rede MLP o número de neurônios de cada camada é de suma importância para o desempenho e agilidade na rede. Não há uma regra que determine a quantidade de neurônios, pois isto depende do tipo do problema. Entretanto, uma proposta realizada por GOLDSCHMIDT (2010, p. 91, Apud (Hecht-Nielsen (1988))) sugere a utilização de  $(2n+1)$  na camada intermediária, sendo  $n$  (o número de neurônios na camada de entrada).

#### 2.6.1.4.1 Algoritmo de treinamento *BackPropagation* (Retropropagação)

O *backPropagation* (retropropagação de erro) é um algoritmo de aprendizagem supervisionado de múltiplas camadas, que opera em duas fases (*forward* e *backward*).

Na primeira fase (*forward pass*) é apresentado um conjunto de dados para a camada de entrada que permanece inalterado em todo o MLP. Os sinais são propagados percorrendo camada por camada até que uma resposta seja produzida para a camada de saída (CASTRO, 2001). Caso a resposta esteja inadequada, o erro é calculado pela Equação 12 e a fase *backward* é então aplicada (GOLDSCHMIDT, 2010).

$$E(k) = e(k)^2 / 2 = (y_d(k) - \hat{y}(k))^2 / 2; \quad (12)$$

Em que:

E: Erro calculado;

K: Pesos neurônios;

y: Saída real.

O Algoritmo *backPropagation* ajusta todos os pesos da rede de forma proporcional à sua contribuição para geração do erro.

A segunda fase de *backward* começa na camada de saída, retro propagando-se contrariamente até chegar à camada de entrada. Sendo comparada a resposta obtida com a desejada, se estiver incorreta o erro é calculado diversas vezes, ajustando os pesos para se retro propagarem até a geração da resposta correta (CASTRO, 2001).

#### 2.6.1.4.2 *Backpropagation* com *momentum*

A taxa de *momentum* ( $\mu$ ) (Equação 13) permite a atenuação das oscilações na descida gradiente, à ideia geométrica por trás provavelmente pode ser mais bem compreendida em termos de análise de espaço eletrônico no caso linear. Se a

relação entre o menor valor e o maior é grande, então a realização de uma descida gradiente é lenta, mesmo que a taxa de aprendizado seja maior devido ao condicionamento da matriz. O impulso introduz algum equilíbrio na atualização entre os vetores associados a valores de tamanho superior e inferior.

$$\Delta\omega_{ij}(t) = \mu\delta_i y_j + m\Delta\omega_{ij}(t-1) \quad (13)$$

Onde:

$\mu$ : momento ;

$y$ : taxa de aprendizado;

$w$ : pesos diferentes.

Os algoritmos recebem os parâmetros de aprendizagem conforme a especificação no padrão do SNNS, bem como suas nomenclaturas. Para o *Std\_Backpropagation*( $n$ ,  $d_{\max}$ ),  $n$ (parâmetro de aprendizado) e  $d_{\max}$  a diferença máxima onde conforme o valor evita excesso de treinamento na rede. Por padrão o valor definido é 0,1. Em *BackpropMomentum*( $n$ ,  $\mu$ ,  $c$ ,  $d_{\max}$ ) tal que:  $n$  parâmetro de aprendizado,  $\mu$  momento de impulso, mais usada por padrão é 0,3.  $c$  é valor de eliminação plana em que é adicionado um valor constante a função de ativação para que a rede passe pontos da superfície de erro. Mais usado 0,1. E  $d_{\max}$  é o mesmo do *backpropagation* (DRAKOS, 1995).

### 2.6.2 Generalização

A capacidade de generalização para obter uma rede com melhor desempenho é possível quando os dados respondem corretamente o processo de treinamento. Os procedimentos de validação cruzada (CV) são usados para detectar se a rede está sendo treinada de maneira excessiva ou sobre-treinamento (*overtraining*). A CV divide os dados em três conjuntos: treinamento, validação (que determina a performance da rede) e teste (usado para avaliar o desempenho final da rede). Quando é obtido o mínimo erro de validação é parado o treinamento (FRANCO; JEREZ; ALIZONDO, 2009).

Durante o treinamento, conforme a Figura 10 é gerado um erro para o conjunto de treinamento (curva inferior) e validação (superior). A aprendizagem é

interrompida quando houver o mínimo de erro de validação. Quando não é interrompida ocorre o excesso de treinamento (*overfitting*). Caso a rede não tenha treinado o suficiente para representar os dados ocorre à parada mais cedo (*underfitting*) (SILVA, 1998).

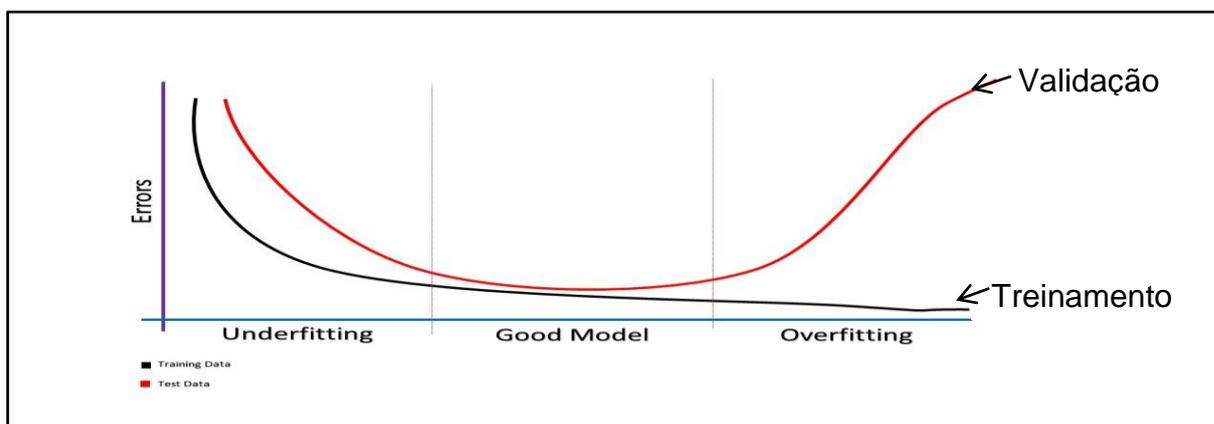


Figura 10 - Curva de erro MSE, generalização da rede: overfitting e underfitting  
Fonte: Adaptado de Silva (1998).

### 2.6.3 Normalização dos Dados

Para minimizar o problema com os dados devido ao uso de unidades e variáveis com diferentes magnitudes é importante realizar um pré-processamento dos dados chamada normalização, na qual os dados são transformados para facilitar o processamento pela função de ativação da RNA. A função de ativação sigmoide, usada na pesquisa, necessita dos dados formatados dentro do intervalo de [0, 1]. A Equação 14 é frequentemente utilizada para normalizar os dados (SILVA; SCHIMIDT, 2016).

$$X_N = (X_o - X_{min}) / (X_{max} - X_{min}) \quad (14)$$

Em que:

$X_o$ : x original;

$X_n$ : x normalizado;

$X_{max}$ : maior valor do parâmetro;

$X_{min}$ : menor valor do parâmetro.

Realizada a normalização, os dados são organizados conforme os padrões de cada software de treinamento das RNAs.

#### 2.6.4 Treinamento da RNA

É o ponto onde se obtém o sucesso ou o fracasso da rede, pois neste procedimento submete-se a rede ao aprendizado, onde alguns fatores são relevantes como o tipo do algoritmo de treinamento e o número de épocas (ciclos ou iterações). Nesta etapa é realizada uma série de ciclos ou épocas, na qual os padrões de treinamento são incluídos na rede e observados caso gere um *overfitting* ou *underfitting*, como mostrado na Figura 10 (ZELL et al., 2000).

A convergência reflete a forma como a rede consegue aprender e alcançar bons resultados. A função do erro quadrático médio é utilizada para medir o desempenho local associado aos resultados produzidos pelos neurônios de saída frente à referida amostra. A Equação 15 é usada para realizar o cálculo do erro médio quadrático ou MSE (*Mean Square Error*), que serve para descobrir se a rede consegue convergir de maneira satisfatória (REYES; VELLASCO; TANSCHKEIT, 2012).

$$MSE = \sum_{t=1}^n (x_i - xi_i)^2 / n \quad (15)$$

Em que:

$X = [X_{1xn}, X_{2xn}, \dots, X_{m \times n}]$ , onde  $X_{ixn}$  representa o vetor de  $n$  amostras.

## 2.7 MÉTODOS ESTATÍSTICOS

De acordo com Diehl, Souza e Domingos (2007) o método estatístico é a determinação da tendência dos fenômenos, na qual a descoberta de suas causas auxilia no desenvolvimento de estudos para a experimentação. Deste modo a estatística é uma poderosa ferramenta de análise para pesquisas quantitativas em processos de validação de dados e cálculo de probabilidades, com a importante tarefa de representar aspectos por meio da linguagem matemática e viabilizar

operações sofisticadas de alto grau para diversos campos e áreas de investigação (WACHELKE, 2006).

Este estudo usa alguns métodos estatísticos para a análise descritiva, análise de variância e coeficiente de Pearson. Freund (2006) explica que a estatística descritiva inclui a apresentação dos dados em forma de tabelas e gráficos e descreve a distribuição dos experimentos usando medidas de tendência (média, mediana e moda), medidas de dispersão ou variação (desvio padrão) e medidas de distribuição.

A variância é definida como o desvio quadrático da média e o coeficiente de variância onde este é calculado entre o desvio padrão (raiz quadrada positiva da variância) e a média. O desvio padrão é o resultado da raiz quadrada positiva da variância, quando os valores são baixos diz-se que estão próximos à média, mas caso estiver alto informa que estão espalhados. O erro padrão da média é uma estimativa do desvio padrão entre a distribuição das amostras (dividido o desvio padrão pela raiz quadrada do número de amostras). Quando o erro diminui com o tamanho da amostra, reflete na precisão da estimativa (LUNET; SEVERO; BARROS, 2006).

### 2.7.1 Teste de Lilliefors (Kolmogorov-Smirnov)

O teste de Lilliefors é baseado no teste de Kolmogorov-Smirnov. Conhecido como teste KS ou K-S, este fornece uma análise quantitativa do teste de normalidade. A estatística D é a maior diferença absoluta entre as frequências relativas e as esperadas dos n valores, mostrada na equação 16 (SEWARD; DOANE, 2014).

$$D_n = \sup_x |F(x) - F_n(x)| \quad (16)$$

Onde:

F(X): frequência acumulada real na observação i;

FN(X): frequência acumulada esperada na observação i sobre a hipótese que os dados vieram de uma distribuição hipotética.

O teste fornece o parâmetro (p-value) que pode ser interpretado como a medida do grau de concordância entre os dados e a hipótese nula ( $H_0$ ), sendo  $H_0$  correspondente à distribuição normal. Quanto menor for o p-value menor é a consistência entre os dados e a hipótese nula. A regra de decisão adotada para saber se a distribuição é normal ou não é rejeitar  $H_0$ : (i), se  $p\text{-value} \leq \alpha$  rejeita-se  $H_0$ , ou seja, não se pode admitir que o conjunto de dados em questão possua distribuição normal; (ii) se  $p\text{-value} > \alpha$  não se rejeita  $H_0$ , ou seja, a distribuição normal é uma distribuição possível para o conjunto de dados (LOPES; BRANCO; SOARES, 2013).

### 2.7.2 Análise De Variância (ANOVA)

Freund e Simon (2000) descrevem a análise de variância como uma medida de variação total para um conjunto de dados, e a soma dos termos para a comparação das diversas populações a fim de verificar diversos fatores. O pressuposto da ANOVA refere-se ao fato de decidir se as amostras observadas são reais ou causais, se são aleatórias ou independentes, se segue uma distribuição normal e se as variâncias populacionais são similares.

Os diferentes níveis de cada fator são chamados de tratamento (Condição ou objeto imposto para avaliar cada experimento), no qual a resposta dos  $k$  tratamentos da Equação 17 resulta em uma variável aleatória (MONTGOMERY; KEATS, 1996).

$$Y_{ij} = \mu + \tau_i + \epsilon_{ij} \quad \{i = 1, 2, \dots, a; j = 1, 2, \dots, n\} \quad (17)$$

Em que:

$Y_{ij}$ : Que é a  $ij$ -ésima observação;

$\mu$ : efeito da média global (Sendo um parâmetro comum a todos os tratamentos);

$\tau$ : Parâmetro  $i$ -ésimo tratamento;

$\epsilon_{ij}$ : Componente de erro associado  $i$ -ésimo tratamento  $j$ -ésimo experimento;

$a$ : nível do fator de experimento.

Para calcular a aceitabilidade entre as médias dos tratamentos é realizado o teste de hipóteses, considerando termos para  $H_0$  e  $H_1$  definido na Equação 18 (SILVA FILHO, 2012).

$$\begin{aligned} H_0: \tau_1 &= \tau_2 = \dots = \tau_k = 0; \\ H_1 &= \tau_1 \neq 0; \end{aligned} \quad (18)$$

Se a hipótese for nula  $H_0=0$ , então o caso de teste é verdadeiro, caso seja aleatório não a evidências estatísticas que o defendam.

O teste de Cochran verifica se os tratamentos são balanceados, se a homogeneidade entre as variâncias. O procedimento é baseado na comparação das variâncias, soma-se e calcula a razão da variância suspeita e a soma de todas. O teste de Bartlett é usado para verificar a homogeneidade das variâncias, se as amostras provêm de distribuições normais, sensível às saídas da normalidade. Este teste é derivado do teste de razão de verossimilhança sobre a normalidade de distribuição (ARSHAM; LOVRIC, 2011).

### 2.7.3 Coeficiente De Correlação e Determinação

O coeficiente de correlação de Pearson ( $r$ ) é uma medida que serve para verificar a força e direção na associação entre duas variáveis ( $x$  e  $y$ ), e utiliza a métrica produto-momento. Os valores podem variar entre -1 e 1, conforme o resultado obtido pela Equação 19 (ALVES; VECCHIA, 2011). Portanto, se  $r=0$  (zero) significa que não há relação linear entre as variáveis,  $r=1$  indica que a correlação linear é perfeita com os indivíduos na mesma linha. Já para  $r=-1$  a relação perfeita negativa nos indivíduos da amostragem.

A FIGURA 11 representa as formas de retas na correlação. Caso ( $0 < r < 1$ ) á uma tendência linear positiva em comum, e se for ( $-1 < r < 0$ ) são espalhados em torno do plano (PUTH; NEUHAUSER; RUXTON, 2014).

$$r = \frac{\sum(x-\bar{x})-(\hat{y}_i-y)}{\sqrt{\sum(x-\bar{x})-\sum(\hat{y}_i-y)^2}} \quad (19)$$

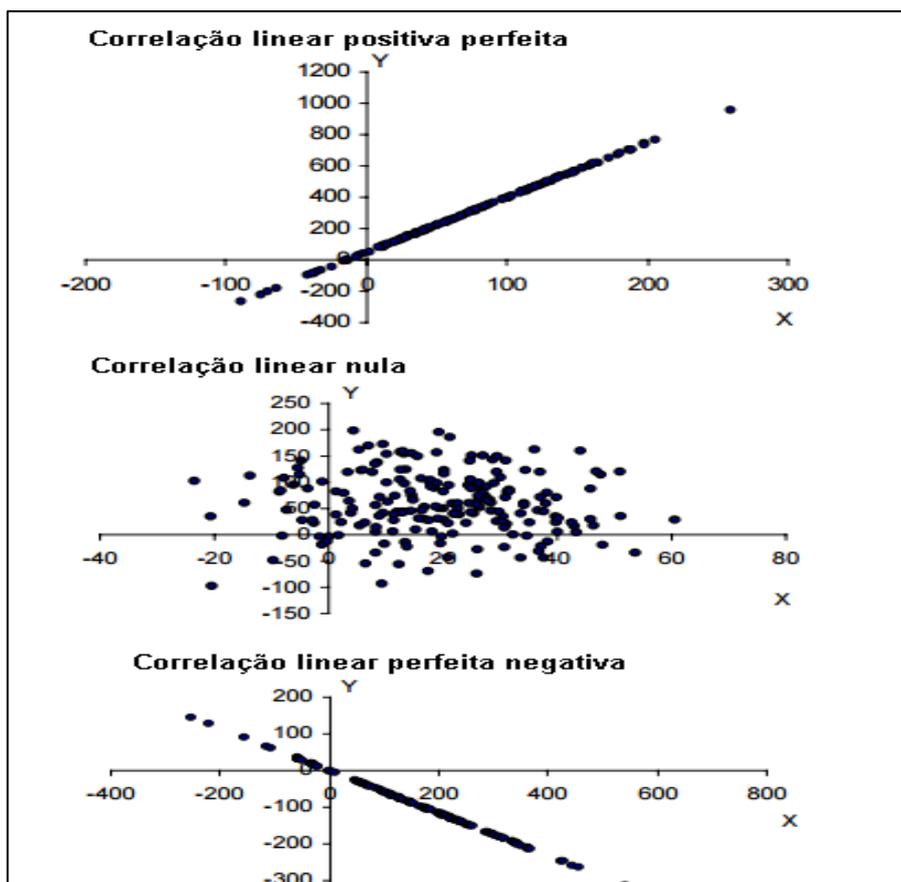


Figura 11 - Tipos de correlações lineares.  
Fonte: Ajustado de Lira (2004);

A interpretação do coeficiente de correlação depende de como são especificados os objetivos e por quais razões está sendo calculado. De acordo com Lira (2004, p. 41, apud CALLEGARI-JACQUES 2003, p. 90) pode ter várias interpretações, mas de acordo com sua intensidade de força, conforme a interpretação na Tabela 6.

Tabela 6 - Interpretação dos valores de correlação.

Valores de $p(+ \text{ ou } -)$	Interpretação
$0,00 <  p  < 0,30$	Fraca correlação
$0,30 \leq  p  < 0,60$	Moderada
$0,60 \leq  p  < 0,90$	Forte
$0,90 \leq  p  < 1,00$	Muito forte

Fonte: Adaptado de Lira (2004).

