UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ENGENHARIA AGRÍCOLA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

ODÍLIO COIMBRA DA ROCHA NETO

REDE NEURAL ARTIFICIAL APLICADA AO MANEJO DA IRRIGAÇÃO

FORTALEZA
2012

ODÍLIO COIMBRA DA ROCHA NETO

REDE NEURAL ARTIFICIAL APLICADA AO MANEJO DA IRRIGAÇÃO

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal do Ceará, como requisito parcial para obtenção do grau de Mestre em Engenharia Agrícola.

Área de concentração: Irrigação e Drenagem

Orientador: Prof. Adunias dos Santos Teixeira, Ph. D.

FORTALEZA

2012

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Biblioteca de Ciências e Tecnologia

R574r Rocha Neto, Odílio Coimbra da.
Rede neural artificial aplicada ao manejo da irrigação / Odílio Coimbra da Rocha Neto. – 2012.
108 f. : il. color., enc. ; 30 cm.

Dissertação (mestrado) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Departamento de Engenharia Agrícola, Programa de Pós-Graduação em Engenharia Agrícola, Fortaleza, 2012.
Área de Concentração: Irrigação e Drenagem.
Orientação: Prof. Dr. Adunias dos Santos Teixeira.

1. Redes neurais (Computação). 2. Irrigação. 3. Agricultura de precisão. I. Título.

CDD 630

ODÍLIO COIMBRA DA ROCHA NETO

REDE NEURAL ARTIFICIAL APLICADA AO MANEJO DA IRRIGAÇÃO

Dissertação submetida à Coordenação do Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal do Ceará, como requisito parcial para obtenção do grau de Mestre em Engenharia Agrícola. Área de concentração: Irrigação e Drenagem

Aprovada em ____/____/_____

BANCA EXAMINADORA

_____
Prof. Adunias dos Santos Teixeira, Ph. D. (Orientador)
Universidade Federal do Ceará - UFC

_____
Prof. Dr. Arthur Plinio de Souza Braga (Conselheiro)
Universidade Federal do Ceará - UFC

_____
Dr. Raimundo Alípio de Oliveira Leão (Conselheiro)
Universidade Federal do Ceará - UFC

Aos meus queridos pais Odílio e Ana Rosa;

Ao meu irmão e cunhada Francisco José e Luciana;

Aos meus amigos;

A minha amada namorada!

AGRADECIMENTOS

Aos meus pais por toda humildade, por minha educação, formação, apoio, incentivo e carinho.

Ao professor Adunias dos Santos Teixeira pela orientação e conhecimentos compartilhados.

Ao professor Clemilson Costa dos Santos do departamento de Engenharia da Computação da UFC de Sobral pelos conselhos e contribuição para a melhoria desse trabalho.

Aos amigos Rafaela Caitano e Marcos Alves que me ajudaram a superar as dificuldades encontradas no curso de pós-gradução, a vocês meu sinceros agradecimentos.

À Universidade Federal do Ceará (UFC) pela formação ao nível de graduação e mestrado e a todos os professores que contribuíram para minha formação profissional e passaram mais que conhecimentos.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo apoio financeiro ao projeto e pela concessão da bolsa. Sem o apoio financeiro desta instituição não seria possível a realização deste trabalho.

Aos professores e funcionários do Departamento de Engenharia Agrícola, em especial aos professores Francisco Marcus Lima Bezerra, Raimundo Nonato Távora Costa, Claudivan Feitosa de Lacerda, Thales Vinicius de Araújo Viana, José Carlos de Araújo e ao professor Arthur Plinio de Souza Braga do Departamento de Engenharia Elétrica.

Aos colegas do grupo de pesquisa: Tadeu, Paulo, Dimas, Clenio, Firmino, Eurileny, Natanael, Gilney, Lúcio, Watylla, Ronney, Lucas.

Um agradecimento especial para aqueles que me ajudaram na etapa de campo: o agricultor Alex e o bolsista Felipe por toda ajuda e colaboração para o desenvolvimento deste trabalho.

Aos amigos de mestrado obtidos por sua parceria e cumplicidade para os trabalhos executados. Aos amigos da graduação que mesmo que muitos tenham tomado rumos distantes não deixam de passar desejo de sucesso a todos nós.

Aos amigos de toda vida Caio Marinho, Thomaz Rocha, Samuel Coelho, Diego Fontenele, Jonhathan Brito, Yale Luck, Yana Luck, Jonathan Negreiros, Renan, Mayrom, Sinara Nalumi e Samara.

E em especial à Sintia Kazumi por dedicação, paciência e amor que me fez suportar todas as dificuldades sem tirar o sorriso do rosto.

“Não deixem que lhe façam pensar que você não é capaz de fazer algo porque essa pessoa não consegue fazer. Se você deseja alguma coisa, se quer realmente, lute por isso e ponto final.”

(Will Smith)

RESUMO

A irrigação é uma das práticas culturais que mais influencia o aumento da produção. No entanto, para o sucesso desta prática necessita-se determinar o tempo certo da aplicação de água para evitar desperdícios. Com isso, o emprego de sensores de umidade, como os sensores capacitivos, para níveis reais de umidade do solo aliados a redes neurais artificiais (RNAs) que calculam tempo de irrigação, podem ser uma aquisição promissora para a automação de sistemas de irrigação. Desta forma, objetivou-se com o presente trabalho desenvolver uma RNA que estime o tempo de irrigação e comparando-o com o tempo estimado pelo método do balanço volumétrico para a cultura da melancia. Foram utilizadas RNAs do tipo perceptron de múltiplas camadas. Para o treinamento foram usados dados de manejos em área do PERÍMETRO IRRIGADO BAIXO ACARAÚ no estado do Ceará onde a umidade do solo é determinada por sensores capacitivos desenvolvidos pela Universidade Federal do Ceará (UFC). Foram testadas redes para as fases da cultura. A primeira fase determinada entre 0 e 30 dias após a semeadura (DAS) e a segunda fase sendo de 31 à 60 DAS. Foram testadas redes com 2 e 4 entradas; com 5, 10 e 20 neurônios na camada intermediária (NCI) e 1.000, 5.000 e 10.000 iterações. Após os treinamentos, as redes neurais artificiais foram testadas em campo para a sua validação, comparando as suas respostas em relação ao método do balanço hídrico volumétrico (BHV) para a segunda fase da cultura. Avaliando as redes com 2 e 4 entradas, observou-se que as redes de 4 entradas obtiveram menor erro quadrático médio, convergindo mais rapidamente para valores próximos a zero, quando comparadas às redes de 2 entradas. Quanto ao NCI, não houve mudanças entre as redes, dispensando a necessidade de programar redes maiores que 5 NCI para essa aplicação. Para o número de épocas de treinamento, a que obteve o melhor ajuste aos valores foram as redes com 10.000 iterações para a primeira fase da cultura e 5.000 iterações para a segunda fase da cultura. Com a etapa de campo pode-se constatar que não houve diferença estatística entre os dois manejos adotados. Assim, a rede neural artificial mostrou-se eficiente para o manejo da irrigação, mesmo tendo no experimento valores inéditos ao treinamento. Neste trabalho pode-se concluir que a RNA de melhores respostas para a primeira fase da cultura apresentou a MLP 4-5-1 com 10.000 épocas de treinamento e taxa de aprendizagem de 0,9 e para a segunda fase, MLP 4-5-1, com 10.000 épocas de treinamento e taxa de aprendizagem de 0,9. Conclui-se também, com a etapa de campo, que a rede foi bem sucedida em calcular o tempo de irrigação.

PALAVRAS-CHAVE: IRRIGAÇÃO DE PRECISÃO, AUTOMAÇÃO, ALGORITMOS NEURAIS, INTELIGÊNCIA COMPUTACIONAL, APRENDIZAGEM DE MÁQUINAS.

ABSTRACT

Irrigation is an agricultural practice that leads to high crop production, however the success of this practice depends largely on correct computation of the timing of the application to avoid excessive or deficit application. Thus, the use of moisture sensors, such as capacitive sensors for determining soil moisture combined with artificial neural networks (ANNs) to calculate irrigation time can be a promising tool for automation of irrigation systems. The objective of this work was to develop an ANN that estimate the irrigation time and to contrast the results with the management based on a volume balance method on a watermelon field. Multilayer perceptron types of ANNs were tested. For ANNs training, data obtained in previous harvest were used. The watermelon field was located in Baixo Acaraú Irrigation District in Ceará State – Brazil, where soil moisture was determined using capacitive sensors developed at the Universidade Federal do Ceará (UFC). Networks were tested for two growing stages. The first stage spanning from 0 to the 30th day after seeding (DAS) and the second stage from the 31st to 60th DAS at harvesting. Networks were tested with 2 and 4 inputs, with 5, 10 and 20 neurons in the intermediate layer (NIL) and 1,000, 5,000 and 10,000 epochs. Upon training, the artificial neural networks were field-tested for validation by comparing their responses to the volumetric water balance method (VWBM) for the second stage an succeeding crop cycle. It was found that networks with four entries presented the largest mean square error, converging rapidly to values close to zero, compared the networks with two entries. For the NIL, it was not found significant difference in the mean square error between all 3 tested architectures, therefore it was not necessary to test networks larger than 5 NIL for this application. For the number of training epochs, the one with the best fit values were networks with 10,000 epochs for the first stage of the crop cycle, and 5,000 epochs for the second stage of the crop cycle. It was found no statistical difference in watermelon yield between the two irrigation timing strategies tested (ANN and VWBM). Therefore the artificial neural network was efficient in irrigation management in the field even though the network was presented to some values not occurring during the training process. Thus, one can conclude that the ANN for best performance was a 4-5-1 with learning rate 0.9, and 10000 and 5000 training epochs, respectively in the first and second crop stage. In addition, it was found that the network successfully scheduled the irrigation during the validation process.

KEYWORDS: PRECISION IRRIGATION, AUTOMATION, NEURAL ALGORITHMS, COMPUTATIONAL INTELLIGENCE, MACHINE LEARNING.

LISTA DE FIGURAS

Figura 1. Modelo de um neurônio artificial. Fonte: Ribeiro. 2007 28
Figura 2. Exemplo de um problema de separação entre duas classes sendo em (1) linearmente separado e em (2) não linearmente separado..... 31
Figura 3. Rede alimentada adiante com uma única camada de neurônios. Fonte: Haykin (1999). 31
Figura 4. Rede alimentada adiante totalmente conectada com uma camada intermediária. Fonte: Haykin (1999). 32
Figura 5. Rede MLP típica com duas camadas intermediárias. Fonte: Haykin, 1999..... 32
Figura 6. Exemplo de um modelo de uma rede neural artificial aplicada no presente trabalho.. 42
Figura 7. Exemplo de curva obtida pelo MATLAB que mostra a redução do erro quadrático médio com o avanço das épocas de treinamento..... 45
Figura 8. Exemplo de validação obtida pelo MATLAB que mostra a relação entre o tempo real de irrigação (Vermelho) e o tempo obtido aplicando a rede neural treinada (Azul)..... 45
Figura 9. Interface gráfica do programa desenvolvida em plataforma C++ a partir da rede neural de melhor resposta..... 46
Figura 10. Desenho esquemático da área experimental. 49
Figura 11. Sensor capacitivo desenvolvido no Laboratório de Eletrônica e Mecânica Agrícola (LEMA). Fonte: SANTOS (2008). 50
Figura 12. Vista parcial da planilha de cálculo de tempo de irrigação pelo método do balanço volumétrico. 51
Figura 13. Relação entre teor de água do solo e respostas dos sensores capacitivos FDR a 10 cm de profundidade (CRUZ, 2009). 51
Figura 14. Relação entre teor de água do solo e respostas dos sensores capacitivos a 30 cm de profundidade (CRUZ, 2009). 52
Figura 15. Medição do comprimento do ramo principal..... 53
Figura 16. Gráfico do erro quadrático médio obtido para rede neural artificial com 2 entradas. 57
Figura 17. Gráfico do erro quadrático médio obtido para rede neural artificial com 4 entradas. 57
Figura 18. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial de 2 entradas..... 58
Figura 19. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial de 4 entradas..... 58
Figura 20. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com duas entradas para a primeira fase da cultura. 59
Figura 21. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com quatro entradas para a primeira fase da cultura..... 59
Figura 22. Gráfico do erro quadrático médio obtido para rede neural artificial com 1000 épocas de treinamento..... 61
Figura 23. Gráfico do erro quadrático médio obtido para rede neural artificial com 5000 épocas de treinamento..... 61
Figura 24. Gráfico do erro quadrático médio obtido para rede neural artificial com 10000 épocas de treinamento..... 62

Figura 25. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 1000 épocas de treinamento. 62
Figura 26. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5000 épocas de treinamento. 63
Figura 27. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 10000 épocas de treinamento..... 63
Figura 28. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 1.000 épocas de treinamento para a primeira fase da cultura. 64
Figura 29. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5.000 épocas de treinamento para a primeira fase da cultura. 64
Figura 30. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10.000 épocas de treinamento para a primeira fase da cultura. 65
Figura 31. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5 neurônios na camada intermediária. . 66
Figura 32. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 10 neurônios na camada intermediária. 67
Figura 33. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 15 neurônios na camada intermediária. 67
Figura 34. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 20 neurônios na camada intermediária. 68
Figura 35. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5 neurônios na camada intermediária para a primeira fase da cultura. 68
Figura 36. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10 neurônios na camada intermediária para a primeira fase da cultura. 69
Figura 37. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 15 neurônios na camada intermediária para a primeira fase da cultura. 69
Figura 38. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 20 neurônios na camada intermediária para a primeira fase da cultura. 70
Figura 39. Gráfico do erro quadrático médio obtido para rede neural artificial com 2 entradas. 72
Figura 40. Gráfico do erro quadrático médio obtido para rede neural artificial com 4 entradas. 72
Figura 41. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 2 entradas. 73
Figura 42. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 4 entradas. 73
Figura 43. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 2 entradas para a segunda fase da cultura. 74
Figura 44. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 4 entradas para a segunda fase da cultura. 74
Figura 45. Gráfico do erro quadrático médio obtido para rede neural artificial com 1000 épocas de treinamento. 76
Figura 46. Gráfico do erro quadrático médio obtido para rede neural artificial com 5000 épocas de treinamento. 76
Figura 47. Gráfico do erro quadrático médio obtido para rede neural artificial com 10000 épocas de treinamento. 77
Figura 48. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para rede neural artificial com 1000 épocas de treinamento. 77