O quadrado do coeficiente de correlação de Pearson é chamado de coeficiente de determinação ou simplesmente ( $R^2$ ). É uma medida da proporção da variabilidade em uma variável que é explicada pela outra (mede a proporção da variação total da variável dependente pela variação da variável independente), capaz de descrever a qualidade do ajuste obtido pela Equação 20 (ALVES; VECCHIA, 2011).

Do qual depende do número de amostras, pois uma correlação ( $R^2=1$ ) é considerada perfeita, ou seja, quanto mais próximo de 1, melhor o ajuste do modelo. Quanto mais alto for o valor de  $R^2$ , melhor o modelo de regressão linear consegue explicar a variação de  $y$  (SUBRAMANIAN; COUTINHO; SILVA, 2007).

$$r^2 = \frac{\sum_{i=0}^n (\hat{y}_i - y)^2}{\sum_{i=1}^n (y_i - y)^2} \quad (20)$$

Em que:

$\sum_{i=0}^n (\hat{y}_i - y)^2$  : correspondente a variação aplicada;

$\sum_{i=1}^n (y_i - y)^2$  : corresponde a variação não aplicada.

O gráfico de dispersão é uma das formas mais usada de representar os pares do total das observações analisadas (LIRA, 2004).

### 3 METODOLOGIA

Este capítulo descreve todo o procedimento de materiais e métodos que faz parte da pesquisa. Abordando os tópicos sobre o tipo de pesquisa, levantamento e tratamento dos dados, tecnologias empregadas para obtenção dos resultados de maneira satisfatória.

Consta a modelagem para calcular as distâncias radiais de alcance do aspersor, desenvolvimento das RNAs do tipo MLP, topologia das RNAs, ajuste dos pesos do modelo, fase de treinamento da rede e pós-processamento dos dados para retornar a sua representação original.

#### 3.1 LEVANTAMENTO DE DADOS

Os dados utilizados na pesquisa foram disponibilizados por Menezes et al.(2015), coletados na fazenda Ouro Verde, área localizada no município de Medianeira, Brasil (25° 12 '19,26 "S; 54° 3 '27,93° W; 360 m), região Oeste do Estado do Paraná, cuja economia se baseia na agropecuária, indústria e serviços. A área do município tem 328,733 km<sup>2</sup> e altitude em relação ao nível do mar, de 402 m. O índice pluviométrico do município é de 1880 mm ano<sup>-1</sup>. O clima predominante é classificado como subtropical úmido (Classificação climática de Köppen-Geiger: Cfa) com verões quentes e temperatura média anual de 21 °C. A área do experimento foi de 7 alqueires e realizado nos meses de julho, agosto e setembro.

Os ensaios caracterizam a distribuição de água por um aspersor usando diferentes combinações de bocal (mm), quebra jato, pressão (KGF/CM<sup>2</sup>), velocidade (m/s), direção do vento (Graus) e precipitação (mm h<sup>-1</sup>). Operaram em um aspersor com uma malha de 16 X 16 coletores (Figura 3), do qual obteve nove combinações de bocais (2,6 x 2,4; 2,8 x 2,4; 3,0 x 2,6; 3,2 x 2,6; 3,4 x 2,6; 3,6 x 2,8; 3,8 x 2,8; 4,0 x 2,8 e 4,0 x 3,2 mm), a uma distância entre os pluviômetros de 1,5m e operando na posição de 1,25 m em relação à superfície do solo. Os valores coletados foram disponibilizados em uma planilha de cálculos contendo 108 linhas com as diversas configurações dos ensaios.

### 3.2 AMBIENTE DE EXPERIMENTO

Para realizar a construção e simulação experimental dos dados foi utilizado o seguinte ambiente:

- a) Notebooks HP (Processador Intel I3 e I7);
- b) Infraestrutura de servidores da UTFPR-Medianeira CPU 4 núcleos, 4GHz, 8 GB memória Ram;
- c) Microsoft Office;
- d) JAVANNS 1.1, SNNS 4.3, *code blocks*, software R X64 e STATISTICA.

### 3.3 TECNOLOGIAS ENVOLVIDAS

Para o treinamento da RNA foi usado os softwares JavaNNS e SNNS por apresentarem uma linguagem de programação acessível e livre (*free*).

O SNNS (Simulator redes neurais Stuttgart) é um simulador para as redes neurais, desenvolvido na universidade de Stuttgart. Seu kernel é escrito na linguagem C, e suporta tecnologias de rede como RCS (ZELL et al., 2000). O SNNS usa como padrão para a extensão dos seus arquivos a seguinte nomenclatura: '.net' (arquivos de rede, unidades e ligações), '.pat' (arquivos de padrões), '.cfg' (arquivo de configurações), '.txt' (arquivo de texto) e '.res' (arquivo de resultados).

O JavaNNS (simulador de redes neurais em Java) foi desenvolvido na Wilhelm Schickard no instituto para ciência da computação (WSI) em Tübingen (Alemanha) é um software simulador para rede neurais artificiais baseado no SNNS, que se destaca por implementar uma interface gráfica sobre o kernel do SNNS, o que torna mais fácil operar o mesmo (FISCHER et al., 2002).

O software R (R-PROJECT, 2017) e STATISTICA (STATISTICA, 2017) para a geração da parte estatística, pois são ferramentas para a análise dos dados, construção de gráficos e cálculos estatísticos (SABINO; LAGE; ALMEIDA, 2014).

O *code blocks* utilizado para codificar e testar o código da rede na linguagem "C", e executa os respectivos testes para averiguar qual rede possui a melhor performance em relação ao modelo observado.

Para a elaboração dos mapas de teste, foi usado o software Surfer, que através do método escolhido (Krigagem) é capaz de estimar o próximo ponto desconhecido. A Krigagem é um método de regressão que utiliza geoestatística para efetuar a interpolação dos pontos (BARBOSA, 2006).

### 3.4 FLUXOGRAMA

As etapas experimentais das simulações podem ser observadas pelo fluxograma apresentadas na Figura 12.

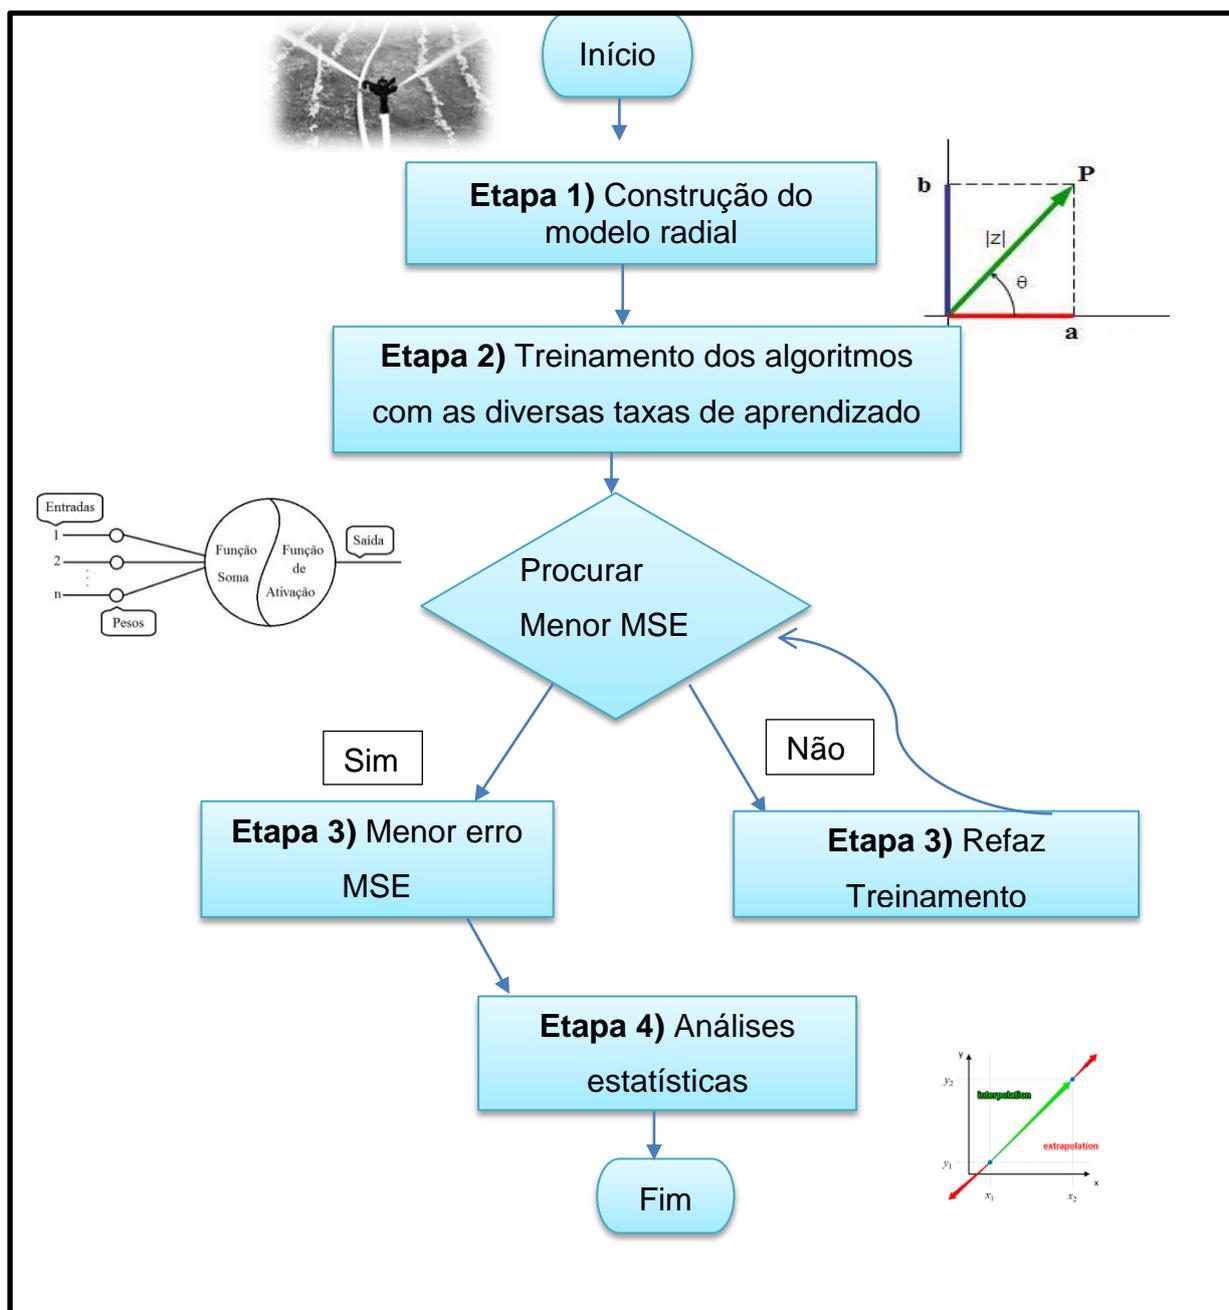


Figura 12 - Fluxograma de atividades.

Fonte: Autoria Própria.

### 3.5 DESENVOLVIMENTO DO EXPERIMENTO

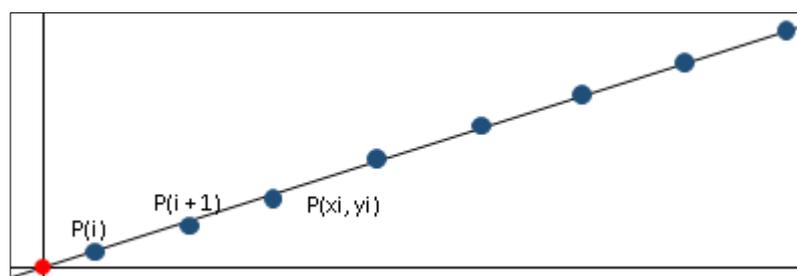
Esta seção descreverá sobre o tratamento dos dados, processo de modelagem linear para a distribuição das distâncias no modelo simulado. Abrange a etapa para a construção da RNA MPL, topologia, ajuste dos pesos sinápticos, o processo de conversão da rede para uma linguagem de programação e a forma como foram feitos os testes.

#### 3.5.1 Modelagem Da Distribuição Das Distâncias Parciais Do Modelo Observado

A modelagem das distribuições foi separada em três fases: interação, matematização e a modelagem concluída.

##### 3.5.1.1 Interação

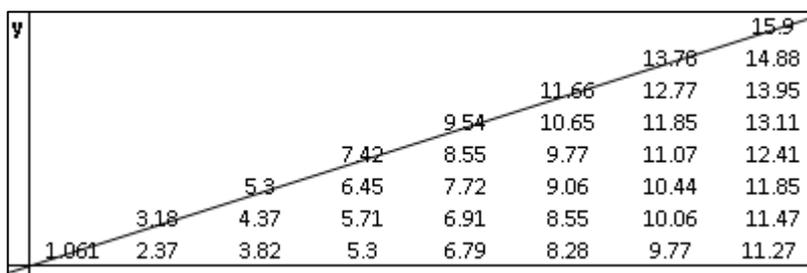
O modelo matemático tem como objetivo de encontrar as distâncias da reta do método ensaio de irrigação por aspersão radial. Para encontrar a reta para o modelo radial da Figura 13, observou-se as medidas do modelo observado em malha (Figura 3). Foram consideradas as dimensões da distância entre os pluviômetros de 1.5m, sendo a primeira distância  $p(0,0)$  de 0,75m por estar em relação à de metade do aspersor.



**Figura 13 - Reta parcial do modelo simulado.**  
**Fonte: Autoria própria.**

### 3.5.1.2 Matemática

Aplicando as fórmulas para o encontro da hipotenusa na reta partindo do ponto zero, com o uso da equação 09 e 10 foi possível ter o encontro dos 8 pontos na diagonal que representa o raio de alcance do aspersor em relação aos pluviômetros, como mostra a Figura 14.



**Figura 14 - Reta contendo as distâncias calculadas**  
**Fonte: Autoria própria.**

### 3.5.1.3 Modelo matemático

As distâncias extraídas (1,06; 3,18; 5,3; 7,42; 9,54; 11,66; 13,78 e 15,9) da Figura 14, são de vital importância para o uso na simulação da RNA, pois através destes, juntamente com os parâmetros das amostras do modelo observado (bocal, quebra jato, pressão, velocidade, direção do vento e precipitação) será treinada a RNA.

### 3.5.2 Tratamento Dos Dados

O procedimento para o tratamento dos dados consiste em adequar as amostras conforme o tipo de função de ativação definida na rede. Os dados observados passaram pelo pré-processamento onde foram aleatorizados e separados conforme as distâncias e juntamente com as configurações dos aspersores passaram pelo processo de normalização usando a Equação 14, do qual

foram transformados para que ficassem no intervalo [0, 1]. Sendo a aleatorização imprescindível para que não haja vícios ou tendências nos dados.

Para o treinamento da RNA o primeiro passo foi dividir o conjunto de amostras em treinamento, validação e teste. Portanto 66% dos dados são utilizados para a fase de treinamento, 26% para a validação e 8% para os testes finais. O treinamento consistiu em apresentar o conjunto e avaliar o erro a cada iteração entre as épocas até que apresente o valor satisfatório.

### 3.5.3 Desenvolvimento Para Construir as Rnas Multilayer Perceptron (MPL)

Para obter as respostas e, considerando o paradigma de aprendizado supervisionado sobre a RNA, tornando-se necessária realizar a análise preliminar. Foram consideradas as características que permitissem uma modelagem com valores compreensíveis a RNA. Neste sentido, optou-se em expressar os valores na escala de 0 a 1 e função de ativação sigmoide logística, para que as diferentes amplitudes das variáveis não interferissem supervalorizando ou sobrevalorizando a influência de uma variável em detrimento da outra no resultado final.

### 3.5.4 Topologia Da Rede

A definição de uma rede se encontra em seu número de camadas. O modelo construído da RNA foi constituído conforme a Tabela 7, do qual a configuração tem 6 neurônios na camada de entradas, 500 neurônios na camada oculta e 1 única saída (6x500x1), função de ativação sigmoide, épocas de iterações e os devidos algoritmos que verificaram se há a eficiência da irrigação no modelo parcial.

**Tabela 7 - Topologia da rede com parâmetros e configurações específicas**

<b>Parâmetro</b>	<b>Configuração</b>
Número de neurônios entrada	6
Número de camadas ocultas	1 (500 neurônios)
Número de neurônios de saída	1
Função de ativação	Sigmoide-logística
Função de treinamento	<i>BackPropagation</i> e o seu termo <i>momentum</i>
Épocas	10000

**Fonte: A autoria própria.**

### 3.5.5 Ajuste Dos Parâmetros e Dados Da Rede

Para alcançar o objetivo da pesquisa, os parâmetros da RNA foram ajustados conforme os algoritmos usados, para obter um nível eficiente sobre o modelo de ensaio de irrigação por aspersão radial. A taxa de aprendizado usada no treinamento das RNAs consistiu no intervalo de (0,1 a 1,0), para cada algoritmo (*backPropagation* sem e com o termo *momentum*).

O termo *momentum*  $\mu$  foi configurado ao valor de 0,3 para o treinamento das RNAs, devido ter apresentado resultados mais propícios nos testes e melhor convergência.

A rede construída conforme a Tabela 7, que tem como entradas os dados do bocal, quebra jato, pressão (kgf/cm<sup>2</sup>), velocidade (m/s), direção do vento (graus) e distância. A precipitação refere-se à saída desejada, já que a rede usa o conceito de aprendizado supervisionado. Esses dados foram formatados e separados em arquivos com a extensão '.pat' (Tabela 8), sendo que cada apresentou os dados as suas respectivas etapas (treinamento, validação ou teste), conforme o layout requerido pelo software SNNS.