Figura 49. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5000 épocas de treinamento. 78
Figura 50. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para rede neural artificial com 10000 épocas de treinamento. 78
Figura 51. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 1.000 épocas de treinamento para a segunda fase da cultura..... 79
Figura 52. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5.000 épocas de treinamento para a segunda fase da cultura..... 79
Figura 53. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10.000 épocas de treinamento para a segunda fase da cultura..... 80
Figura 54. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5 neurônios na camada intermediária. . 81
Figura 55. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 10 neurônios na camada intermediária. 81
Figura 56. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 15 neurônios na camada intermediária. 82
Figura 57. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 20 neurônios na camada intermediária. 82
Figura 58. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5 neurônios na camada intermediária para a segunda fase da cultura..... 83
Figura 59. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10 neurônios na camada intermediária para a segunda fase da cultura..... 83
Figura 60. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 15 neurônios na camada intermediária para a segunda fase da cultura..... 84
Figura 61. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 20 neurônios na camada intermediária para a segunda fase da cultura..... 84
Figura 62. Gráfico comparativo de lâmina de água aplicada (mm/dia) entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico. 85
Figura 63. Gráfico comparativo de lâmina de água aplicada acumulado (mm) entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico.86
Figura 64. Fotografia retirada no dia 26/11/2010 retratando a cobertura da planta sobre a área e o fruto em desenvolvimento..... 87
Figura 65. Regressão linear entre o tempo de irrigação obtido pelo método do Balanço Hídrico Volumétrico (BHV) e o estimado pela rede neural artificial (RNA) no campo..... 88
Figura 66. Variação da umidade do solo antes da irrigação na camada de 0-20 cm entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico no horário das 7 horas antes da irrigação..... 89
Figura 67. Variação da umidade do solo antes da irrigação na camada de 20-40 cm entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico no horário das 7 horas antes da irrigação..... 89
Figura 68. Fotografia retirada no 48º DAS retratando a cobertura da planta sobre a área de cultivo..... 90
Figura 69. Gráfico de acompanhamento da umidade do solo nas camadas de 0-20 e 20-40 para a área utilizada para o manejo através do Balanço Volumétrico no horário das 7 horas antes da irrigação e a lâmina diária aplicada nesta área..... 91

Figura 70. Gráfico de acompanhamento da umidade do solo nas camadas de 0-20 e 20-40 para a área utilizada para o manejo através das Redes Neurais Artificiais no horário das 7 horas..... 92
Figura 71. Acompanhamento do crescimento linear do ramo principal ao longo do 18º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura. 93
Figura 72. Taxa de crescimento linear do ramo principal no 18º DAS comparado com a taxa de consumo hídrico (mm hora^{-1}). 93
Figura 73. Fotografia tirada entre duas linhas de cultivo no 18º DAS. 94
Figura 74. Acompanhamento do crescimento linear do ramo principal ao longo do 25º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura. 95
Figura 75. Taxa de crescimento linear do ramo principal no 25º DAS comparado com a taxa de consumo hídrico (mm hora^{-1}). 95
Figura 76. Fotografia tirada entre duas linhas de cultivo no 25º DAS. 96
Figura 77. Acompanhamento do crescimento linear do ramo principal ao longo do 39º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura. 97
Figura 78. Taxa de crescimento linear do ramo principal no 39º DAP comparado com a taxa de consumo hídrico (mm hora^{-1}). 97
Figura 79. Fotografia tirada entre duas linhas de cultivo no 39º DAS. 98
Figura 80. Acompanhamento do crescimento linear do ramo principal ao longo do 46º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura. 99
Figura 81. Taxa de crescimento linear do ramo principal no 46º DAS comparado com a taxa de consumo hídrico (mm hora^{-1}). 99
Figura 82. Fotografia tirada entre duas linhas de cultivo no 46º DAS. 100

LISTA DE TABELAS

Tabela 1. Áreas plantadas e colhidas, quantidade produzida, rendimento médio e valor da produção de melancia, segundo as grandes regiões e as unidades da federação produtoras no ano de 2009. Fonte: IBGE, 2009..... 25
Tabela 2. Ranking das exportações do Ceará em 2010. Fonte: ADECE, 2011. 26
Tabela 3.- Horários das irrigações por tratamento utilizado no trabalho de REBOUÇAS NETO (2010) 42
Tabela 4. Teste de normalidade de Kolmogorov-Smirnov obtido pelo programa SPSS para os dados de produção (kg/planta) para cada um dos manejos. 101
Tabela 5. Teste de homogeneidade da variância de Levene obtido pelo programa SPSS para os dados de produção (kg/planta) entre as áreas manejadas. 102
Tabela 6. Teste t para comparação de médias para dados não pareados obtido pelo programa SPSS para os dados de produção (kg/planta) para cada um dos manejos. 102

LISTA DE SÍMBOLOS

Ξ	Permissividade do meio
C	Capacitância
K	Neurônio k
$x_1, x_2, ..., x_n$	Sinais de entrada
$w_{k1}, w_{k2}, ..., w_{kn}$	Pesos sinápticos do neurônio k
y_k	Sinal de saída do neurônio k
b_k	*Bias*
α	Taxa de aprendizagem
φ	Função de ativação
σ	Sensibilidade
θ	Umidade do solo em base de volume
E_a	Eficiência de aplicação

SUMÁRIO

1. INTRODUÇÃO 18
2. REVISÃO DE LITERATURA 20
2.1. Agricultura de precisão 20
2.2. Sensores capacitivos de umidade utilizados no manejo da irrigação 21
2.3. Melancia 24
2.4. Redes neurais artificiais (RNAs) 26
2.5. Modelo de um neurônio artificial 28
2.6. Arquitetura das RNAs 30
2.7. Algoritmo de Treinamento Backpropagation 34
2.8. Redes Neurais Artificiais e suas aplicações na agricultura 37
3. MATERIAL E MÉTODOS 41
3.1. Desenvolvimento das redes Multilayer Perceptron (MLP) 41
3.2. Aquisição dos dados de treinamento 42
3.3. Avaliação das redes neurais artificiais 43
3.4. Algoritmo de treinamento e avaliação do seu desempenho 44
3.5. Desenvolvimento do aplicativo neural para o manejo. 46
3.6. Etapa de campo 47
3.6.1. Área experimental 47
3.6.2. Sistema de irrigação 48
3.6.3. Avaliação de crescimento 52
3.6.4. Avaliação da produtividade 53
4. RESULTADOS E DISCUSSÃO 55
4.1. Testes das RNAs para a primeira fase da cultura (0 – 30 DAS) 55
4.1.1. Número de entradas 55
4.1.2. Número de épocas de treinamento 60
4.1.3. Número de neurônios na camada intermediária 65
4.2. Testes das RNAs para a segunda fase da cultura (31 - 60 DAS) 70
4.2.1. Número de entradas 71
4.2.2. Número de épocas de treinamento 75
4.2.3. Número de neurônios na camada intermediária 80
4.3. Etapa de campo 85

4.3.1. Acompanhamento da irrigação 85
4.3.2. Acompanhamento da umidade do solo antes da irrigação 88
4.3.3. Taxa de crescimento 92
4.3.4. Produtividade 101
5. CONCLUSÕES E RECOMENDAÇÕES 104
REFERÊNCIAS 105

1. INTRODUÇÃO

De acordo com BERNARDO e MONTOVANI (2008) a irrigação é uma das práticas culturais que mais influenciam a produção agrícola. No entanto, para o seu sucesso econômico é necessário identificar três conceitos básicos: quando, quanto e como irrigar. Os quais são definidos com base na capacidade de armazenamento do solo e no consumo de água pelas plantas.

A irrigação de precisão visa ao aumento da eficiência do uso da água e para esse objetivo se alia à utilização de sistemas inteligentes. O uso recente dos sistemas inteligentes no meio agrícola, introduzidos pela visão computacional, robótica e sistemas de controle, como as Redes Neurais Artificiais (RNA), tem promovido interessantes respostas nos sistemas de produção agrícola (MURASE, 2000). O mesmo autor afirma que a aplicabilidade dessas novas técnicas é crescente e o custo de implantação sofre um decréscimo constante, permitindo sua inserção no meio rural. O sucesso das redes neurais está diretamente relacionado com a sua alta versatilidade, pois existem aplicações para as mais diversas áreas, e isto faz delas uma tecnologia bastante promissora para o desenvolvimento de aplicações na agropecuária (GUISELINI *et al.*, 2010).

A utilização de RNAs tem proporcionado resultados satisfatórios ao contribuir com agilidade e facilidade nos procedimentos associados ao meio agrícola, como é o caso da estimativa da Evapotranspiração de Referência (ETo). A capacidade de generalização das RNAs possibilita estimar parâmetros que influenciam a colheita a partir de amostras dos valores destes parâmetros anteriormente coletados em campo. A importância disso é que o gestor agrícola terá um grande auxílio na tomada antecipada de decisões que contribuam para a melhoria de sua produção (TRIGO, BATISTA JÚNIOR e LIMA NETO, 2005).

Com isso, a utilização de RNAs em sistemas agrícolas, como o manejo da irrigação tratado nesta dissertação, pode trazer vantagens na produção agrícola. Este trabalho propõe e demonstra, as vantagens que podem ser obtidas ao aliar a capacidade de generalização das RNAs com a utilização de sensores de umidade do solo, como o sensor capacitivo de umidade, na automação da irrigação.

O resultado obtido é um sistema automático que tem a capacidade de ajustar o tempo de irrigação de acordo com a necessidade da cultura, característica que é de crucial importância para que sejam obtidas altas produtividades, aliado a um menor consumo hídrico que evita: perdas por percolação profunda causada pelo excesso de aplicação, ou estresse causado por aplicações inferiores ou tardias.

Desta forma, objetivou-se com o presente trabalho, implementar uma RNA que melhor estime o tempo de irrigação e comparar as respostas desta rede neural artificial com o método de balanço hídrico volumétrico em campo, para a cultura da melancia.

2. REVISÃO DE LITERATURA

Nesta seção serão abordados temas importantes que servirão para um melhor entendimento deste trabalho como: a agricultura de precisão e sua importância, os sensores capacitivos de umidade do solo e o motivo da escolha da cultura da melancia para este experimento. Será também abordada neste capítulo uma revisão mais detalhada da técnica da Rede Neural Artificial que será utilizada e avaliada neste trabalho.

2.1. Agricultura de precisão

A agricultura de precisão consiste na administração detalhada do solo e da cultura, adequando a produção agrícola às diferentes condições encontradas em cada parcela de uma lavoura, oferecendo como resultados maior produtividade e menores custos com insumos e mão de obra. As vantagens de sua aplicação são muitas: (a) economia de insumos agrícolas (pesticidas, fertilizantes, corretivos agrícolas); (b) aumento da produtividade (devido à otimização no uso do solo) e (c) sustentabilidade da terra em longo prazo, explorando-a de forma otimizada e não depredadora (MOLIN, 2003).

A idéia de agricultura de precisão surgiu antes mesmo do período da Revolução Industrial, como uma técnica de tratar a cultura em busca do seu melhor rendimento, levando em conta os aspectos de localização, fertilidade do solo, entre outros fatores (LAMPARELLI, 2008).

Essa nova tecnologia envolve, por exemplo: computadores pessoais, sistemas de informações geográficas, sistema de localização por satélite, dispositivos de

sensoriamento remoto, controle automatizado de máquinas e sistemas de comunicação. A integração desta tecnologia conecta sistemas de posicionamento global (GPS) com imagens das áreas de cultivo, permitindo que outros equipamentos ligados a este sistema possam ser configurados dinamicamente para controlar os índices de produtividade, níveis de irrigação e aplicação de pesticidas. Essa tendência consiste de um ciclo de análise da produtividade do solo (através da colheita), análise das características do solo (através de coleta de amostras ou imagens de satélite), controle preciso da aplicação de insumos e correção da terra e controle preciso da plantação e da aplicação de agroquímicos (SANTOS, 2008).

2.2. Sensores capacitivos de umidade utilizados no manejo da irrigação

O uso de métodos e técnicas para determinar a umidade do solo é de grande importância econômica, pois proporcionam aumento na eficiência de irrigação e contribui para reduzir custo em energia, água e mão de obra (DETOMINI, 2007).

Existem vários métodos e técnicas utilizadas para a determinação direta ou indireta da umidade, utilizando-se diferentes instrumentos (HILLEL, 2003, apud ROSSATO et al., 2005). COELHO (2003) afirma que nenhum método deve ser considerado como o melhor, sem a consideração dos objetivos desejados pelo pesquisador ou produtor, da instrumentação disponível, do nível de precisão desejada, da capacidade de investimento e outros fatores que possam limitar a sua escolha.

Como o próprio nome implica, os métodos diretos permitem a determinação direta da umidade do solo, sendo o principal, o método gravimétrico. Tal método consiste na coleta e pesagem de um determinado volume de solo (massa úmida) que é posteriormente submetida a temperaturas de 105 – 110 °C, por um período de 24 h a 48 h, para obtenção da massa dos sólidos do solo (massa seca). A umidade é então

determinada pela diferença entre as duas medidas (úmida e seca) dividida pela massa dos sólidos. O método gravimétrico tem como limitações a morosidade da obtenção dos resultados e a necessidade de intensa mão de obra (LEY et al., 1994, apud OLIVEIRA 2008).

Os métodos indiretos baseiam-se na variação de propriedades químicas ou físicas do solo, em função do conteúdo de água. SOUZA & MATSURA (2002) citam como exemplos de métodos indiretos a sonda de nêutrons, resistência elétrica e Reflectometria no Domínio do Tempo (TDR). Grande parte destes métodos necessita de calibração (OLIVEIRA, 2008). Além destes, o uso de equipamentos baseados na Reflectometria no Domínio da Frequência (FDR) tem aumentado ao longo dos anos já que, depois de instalados os tubos de acesso e feita a calibração do equipamento, são de leitura rápida e não destrutiva, o que permite, por exemplo, monitorar o conteúdo de água no solo em função do tempo, em uma determinada faixa de profundidade, permitindo, posteriormente, e mesmo em tempo real, calcular a variação de armazenamento de água no solo em estudos relacionados ao balanço hídrico de uma cultura (TERRA et al., 2008).

NADLER e LAPID (1996) afirmam que existe a necessidade da disponibilização de dispositivos para medir a umidade do solo com acurácia, a preços acessíveis e estrategicamente convenientes, que substituam o uso da sonda de nêutrons.

Dentre os sensores FDR, destacam-se os sensores capacitivos de placas (REBOUÇAS NETO, 2010; CRUZ, 2009; OLIVEIRA, 2008) cujo princípio de funcionamento tem comportamento eletrostático similar ao de um capacitor de placas planas. Portanto, um campo elétrico é formado entre as suas placas. Tal campo é alterado quando um material é inserido entre estas placas, causando uma variação nas características capacitivas do conjunto, mantendo-se enquanto esse material permanecer

dentro do campo. O material que preenche o espaço entre as placas de um capacitor é chamado de dielétrico e varia de acordo com a sua composição.

Os sensores capacitivos têm por base o uso de um capacitor e um frequencímetro em um circuito RC (Resistor e capacitor), onde a frequência de oscilação do circuito depende do teor de água no solo onde o mesmo está inserido (OLIVEIRA, 2008). Considerando um capacitor de placas planas, obtem-se a capacitância pela Equação 01.

$$C = \xi \times \frac{ab}{d} \tag{01}$$

Onde: ab é a área das placas paralelas, em m²; d é a distância que as separa, em m, ξ é a permissividade do meio, em F m^{-1} e C é a capacitância em Farads.

De acordo com REDONDO e LÍBERO (1996), é necessário um tempo para carregar ou descarregar totalmente um capacitor. Se um capacitor estiver inicialmente descarregado, sua tensão aumentará até que se iguale à tensão de alimentação. O intervalo de tempo que essa tensão leva para aumentar e atingir o seu ponto máximo é conhecido como tempo de subida e dependerá do produto RC do circuito. O tempo que o capacitor leva para descarregar vai depender do valor da resistência, sendo que quanta maior a resistência, maior será o tempo de descarga.

Além disso, características como equipamentos mais leves, instalação permanente, rápida resposta, ausência de efeitos radioativos e pouco erro aleatório de contagem associado tornam os sensores capacitivos mais vantajosos que os sensores tradicionais (OLIVEIRA, 2008).