**Tabela 8 – Exemplo do padrão SNNS para o arquivo usado com a extensão ‘.pat’.**


---

*SNNS pattern definition file V3.2*
*generated at mon Dec 01 18:08:50 2017*


---

*No. of patterns : 560*
*No. of input units : 6*
*No. of output units : 1*


---

*//Dados de entrada*
*//Bocal - Quebra jato – Pressão – Velocidade - Direção vento - Distância*
*0,71 0,50 0,00 0,05 0,43 0,00*
*0,68 //precipitação (saída observada)*
*0,71 0,50 0,00 0,05 0,43 0,14*
*0,27*
*0,71 0,50 0,00 0,05 0,43 0,29*
*0,36*
*0,71 0,50 0,00 0,05 0,43 0,43*
*0,72*
*0,71 0,50 0,00 0,05 0,43 0,57*
*0,35*
*0,71 0,50 0,00 0,05 0,43 0,71*
*0,00*
*0,71 0,50 0,00 0,05 0,43 0,86*
*0,00*
*0,71 0,50 0,00 0,05 0,43 1,00*


---

**Legenda:** *No. of patterns*: Número de padrões; *No. of input units*: neurônios na camada de entrada; *No. of output units*: neurônios na camada de saída.

**Fonte:** Autoria própria.

A quantidade de amostras apresentadas na Tabela 9, foram reservadas para cada fase de execução da RNA (treinamento, validação e teste).

**Tabela 9 - Quantidade de amostras para a execução das RNAs**

<b>Fase(s)</b>	<b>Entrada</b>	<b>Saída</b>	<b>Amostras</b>	<b>Treinamento %</b>
Treinamento	6	1	560	66
Validação	6	1	240	26
Teste	6	1	64	8

---

**Fonte:** Autoria própria.

### 3.5.6 Treinamento da MLP

Com a topologia e o ajuste dos parâmetros configurados se treinou a rede pelo software SNNS. O conjunto de dados é inserido na camada de entrada (*forward*), e se propaga pelas camadas ocultas chegando até a camada de saída, onde o valor encontrado é comparado com o esperado na saída (*backward* aplica a equação 12) e essa diferença (chamada de erro) retropropaga de volta nas camadas fazendo os ajustes de pesos para minimizar o erro.

Parte 1: o processo de treinamento pode ser automatizado pelo aplicativo chamado *Batchman*, que faz parte do pacote do SNNS. O *batchman* aceita como entrada um arquivo de lotes com uma sequência de comandos, variáveis e instruções que serão executados. Para a definição da topologia da rede, foram criados os neurônios correspondentes das entradas, camada oculta e saída. Entre os comandos possíveis de serem usados no arquivo de lotes, existe no SNNS o comando *bignet* que recebe como parâmetro a topologia desejada e cria a respectiva rede com a extensão '.net'.

Parte 2: a inicialização do treinamento da rede, com o tipo de algoritmo da topologia e respectivos pesos, em que a cada iteração passou por um grande número de épocas para o conjunto de treinamento e validação. Quando identificado o menor erro MSE este era armazenado para fins de averiguação dos resultados.

### 3.5.7 Pós-processamento da RNA

Realizadas todas as etapas do treinamento, o SNNS gera um arquivo que representa, de forma estruturada, as redes neurais treinadas com a extensão “.net”. Essa estrutura detalha toda a rede com sua topologia, valores e pesos. Na pesquisa a linguagem escolhida para implementar os programas é a linguagem de programação C.

O SNNS2C faz parte do software SSNS, em que, lê o arquivo onde contém a rede neural escolhida e gera a sua representação em código fonte C. O código foi

adicionado na forma de biblioteca, a um programa desenvolvido para gerar as simulações com a rede neural de menor erro MSE.

### 3.5.8 Estatística Da Rna

O processo estatístico consistiu em analisar os resultados das simulações da RNA de menor erro MSE, buscando avaliar o seu desempenho. Tendo os dados dos pontos amostrais observados em comparação com os dados simulados pela RNA foi calculado o valor do coeficiente de determinação ( $R^2$ ) e a equação de regressão, de forma a avaliar o quanto os dados reais e simulados estão semelhantes.

A topologia da rede neural que apresentou o menor erro MSE foi averiguada por testes estatísticos, e nesta realizados os testes finais para comprovar se há a resposta desejada do modelo na simulação dos valores do ensaio radial do aspersor.

## 4 ANÁLISE DE RESULTADOS

Neste capítulo serão abordados os resultados obtidos pelos testes da RNA, a fim de verificar a eficiência do modelo, interpolação linear e testes estatísticos da Anova, Lilliefors (Kolmogorov-Smirnov), coeficiente de Pearson e determinação.

### 4.1 MELHOR TOPOLOGIA DA REDE

Avaliado os treinamentos e escolhida a rede que obteve o menor erro MSE para determinar o momento de parada ideal. As redes foram testadas com 10 mil épocas, julgada como sendo o suficiente, sempre considerando evitar a ocorrência indesejada de *underfitting* ou *overfitting*. Se adicionados uma quantidade pequena de épocas, elas podem resultar em um treinamento insuficiente, já em excesso pode ocasionar memorização dos dados de treinamento e, conseqüentemente, baixar a capacidade de generalização (MARTINS et al., 2015).

O algoritmo *backpropagation* da Tabela 10 e representado na Tabela 11 sem o termo *momentum*, utilizaram as taxas de aprendizado no intervalo de 0,1 a 1,0. O treinamento com essas taxas deu-se pela influência da alteração, pois com uma taxa de aprendizado muito pequena o treinamento terá uma trajetória suave, pequenas iterações e aprendizado lento, já para uma taxa maior há uma mudança grande nos pesos da rede, aumento de velocidade do aprendizado e podem ocorrer oscilações na rede, que prejudicam o seu aprendizado. Os valores de teste 1 até 8 representam o coeficiente de determinação ( $R^2$ ) calculado para cada um dos testes. Para cada taxa de aprendizado se obteve o número de neurônios na camada oculta que gerou o menor erro de MSE.

Do total foi realizado três testes para cada taxa de aprendizado, no algoritmo *backPropagation* com e sem o termo *momentum*. Construídas 30 mil redes, do qual apenas uma foi selecionada para satisfazer os resultados da pesquisa.

Tabela 10 – Valores de  $R^2$  da correlação entre os valores observados e simulados pela RNA treinada com o algoritmo *backpropagation* sem o termo *momentum*

<b>Tx de</b>											
<b>Aprendizado</b>	<b>Teste 1</b>	<b>Teste 2</b>	<b>Teste 3</b>	<b>Teste 4</b>	<b>Teste 5</b>	<b>Teste 6</b>	<b>Teste 7</b>	<b>Teste 8</b>	<b>Neurônios</b>	<b>Época</b>	<b>MSE</b>
0,1	0,9799	0,6775	0,7978	0,8223	0,8125	0,6418	0,6268	0,9473	33	3983	0,00451845
0,2	0,9028	0,9549	0,9479	0,9555	0,9539	0,9321	0,8985	0,9748	217	2015	0,00444166
0,3	0,9282	0,9432	0,9443	0,9563	0,9474	0,9277	0,8915	0,9808	475	1321	0,0043278
0,4	0,9151	0,9479	0,9452	0,9739	0,9588	0,928	0,9229	0,9812	85	1130	0,00436493
0,5	0,9556	0,9064	0,953	0,9443	0,9268	0,9033	0,8562	0,9766	495	969	0,0042659
0,6	0,9264	0,9435	0,9529	0,9673	0,953	0,9318	0,9007	0,9847	93	751	0,00435358
0,7	0,9326	0,9425	0,9489	0,9647	0,9538	0,9261	0,8926	0,9772	368	798	0,0044916
0,8	0,9368	0,9255	0,9586	0,9618	0,9399	0,9254	0,8813	0,981	172	542	0,00441278
0,9	0,941	0,9294	0,9564	0,9667	0,9381	0,9309	0,8877	0,9789	252	545	0,00451077
1,0	0,9539	0,8902	0,9549	0,9583	0,8751	0,9184	0,8479	0,9778	449	418	0,00469524

Legenda: *BackPropag*: *backpropagation* ; MSE: erro quadrático médio; Tx de aprendizado: taxa de aprendizado.

Fonte: Autoria própria.

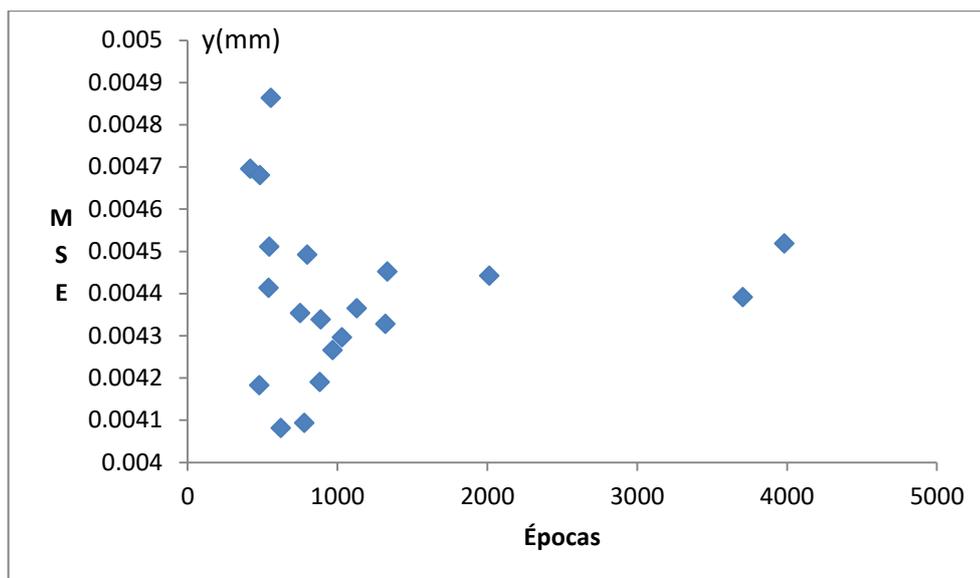
Tabela 11 - Valores de R2 da correlação entre os valores observados e simulados pela RNA treinada com o algoritmo *backpropagation* com o termo *momentum=0,3*

Tx de											
Aprendizado	Teste 1	Teste 2	Teste 3	Teste 4	Teste 5	Teste 6	Teste 7	Teste 8	Neurônios	Época	MSE
0,1	0,9636	0,8772	0,9468	0,9248	0,9128	0,8739	0,7969	0,9791	77	3705	0,00439144
0,2	0,913	0,9509	0,945	0,9563	0,9481	0,9279	0,8969	0,9773	401	1334	0,00445148
0,3	0,9636	0,8934	0,9493	0,9679	0,9414	0,8818	0,8766	0,9613	399	890	0,004338
0,4	0,938	0,8539	0,9398	0,9539	0,9363	0,8333	0,8345	0,9627	416	882	0,00419026
0,5	0,9628	0,9249	0,928	0,9325	0,9652	0,8761	0,8672	0,9459	488	780	0,00409313
0,6	0,8951	0,9235	0,953	0,9432	0,9293	0,9093	0,8552	0,9703	423	1031	0,00429593
0,7	0,9656	0,9033	0,9509	0,9414	0,9556	0,8585	0,8568	0,973	459	623	0,0040812
0,8	0,9163	0,9215	0,9511	0,9355	0,9265	0,9055	0,8486	0,9612	461	480	0,00418203
0,9	0,9224	0,8963	0,9347	0,8895	0,9312	0,8422	0,8206	0,9399	491	484	0,00467971
1,0	0,9551	0,7519	0,9661	0,9279	0,874	0,7951	0,7853	0,9654	65	556	0,00486291

Legenda: *BackPropag*: *backpropagation* ; MSE: erro quadrático médio; Tx de aprendizado: taxa de aprendizado.

Fonte: Autoria própria.

A Figura 15 apresenta o gráfico da iteração do menor erro MSE e as épocas, concluindo que do total de 10 mil épocas treinadas, o menor erro MSE ficou no intervalo de 0,0040 a 0,0049mm e entre 500 a 4000 épocas. Diante disso, observa-se que os treinamentos realizados nas RNAs não necessitam de tantas épocas para satisfazer os resultados.



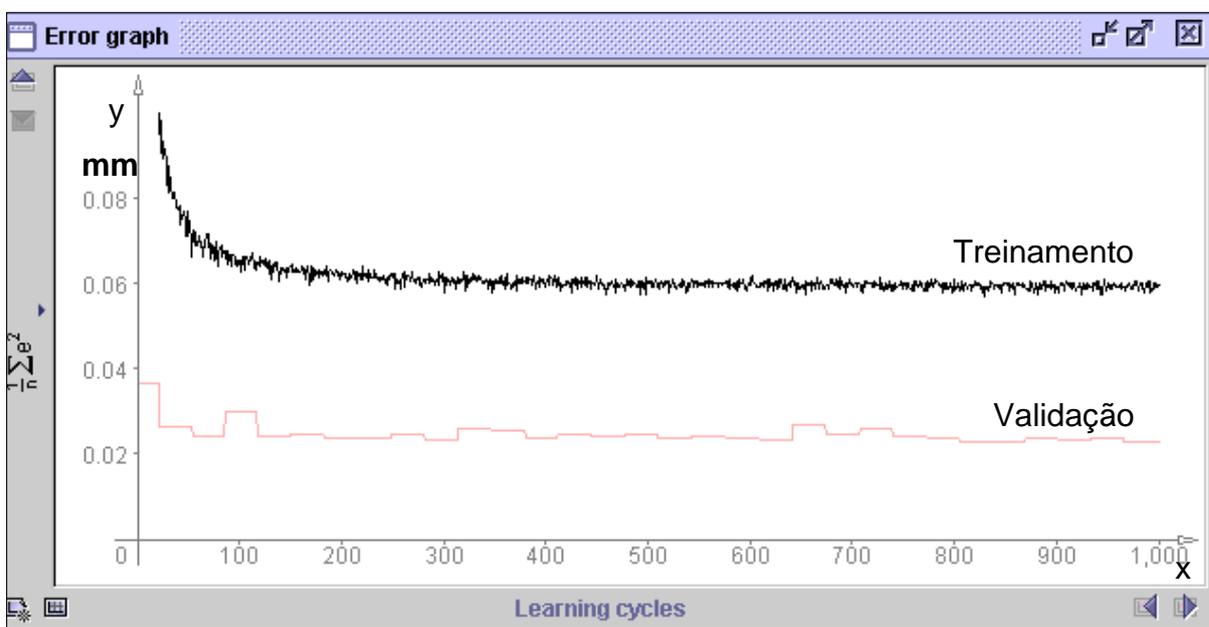
**Figura 15 – Menor erro MSE observado versus as épocas de treinamento**  
**Fonte: Autoria própria.**

O processo de treinamento normalmente é feito com o algoritmo de *backpropagation* padrão (sem o termo *momentum*) o qual pode apresentar uma lenta taxa de convergência. O termo *momentum* é uma alternativa que pode acelerar a convergência da rede e aumentar a capacidade de generalização (ROJAS; FELDMAN, 1996). Avaliando os resultados das redes, no algoritmo *backpropagation* sem o termo *momentum* (Tabela 10) o treinamento atingiu os valores do menor erro MSE no intervalo de 0,0042 a 0,00469mm. No algoritmo *backpropagation* com o termo *momentum* da Tabela 11, os resultados observados e simulados obtiveram o menor erro MSE em torno de 0,0040812 a 0,00478mm.

O resultado da avaliação do *backpropagation* sem e com o termo *momentum* obteve o menor erro MSE **com o termo *momentum*** de 0,00408mm, portanto indica que sua convergência foi satisfatória no treinamento das RNAs.

## 4.2 ESCOLHA DA MELHOR REDE

A melhor rede (6x459x1) na simulação é determinada pelo seu menor erro MSE (0,0040812) a taxa de aprendizado de 0,7, constituindo 459 neurônios na camada oculta. A Figura 16, demonstra a validação do erro de treinamento (linha acima) e de validação (linha abaixo) ao longo das épocas.



**Figura 16 - Curva de treinamento da RNA pelo menor erro MSE**  
**Fonte: Autoria própria.**

Verificando a capacidade de generalização entre o conjunto de treinamento (primeira curva, acima) e validação (segunda curva, abaixo) a época 623 obteve o menor erro MSE (entre a validação e o treinamento), sendo satisfatório para o resultado, pois evitou a ocorrência de *overfitting* e *underfitting* na rede simulada.

## 4.3 ESTATÍSTICA DA REDE

Os testes para averiguar a eficiência do modelo baseado nas redes neurais para simular a irrigação por aspersão foram escolhidos por meio da revisão de

literatura. A estatística descritiva mostrada na Tabela 12 destaca a (média, variância, desvio padrão e o erro padrão) para cada uma das amostras testadas.

**Tabela 12 – Estatística descritiva da melhor RNA.**

Testes	Média	Variância	Desvio Padrão	Erro Padrão
Obs T1	0,295	0,121571	0,348671	0,123274
Sim T1	0,200375	0,059233	0,243377	0,086047
Obs T2	0,2575	0,064136	0,25325	0,089538
Sim T2	0,162125	0,023648	0,15378	0,05437
Obs T3	0,41125	0,148841	0,385799	0,136401
Sim T3	0,433	0,115637	0,340054	0,120227
Obs T4	0,32125	0,081298	0,285128	0,100808
Sim T4	0,266625	0,046485	0,215605	0,076228
Obs T5	0,26125	0,06087	0,246718	0,087228
Sim T5	0,205875	0,035944	0,18959	0,06703
Obs T6	0,25875	0,065355	0,255647	0,090385
Sim T6	0,179875	0,02682	0,163768	0,057901
Obs T7	0,2875	0,069907	0,2644	0,093479
Sim T7	0,208375	0,03555	0,188548	0,066662
Obs T8	0,52625	0,183798	0,428717	0,151574
Sim T8	0,44175	0,105039	0,324097	0,114586

**Legenda: sim: simulado; obs: observado; medidas em mm.**

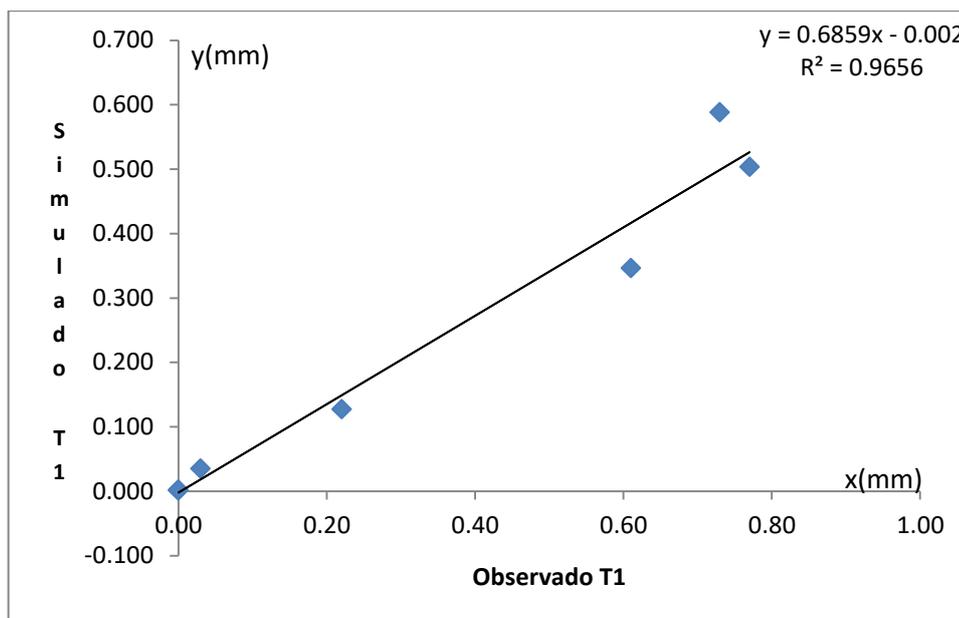
**Fonte: Autoria própria.**

As interpretações para o resultado descritivo das amostras observadas e simuladas apresentaram uma diferença pequena entre as médias dos pares, no geral houve a diferença de 10%. A variância apresentou resultado baixo de 0,01 até 0,08 entre os pares das amostras, destacando proximidade em relação à média. O desvio padrão obteve uma dispersão dos valores das amostras no intervalo de 0,15 a 0,42, concluindo que estão agrupadas próximas à média. O erro padrão ficou em torno de 0,05 a 0,11, que representa uma estimativa mais precisa sobre a média das amostras. Quando se tem um número grande de amostras e menor erro padrão em relação à média, se avalia uma estimativa precisa sobre o experimento.

A qualidade do modelo de irrigação por aspersão radial é calculado pelo coeficiente de determinação ( $R^2$ ), do qual se tem base do quanto o modelo simulado pela RNA é eficiente em relação ao observado.

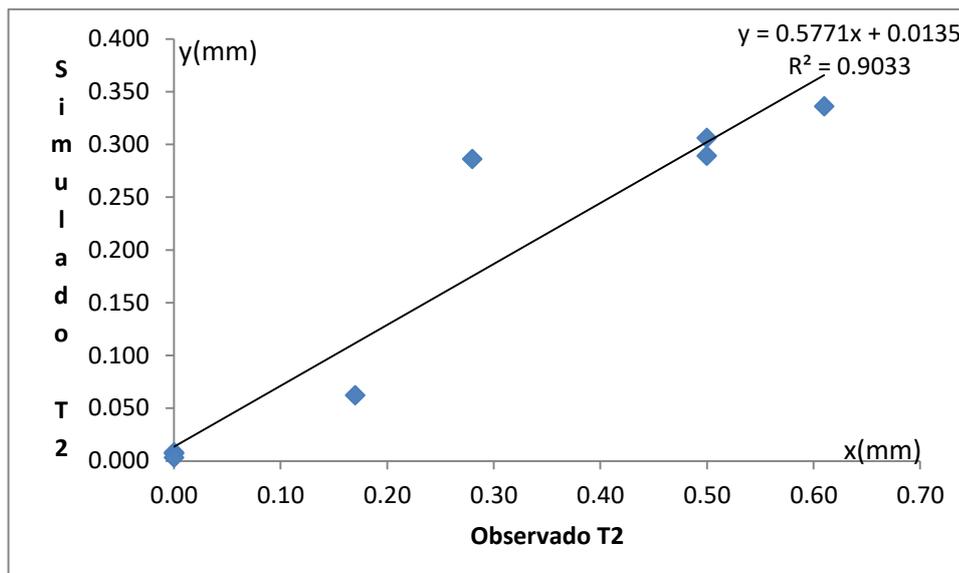
A Figura 17, apresenta a plotagem dos dados simulados em função dos dados observados do teste 1. Observa-se, que os pontos se aproximam do ajuste da

reta (coeficiente de correlação de Pearson  $r=0,98$ ). O valor do  $R^2$  foi de 0,96 indicando que a reta de regressão é ótima, pois está próximo de 1. A função de regressão escreve a relação de força entre as amostras, mas também indica a possibilidade de antecipar futuros novos pares. O método dos mínimos quadrados é usado para ajustar a reta de regressão.



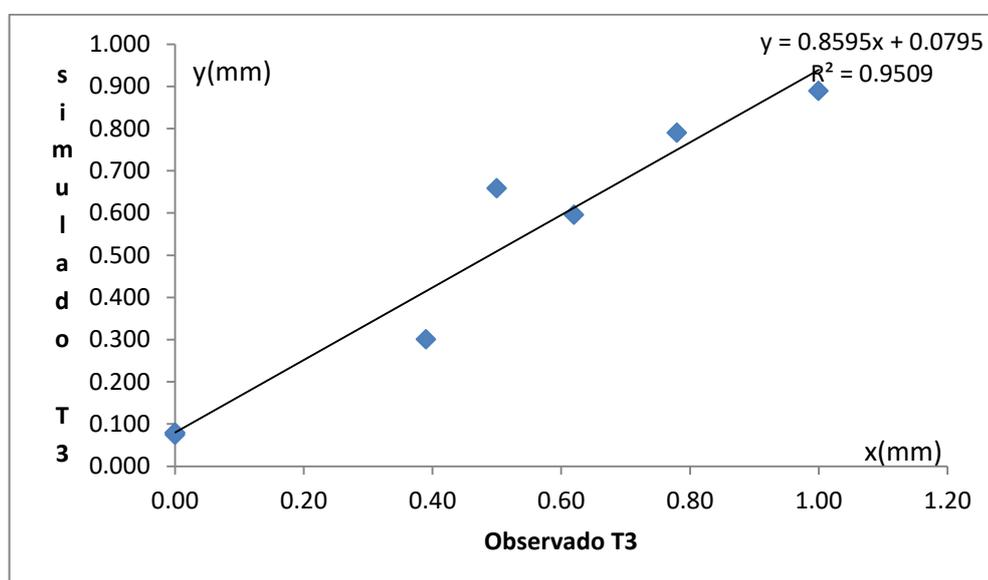
**Figura 17 - Dispersão do teste 1 entre as amostras Observado e o Simulado**  
Fonte: Autoria própria.

Na Figura 18 observa-se o valor de  $R^2 = 0,90$ , o coeficiente de correlação de Pearson foi de 0,95. Por meio do valor do  $R^2$  da reta de regressão, verifica-se que o modelo é ótimo, logo nas amostras houve um ajuste de qualidade.



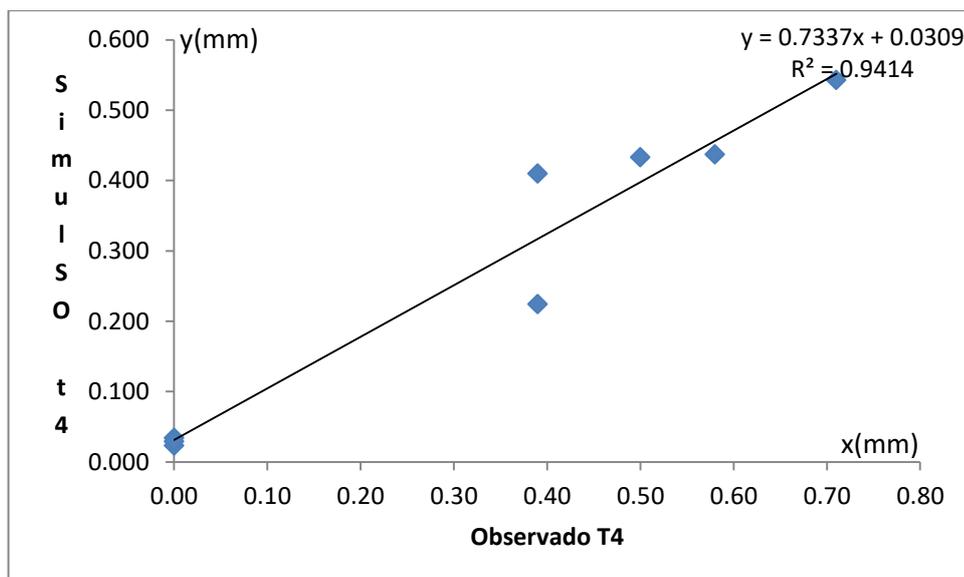
**Figura 18 - Dispersão do teste 2 entre as amostras Observado e o Simulado**  
**Fonte: Autoria própria.**

No teste 3 o coeficiente correlação de Pearson foi de 0,97 indicando uma correlação forte e o valor do  $R^2 = 0,95$ , demonstra que houve uma ótima qualidade no ajuste, onde 95% das variações de y (simulado) estão sendo explicadas pelas variações de x (observado) (Figura 19).



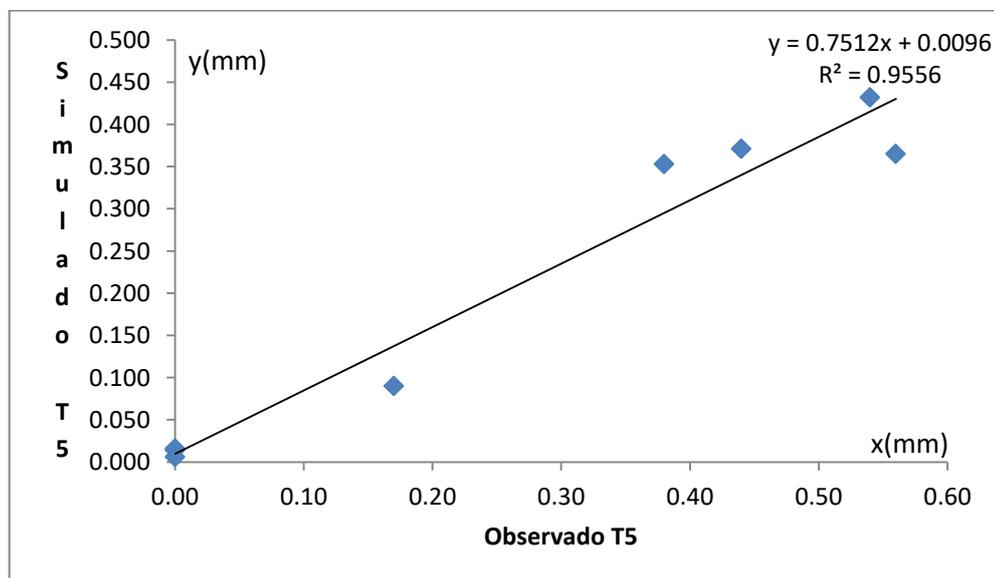
**Figura 19 - Dispersão do teste 3 entre as amostras Observado e o Simulado**  
**Fonte: Autoria própria.**

A Figura 20 também indica um ajuste ótimo entre x (observado) e y (simulado) para o teste 4, com o  $R^2 = 0,94$ . Isto significa que 94% das amostras apresentam qualidade no ajustamento.



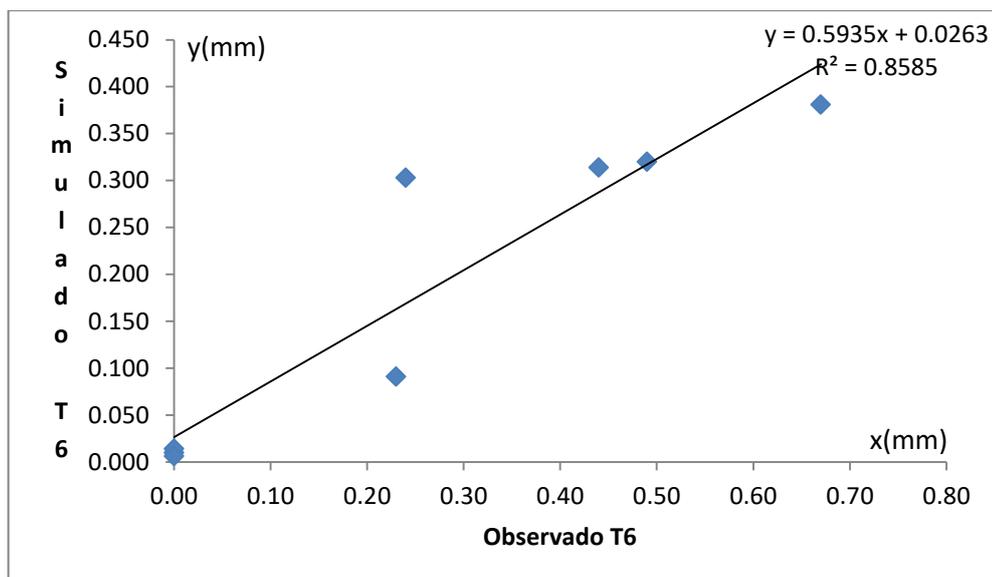
**Figura 20 - Dispersão do teste 4 entre as amostras Observado e o Simulado**  
 Fonte: Autoria própria.

A Figura 21 demonstra o valor de  $R^2 = 0,95$  para o teste 5, desta forma 95,56% do modelo simulado tem qualidade ótima sobre o ajuste do observado.



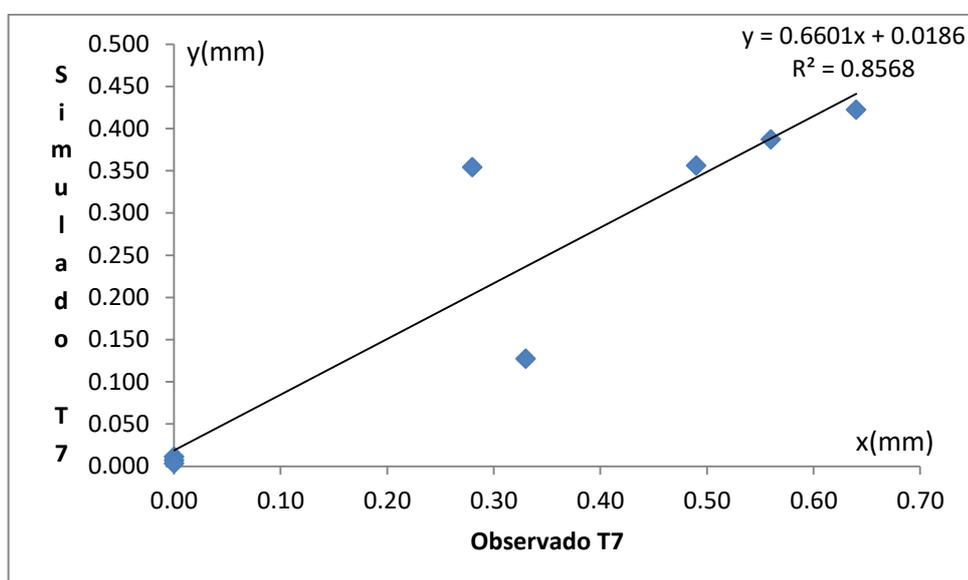
**Figura 21 - Dispersão do teste 5 entre as amostras Observado e o Simulado**  
 Fonte: Autoria própria.

Já para o teste 6 (Figura 22) o valor de  $R^2$  foi de 0,85, apresentando uma boa qualidade, entretanto deixa de explicar 14,5% das amostras observadas. A performance deste teste foi um pouco baixo, mas ainda mostra que o modelo ajustado é satisfatório a 85% no modelo de regressão, ou seja, 85,8% das variações dos dados simulados estão sendo explicados pelos dados observados.



**Figura 22 – Dispersão do teste 6 entre as amostras Observado e o Simulado**  
**Fonte: Autoria própria.**

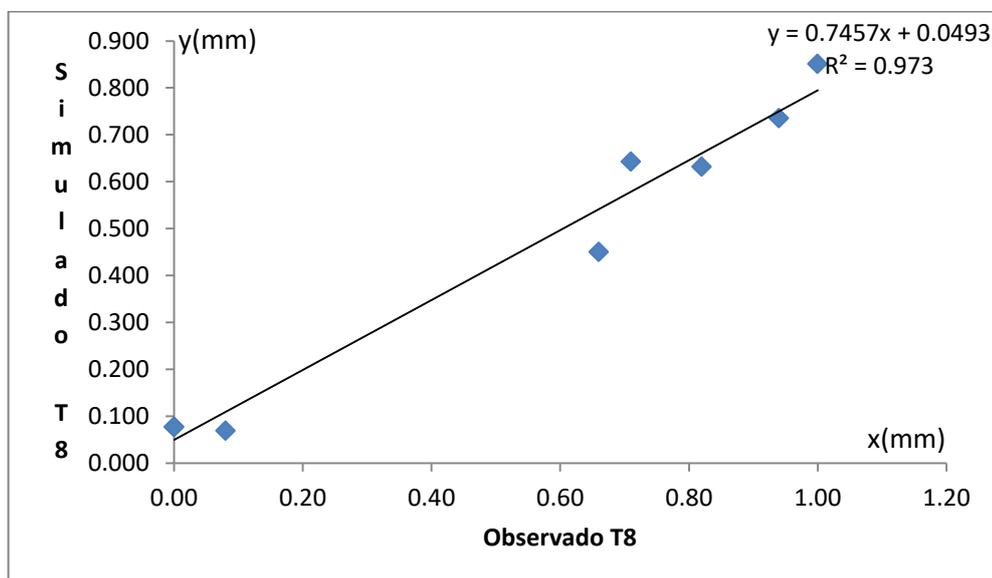
O mesmo ocorre no teste 7 o valor de  $R^2$  foi de 0,856, o ajuste linear foi bom onde os valores simulado explicam 85,6% dos valores observado no modelo de regressão (Figura 23).