2.3. Melancia

A melancia ocupa lugar de destaque entre as hortaliças de importância econômica no Brasil e no mundo. De acordo com QUEIRÓZ (2008), a melancia (*Citrullus lanatus*) pertence à família *Cucurbitaceae*, da qual também fazem parte outras espécies como melão, abóbora, pepino e outras de menor valor comercial. É originária das regiões secas da África tropical, tendo um centro de diversificação secundário no Sul da Ásia. A melancia cultivada (*C. lanatus* var. *lanatus*) deriva provavelmente da variedade *C. lanatus* var. *citroides* existente na África Central. A domesticação ocorreu na África Central onde a melancia é cultivada há mais de 5000 anos (ALMEIDA, 2008).

É uma planta herbácea de ciclo vegetativo anual. O sistema radicular é extenso, mas superficial, com um predomínio de raízes nos primeiros 60 cm do solo. Os caules rastejantes são angulosos, estriados, pubescentes, com gavinhas ramificadas. As folhas são profundamente lobadas. A espécie é monóica. As flores são solitárias, pequenas, de corola amarela. Permanecem abertas durante menos de um dia e são polinizadas por insetos. O fruto é um pepônio cujo peso varia entre 1 e 3 kg até mais de 25 kg. A forma pode ser redonda, oblonga ou alongada, podendo atingir 60 cm de comprimento. A casca é espessa (1-4 cm). A polpa é normalmente vermelha, podendo ser amarela, laranja, branca ou verde. As sementes encontram-se incluídas no tecido da placenta que constitui a parte comestível (ALMEIDA, 2008).

Esta olerícola desenvolve-se melhor sob condições de clima quente e umidade baixa, com temperaturas variando de 18º a 25°C e extremos de 10º a 32°C. A planta tem melhor crescimento quando ocorrem temperaturas de 20º a 30°C, com pouca variação entre as temperaturas diurnas e noturnas. Quando ocorrem temperaturas abaixo

de 12°C, o crescimento é praticamente paralisado, sendo que abaixo de 18°C pode não ocorrer formação de flores (VILLA, 2001).

Na Tabela 1 observam-se os dados brasileiros de produção da cultura da melancia em 2009 fornecidos pelo IBGE. Nesta tabela percebe-se que o Nordeste é a região com maior de área plantada (37.135 ha). Nesta região o maior produtor é o estado da Bahia, com mais de 56% da produção regional, no entanto o Ceará se destaca com a melhor produtividade, com mais de 35 toneladas por hectare, sendo esta bem superior à média tanto regional, 19,89 t ha^{-1}, quanto nacional (22,04 t ha^{-1}) .

Segundo a ADECE (2011), o Ceará liderou em 2010 as exportações brasileiras de melancia, mesmo apresentando queda da produção de 34,5% em relação ao ano anterior. Isso mostra a importância econômica desta cultura para o Estado que, conforme a Tabela 2, representa 55% das exportações brasileiras de melancia, gerando uma renda superior a 6,7 bilhões de dólares.

Tabela 1. Áreas plantadas e colhidas, quantidade produzida, rendimento médio e valor da produção de melancia, segundo as grandes regiões e as unidades da federação produtoras no ano de 2009. Fonte: IBGE, 2009.

Grandes Regiões e Unidades da Federação produtoras	Área Plantada (ha)	Área colhida (ha)	Quantidade produzida (t)	Rendimento médio (kg/ha)	Valor da Produção (1 000 R$)
Brasil	**94871,00**	**93278,00**	**2056309,00**	**22044,00**	**707217,00**
Norte	**15963,00**	**15709,00**	**261892,00**	**16671,00**	**103490,00**
Rondônia	953,00	953,00	13932,00	14619,00	3426,00
Acre	669,00	669,00	8902,00	13306,00	2331,00
Amazonas	4782,00	4606,00	31318,00	6799,00	18298,00
Roraima	984,00	944,00	7575,00	8024,00	3712,00
Pará	4560,00	4535,00	109477,00	24140,00	51357,00
Amapá	510,00	497,00	2553,00	5136,00	3238,00
Tocantins	3505,00	3505,00	88135,00	25145,00	21128,00
Nordeste	**37135,00**	**36678,00**	**729660,00**	**19893,00**	**246115,00**
Maranhão	3098,00	3098,00	27854,00	8990,00	10192,00
Piauí	2361,00	2315,00	60478,00	26124,00	17378,00
Ceará	1465,00	1464,00	51281,00	35028,00	19229,00
Rio Grande do Norte	3104,00	3054,00	73731,00	24142,00	27020,00

Pernambuco	5366,00	5006,00	104300,00	20834,00	27995,00
Alagoas	60,00	60,00	1385,00	23083,00	404,00
Sergipe	574,00	574,00	11765,00	20496,00	3866,00
Bahia	21107,00	21107,00	398866,00	18897,00	140033,00
Sudeste	**8786,00**	**7916,00**	**207243,00**	**26180,00**	**81145,00**
Minas gerais	1944,00	1944,00	45225,00	23263,00	15478,00
Rio de Janeiro	71,00	71,00	1310,00	18450,00	284,00
São Paulo	6771,00	5901,00	160708,00	27234,00	65383,00
Sul	**24536,00**	**24529,00**	**588608,00**	**23996,00**	**194807,00**
Paraná	4527,00	4527,00	114189,00	25223,00	47087,00
Santa Catarina	958,00	958,00	18722,00	19542,00	6530,00
Rio Grande do Sul	19051,00	19044,00	455697,00	23928,00	141190,00
Centro-Oeste	**8451,00**	**8446,00**	**268906,00**	**31838,00**	**81661,00**
Mato Grosso do Sul	752,00	747,00	19827,00	26542,00	5683,00
Mato Grosso	475,00	475,00	7413,00	15606,00	4776,00
Goiás	7222,00	7222,00	241636,00	33458,00	71188,00
Distrito Federal	2,00	2,00	30,00	15000,00	13,00

Tabela 2. Ranking das exportações do Ceará em 2010. Fonte: ADECE, 2011.

Produto	Ceará(US$ 1.000)	Brasil (US$ 1.000)	Participação Ceará/Brasil (%)	Ranking Ceará/Brasil
Calçados	403.446.381	1.647.600.661	24,5	2º
Castanha de Caju	182.015.701	229.571.712	79,3	1º
Couros e Peles	163.865.883	1.742.722.794	9,4	3º
Melão	74.259.055	121.969.814	60,9	1º
Lagosta	60.195.313	84.670.630	71,1	1º
Cera de Carnaúba	43.629.881	100.399.640	43,5	2º
Suco de Frutas[1]	29.598.539	150.367.295	19,7	1º
Banana	11.199.405	45.398.163	24,7	3º
Mel	9.721.535	55.055.677	17,7	2º
Extratos Vegetais	8.678.775	26.582.393	32,6	1º
Melancia	6.792.849	12.356.105	55,0	1º
Floricultura	3.290.644	28.753.900	11,4	2º
Rosas	117.103	179.469	65,2	1º

[1]sucos de frutas, exceto Suco de Laranja.

2.4. Redes neurais artificiais (RNAs)

De acordo com HAYKIN (1999) uma rede neural é um processador paralelamente distribuído, constituído de unidades de processamento simples, que têm a propensão natural para armazenar conhecimento experimental e torná-lo disponível para

uso futuro. Ela se assemelha ao cérebro em dois aspectos: o conhecimento é adquirido pela rede a partir de seu ambiente, através de um processo de aprendizagem, e as forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

Para BRAGA *et al*. (2000), as RNAs são sistemas paralelos, distribuídos, compostos por unidades de processamento simples (perceptron) que calculam determinadas funções matemáticas (normalmente não-lineares). Tais unidades são dispostas em uma ou mais camadas e interligadas por um grande número de conexões, geralmente unidirecionais.

As RNAs têm sido utilizadas para solução de vários problemas computacionais e pode-se afirmar que esta utilização se dá em função das seguintes propriedades: não-linearidade, mapeamento de entrada, adaptabilidade e generalização.

BRAGA (2000) ainda afirma que as RNAs são capazes de solucionar problemas mais complexos em função de sua característica natural e do paralelismo interno inerente de sua arquitetura. Por isto, apresentam possibilidade de maior desempenho comparada com os modelos convencionais. A solução de problemas utilizando RNAs é obtida seguindo alguns procedimentos: inicialmente é apresentado o problema (os dados de entrada), posteriormente a RNA extrai automaticamente as características destas informações e aprendem com estas informações e, finalmente, sugerem um resultado.

A capacidade de reconhecer padrões não apresentados à RNA após o período de treinamento é denominada capacidade de generalização e é uma característica importante para estes modelos. De acordo com FIGUEIRÊDO (2006), as RNAs são capazes de extrair informações não apresentadas de forma explícita através

de exemplos. Assim, são capazes de atuar como mapeadores universais de funções multivariáveis.

2.5. Modelo de um neurônio artificial

De acordo com HAYKIN (1999), um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma RNA. A descrição do modelo do neurônio[1] resultou em um modelo com n terminais de entrada x_1, x_2,...,x_n (que representam os dendritos) e apenas um terminal de saída y (representando o axônio). Para emular o comportamento das sinapses, os terminais de entrada do neurônio têm pesos acoplados w_{k1}, w_{k2}, ...,w_{kn} cujos valores podem ser positivos ou negativos. O efeito de uma sinapse particular i no neurônio é dado por $x_i w_i$. Os pesos determinam em que grau o neurônio deve considerar sinais de disparo existentes naquela conexão. Uma descrição do neurônio artificial é mostrada na Figura 1.

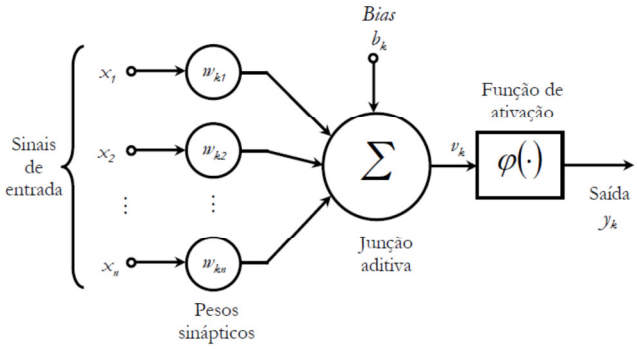

Figura 1. Modelo de um neurônio artificial. Fonte: Ribeiro. 2007

[1] Proposto originalmente por McCulloch e Pitts em 1943 (HAYKIN, 1999).

Neste modelo não-linear (Figura 1), podem ser identificados três elementos básicos:

• Sinapses: ou conexão de entrada, caracterizadas por pesos ou forças próprias. Um sinal x_j na entrada da sinapse j, conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj};

• Junção aditiva: responsável pela soma ponderada dos sinais de entrada;

• Função de ativação: restringe a amplitude da saída de um neurônio e limita o intervalo permissível de amplitude do sinal de saída. Podem ser do tipo linear e não-linear. Tipicamente o intervalo normalizado da amplitude da saída de um neurônio é escrito como o intervalo unitário fechado [0, 1] ou alternativamente [-1, 1].

O modelo neuronal apresentado na Figura 1 inclui também um *bias* aplicado externamente, representado por b_k. O *bias* tem o efeito de aumentar, se positivo, ou diminuir, se negativo, a entrada líquida da função de ativação.

Em termos matemáticos, pode-se descrever um neurônio k qualquer através do seguinte par de Equações 02 e 03:

$$v_k = \sum_{j=1}^{m} w_{kj} x_j \tag{02}$$

$$y_k = \varphi(v_k + b_k) \tag{03}$$

Onde x_1, x_2, ...,x_n são os sinais de entrada; w_{k1}, w_{k2}, ..., w_{kn} são os pesos sinápticos do neurônio k; v_k é a saída do combinador linear devido aos sinais de entrada; b_k é o *bias*; φ é a função de ativação; e y_k é o sinal de saída do neurônio.

2.6. Arquitetura das RNAs

De acordo com HAYKIN (1999), a arquitetura é uma maneira pela qual os neurônios de uma RNA estão estruturados. A definição da arquitetura é de grande importância na concepção da RNA, uma vez que ela restringe o tipo de problema que pode ser tratado pela RNA. Podem-se identificar três tipos de arquitetura:

•Redes alimentadas adiante (*feedforward*) de uma única camada;

•Redes alimentadas adiante de múltiplas camadas (*Multilayer Feedforward Networks*);

•Redes recorrentes.

Redes com uma única camada de nós só conseguem resolver problemas linearmente separáveis. Já as redes com mais de uma camada tem o poder de resolver problemas não-linearmente separáveis. A Figura 2 mostra exemplos de problema linearmente e não-linearmente separável. Redes recorrentes, por sua vez, são mais apropriadas para resolver problemas que envolvem processamento temporal. Fazem parte da definição da arquitetura os seguintes parâmetros: número de camadas da rede, número de nós da camada escondida, tipo de conexão entre os nós e a topologia da rede. As RNAs de uma única camada possuem uma camada de entrada contendo nós fonte e uma única camada de saída, com nós computacionais. A camada de entrada não é considerada no número de camadas pelo fato dos neurônios de entradas serem especiais, cuja função é distribuir cada uma das entradas da rede (sem modificá-las) a todos os neurônios da camada seguinte. A Figura 3 ilustra as redes feedforward de uma única camada.

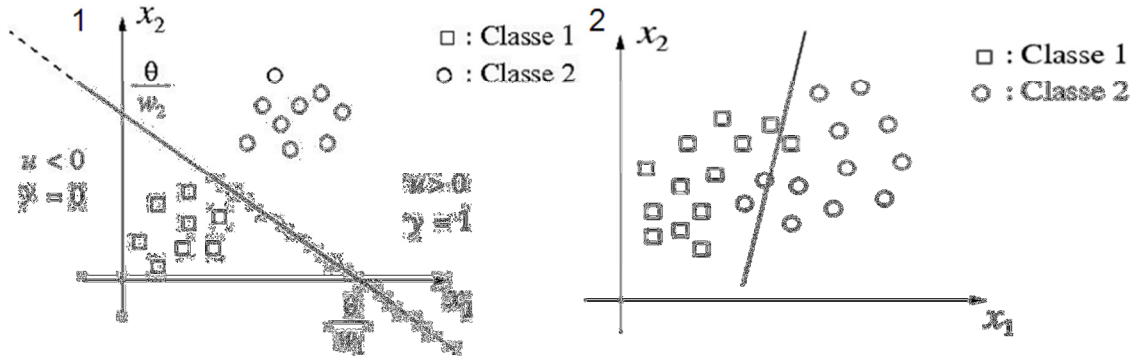

Figura 2. Exemplo de um problema de separação entre duas classes sendo em (1) linearmente separado e em (2) não linearmente separado.

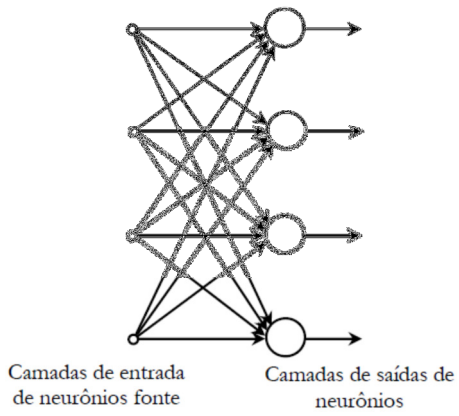

Figura 3. Rede alimentada adiante com uma única camada de neurônios. Fonte: Haykin (1999).

Segundo CYBENKO (1989), uma rede com uma camada intermediária pode implementar qualquer função contínua. A utilização de duas camadas intermediárias permite a aproximação de qualquer função. RNAs com camadas intermediárias podem ser classificadas como totalmente ou parcialmente conectada. Uma RNA é dita totalmente conectada quando cada um dos nós de uma camada da rede está conectado a todos os nós da camada adjacente seguinte. Entretanto, se alguns dos elos de comunicação (conexões sinápticas) estiverem faltando na rede, pode-se dizer que ela está parcialmente conectada. Na Figura 4 é apresentado um exemplo de RNA alimentada adiante, com duas camadas totalmente conectadas. As RNAs alimentadas

adiante com múltiplas camadas, comumente denominadas de MLP (*Multilayer Perceptron*), são as redes mais difundidas na literatura e serão utilizadas neste trabalho.

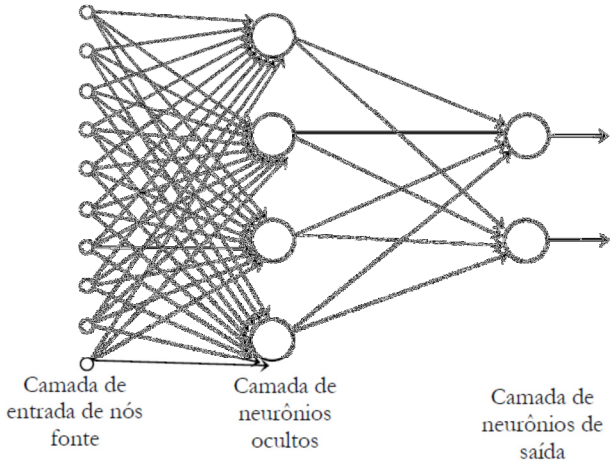

Figura 4. Rede alimentada adiante totalmente conectada com uma camada intermediária. Fonte: Haykin (1999).

A precisão obtida e a implementação da função objetivo dependem do número de nós utilizados nas camadas intermediárias (HAYKIN, 1999). A Figura 5 mostra o grafo arquitetural de uma MLP com duas camadas ocultas e uma camada de saída. A rede aqui representada é totalmente conectada. O fluxo do sinal através da rede progride para frente, da esquerda para a direita e de camada em camada.

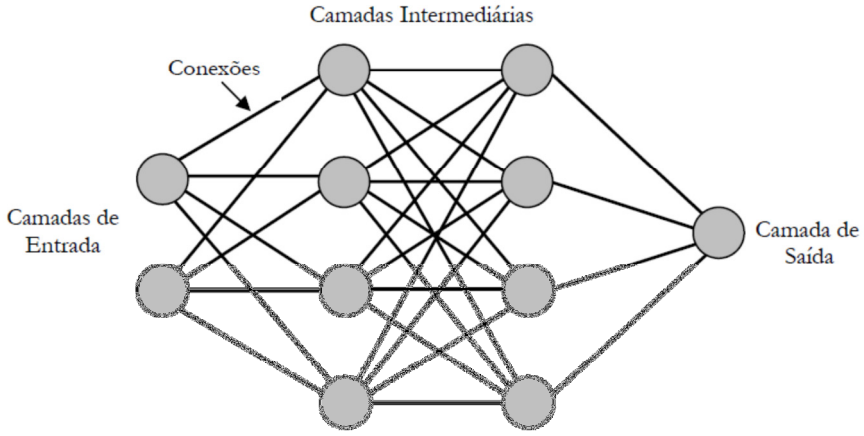

Figura 5. Rede MLP típica com duas camadas intermediárias. Fonte: Haykin, 1999.

Em uma rede MLP o processamento realizado por cada nó é definido pela combinação dos processamentos realizados pelos nodos da camada anterior que estão conectados a ele. Quando se segue da primeira camada intermediária em direção a camada de saída, as funções implementadas se tornam cada vez mais complexas (FIGUEIRÊDO, 2006).

De acordo com BRAGA *et al*. (2000), o número de neurônios na camada intermediária depende dos fatores como: número de amostras de treinamento, quantidade de ruído presente nos exemplos, complexidade da função a ser aprendida ou distribuição estatística dos dados de treinamento.

O número de nós nas camadas intermediárias é em geral definido empiricamente. Este número depende fortemente da distribuição dos padrões de treinamento e validação da rede (RIBEIRO, 2007).

Ainda segundo RIBEIRO (2007), existem problemas que necessitam apenas de uma unidade de entrada e de uma unidade de saída, e outros que podem precisar de várias unidades intermediárias. O número de unidades intermediárias pode também, em alguns casos, crescer exponencialmente com o número de entradas. A solução neural mais eficiente é aquela em que o número de unidades cresce apenas proporcionalmente com o aumento do número de unidades de entrada.

BRAGA (2000) afirma que, para a solução de problemas práticos de reconhecimento de padrões, aloca-se para a rede um número de unidades intermediárias suficientes para a solução do problema. Deve-se ter cuidado de não utilizar unidades demais, o que pode levar a rede a memorizar os padrões de treinamento, em vez de extrair características gerais que permitirão a generalização ou o reconhecimento de padrões não vistos durante o treinamento (*overfitting*); nem um número muito pequeno,

que pode forçar a rede a gastar tempo em excesso tentando encontrar uma representação ótima, sem apresentar convergência durante o treinamento (*underfitting*).

2.7. Algoritmo de Treinamento Backpropagation

De acordo com BRAGA (2000), há diversos algoritmos de treinamento disponíveis e o método e a velocidade com que os pesos são ajustados dependem do tipo utilizado. Os algoritmos de treinamento podem ser vistos como algoritmos de otimização que promovem a minimização da função erro, definida em relação aos valores esperados na saída, obedecendo aos limites de tolerância pré-estabelecidos. Dentre as diferentes técnicas de otimização aplicáveis o algoritmo *Backpropagation* tem mostrado excelentes resultados.

O algoritmo *backpropagation* provê um aprendizado supervisionado, isto é, ele procura achar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, segundo um erro mínimo, ajustando os pesos entre as camadas através da retropropagação do erro encontrado em cada iteração (VIEIRA e ROISENBERG, 2000).

MORAIS (2009) relatou o algoritmo neural em quatro passos. No primeiro ocorre a introdução dos dados da rede neural. Nesta etapa é definido o número de camadas, número de neurônios em cada uma das camadas e a introdução dos pesos e limiares (*baias)* de maneira randomizada. Nesta etapa também são definidos os critérios de parada do treinamento, que são o número de épocas e o erro mínimo aceitável.

No segundo passo é apresentado o vetor de entrada (X_j, j = 0, 1, 2,..., n) e a saída desejada (Y_o). Cada unidade de entrada transmite o sinal recebido para a primeira

camada intermediária, de mesma forma ocorre entre as camadas intermediárias e a camada de saída. Em cada unidade de processamento uma combinação linear é realizada alimentação da função de ativação, a função utilizada no presente trabalho foi do tipo sigmóide logística, Equação 04, no qual, uma vez que os dados de treinamento se ajustam entre a região de saturação, pode-se trabalhar com valores contínuos. Esta combinação é dada pela soma ponderada de todos os valores recebidos dos nós da camada anterior multiplicados pelos pesos de suas respectivas conexões.

$$Y_k = \frac{1}{1+\exp(-u_k)} \tag{04}$$

Onde Y_k representa a saída obtida pelo neurônio "k", U_k a resposta obtida pelo somatório ponderado de todas as conexões e os pesos deste neurônio "k".

O terceiro passo é definido pela retropropagação do erro. Inicialmente se calcula o erro entre o valor obtido pela rede e o valor da resposta desejada, Equação 05. Posteriormente calcula a sensibilidade da camada de saída para a função sigmóide logística, Equação 06. Com isso é possível realizar a atualização dos pesos das conexões da camada de saída, Equação 07.

$$Erro = Y_o - Y_e \tag{05}$$

Onde Y_o representa a saída desejada utilizada para o treinamento; Y_e a saída obtida pela RNA.

$$\sigma_s = -erro \times Y_e \times (1 - Y_e) \tag{06}$$

Onde σ_s representa a sensibilidade da camada de saída.

$$W_{i+1} = W_i - (\propto \times \sigma \times X_j) \tag{07}$$

Onde o W_{i+1} representa o peso da conexão após a atualização, W_i sendo o peso antes da atualização, $\propto$ a taxa de aprendizagem (parâmetro definido pelo programador, onde o seu valor situa-se entre 0 e 1), X_j o valor de entrada para esta conexão.

Para atualização das camadas anteriores o processo é semelhante: é calculada a sensibilidade de cada neurônio da camada anterior, Equação 08, e utilizado a Equação 07 para a atualização dos pesos desta conexão.

No quarto passo é calculado o erro quadrático médio (EQM), obtido pela Equação 09. Com isso são aplicados os critérios de parada da rede, se algum dos critérios for alcançado é determinado o fim da etapa de treinamento, se não ocorrer, a rede retorna ao segundo passo e repete o processo. São dois os critérios de parada adotados: é o EQM inferior ao mínimo aceitável; e o número de época de treinamento, representado pelo segundo e terceiro passo, ser alcançado.

$$\sigma_j = Y_j \times \left(1 - Y_j\right) \times W_i \times \sigma_i \tag{08}$$

Onde σ_j representa a sensibilidade do neurônio "j", Y_j o valor de saída deste neurônio, W_i o peso da conexão deste neurônio para a camada posterior e σ_i a sensibilidade da camada posterior.

$$EQM = \frac{\sum_{i=1}^{n}(Y_o - Y_e)^2}{n} \tag{09}$$

Onde o EQM representa o erro quadrado médio em minutos; n o número de observações de treinamento; Y_o a saída desejada utilizada para o treinamento; Y_e a saída obtida pela RNA.

2.8. Redes Neurais Artificiais e suas aplicações na agricultura

POKRAJAC e OBRADOVIC (2001) estudaram a eficiência das redes neurais na aplicação de fertilizantes a taxas variáveis. Neste trabalho os autores procuraram uma ferramenta que aperfeiçoasse o lucro no ramo da agricultura através da aplicação de fertilizantes de múltiplos nutrientes na agricultura de precisão, pelo uso de redes neurais baseadas em técnicas de otimização não linear. Os resultados obtidos com o uso das redes neurais dos tipos bases radiais (RBF) e MLP foram comparados com o método do mínimo erro quadrático. Depois do treinamento das redes, as taxas de aplicação do nitrogênio, fósforo e potássio foram estimados sobre um campo de teste. Os seus resultados experimentais sugerem que a técnica proposta tem um alto potencial no aumento do lucro com reduções substanciais nas taxas de aplicação de fertilizantes quando comparada com a aplicação tradicional.

SILVA *et al.* (2004) utilizaram as redes neurais com o intuito de melhorar o processo de adubação para a cultura da goiabeira e suas respostas foram satisfatórias, mostrando assim o grande potencial para a recomendação correta de adubação fosfatada. No trabalho foi desenvolvida uma MLP utilizando uma ferramenta específica do programa MATLAB, função denominada Tool Box Neural Network, e para o treinamento foram coletados 441 amostras onde 2/3 destas amostras foram utilizados para o treinamento propriamente dito e os demais dados utilizados para a validação da RNA. Os resultados mostraram que a RNA desenvolvida estimou bem as dosagens de adubação aplicada e que, mesmo o método sendo aplicado para a cultura da goiabeira, a metodologia proposta pode ser aplicada a outras culturas de interesse.

MOREIRA e CECÍLIO (2008) desenvolveram uma rede do tipo MLP para gerar estimativas mensais e anuais das temperaturas mínima, média e máxima do ar para

região nordeste. Neste trabalho, os autores testaram diferentes MLPs para obter aquela de melhor ajuste ao problema estudado e compararam essas respostas com as adquiridas pelo método comumente utilizado de ajuste de equações de regressão, concluindo que as redes obtidas possibilitaram a estimativa mensal e anual das temperaturas estudadas e que suas respostas superaram o método comparado.

MOREIRA *et al*. (2009) aplicaram redes neurais para gerar estimativas mensais da erosividade da chuva no estado de Minas Gerais. Nesta aplicação, os autores obtiveram diferentes arquiteturas para os meses estudados. No entanto, foi constatado que as menores arquiteturas possuem maiores capacidades de generalização e as redes de maior arquitetura tem a maior capacidade de aprendizagem, necessitando um menor número de iterações para obter suas respostas. Assim, concluíram que as redes desenvolvidas obtiveram os índices de até 93% de acerto, tornando-se uma alternativa viável para a obtenção desses valores para qualquer localidade.

LYRA *et al.* (2010), em seu estudo, programaram um modelo baseado em redes neurais artificiais para estimar o coeficiente de rugosidade de Manning para períodos de vazão mínima, média e máxima mensal. Para estimar esses valores através das RNAs foram utilizados os valores médios mensais da cota, vazão, declividade e raio hidráulico. Esses dados totalizaram 208 observações onde 170 foram usados para o treinamento e 38 para a validação do modelo. As RNAs utilizadas foram do tipo MLP e passaram por testes variando o número de camadas intermediárias e o número de neurônios em cada uma dessas camadas. Os resultados indicaram que a RNA de melhor desempenho foi obtida com uma camada intermediária contendo dez neurônios, com resultados bem próximos aos valores observados, demonstrando a eficiência da aplicação da rede neural artificial para estimar os valores de rugosidade de Manning.

UMAIR e USMAN (2010) aplicaram um controlador neural para definição do tempo de irrigação. Neste trabalho o controlador neural funcionou como um controlador inteligente, recebendo como entradas o valor de umidade do solo atual, adquirido pelo modelo de evapotranspiração de referencia de Penman-Monteith, e o valor desejado de umidade do solo. A topologia da RNA utilizada foi MLP com atraso no tempo, com uma camada intermediária e uma saída binária, onde o valor 1 representa o funcionamento do sistema e o valor 0 o estado desligado do sistema de irrigação. A RNA elaborada foi comparada com um controlador liga/desliga baseado no nível de umidade do solo atual. As respostas obtidas pelo controlador neural se mostraram mais eficientes, uma vez que este não tem uma resposta constante por conta das limitações do aparelho.

ASADOLLAHFARDI, TAKLIFY E GHANBARI (2011) desenvolveram uma RNA para prever sólidos totais dissolvidos para ser utilizados como indicador de qualidade da água em recursos hídricos. Foram testados neste trabalho dois tipos de RNAs, uma MLP e outra rede neural recorrente. Os resultados obtidos entre as topologias testadas e os níveis reais de qualidade da água do rio avaliado, Talkheh Rud, foram próximas, os autores concluíram que a RNA é adequada para estimativa imediata da qualidade da água.

SOBRINHO *et al.* (2011) obtiveram uma rede neural artificial capaz de estimar, com precisão satisfatória, a evapotranspiração de referência de dados a partir de temperatura do ar diária. Para o treinamento desta rede foram utilizados dados meteorológicos entre os anos de 2005 e 2008, dos quais foram obtidos os valores de evapotranspiração de referência por meio do método do Penman-Monteith. No trabalho foram utilizadas várias topologias de redes do tipo MLP, variando os números de neurônios da camada intermediária. A rede de melhor resposta foi obtida com três

entradas (temperatura máxima, média e mínima), 20 neurônios na camada intermediária e um neurônio na camada de saída com a resposta de ETo. Os autores concluíram que o aumento de neurônios da camada intermediária, assim como a inclusão de uma segunda camada intermediária não promoveu melhoria nos resultados. O desempenho da rede obtida foi satisfatório, mostrando a grande vantagem deste método que pode obter respostas confiáveis de ETo apenas com valores de temperatura do ar.