**Figura 23 - Dispersão do teste 7 entre as amostras Observado e o Simulado**  
**Fonte: Autoria própria.**

A melhor explicação ocorreu no teste 8 apresentado na Figura 24, onde o valor do  $R^2$  foi de 0,97. Neste teste o modelo linear de regressão deixa de explicar

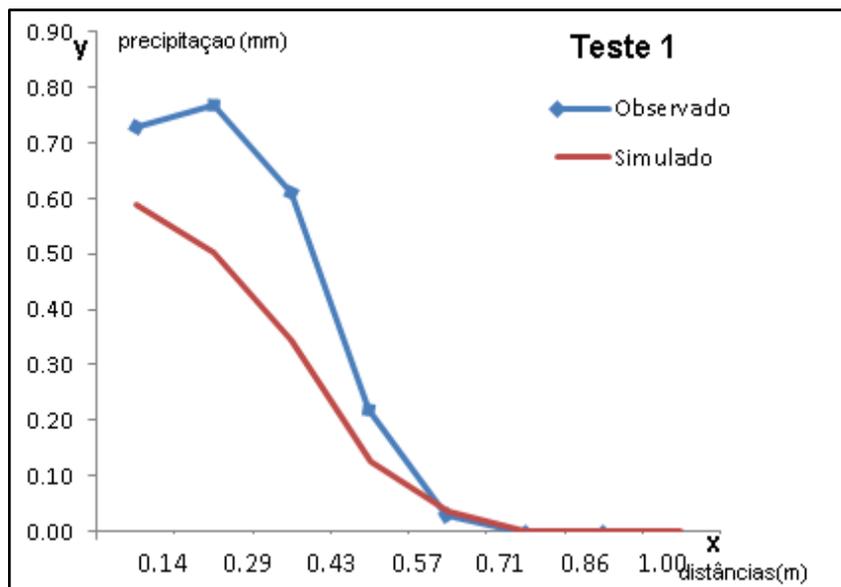
somente 2,7% das amostras observadas, ou seja, 97,3% das amostras são explicadas no modelo de regressão, logo a um ajuste de ótima qualidade.



**Figura 24 - Dispersão do teste 8 entre as amostras Observado e o Simulado**  
 Fonte: Autoria própria.

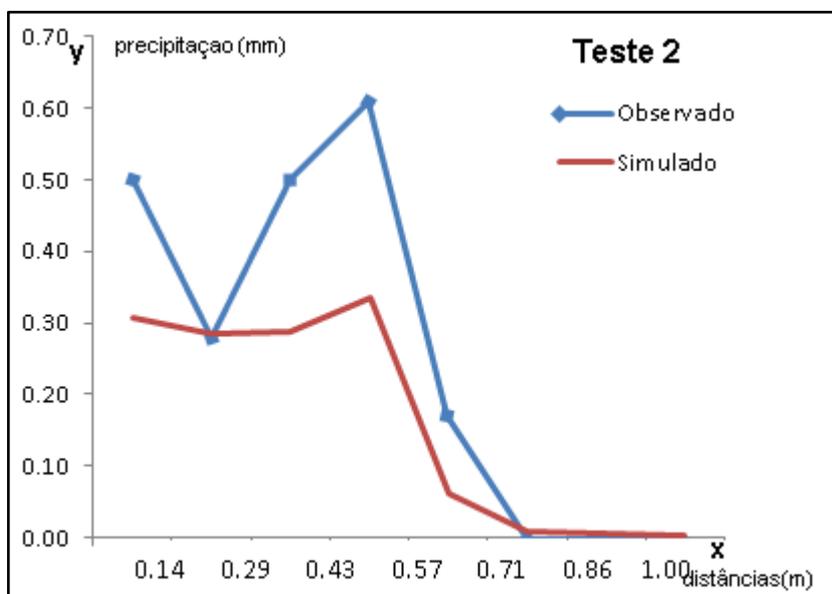
A relação entre os testes verifica o quanto o modelo observado se relaciona com o simulado em comparação com as distribuições das distâncias, pois quanto mais dispersas as precipitações do aspersor menor captação é realizada pelos coletores. A média geral de todos os testes para o  $R^2$  ficou em torno de 93%, indicando uma boa qualidade.

A comparação do primeiro teste é demonstrado na Figura 25, entre o modelo observado (linha azul quadriculada, acima) e simulado (linha lisa marrom, abaixo), do qual a relação entre as amostras distintas é de aproximadamente 0,27mm de precipitações nas distâncias próximas de 0,14 á 0,43m .



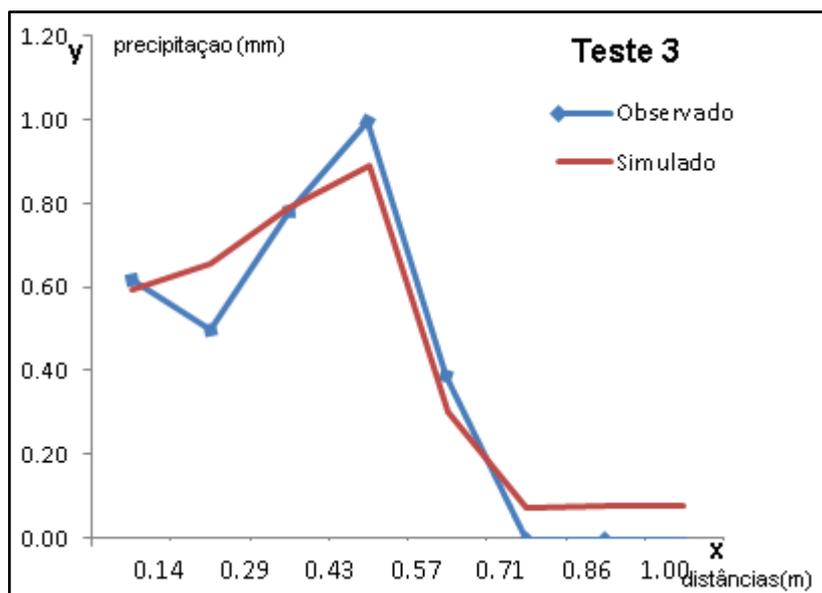
**Figura 25 - Relação das distâncias do modelo simulado e observado do teste 1**  
**Fonte: Autoria própria.**

A relação do resultado do teste 2 exibido na Figura 26, mostra uma oscilação de aproximadamente 0,21 á 0,27mm de precipitações na distância de 0,29 e 0,43m.



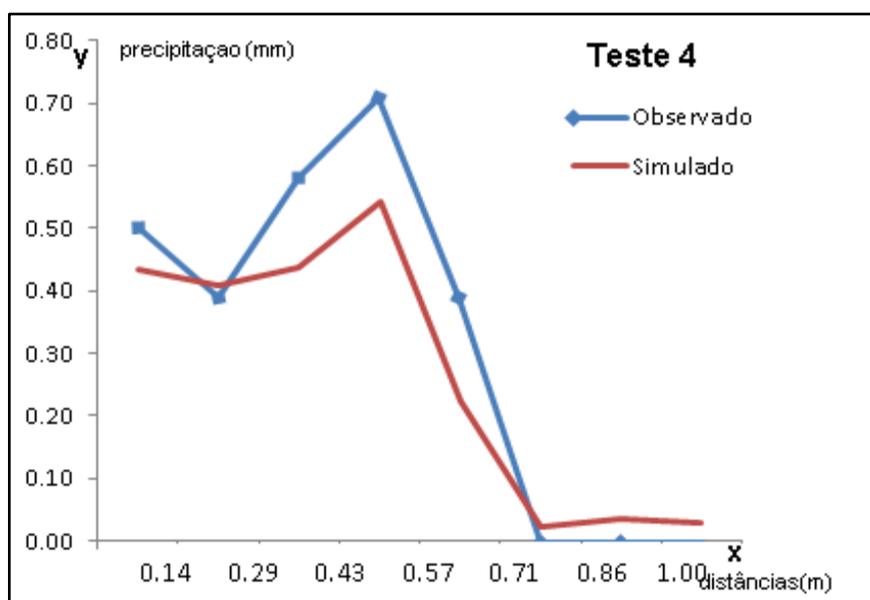
**Figura 26 - Relação das distâncias do modelo simulado e observado do teste 2**  
**Fonte: Autoria própria.**

A Figura 27 apresenta o modelo observado e simulado do teste 3, do qual a mínimas variações, estando próximas as precipitações observadas e simuladas. Variando em 0,15mm na distância de 0,86 á 1,00m.



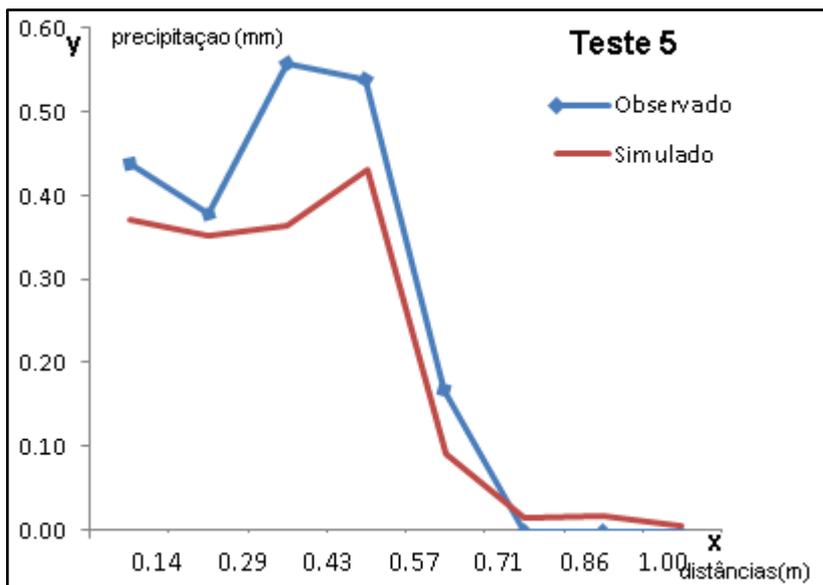
**Figura 27 - Relação das distâncias do modelo simulado e observado do teste 3**  
**Fonte: Autoria própria.**

O teste 4 (Figura 28), mostra também pequenas variações na precipitação em 0,16mm de precipitação em relação a distância de 0,43 á 0,57m.



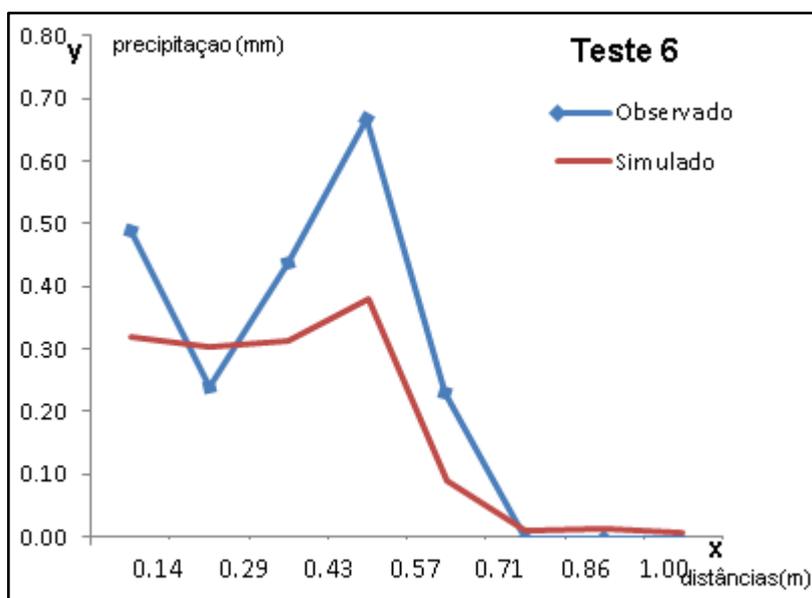
**Figura 28 - Relação das distâncias do modelo simulado e observado do teste 4**  
**Fonte: Autoria própria.**

A variação do teste 5 (Figura 29) entre o modelo observado e simulado é evidenciada com maior destaque na distância de 0,43m, com uma pequena diferença de 0,19mm de precipitação.



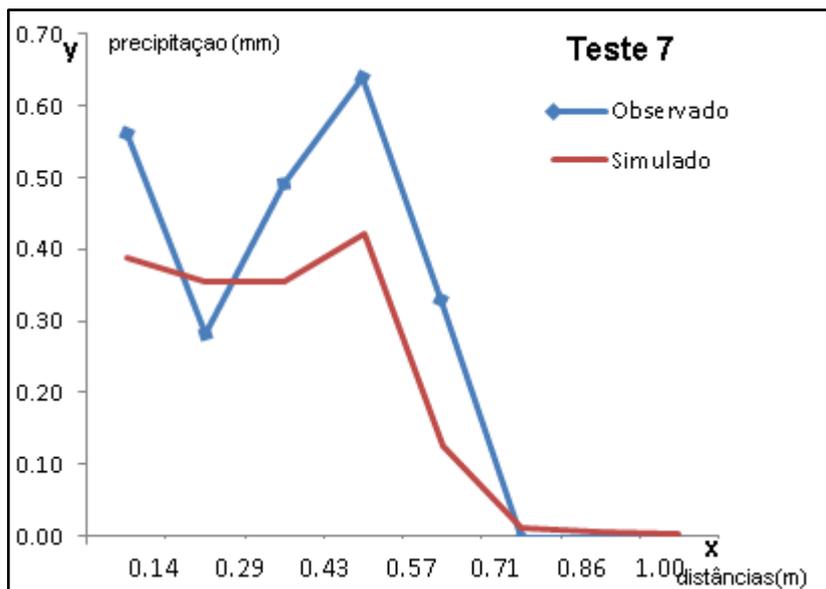
**Figura 29 - Relação das distâncias do modelo simulado e observado do teste 5**  
**Fonte: Autoria própria.**

Já a Figura 30 demonstra a maior variação na distância de 0,43m, com precipitação em torno de 0,29mm.



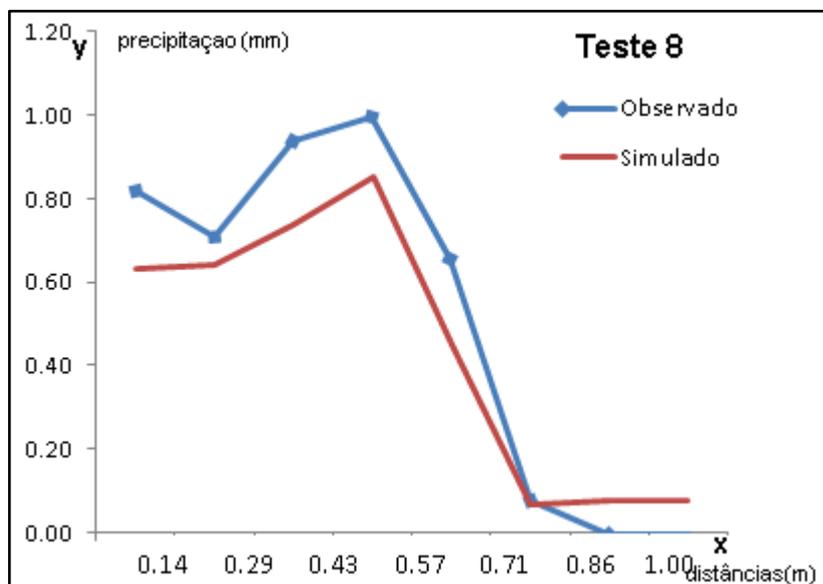
**Figura 30 - Relação das distâncias do modelo simulado e observado do teste 6**  
**Fonte: Autoria própria.**

Para o teste 7 (Figura 31) a variância foi de 0,21mm de precipitação na distância aproximada de 0,50m, assemelhando-se ao teste anterior.



**Figura 31 - Relação das distâncias do modelo simulado e observado do teste 7**  
**Fonte: Autoria própria.**

O teste 8 foi o mais promissor entre todos, visualizado na Figura 32 destaca poucas diferenças na aproximação das amostras observadas e simuladas. A maior variação ocorreu na distância de 0,57m com 0,21mm de precipitação.



**Figura 32 - Relação das distâncias do modelo simulado e observado do teste 8**  
**Fonte: Autoria própria.**

Os resultados obtidos pelo teste de Lilliefors (Kolmogorov-Smirnov) da Tabela 13, mostram que tanto as amostras observadas e simuladas possuem distribuição normal, pois para todos os testes o valor de p foi maior que  $\alpha = 0,05$  ( $\alpha$ =nível de significância). Se tivesse ocorrido alguma consequência de valores

baixos do nível de significância para os testes, este poderia ser explicado pelo nível oscilatório da RNA. O grau de concordância entre os amostras simuladas e observadas se mostraram promissoras para adequar a normalidade dos testes.

**Tabela 13 - Teste de Lilliefors (Kolmogorov-Smirnov) para as amostras resultantes da análise da RNA entre observado e o simulado**

<b>Lilliefors (Kolmogorov-Smirnov)</b>					
Testes	D	Valor-p	Testes	D	Valor-p
Obs T1	0,27638	0,07255	Sim T1	0,25159	0,1426
Obs T2	0,22037	0,3021	Sim T2	0,28974	0,0567
Obs T3	0,23178	0,2331	Sim T3	0,22606	0,2661
Obs T4	0,24506	0,1684	Sim T4	0,24697	0,1605
Obs T5	0,23018	0,242	Sim T5	0,28113	0,06223
Obs T6	0,21926	0,3095	Sim T6	0,27392	0,07844
Obs T7	0,23656	0,2078	Sim T7	0,28005	0,06446
Obs T8	0,24747	0,1585	Sim T8	0,2448	0,1695

**Legenda: obs: observados; sim: simulado.**

**Fonte: Aatoria própria.**

O coeficiente de Pearson (Tabela 14) concluiu que a correlação entre as amostras lineares é perfeitamente positiva, então podemos afirmar que os dados observados ficam próximos ao simulados pela RNA e vice-versa. Os testes estatísticos confirmam o relacionamento da correlação entre as amostras observadas e as simuladas em um grau muito forte. Para o valor de  $p \leq \alpha$  (0.05) significa que a proporção entre os desvios padrão ou variâncias é estatisticamente significativa (rejeita H0), logo existe um relacionamento linear nas amostras.

**Tabela 14 - Correlação de Pearson entre o modelo observado e o simulado**

<b>Pearson produto-momento</b>		
Testes	Valor-p	Cor
Obs X Sim T1	t = 12,985, df = 6 Valor-p = 1,285e-05	0,982668
Obs X Sim T2	t = 7,4877, df = 6, Valor-p = 0,0002932	0,950435
Obs X Sim T3	t = 10,782, df = 6, Valor-p = 3,764e-05	0,975154
Obs X Sim T4	t = 9,8167, df = 6, Valor-p = 6,436e-05	0,970252
Obs X Sim T5	t = 11,369, df = 6 Valor-p = 2,775e-05	0,977566

Obs X Sim T6	t = 6,033, df = 6, Valor-p = 0,0009372	0,926542
Obs X Sim T7	t = 5,9909, df = 6, Valor-p = 0,0009722	0,925619
Obs X Sim T8	t = 14,716, df = 6, Valor-p = 6,185e-06	0,986429

**Legenda: obs: observados; sim: simulados; df: graus de liberdade; cor: correlação.**

**Fonte: Autoria própria.**

O teste da Anova para um fator foi usado para a melhor compreensão dos resultados da RNA, comparando as amostras observadas e as simuladas. Nota-se que não houve diferença significativa entre as amostras ( $p = 0,318177 > \alpha = 0,05$ ), ao nível de 5% de significância exibida na Tabela 15.

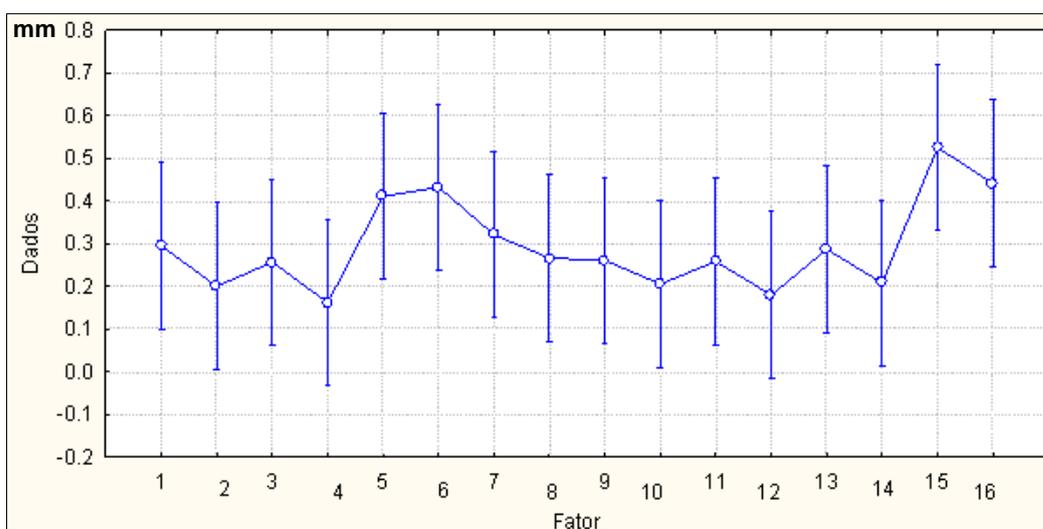
**Tabela 15 – Estatística da ANOVA aninhada entre dados e fatores**

Efeito	Graus de liberdade	amostra SS	amostra MS	amostra F	amostra p
Interceptação	1	1,112,387	1,112,387	1,430,569	0
Fator	15	134,632	0,08975	11,543	<b>0,318177</b>
Erro	112	870,893	0,07776		
Total	127	1,005,525			

**Legenda: SS: soma dos quadrados, MS: quadrados médios sequências, F: análise de cada termo, p: mede a evidência do modelo.**

**Fonte: Autoria própria.**

A Figura 33 compara as médias das amostras observadas. Nota-se que ficam entre o intervalo de 0,1 á 0,5mm.



**Figura 33 - Comparação das médias em relação às amostras**

**Fonte: Autoria própria.**

Percebe-se na Figura 34, que os pontos dos testes estão próximos da reta, e que os valores de  $y$  estão normalmente distribuídos para cada valor de  $x$ , indicando a normalidade da distribuição.

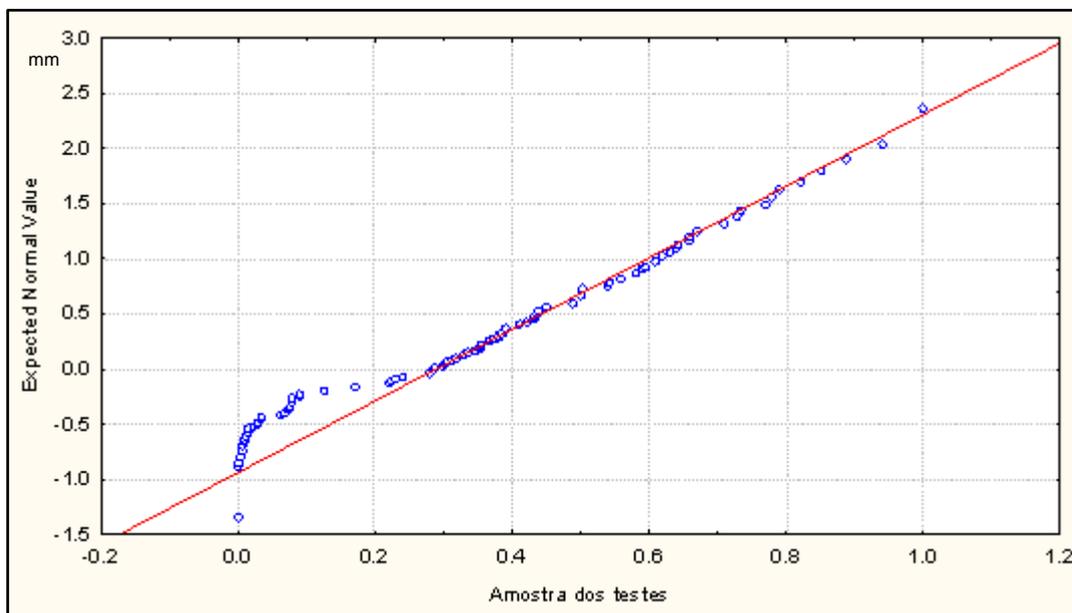
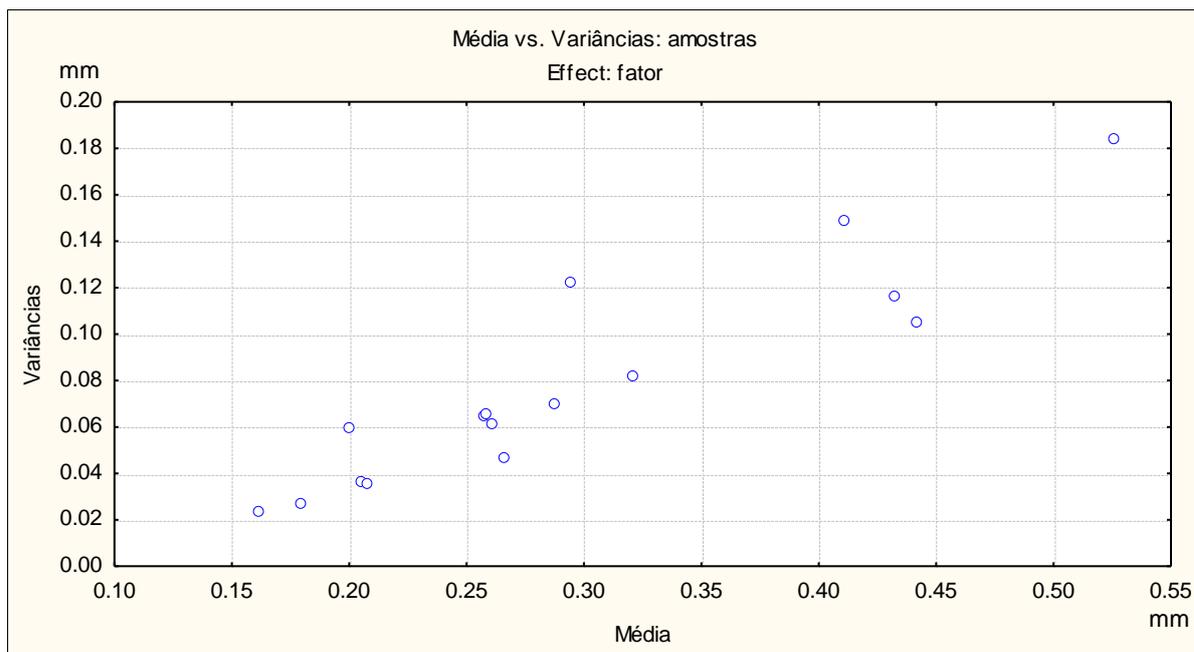


Figura 34 - Dispersão dos dados referente aos testes

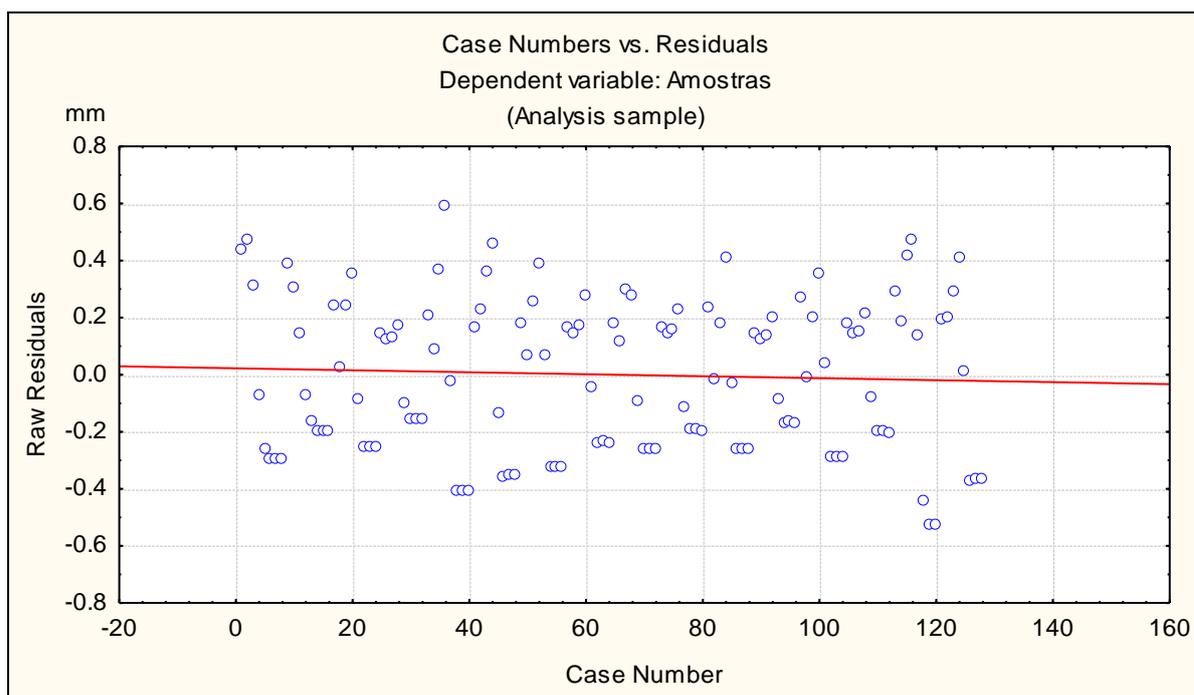
Fonte: Autoria própria.

Ao Comparar os valores da média e da variância entre as amostras observadas e as simuladas (Figura 35), se pode observar que elas não se afastam muito da reta indicando uma homogeneidade das variâncias, que é confirmado pelos testes de Cochran C e de Bartlet. Em ambos os testes o valor de  $p > \alpha = 0,05$ , logo se aceita a hipótese de que as variâncias das amostras são iguais ao nível de significância a 5%. Portanto neste teste ratifica a suposição de homogeneidade como válida.



**Figura 35 - Análise comparativa das médias e as variâncias das amostras**  
Fonte: Autoria própria.

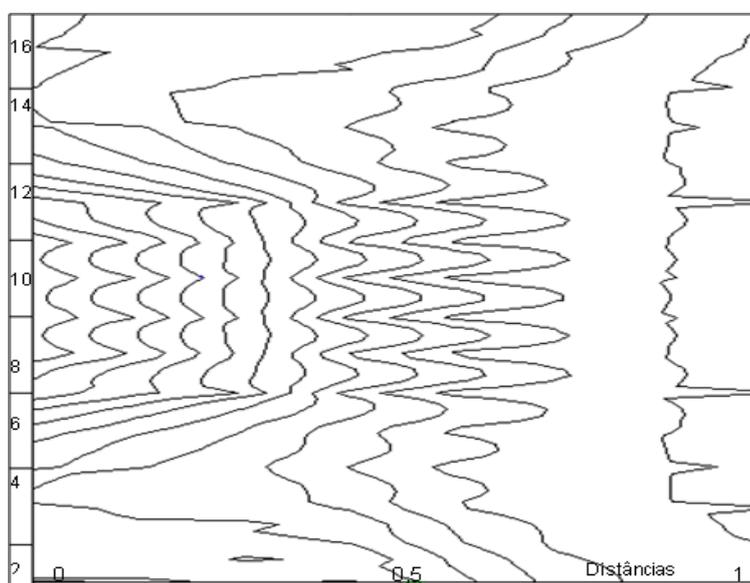
Observando a Figura 36 de resíduos x amostras, os resíduos estão distribuídos aleatoriamente em torno da reta  $e = 0$  (alternância homogênea de pontos positivos e negativos), padrões de alternância de sinais, logo os resíduos são independentes, condiz que o erro (diferença residual entre as amostras e previstos de Y) deva ser independente para cada valor de x.



**Figura 36 - Independência das amostras**  
Fonte: Autoria própria.

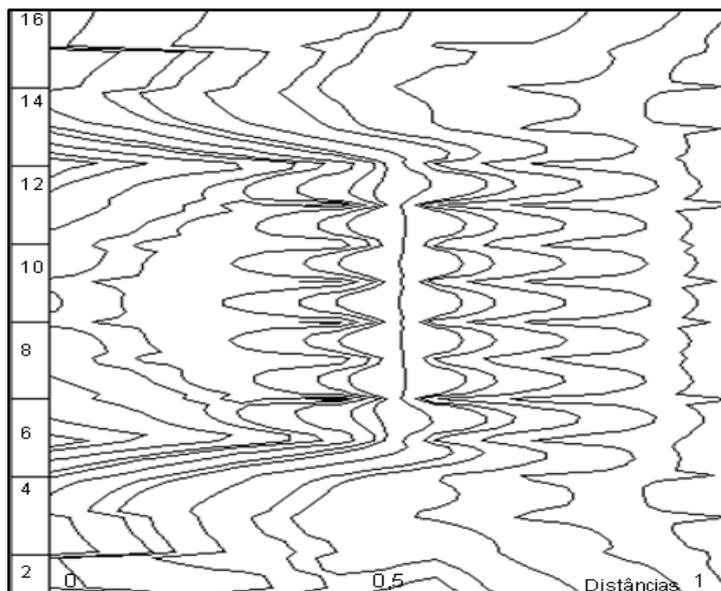
O conjunto de dados do ensaio radial simulados pela RNA permite representar um ensaio em malha. A Figura 37 se refere ao primeiro conjunto discreto de dados, as precipitações são representadas com a unidade de medida em mm, na malha de 16x16 coletores distribuídos. Observa-se na parte lateral a esquerda os pontos da malha e na parte inferior as distâncias (0 a 1).

Os valores foram interpolados pelo método da Krigagem e estimativa linear. Conforme os pluviômetros vão se afastando decai os valores de precipitação. As precipitações observadas comparadas por seus valores com as simuladas variam em torno de 0,0 á 0,27mm de precipitação.



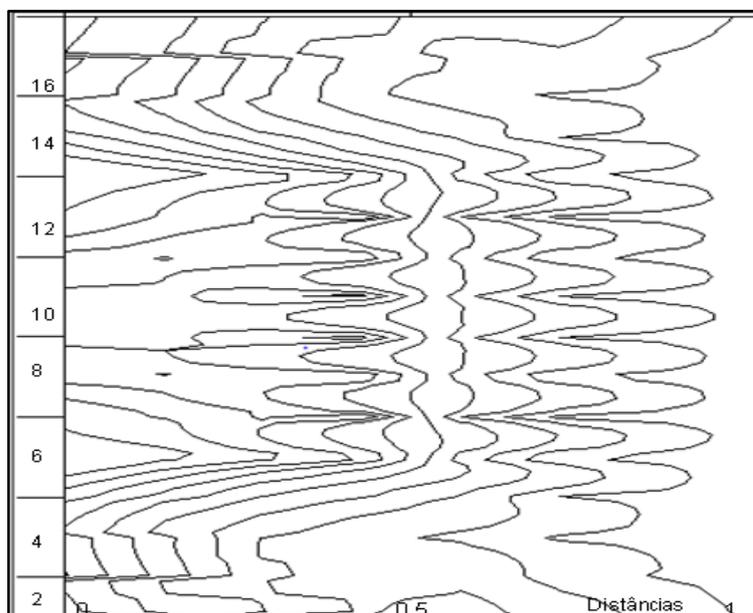
**Figura 37 - Mapa de isolinhas do teste 1**  
**Fonte: Autoria própria.**

A Figura 38 representa a interpolação do conjunto de dados 2, observando a captação de precipitações do ponto na distância linear parcial. Neste teste a comparação de valores observados e os simulados variam em torno de 0,0 á 0,27mm.