Estes exemplos mostram o potencial das RNAs para resolver problemas que demandam muitos cálculos e rapidez de execução. Mostram também a eficiência da topologia MLP na resolução desses problemas e a não necessidade de aplicação de uma segunda camada intermediária, já que as redes com uma camada resolveram satisfatoriamente os problemas propostos. Essas vantagens aliadas à praticidade de implementação deste recurso na automação, podem contribuir para a melhoria do manejo da irrigação, resultando em economia de água.

3. MATERIAL E MÉTODOS

Nesta seção serão abordadas as técnicas utilizadas na execução deste trabalho como: obtenção dos dados de treinamento e validação das RNAs, avaliação das respostas das redes quanto a topologia e avaliação no campo da RNA treinada.

3.1. Desenvolvimento das redes Multilayer Perceptron (MLP)

Foram testados neste trabalho MLPs compostas de uma camada de entrada, uma camada intermediária ou oculta e uma camada de resposta ou de saída, como exemplo exposto na Figura 6. A camada de entrada da rede é referente aos estímulos dos quais a rede obterá a resposta. Os estímulos utilizados foram valores de umidade do solo obtidos por meio de sensores capacitivos no campo agrícola de realização do manejo. A camada intermediária ou oculta foi formada por neurônios, cuja sua quantidade dependeu dos testes realizados para satisfazer a aplicação desejada, recebendo como estímulos as respostas obtidas da camada anterior. A camada de resposta ou de saída foi formada por um neurônio, que de acordo com as respostas obtidas da camada intermediária, gerou a resposta que, no caso deste trabalho, representa o tempo de irrigação.

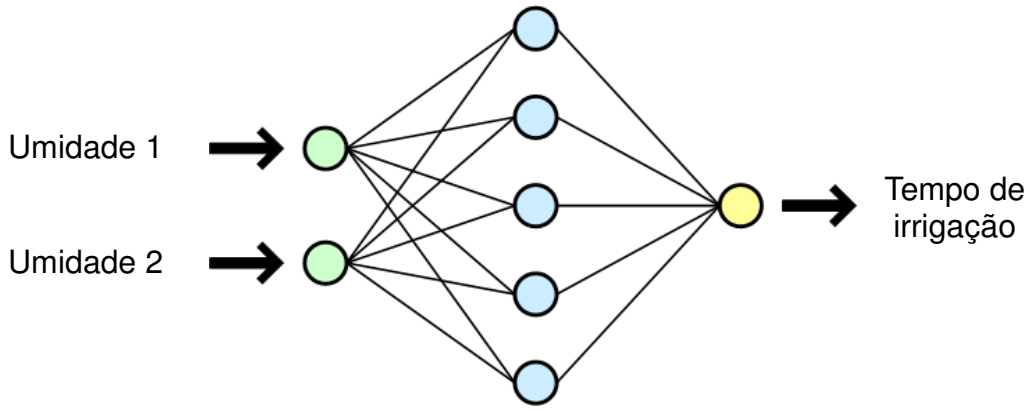

Figura 6. Exemplo de um modelo de uma rede neural artificial aplicada no presente trabalho.

3.2. Aquisição dos dados de treinamento

Para o treinamento da MLP foram utilizados dados de manejo da cultura da melancia apresentado em REBOUÇAS NETO (2010) cujo objetivo avaliar o efeito da frequência da irrigação no desenvolvimento da cultura da melancia.

Neste experimento foram realizados quatro tratamentos, variando-se no número de irrigações diárias. Na Tabela 2 são observados os horários das irrigações.

Tabela 3.- Horários das irrigações por tratamento utilizado no trabalho de REBOUÇAS NETO (2010)

Tratamentos	Horários das irrigações							
	7:00	8:00	9:00	11:00	12:00	13:00	15:00	16:00
1	X		X	X		X	X	
2			X	X		X	X	
3		X			X			X
4		X			X			

X sinal identificado da realização da irrigação.

Correlacionando-se os valores de frequência e os tempos de irrigação para os 4 tratamentos foram obtidos 470 conjuntos de dados aplicáveis para o treinamento. Foram então utilizados 295 para o treinamento da RNA e 175 para a sua validação.

Cada conjunto corresponde aos valores dos sensores capacitivos de umidade do solo utilizados no manejo do trabalho. E foi usado como dado de entrada para as RNAs treinadas e os tempos de irrigação correspondentes às leituras dos sensores, estes tempos utilizados para os dados de saída. A primeira fase compreende aos dados de irrigação coletados até o 30º dia após a semeadura (DAS) da cultura, período associado à germinação e fase inicial do crescimento vegetativo. Nesta fase foram obtidos 230 conjuntos de dados onde 145 foram usados para treinamento e 85 para a validação. A segunda fase compreende a fase de maior consumo hídrico da planta, incluindo a fase final do crescimento vegetativo, floração e frutificação. Obteve-se para esta fase 240 conjuntos de dados onde 150 foram usadas para o treinamento e 90 para a validação.

3.3. Avaliação das redes neurais artificiais

Foram avaliadas diferentes redes, variando o número de entradas, o número de neurônios na camada intermediária e o número de épocas de aprendizagem, que consiste no número de vezes que a rede, na etapa de aprendizagem, recebeu todos os valores usados para o treinamento.

Foram avaliadas redes com duas e quatro entradas, sendo que duas entradas correspondentes a um par de sensores (um localizado a 0,1 m e outro a 0,3 m de profundidade do solo) e quatro entradas referente a dois pares de sensores. Na avaliação do número de neurônios na camada intermediária foram testadas redes com 5, 10, 15 e

20 neurônios. Para a avaliação do número de épocas de aprendizagem, as redes foram submetidas a 1.000, 5.000 e 10.000 iterações.

3.4. Algoritmo de treinamento e avaliação do seu desempenho

O algoritmo de treinamento utilizado foi o *backpropagation* que consiste em duas etapas: a primeira, *feedforward*, onde são calculadas as saídas de cada camada; e a seguinte, *backpropagation* onde é realizada a atualização dos pesos de todas as camadas da rede.

A rede foi escrita e testada no programa MATLAB. Para a avaliação do desempenho das redes neurais foram usadas curvas de erro quadrático médio (EQM) e curvas comparativas de valores reais e valores obtidos pela rede neural.

A Figura 7 representa um exemplo de uma curva obtida pelo programa MATLAB durante o treinamento das redes avaliadas. Nestes gráficos, o eixo Y representa os valores de erro quadrático médio (EQM) obtido em cada uma das épocas de treinamento e o eixo X a época deste treinamento. Para uma rede ter melhor desempenho do que outra é necessária que esta atinja o erro mínimo, ao qual foi atribuído 0,0001 (MOREIRA *et al.*, 2009; LYRA *et al.*, 2010; SOBRINHO, 2011), com o menor número de épocas.

Na Figura 8 observa-se um exemplo de uma curva comparativa de valores reais e valores obtidos pela rede neural. No gráfico, o eixo Y representa o tempo de irrigação em minutos e o eixo X, o número da observação. A curva em vermelho representa os valores de tempo de irrigação usando nos conjunto de dados de validação e em azul, a resposta obtida pela rede neural após o treinamento. Para a rede ser

considerada de melhor desempenho, deve mostrar maior proximidade entre as duas curvas, principalmente nos pontos de máximo e mínimo, mostrando melhor poder de generalização.

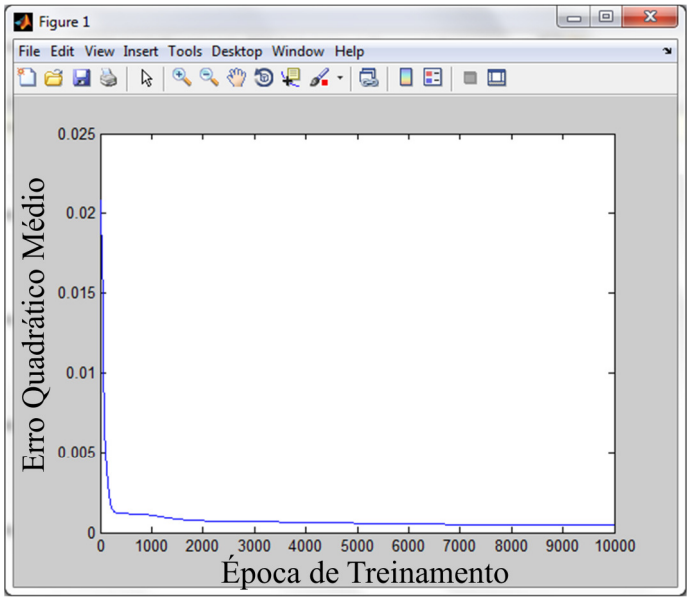

Figura 7. Exemplo de curva obtida pelo MATLAB que mostra a redução do erro quadrático médio com o avanço das épocas de treinamento.

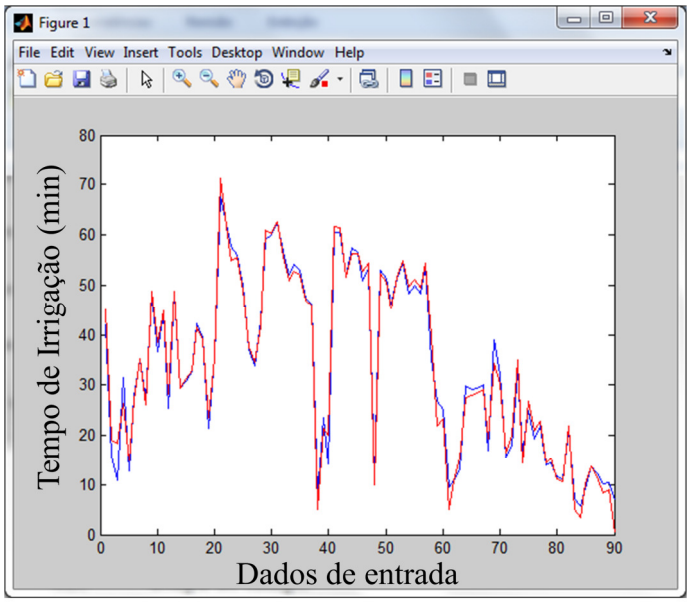

Figura 8. Exemplo de validação obtida pelo MATLAB que mostra a relação entre o tempo real de irrigação (Vermelho) e o tempo obtido aplicando a rede neural treinada (Azul).

3.5. Desenvolvimento do aplicativo neural para o manejo.

A rede neural de melhor desempenho para cada uma das fases foi convertida em um software programado em linguagem C++ orientada a objeto, utilizando o copilador Borland C++ Builder. O programa desenvolvido, cuja interface com o usuário pode ser visto na Figura 9, calcula o tempo de irrigação a partir dos dados obtidos dos sensores. Utilizando os botões "Fase 1" ou "Fase 2", o usuário terá a resposta da rede neural para esses valores de frequência fornecidos sendo esse tempo dado em minutos.

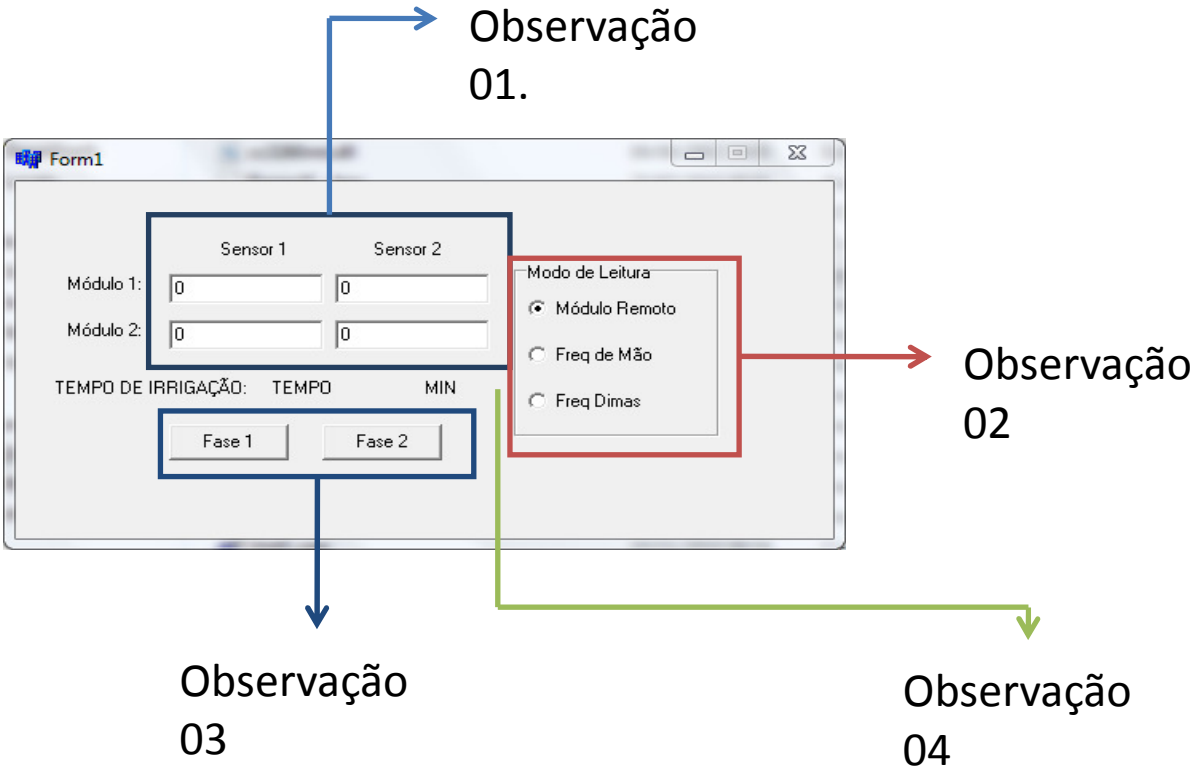

Figura 9. Interface gráfica do programa desenvolvida em plataforma C++ a partir da rede neural de melhor resposta.

A Figura 9 revela a interface dividida em quatro observações. Na observação 01 é onde o usuário adiciona os dados de entada para alimentação da rede, neste campo o sensor 1 representando os sensores na primeira profundidade e sensor 2 da segunda profundidade.

Observação 02 é o campo destinado à definição do equipamento utilizado na aferição dos sensores capacitivos. Há três aparelhos utilizados no campo para realizar as aferições dos valores de frequência, cada um altera o valor de saída de frequência dependendo da necessidade do aparelho. A resposta obtida pelo frequencímetro é igual ao padrão, já no Freq. Dimas, frequencímetro utilizado por OLIVEIRA (2008), é o valor padrão multiplicado por 0,32 e o módulo remoto, aparelhos utilizados por CRUZ (2009) e REBOUÇAS NETO (2010), é o valor padrão dividido por 2,56.

Observação 03 é o campo onde o operador seleciona em que fase da cultura manejada se encontra. Fase 1 representa o período entre 0 – 30 DAS e Fase 2 representa o período entre 31 – 60 DAS. Observação 04 é a resposta do tempo de irrigação em minutos.

3.6. Etapa de campo

Após as avaliações de definição das RNAs de melhor desempenho para a primeira e segunda fase e a confecção do aplicativo neural a ser utilizado no manejo da irrigação, as redes foram avaliadas em campo, comparando-se o manejo definido por elas com o determinado manejo por meio do método do balanço hídrico volumétrico (BHV).

3.6.1. Área experimental

O experimento foi conduzido no período de 10 de novembro a 12 de dezembro de 2010, compreendendo a segunda fase da cultura do 30º a 62º dias após o

plantio, no Perímetro Irrigado do Baixo Acaraú. Este está situado nos municípios de Marco, Acaraú e Bela Cruz, a 210 km de Fortaleza, nas coordenadas geográficas 3°07'13" de latitude Sul e 40°05'13" de longitude Oeste.

O clima da região, de acordo com a classificação de Köppen, é do tipo Aw', tropical chuvoso, com precipitação média anual de aproximadamente 900 mm e umidade relativa do ar em torno de 70%. A evaporação anual no tanque classe A é de 1.600 mm ano^{-1}, a temperatura média anual de 28,1° C, sendo a mínima e a máxima anuais de 22,8 e 34,7 ºC, respectivamente, e a insolação é de 2.650 h ano^{-1} (DNOCS, 2010).

A área experimental foi de por 1,0 ha, do Lote C07/1, cultivada com melancia da variedade Crimson Sweet, em espaçamento de 0,9 m entre plantas e 3,0 m entre linhas, totalizando 3.704 plantas.

3.6.2. Sistema de irrigação

Na irrigação foram utilizados gotejadores *STREAMLINE* (NETAFIM, 2010), apresentando 1,49 L h^{-1} para pressão de serviço de serviço de 8 mca, com espaçamento de 0,30m entre emissores e 3 m entre linhas, resultando em vazão por hectare de 15,89 m^3 h^{-1}. Foram realizadas duas irrigações diárias, sendo a primeira sendo às 7 horas e a segunda às 14 horas. Para o manejo do experimento a área foi dividida em duas áreas de 0,5 ha cada, conforme a Figura 10. Na Área 1 foi adotado o manejo utilizando o método balanço volumétrico e na Área 2, o manejo utilizando o aplicativo neural.

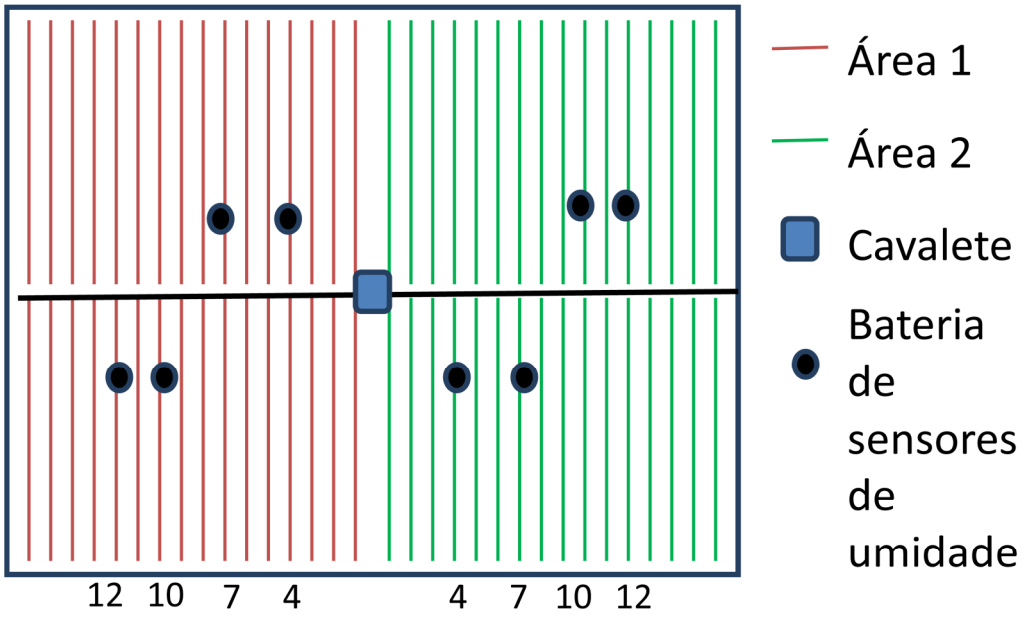

Figura 10. Desenho esquemático da área experimental.

Em cada uma das áreas foram instaladas quatro baterias de sensores do tipo capacitivo, sendo três compostas por um par de sensores, um instalado na profundidade de 0,10 m e outro na de 0,30 m; e uma bateria composta por três sensores, com o terceiro instalado a 0,45 m de profundidade. Essas baterias foram instaladas nas linhas 4, 7, 10, 12 de gotejo em relação ao cavalete, no final do primeiro terço onde se encontra a pressão média da linha (Figura 10).

Os sensores de umidade utilizados neste experimento foram os sensores capacitivos TOPDEA, nome proposto por OLIVEIRA (2008) para os sensores, fabricado no Laboratório de Eletrônica e Mecânica Agrícola (LEMA) da Universidade Federal do Ceará (UFC). Na Figura 11 vê-se os sensores capacitivos utilizados neste experimento.

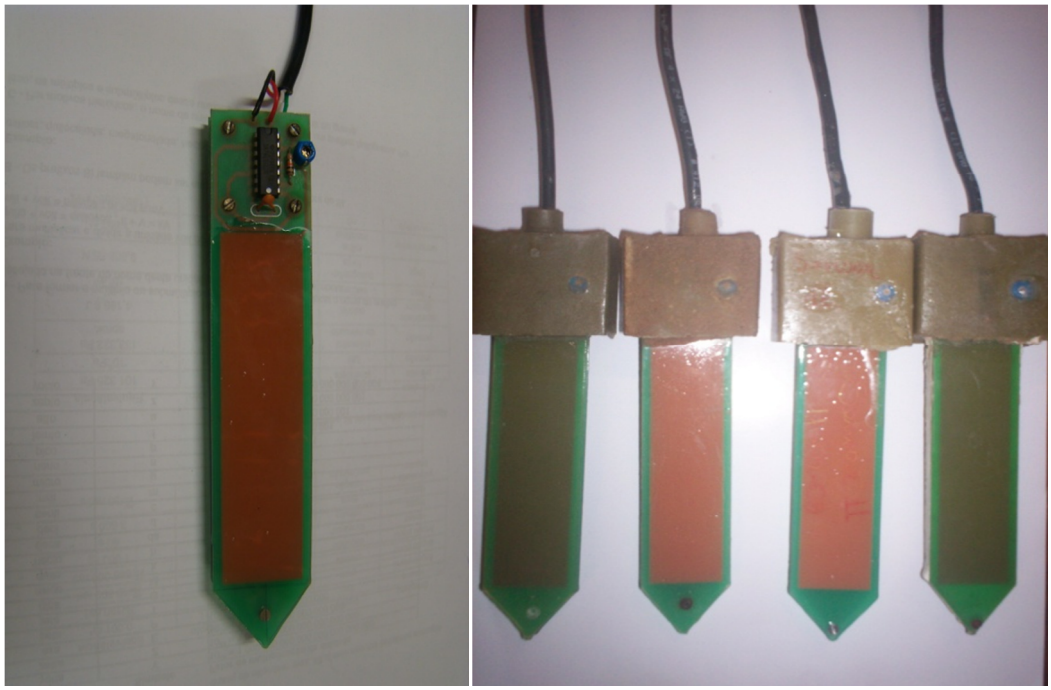

Figura 11. Sensor capacitivo desenvolvido no Laboratório de Eletrônica e Mecânica Agrícola (LEMA). Fonte: SANTOS (2008).

Para calcular o tempo de irrigação pelo método do balanço volumétrico foi utilizada uma planilha, parcialmente apresentada na Figura 12, onde ocorre a conversão dos valores de frequência para valores de umidade volumétrica, utilizando as equações de calibração apresentadas nas Figuras 13 e 14 obtidas por CRUZ (2009). O tempo de irrigação foi então calculado utilizando a Equação 10.

$$T=\frac{(\theta_{CC}-\theta_{atual})\times EL\times EE}{Q\times E_a} \qquad (10)$$

Onde: T representa o tempo de irrigação em horas; θ_{CC} é a umidade na capacidade de campo em cm^3cm^{-3}; θ_{Atual} é a umidade atual em cm^3cm^{-3}; EL é o espaçamento entre linhas em m; EE é o espaçamento entre emissor em m; Q a vazão por emissor em L h^{-1} e E_a a eficiência de aplicação, que para o experimento foi de 0,964.

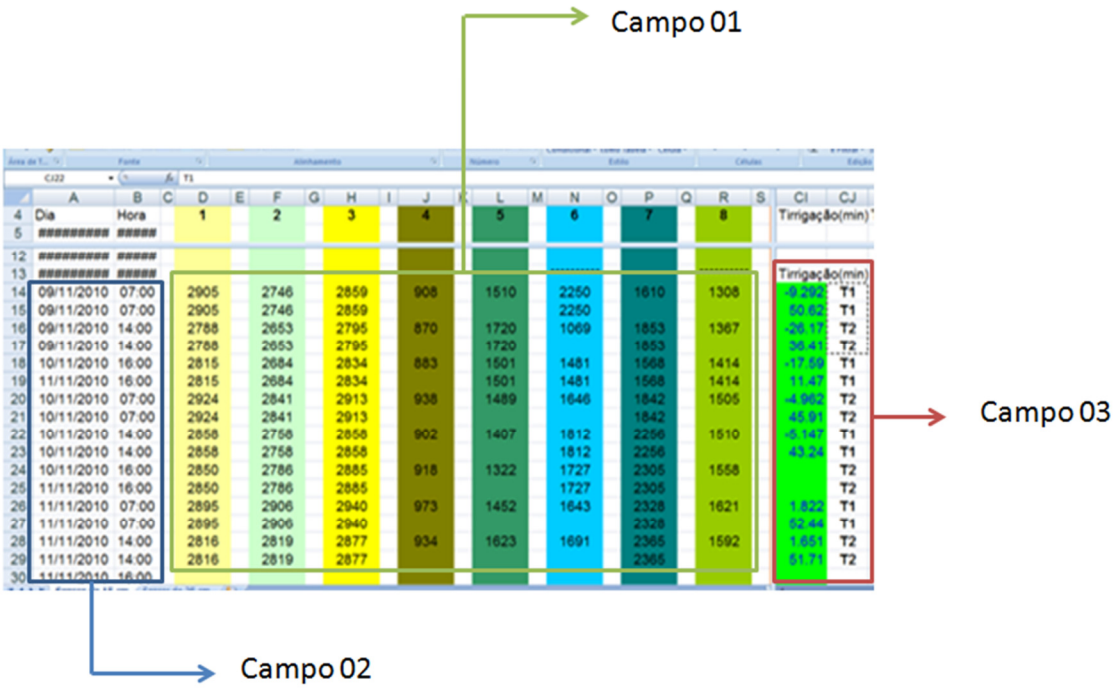

Figura 12. Vista parcial da planilha de cálculo de tempo de irrigação pelo método do balanço volumétrico.

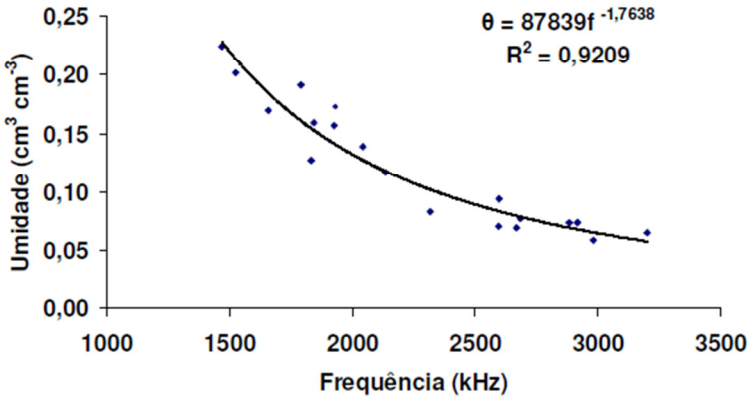

Figura 13. Relação entre teor de água do solo e respostas dos sensores capacitivos FDR a 10 cm de profundidade (CRUZ, 2009).

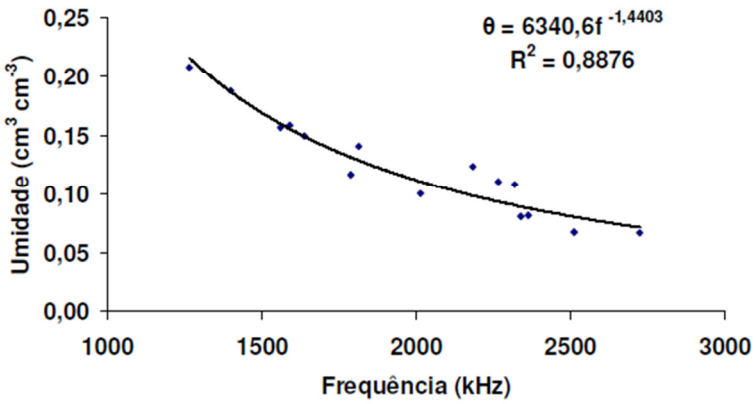

Figura 14. Relação entre teor de água do solo e respostas dos sensores capacitivos a 30 cm de profundidade (CRUZ, 2009).

Na Figura 12 a planilha foi separada em três campos. Campo 01 é destinado para a introdução dos valores de frequência em valores padrões de cada um dos sensores instalados no campo. Campo 02 é destinado ao registro das datas e horários dos valores de frequência obtidos. O Campo 03 é destinado as resposta do método do Balanço Hídrico Volumétrico.

3.6.3. Avaliação de crescimento

Foram realizadas avaliações semanais, entre o 18º e o 46º dia após a semeadura, para verificar se houve diferença devido ao manejo no comportamento das plantas avaliadas. Foram escolhidas cinco plantas em cada uma das áreas e realizadas leituras à: 18 h do dia anterior e 05h, 08h, 11h e 14h do dia da avaliação.

Foram avaliados o tamanho da rama principal e a umidade do solo, utilizando o sensor capacitivo, na hora da avaliação. Na Figura 15 observa-se um exemplo da avaliação do comprimento do ramo principal.

Figura 15. Medição do comprimento do ramo principal.

A partir dos valores de umidade do solo, em cm^3 cm^{-3}, calculando-se os valores de consumo por meio da Equação 11.

$$Consumo = (\theta_{atual} - \theta_{LA}) \times h \quad (11)$$

Onde: Consumo representa a umidade do solo consumida pelo processo de evapotranspiração, em mm; θ_{atual} representa a umidade do solo atual, em cm^3 cm^{-3}; θ_{LA} representa a umidade da leitura anterior, em cm^3cm^{-3} e h representa a camada de solo onde esta retida a umidade, em mm.

3.6.4. Avaliação da produtividade

Foram selecionadas 5 plantas de cada um dos tratamentos e nestas plantas foram realizados pesagens de seus frutos em totalidade. Dos valores obtidos foram realizados testes estatísticos paramétricos para dados não pareados. Para a execução desse tipo de teste são necessários alguns pré-requisitos. O primeiro deles é que a

distribuição da amostra seja normal. Para o teste de normalidade foi aplicado o teste de Kolmogorov-Smirnov, onde a hipótese nula e hipótese alternativa correspondem, respectivamente, à distribuição ser normal e não normal.

O segundo pré-requisito para aplicação de testes paramétricos para dados não pareados é que as variâncias populacionais sejam constantes, para este trabalho foi realizado o teste de Levene no qual a hipótese nula representa que a amostra é homogênea e a hipótese alternativa é que há heterogeneidade entre as amostras.

Após a aplicação dos testes supracitados, foi realizado o teste t de comparação de médias para dados não pareados. Todos os procedimentos estatísticos foram executados no programa estatístico SPSS (TECHNOLOGIES, 2012).