**Figura 38 - Mapa de isolinhas do teste 2**  
**Fonte: Autoria própria.**

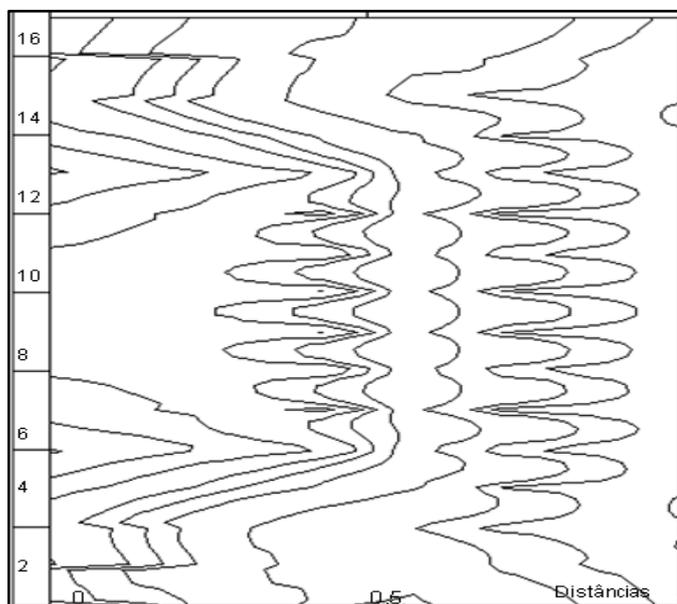
A interpolação do teste 3 é vista na Figura 39, as precipitações das distâncias mais altas são representadas na parte inferior. As precipitações comparadas por seus valores variam em torno do intervalo de 0,0 á 0,16mm.



**Figura 39 - Mapa de isolinhas do teste 3**  
**Fonte: Autoria própria.**

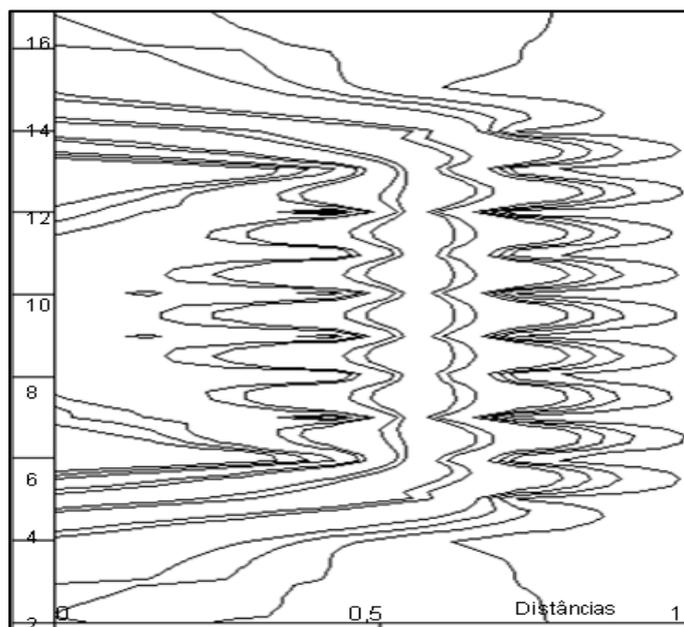
A Figura 40 também apresenta bons índices de precipitações, e revela que o modelo simulado do teste 4, apresentou bons resultados na simulação da captação

de chuva. Neste teste os valores comparados variam de 0,0 á 0,17mm de precipitação.



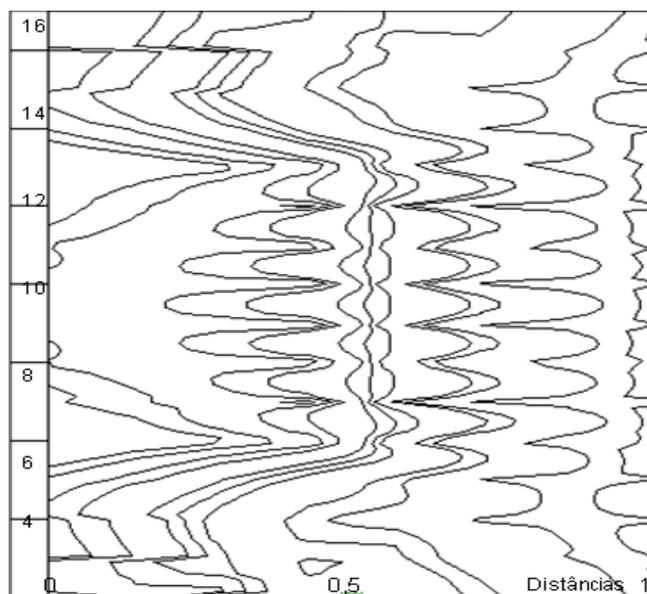
**Figura 40 - Mapa de isolinhas do teste 4**  
**Fonte: Autoria própria.**

A simulação radial da Figura 41 obteve dados precipitados variáveis e maiores nas posições iniciais, mas ao ser comparado seus valores com as amostras observadas ficam em torno de 0,0 a 0,20mm.



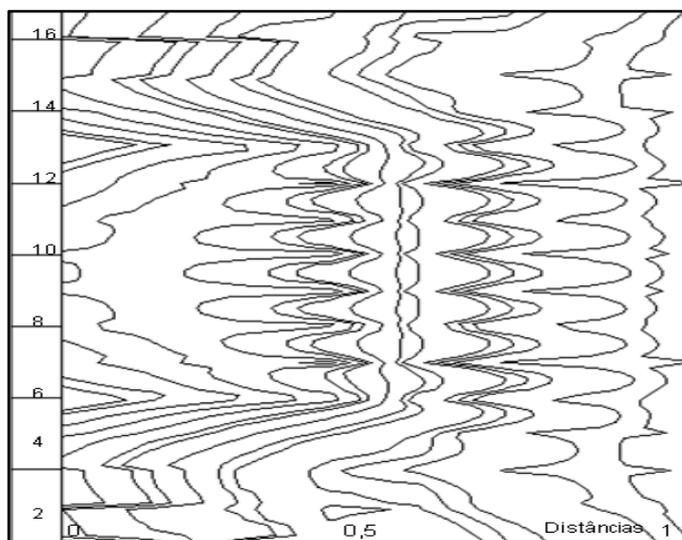
**Figura 41 - Mapa de isolinhas do teste 5**  
**Fonte: Autoria própria.**

A Figura 42 evidencia que os resultados precipitados tem um nível de determinação forte e níveis precipitados mostram de acordo com os anteriores com a maior incidência de chuva artificial no meio do conjunto de dados em valores próximos de 0,0 a 0,29mm.



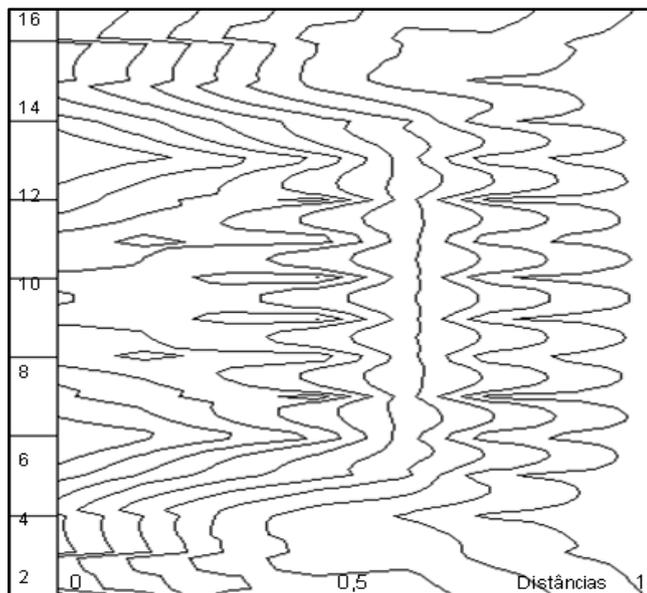
**Figura 42 - Mapa de isolinhas do teste 6**  
Fonte: Autoria própria.

O teste 7 (Figura 43) obtêm o critério parecido com o teste anterior. Já na comparação dos valores observados e os simulados variou de 0,0 a 0,20mm de precipitação.



**Figura 43 - Mapa de isolinhas do teste 7**  
Fonte: Autoria própria.

A Figura 44 mostra os melhores resultados das precipitações em um nível de eficiência muito forte, e este teste se destaca por ter sido o de melhor resposta dentre os outros. A comparação entre os valores resultou na pequena diferença de 0,0 a 0,21 mm de precipitação.



**Figura 44 - Mapa de isolinhas do teste 8**  
**Fonte: Autoria própria.**

Portanto, observa-se que as precipitações simuladas pelas RNAs comparadas com as observadas das amostras tiveram uma similaridade mínima em torno de 0,0 a 0,29mm.

As amostras obtiveram grande incidência nos valores, que averiguaram nas simulações obtidas pelas RNAs resultados satisfatórios aos realizados na irrigação em campo.

## 5 CONSIDERAÇÕES FINAIS

A conclusão obtida pela topologia de rede neural multicamadas foi de 6 neurônios na camada de entrada, 459 na camada oculta e 1 na camada de saída. Obteve desempenho satisfatório, treinada com o algoritmo *backpropagation* com o termo *momentum* obtendo boa capacidade de generalização.

Os resultados avaliaram que o uso de modelos baseados em redes neurais artificiais para simular os valores da precipitação dos aspersores radiais são promissores, já que o modelo desenvolvido nesta pesquisa simulou valores muito próximos dos observados nos ensaios radiais do aspersor.

As análises estatísticas conseguiram prever a normalidade na simulação dos dados radiais.

A pesquisa teve como objetivo contribuir para a área da simulação com este trabalho sobre o ensaio da irrigação por aspersão radial. A conclusão gerou resultados positivos em relação ao trabalho original, mostrando para a área agrônômica boas perspectivas ao propor e avaliar o sistema radial realizado em campo. A pesquisa ajuda a ter noção de que realizar a simulação como um pré-teste antes de por em prática, propicia redução de custos e avaliação do modelo a ser implementado na prática do campo.

## 6 TRABALHOS FUTUROS

No decorrer do desenvolvimento deste trabalho, observou-se a possibilidade de novas pesquisas que possam contribuir em:

1. Elaborar modelos de simulação de diferentes métodos de irrigação, os quais possam contribuir reduzindo custos e facilitando a avaliação dos sistemas de irrigação.
2. Simular o uso de irrigação por aspersão com fertilizantes por meio das RNAs.
3. Desenvolver um sistema que com a entrada das distâncias em um modelo de ensaio radial e com a obtenção dos demais parâmetros do sistema através de sensores, possa realizar a avaliação do sistema de irrigação.
4. Realizar o estudo sobre os coeficientes de uniformidade CUC, CUD e CUE e calcular seu perceptivo percentual em relação do modelo simulado e o observado.

## REFERÊNCIAS

ALVES, Elis Dener Lima; VECCHIA, Francisco Arthur Silva. **Análise de diferentes métodos de interpolação para a precipitação pluvial no Estado de Goiás**. Acta Scientiarum. Human And Social Sciences, [s.l.], v. 33, n. 2, p.193-197, 19 dez. 2011. Universidade Estadual de Maringá.  
<http://dx.doi.org/10.4025/actascihumansoc.v33i2.13815>.

ANA, Agência Nacional de Águas. **ATLAS IRRIGAÇÃO - Uso da Água na Agricultura Irrigada**. Brasília: Ana, 2017. 86 p. ISBN 978-85-8210-051-6. Disponível em: <[www.atlasirrigacao.ana.gov.br](http://www.atlasirrigacao.ana.gov.br)>. Acesso em: 05 abr. 2018.

ANDRADE, Camilo de Lelis Teixeira de; BRITO, Ricardo A. L.. **Cultivo do milho - Irrigação**. 2010. Disponível em:  
<[http://www.cnpms.embrapa.br/publicacoes/milho\\_6\\_ed/imetodos.htm](http://www.cnpms.embrapa.br/publicacoes/milho_6_ed/imetodos.htm)>. Acesso em: 06 jul. 2016.

ANTON, Howard; RORRES, Chris. **Álgebra linear com aplicações**. 8. ed. Porto Alegre,rs: Bookman, 2001. 572 p.

ARSHAM, Hossein; LOVRIC, Miodrag. **Bartlett's Test**. International Encyclopedia Of Statistical Science, p.87-88, 2011. Springer Berlin Heidelberg.  
[http://dx.doi.org/10.1007/978-3-642-04898-2\\_132](http://dx.doi.org/10.1007/978-3-642-04898-2_132).

BERNARDO, Salassier; SOARES, Alves Antonio; MANTOVANI, Everaldo. **Manual de irrigação**. 8. ed. Viçosa: Ufv, 2009. 625 p.

BARBOSA, João Paulo Macieira. **Utilização de método de interpolação para análise e espacialização de dados climáticos: o sig como ferramenta**. Caminhos de Geografia, n. 1, p.85-96, fev. 2006. ISSN 1678-6343.

BORGES, Giovana Mara Rodrigues; THEBALDI, Michael Silveira. **Estimativa da precipitação máxima diária anual e equação de chuvas intensas para o município de Formiga, MG, Brasil**. Ambiente e Agua - An Interdisciplinary Journal Of Applied Science, Formiga - Mg, v. 11, n. 4, p.891-902, 25 out. 2016. Instituto de Pesquisas Ambientais em Bacias Hidrográficas (IPABHi).  
<http://dx.doi.org/10.4136/ambi-agua.1823>.

BURAK, Dionísio. **Modelagem Matemática sob um olhar de Educação Matemática e suas implicações para a construção do conhecimento matemático em sala de aula**. Revista Modelagem na Educação Matemática, Ponta Grossa/Pr, v. 1, n. 1, p.10-27, 2010.

CALHEIROS, Carlos B. M. et al. **Definição da taxa de infiltração para dimensionamento de sistemas de irrigação por aspersão.** Revista Brasileira de Engenharia Agrícola e Ambiental, Campina Grande, Pb, v. 13, n. 6, p.665-670, abr. 2009..

CASTRO, Fernando César de; CASTRO, Maria Cristina de. **Multilayer Perceptrons.** Disponível em <[http://www.feng.pucrs.br/~decastro/pdf/RNA\\_C4.pdf](http://www.feng.pucrs.br/~decastro/pdf/RNA_C4.pdf)>. Acesso 01 ago. 2016.

CHAPRA, Steven C. **Métodos Numéricos Aplicados Com Matlab Para Engenheiros e Cientistas.** 3. ed. Porto Alegre,rs: Amgh Editora, 2013. 672 p.

CHRISTIANSEN, J. E. **Irrigation by Sprinkling.** Berkeley: California Agricultural Station. 1942. 124p. Bulletin, 670.

CONCEIÇÃO, Marco Antônio Fonseca. **Simulação da distribuição de água em micro aspersores sobre condição de vento.** 2002. 110 f. Tese (Doutorado) - Curso de Agronomia, Irrigação e Drenagem, USP, Piracicaba/SP, 2002.

CUSTODIO, Rogério; ANDRADE, João Carlos de; AUGUSTO, Fábio. **O ajuste de funções matemáticas a dados experimentais.** Química Nova, Campinas - SP, p.219-225, fev. 1996.

DANTAS JUNIOR, Edvaldo Eloy; CHAVES, Lúcia Helena Garófalo. **Yield and Water Use Efficiency of Green Maize Planted in Conditions Brazilian Semiarid.** Agricultural Sciences, [s.l.], v. 05, n. 06, p.498-503, 2014. Scientific Research Publishing, Inc., <http://dx.doi.org/10.4236/as.2014.56051>.

DAVIS, J. Philip; HERSH, Reuben, **A experiência matemática.** 1995. Disponível em: <[http://www.feis.unesp.br/Home/Extensao/teia\\_saber/Teia2003/Trabalhos/matematica/Apresentacoes/Apresentacao\\_03.pdf](http://www.feis.unesp.br/Home/Extensao/teia_saber/Teia2003/Trabalhos/matematica/Apresentacoes/Apresentacao_03.pdf)>. Acesso em: 20 nov. 2016.

DRAKOS, Nikos. **Parameters of the Learning Functions.** 1995. Computer Based Learning Unit, University of Leeds.. Disponível em: <<http://www.ra.cs.uni-tuebingen.de/SNNS/UserManual/node52.html>>. Acesso em: 01 out. 2017.

DIEHL, Carlos Alberto; SOUZA, Marcos Antônio de; DOMINGOS, Laura Elaine Cabral. **O uso da estatística descritiva na pesquisa em custos: análise do xiv**

**congresso brasileiro de custos.** Contexto, Porto Alegre, v. 7, n. 12, p.1-24, jun. 2007.

FARIA, Lessandro Coll. **Modelagem da aplicação de água de aspersores de tamanho médio em condições de vento.** 2011. 90 f. Tese (Doutorado) - Curso de Pós-graduação em Engenharia Agrícola, Universidade Federal de Lavras, Lavras/mg, 2011.

FARIA, Lessandro C. et al. **Simulação da uniformidade da irrigação de sistemas convencionais de aspersão operando sob diferentes condições de vento.** Scielo, Jaboticabal, Sp, v. 29, n. 1, p.19-27, jan. 2009.

FRANCO, Leonardo; JEREZ, José M.; ALIZONDO, David A.. **Constructive Neural Networks.** Spain: Springer, 2009. 281 p.

FREUND, John E.. **Economia, administração e contabilidade Estatística Aplicada.** 11. ed. Porto Alegre,rs: Bookman, 2006. 536 p.

FREUND, J.E. & SIMON, G.A. **Estatística Aplicada.** 9ª Ed. Porto Alegre: Bookman, 2000.

FERNEDA, Edberto. **Redes neurais e sua aplicação em sistemas de recuperação de informação.** Scielo, Ribeirão Preto, v. 35, n. 1, p.25-30, jan. 2006. Disponível em: <<http://www.scielo.br/pdf/ci/v35n1/v35n1a03.pdf>>. Acesso em: 11 out. 2016.

FISCHER, Igor et al. **JavaNNS Java Neural Network Simulator.** 2002. Disponível em: <<http://www.ra.cs.uni-tuebingen.de/software/JavaNNS/manual/JavaNNS-manual.html>>. Acesso em: 10 nov. 2016.

FRIZZONE, J. A. **Uniformidade e eficiência da irrigação.** Piracicaba, SP: Dep. de Eng. Rural, 2013. 11 p. Disponível em: <[http://www.gpeas.ufc.br/disc/sup/ind\\_des\\_sist.pdf](http://www.gpeas.ufc.br/disc/sup/ind_des_sist.pdf)>. Acesso em: 18 out. 2016.

GILLES, Luciléia et al. **Perdas de água, solo, matéria orgânica e nutriente por erosão hídrica na cultura do milho implantada em área de campo nativo, influenciadas por métodos de preparo do solo e tipos de adubação.** Revista Brasileira de Ciência do Solo, [s.l.], v. 33, n. 5, p.1427-1440, out. 2009. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0100-06832009000500033>.

GOLDSCHMIDT Ronaldo Ribeiro, 2010. **Uma Introdução à Inteligência Computacional: fundamentos, ferramentas e aplicações**. 1.ed. Rio de Janeiro. 143 p.

GOMES, Jésus de Lisboa; BARBIERI, José Carlos. **Gerenciamento de recursos hídricos no Brasil e no Estado de São Paulo: um novo modelo de política pública**. Cadernos Ebape.br, v. 2, n. 3, p.01-21, dez. 2004. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1679-39512004000300002>.

GOTELLI, Nicholas J.; ELLISON, Aaron M.. **Princípios de Estatística em Ecologia**. Porto Alegre/rs: Artmed, 2004. 499 p. ISBN 978-0-87893-269-6.

GUIMARÃES, Raphael Mendonça et al. **Caracterização da exposição de população a organoclorados: uma aplicação da análise de cluster**. Revista Brasileira de Epidemiologia, Rio de Janeiro, v. 16, n. 2, p.231-239, jun. 2013. <Http://dx.doi.org/10.1590/S1415-790X2013000200001>.

HAYKIN, S. **Redes neurais: princípios e prática**. Porto Alegre: Bookman, 2001.

HELENE, Otaviano. **Método dos mínimos quadrados com formalismo matricial**. Livraria da Física, 2006. 102 p

KAUARK, Fabiana; MANHÃES, Fernanda Castro; MEDEIROS, Carlos Henrique. **Metodologia da pesquisa**. Itabuna, Via Litterarum: Via Litterarum Editora, 2010. 88 p.

KLÜBER, Tiago Emanuel; BURAK, Dionísio. **Concepções de modelagem matemática: contribuições teóricas**. Educ. Mat. Pesqui, São Paulo, v. 10, n. 1, p.17-34, 2008.

LECUN, Yann; BENGIO, Yoshua; HINTON, Geoffrey. **Deep learning**. Nature, [s.l.], v. 521, n. 7553, p.436-444, 27 maio 2015. Springer Nature. <http://dx.doi.org/10.1038/nature14539>.

LEVIDOW, Les et al. **Improving water-efficient irrigation: Prospects and difficulties of innovative practices**. *Agricultural Water Management*, v. 146, p.84-94, dez. 2014. Elsevier BV. <http://dx.doi.org/10.1016/j.agwat.2014.07.012>.

LÉO, Luís Fernando Rossi; HERNANDEZ, Fernando Braz Tangerino. **O futuro da irrigação nos países de terceiro mundo**. 2001. Disponível em: <<http://www.agr.feis.unesp.br/avp180701.htm>>. Acesso em: 12 out. 2016.

LINDEN, Ricardo. **Técnicas de Agrupamento**. Sistemas de Informação da Fsma, Rio de Janeiro, v. 4, p.18-36, jan. 2009.

LIRA, Sachiko Araki. **Análise de correlação: abordagem teórica e de construção dos coeficientes com aplicações**. 2004. 209 f. Dissertação (Mestrado) - Curso de Pós Graduação em Métodos Numéricos, Engenharia dos Setores de Ciências Exatas e de Tecnologia, Universidade Federal do Paraná, Curitiba, 2004.

LOPES, Guido N. et al. **Irrigação Magnética**. Agro@ambiente, Roraima, v. 1, n. 1, p.1-8, dez. 2007. ISSN 1982-8470.

LOPES, Manuela de Mesquita; BRANCO, Verônica Teixeira Franco Castelo; SOARES, Jorge Barbosa. **Utilização dos testes estatísticos de Kolmogorov-Smirnov e Shapiro-Wilk para verificação da normalidade para materiais de pavimentação**. Transportes, [s.l.], v. 21, n. 1, p.59-66, 30 abr. 2013. Programa de Pós Graduação em Arquitetura e Urbanismo. <http://dx.doi.org/10.4237/transportes.v21i1.566>.

LUNET, Nuno; SEVERO, Milton; BARROS, Henrique. **Desvio Padrão ou Erro Padrão**. Scielo, v. 20, n. 1-2, p.55-59, 2006. ISSN 0871-3413.

MARTINS, Caio Louzada; RODRIGUES, Wagner Nunes; REIS, Edvaldo Fialho dos. **Avaliação do desempenho de sistemas de irrigação no sul do Estado do Espírito Santo**. Agro Ambiente On-line, Boa Vista, Rr, v. 7, n. 2, p.236-241, 01 maio 2013. Disponível em: <<http://biblioteca.incaper.es.gov.br/digital/bitstream/item/460/1/1069-6075-1-PB-CAIO.pdf>>.

MARTINS, Camila Aparecida da Silva et al. **Desempenho de sistemas de irrigação por aspersão convencional na cultura do milho (Zea mays L.)<sup>1</sup>. Idesia (arica)**, [s.l.], v. 29, n. 3, p.65-74, dez. 2011. SciELO Comisión Nacional de Investigación Científica Y Tecnológica (CONICYT). <http://dx.doi.org/10.4067/s0718-34292011000300010>.

MARTINS, E.r et al. **Configuração de redes neurais artificiais para prognose da produção de povoamentos clonais de eucalipto**. Revista Brasileira de Ciências Agrárias - Brazilian Journal Of Agricultural Sciences, [s.l.], v. 10, n. 4, p.532-537, 30

dez. 2015. Revista Brasileira de Ciências Agrárias.  
<http://dx.doi.org/10.5039/agraria.v10i4a5350>.

MAZZINI, P. L. F; SCHETTINI, C. A. F. 2009. **Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase sinóticos**. Braz. J. Aquat. Sci. Technol., v. 13, n. 1, p.53-64. ISSN 1808-7035.

MENDEL, J. M.; MCLAREN, R. W. **Reinforcement-learning control and pattern recognition systems**. In: MENDEL, J. M.; FU, K. S. (Ed.). Adaptive, learning, pattern recognition systems: theory and applications. New York: Academic Press, p. 287-318, 1970.

MENDONÇA, José Francisco Bezerra. **Solo: substrato da vida**. / Brasília: Embrapa Recursos Genéticos e Biotecnologia, 2006. 156 p.

MENDOZA, Guillermo Trujano. **Geometria analítica**. 2. ed. México: Pearson Educación de México, 2005. 504 p.

MENEZES, Paulo L. de et al.;. **Artificial neural network model for simulation of water distribution in sprinkle irrigation**. Revista Brasileira de Engenharia Agrícola e Ambiental, [s.l.], v. 19, n. 9, p.817-822, set. 2015. FapUNIFESP (SciELO).  
<http://dx.doi.org/10.1590/1807-1929/agriambi.v19n9p817-822>.

MOLIN, José Paulo; AMARAL, Lucas Rios do; COLAÇO, André Freitas. **Agricultura de precisão**. São Paulo: Oficina de Textos, 2015. 631 p.

MONTEIRO, Adson Brito et al. **Análise estatística multivariada de dados hidroquímicos do aquífero cabeças - sudeste da bacia sedimentar do Parnaíba - PI**. In: XVI Congresso brasileiro de águas subterrâneas e XVII encontro nacional de perfuradores de poços, 16., 2010, Parnaíba - Pi. Suplemento. São Paulo: Águas Subterrâneas, 2010. v. 24, p. 1 - 19.

MONTGOMERY, Douglas C; KEATS, J. Bert. **Statistical applications in process control**. 10. ed. Arizona: Marcel Dekker, 1996. 670 p. (3).

PEREIRA, Antônio Roberto; ANGELOCCI, Luiz Roberto; SENTELHAS, Paulo Cesar. **Meteorologia agrícola**. Piracicaba, SP: Lce 306, 2007. 184 p. Disponível em: <[http://www.leb.esalq.usp.br/aulas/lce306/MeteorAgricola\\_Apostila2007.pdf](http://www.leb.esalq.usp.br/aulas/lce306/MeteorAgricola_Apostila2007.pdf)>. Acesso em: 17 set. 2016.

PIMENTEL, Carlos. **A relação da planta com a água**. 2. ed. Rio de Janeiro: Edur - Editora Universidade Federal Rural do Rio de Janeiro, 2004. 191 p. ISBN: 85-85720-45-X.

PINTO, U.r.c. et al. **Uniformidade de Distribuição de Água em Aspersão Convencional Sob Diferentes Pressões de Serviços**. Global Science And Technology, [s.l.], v. 8, n. 2, p.160-169, 30 ago. 2015. Global Science and Technology. <http://dx.doi.org/10.14688/1984-3801/gst.v8n2p160-169>.

PIRES, Regina Célia de M. et al. **Agricultura irrigada. Revista Tecnologia e Inovação Agropecuária**, São Paulo, v. 1, n. 1, p.98-111, jun. 2008. Disponível em: <[http://www.dge.apta.sp.gov.br/publicacoes/T&IA;/T&IAv1n1;/Revista\\_Apta\\_Artigo\\_Agricultura.pdf](http://www.dge.apta.sp.gov.br/publicacoes/T&IA;/T&IAv1n1;/Revista_Apta_Artigo_Agricultura.pdf)>. Acesso em: 29 nov. 2016

PRADO, Giuliani do and COLOMBO, Alberto. **Determinação do perfil radial de aspersores a partir de ensaios de distribuição de água em sistemas autopropelidos de irrigação**. Eng. Agríc. [online]. 2010, vol.30, n.2, pp.232-243. ISSN 0100-6916. <http://dx.doi.org/10.1590/S0100-69162010000200005>.

PUTH, Marie-therese; NEUHAUSER, Markus; RUXTON, Graeme D.. **Effective use of Pearson's productmoment correlation coefficient**. Elsevier, U.k, v. 93, n. 14, p.183-189, jul. 2014.

REYES, Javier; VELLASCO, Marley; TANSCHKEIT, Ricardo. **Monitoramento e diagnóstico de múltiplos sensores por redes neurais auto-associativas**. Sba: Controle & Automação Sociedade Brasileira de Automatica, [s.l.], v. 23, n. 2, p.121-137, abr. 2012. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0103-17592012000200001>.

RODRIGUES, Rogério Rangel et al. **Eficiência e uniformidade de um sistema de irrigação por gotejamento na cultura do cafeeiro / Efficiency and uniformity of a drip irrigation system in the coffee crop**. Revista Ambiência, [s.l.], v. 9, n. 2, p.323-324, 15 ago. 2013. GN1 Genesis Network. <http://dx.doi.org/10.5777/ambiencia.2013.02.07>.

ROJAS, Raul; FELDMAN, J.. **Neural Networks: A Systematic Introduction**. Springer-verlag, Berlin: Springer, 1996. 509 p.

R-PROJECT. **The R Project for Statistical Computing**. 2017. Disponível em: <<https://www.r-project.org/>>. Acesso em: 12 dez. 2017.

SABINO, Claudia Vilhena Schayer; LAGE, Ludmila Vieira; ALMEIDA, Katiane Cristina de Brito. **Uso de métodos estatísticos robustos na análise ambiental**. Engenharia Sanitaria e Ambiental, [s.l.], v. 19, n. , p.87-94, jan. 2014. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1413-41522014019010000588>.

SANDRI, Delvio; MATSURA, Edson E.; TESTEZLAF, Roberto. **Metodologia para avaliação do desgaste por abrasão de bocais de aspersores rotativos**. Revista Brasileira de Engenharia Agrícola e Ambiental, v. 7, n. 1, p.7-12, abr. 2003. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1415-43662003000100002>.

SANTOS, Denise Dias dos; GALVANI, Emerson. **Distribuição sazonal e horária das precipitações em caraguatatuba-sp e a ocorrência de eventos extremos nos anos de 2007 a 2011**. Ciência e Natura, Sp, v. 36, n. 2, p.214-229, 14 maio 2014. Universidad Federal de Santa Maria. <http://dx.doi.org/10.5902/2179460x11891>.

SEWARD, Lori E.; DOANE, David P.. **Estatística Aplicada à Administração e Economia**. 4. ed. São Paulo: Amgh Ltda., 2014. 812 p.

SILVA, Leandro Nunes de Castro. **Análise e síntese de estratégias de aprendizado para redes neurais artificiais**. 250 f. Dissertação (Mestrado) - Curso de Engenharia Elétrica, Faculdade de Engenharia Elétrica e de Computação, Unicamp, Campinas/SP, 1998. Disponível em: [ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/lnunes\\_mest/](ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/theses/lnunes_mest/). Acesso em: 18 jan. 2018.

SILVA, Wend Rocha da; SILVA, Mérik Rocha; PIRES, Tatiani Botini. **O uso sustentável e a qualidade da água na produção animal**. Nutritime, Maringa, v. 11, n. 5, p.3617-3636, set/out 2014. Disponível em: [http://www.nutritime.com.br/arquivos\\_internos/artigos/ARTIGO266.pdf](http://www.nutritime.com.br/arquivos_internos/artigos/ARTIGO266.pdf). Acesso em: 20 set. 2016.

SILVA, Saulo Rodrigues e; SCHIMIDT, Fernando. **Reduction of input variables in artificial neural networks as from principal components analysis data in the modeling of dissolved oxygen**. Química Nova, São Paulo, p.1-10, 2016. GN1 Genesis Network. <http://dx.doi.org/10.5935/0100-4042.20160024>.

SILVA, César Antônio; SILVA, José da. **Avaliação de uniformidade em sistemas de irrigação localizada**. Rev. Científica Eletrônica de Agronomia, Graça, n. 8, ano IV, p. 1-17, ISSN 1677-0293, dez. 2005.

SILVA FILHO, Augusto Sousa da. **Estudo sobre a aplicação da Análise de Variância**. Pensar Gestão e Administração, Belo Horizonte, v. 2, n. 1, p.1-13, jul. 2012. ISSN 2237-2024.

SMITH, Stanley A.; CHARLES, Randall I.; DOSSEY, John A.; BITTINGER, Marvin L. **Álgebra**. México: Pearson Addison Wesley, 2001. 661 p.

SERRAT Beatriz Monte; [et al.]. **Conhecendo o solo / Departamento de Solos e Engenharia Agrícola**, 2002. 27 pg.

STATISTICA. **STATISTICA Features Overview**. 2017. Disponível em: <<http://www.statsoft.com/Products/STATISTICA-Features>>. Acesso em: 12 dez. 2017.

SUBRAMANIAN, Anand; COUTINHO, Antônio Souto; SILVA, Luiz Bueno da. **Aplicação de método e técnica multivariados para previsão de variáveis termo ambientais e perceptivas**. Scielo, v. 17, n. 1, p.52-70, jan. 2007.

SOUZA, Ivam H. de; ANDRADE, Eunice M. de; SILVA, Elio L. da. **Avaliação hidráulica de um sistema de irrigação localizada de baixa pressão, projetado pelo software "bubbler"**. Scielo, Jaboticabal, Sp, v. 25, n. 1, p.264-271, fev. 2005. Disponível em: <[http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0100-69162005000100029](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-69162005000100029)>. Acesso em: 09 set. 2016.

TAYLOR, John R.. **An introduction to error analysis**. 2. ed. Usa: University Science Books, 1997. 349 p.

TESTEZLAF, Roberto. **Irrigação: métodos, sistemas e aplicações**. Campinas/SP: Feagri, 2017. 215 p. Disponível em: <[http://www.agr.feis.unesp.br/pdf/testezlaf\\_irrigacao\\_metodos\\_sistemas\\_aplicacoes\\_2017.pdf](http://www.agr.feis.unesp.br/pdf/testezlaf_irrigacao_metodos_sistemas_aplicacoes_2017.pdf)>. Acesso em: 20 maio 2017.

VANZELA, Luiz Sergio; ANDRADE, Meire Cristina Nogueira de. **Importância da irrigação para o desenvolvimento econômico regional**. 2002. Disponível em: <<http://www.agr.feis.unesp.br/lsvimpirrigacao.htm>>. Acesso em: 04 out. 2016.

VARGA, Gyorgy. **Teste de Modelos Estatísticos para a Estrutura a Termo no Brasil**. Revista Brasileira de Economia, Rio de Janeiro, v. 63, n. 4, p.361-394, out. 2009.

WACHELKE, João Fernando Rech. **A estatística para pesquisadores**. Psicologia em Estudo, [s.l.], v. 11, n. 2, p.449-450, ago. 2006. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s1413-73722006000200024>.

WITTEN, Ian H.; FRANK, Eibe; HALL, Mark A. **Data Mining: Practical Machine Learning Tools and Techniques**. 3. ed. United States: Morgan Kaufmann Series In Data Management Systems, 2005. 629 p.

YAMAMOTO, Jorge Kazuo; LANDIM, Paulo M. Barbosa. **Geoestatística: conceitos e aplicações**. São Paulo: Oficina de Textos, 2013. 551 p.

ZELL Andreas et al. (Eberhard-karls-universität Tübingen; Germany). **Stuttgart Neural Network Simulator**. 2000. Disponível em: <<http://www.ra.cs.uni-tuebingen.de/SNNS/>>. Acesso em: 10 nov. 2016.