4. RESULTADOS E DISCUSSÃO

Nesta seção serão abordados os resultados obtidos neste trabalho. Este capítulo foi dividido em três tópicos: testes das redes neurais artificiais para a primeira fase da cultura (0 – 30 DAS), testes das redes neurais artificiais para a segunda fase da cultura (31 - 60 DAS) e etapa de campo.

4.1. Testes das RNAs para a primeira fase da cultura (0 – 30 DAS)

Nesta seção serão abordados os resultados dos treinamentos para a primeira fase da cultura para cada um dos elementos da arquitetura avaliados. Inicialmente foram testadas redes variando o número de entradas, mas com o número de neurônios (5) e número de épocas (5.000) constantes. Em seguida os testes para a definição do número de épocas utilizando o número de entradas de melhor resposta e 5 neurônios na camada intermediária. Posteriormente testando o número de neurônios na camada intermediária utilizando o número de entradas e épocas definidos nos testes anteriores.

4.1.1. Número de entradas

Nas Figuras 16 e 17 observam-se os gráficos do erro quadrático médio obtido para as redes neurais com duas e quatro entradas, respectivamente. Como observado, a RNA composta por duas entradas não foi bem sucedida em atingir baixos valores de erro quadrático, comparado com os resultados da RNA com quatro entradas, a qual atingiu valores inferiores a 0,0012 antes mesmo de se completarem 250 épocas

de treinamento, enquanto a rede neural artificial com 2 entradas não atingiu erros inferiores a 0,0068 nas 5.000 épocas de treinamento. Este resultado pode ser devido à RNA com duas entradas não ter proporcionado a convergência ao mínimo global da superfície de erro e ter estacionado em um mínimo local, como também devido à baixa precisão derivada do número insuficiente de entradas, não conduzindo ao o mínimo global, já que o aumento de número de entradas redirecionou mais facilmente para este mínimo global.

Nas Figuras 18 e 19 estão apresentados os gráficos comparativos entre os tempos reais de irrigação, obtidos em campo e usados para validação da RNA após o seu treinamento (em vermelho) e os tempos de irrigação estimados pela rede neural artificial treinada (em azul) e nas Figuras 20 e 21 observam-se as curvas de regressão entre os tempos observados de irrigação, usados para a validação, e os tempos obtidos pela RNA. Observa-se então que a RNA com quatro entradas obteve um desempenho superior à rede com duas entradas em estimar os valores de tempo de irrigação, com a análise de regressão atingindo um R^2 de 0,9962 enquanto para a rede com duas entradas atingiu R^2 de 0,6267. Embora a rede neural com duas entradas não tenha conseguido um bom desempenho, observa-se na Figura 18 que esta rede seguiu a mesma tendência do valor de resposta de tempo de irrigação real. Esses resultados indicam que a RNA com quatro entradas se mostrou mais eficiente e precisa para a obtenção dos tempos de irrigação para a primeira fase da cultura.

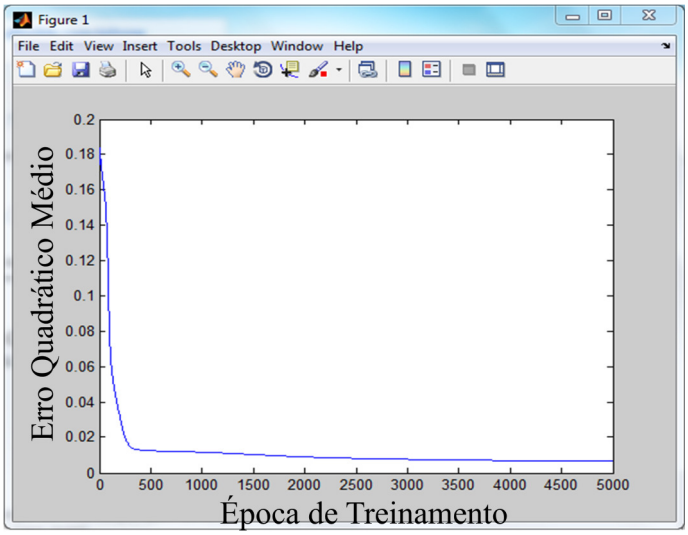

Figura 16. Gráfico do erro quadrático médio obtido para rede neural artificial com 2 entradas.

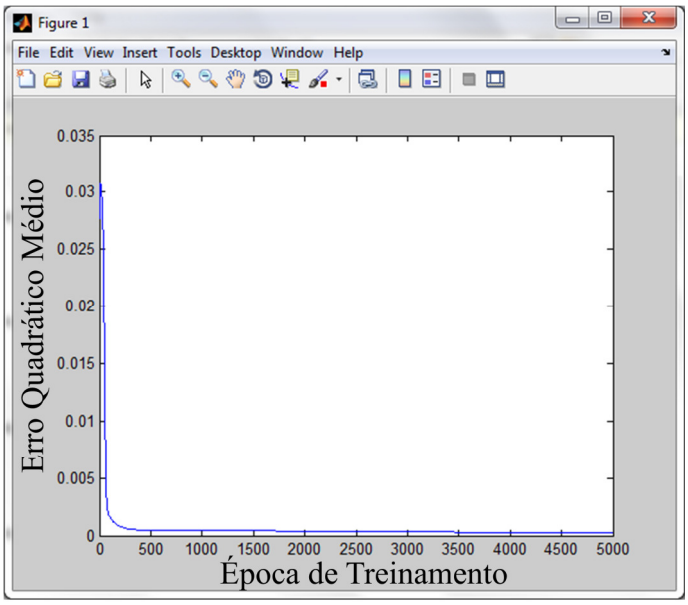

Figura 17. Gráfico do erro quadrático médio obtido para rede neural artificial com 4 entradas.

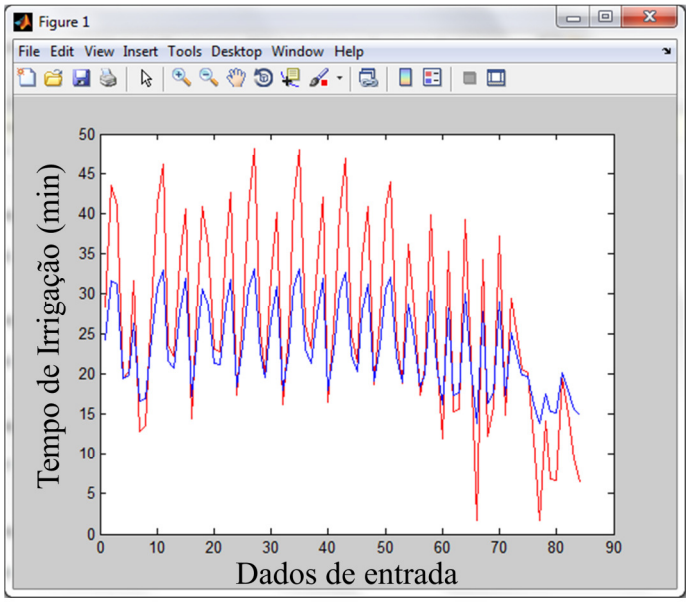

Figura 18. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial de 2 entradas.

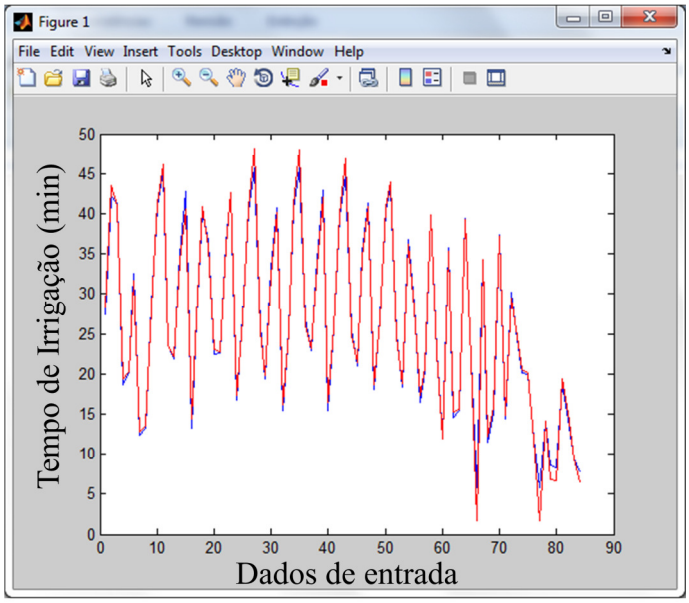

Figura 19. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial de 4 entradas.

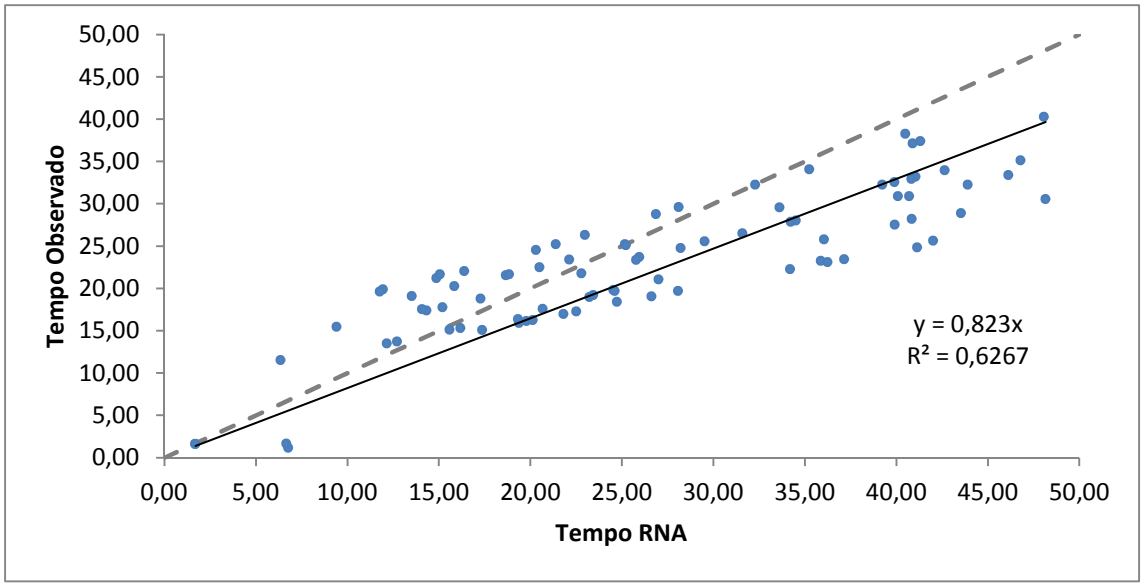

Figura 20. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com duas entradas para a primeira fase da cultura.

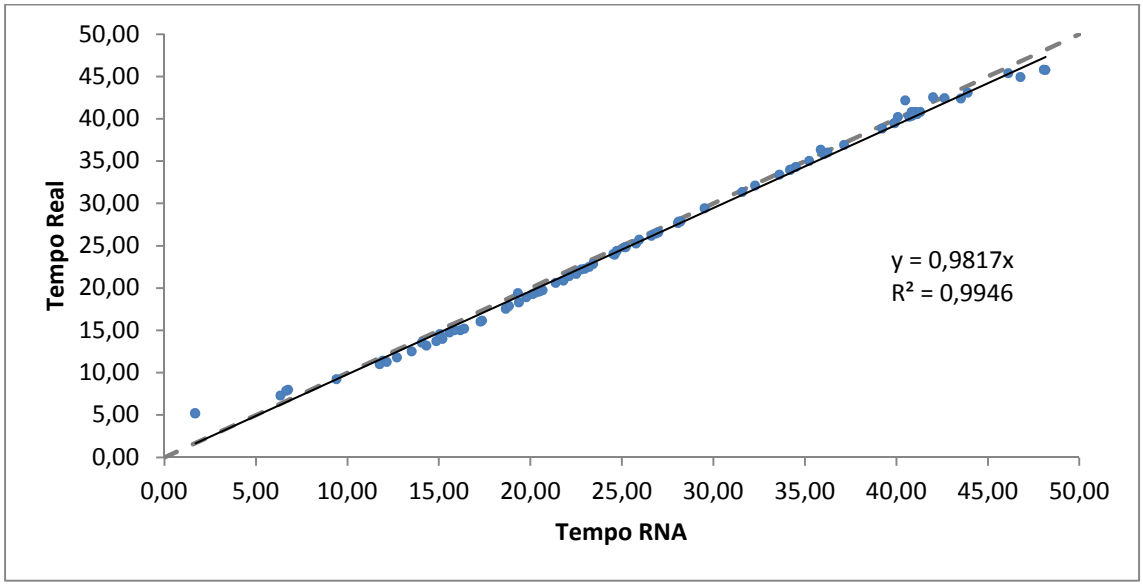

Figura 21. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com quatro entradas para a primeira fase da cultura.

4.1.2. Número de épocas de treinamento

Uma vez definido o número de entradas em quatro foram obtidos as Figuras 22, 23 e 24 representando gráficos do erro quadrático médio obtido para as redes neurais com 1.000, 5.000 e 10.000 épocas de treinamento, respectivamente. Mostra-se que nos três casos não foi obtido ganho no desempenho da RNA, uma vez que as três RNAs conseguiram atingir valores inferiores a 0,001 antes mesmo de atingir 200 épocas de treinamento. O erro mínimo ao atingir 1.000, 5.000 e 10.000 épocas de treinamento foram 0,00045; 0,00022 e 0,00013, obtendo melhora em torno de 50% na redução do erro em aplicação.

Nas Figuras 25, 26 e 27 encontram-se os gráficos comparativos entre os tempos reais de irrigação em vermelho e o tempo de irrigação estimado pela rede neural artificial treinada com 1.000, 5.000 e 10.000 épocas de treinamento e nas Figuras 28, 29 e 30 observam-se as curvas de regressão entre os tempos observados de irrigação, usados para a validação, e os tempos obtidos pela RNA. Observa-se que houve uma pequena melhora com o aumento do número de épocas, tendo a rede com 10.000 épocas de treinamento uma convergência (R^2 = 0,9961) maior do que a obtida pela rede treinada com 1.000 épocas de treinamento (R^2 = 0,9856), sendo recomendado, para esta aplicação, RNAs com 10.000 épocas de treinamento.

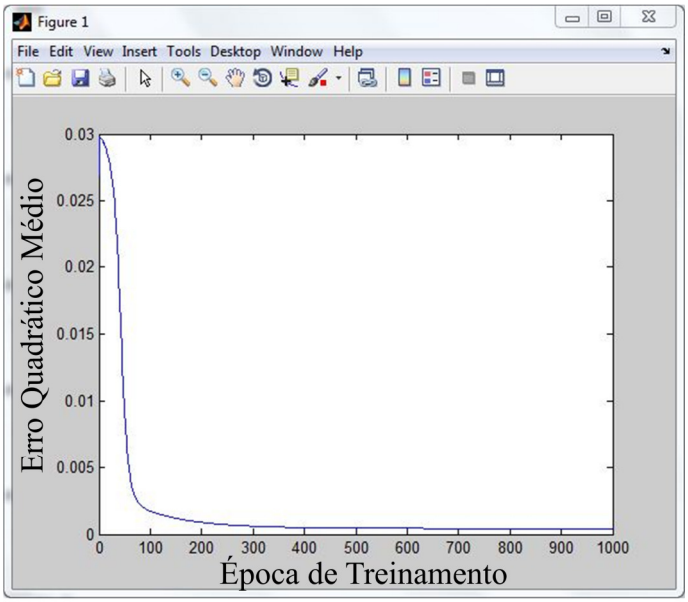

Figura 22. Gráfico do erro quadrático médio obtido para rede neural artificial com 1000 épocas de treinamento.

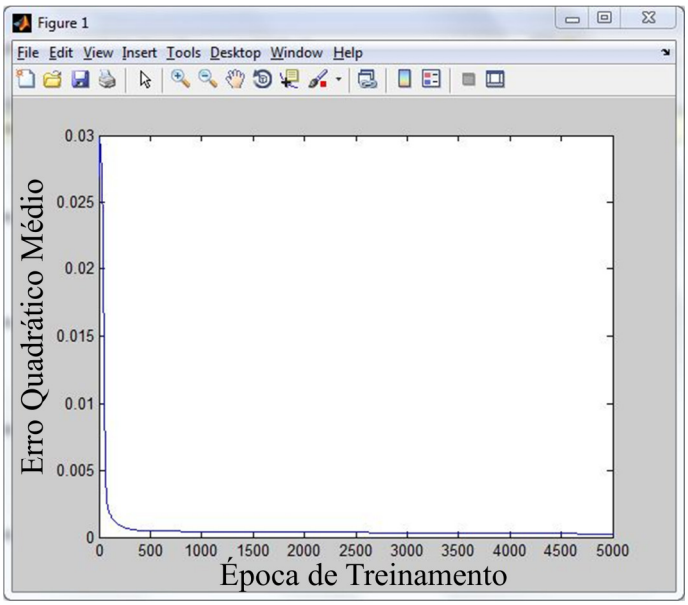

Figura 23. Gráfico do erro quadrático médio obtido para rede neural artificial com 5000 épocas de treinamento.

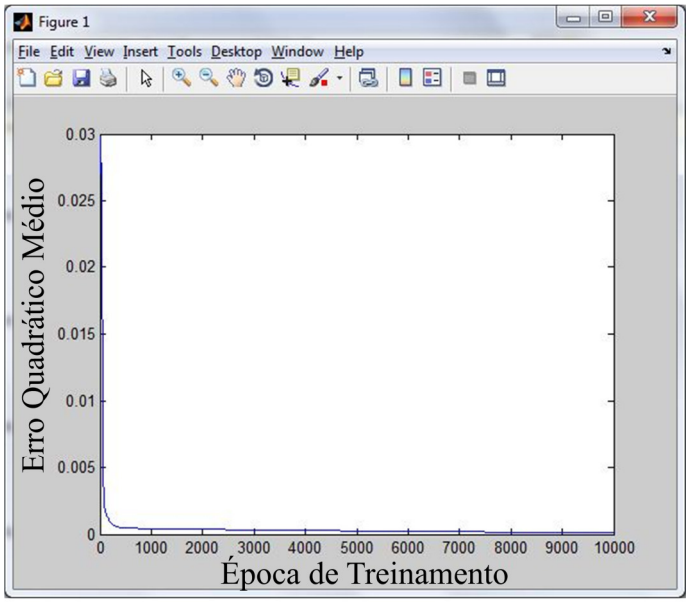

Figura 24. Gráfico do erro quadrático médio obtido para rede neural artificial com 10000 épocas de treinamento.

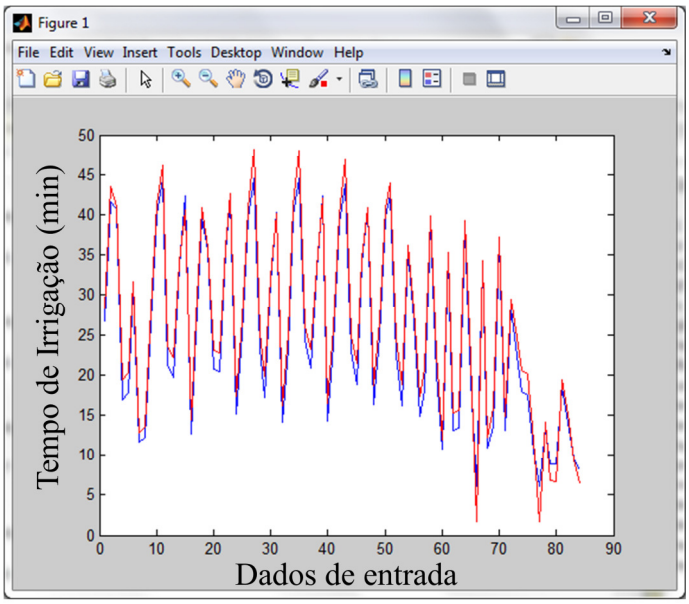

Figura 25. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 1000 épocas de treinamento.

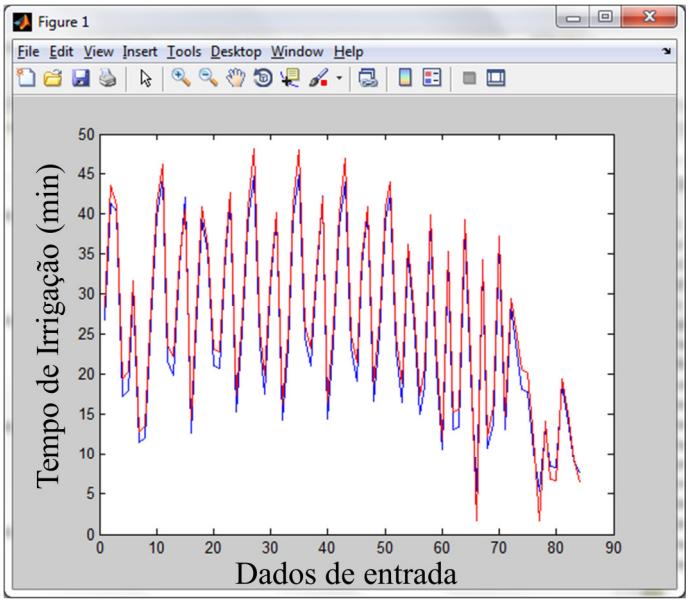

Figura 26. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5000 épocas de treinamento.

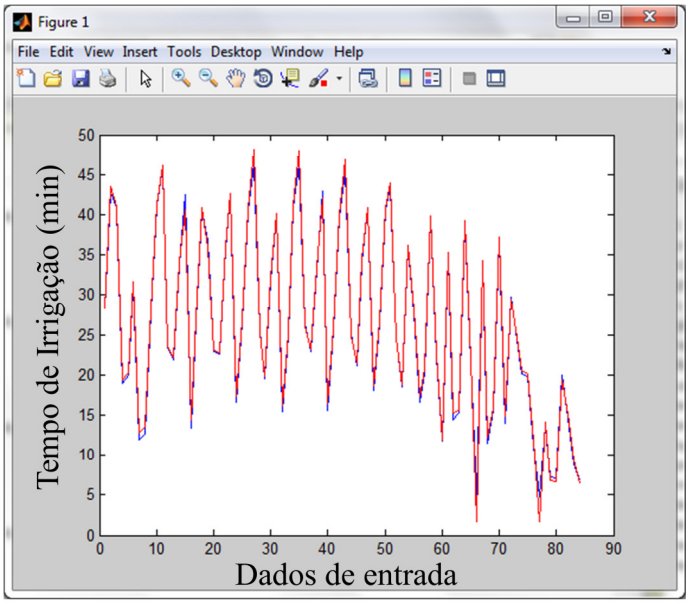

Figura 27. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 10000 épocas de treinamento.

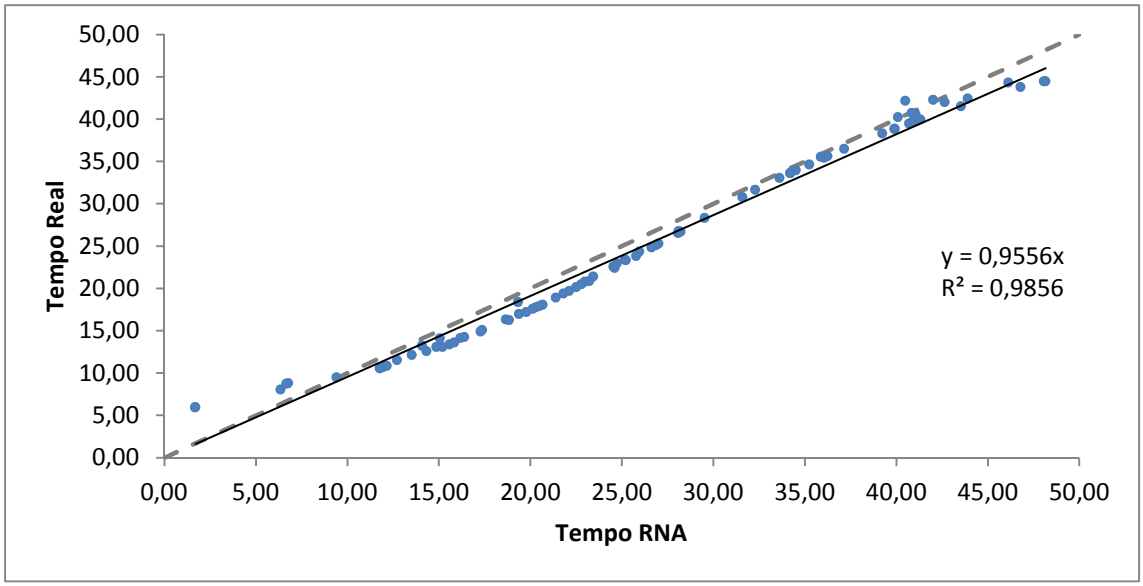

Figura 28. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 1.000 épocas de treinamento para a primeira fase da cultura.

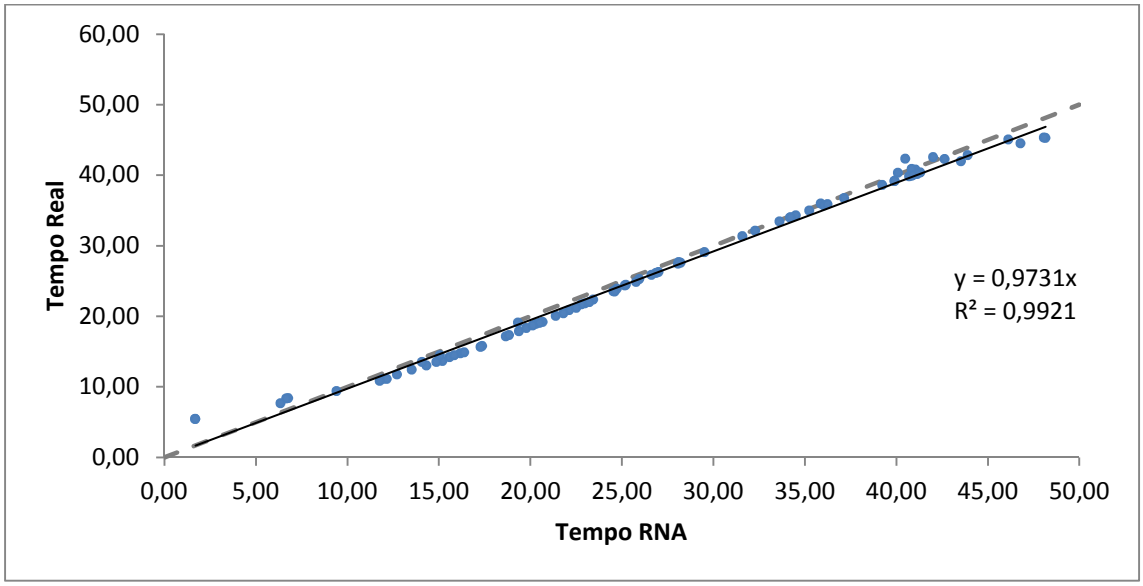

Figura 29. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5.000 épocas de treinamento para a primeira fase da cultura.

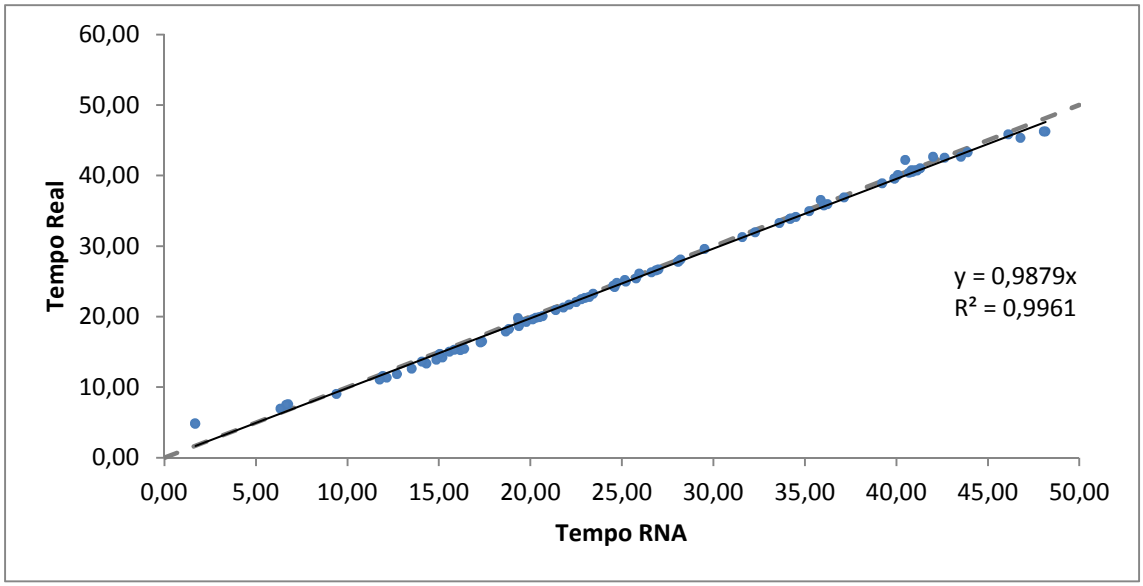

Figura 30. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10.000 épocas de treinamento para a primeira fase da cultura.

4.1.3. Número de neurônios na camada intermediária

Nas Figuras 31, 32, 33 e 34 observam-se os gráficos comparativos entre os tempos reais de irrigação em vermelho e o tempo de irrigação estimado pela rede neural artificial treinada com 5, 10, 15 e 20 neurônios na camada intermediária e nas Figuras 35, 36, 37 e 38 observam-se as curvas de regressão entre os tempos observados de irrigação, usados para a validação, e os tempos obtidos pela RNA. Os resultados mostraram que não há melhora na resposta das RNAs ao aumento do número de neurônios na camada intermediária de 5 para 20, mas houve uma leve perca de rendimento com o aumento deste número, sendo a rede com 5 neurônios na camada intermediária com melhor desempenho, obtendo um R^2 igual a 0,9968 e a rede com 20 neurônios na camada intermediária a de pior desempenho, obtendo um R^2 igual a 0,9947.

De acordo com SILVA (2005), uma das principais características de uma RNA é seu poder de generalização, que é a capacidade de uma rede neural responder adequadamente a padrões jamais vistos. Uma rede muito grande, com o número de neurônios muito superior aos necessários para o problema em análise, não responderá corretamente a estes padrões inéditos e perderá a sua capacidade de generalização. Isso se deve à adaptação dos pesos sinápticos ao vetor de entrada e ao ruído ocorrido no treinamento. Na presente aplicação, a rede com 5 neurônios na camada intermediária teve melhor resposta em comparação às demais arquiteturas testadas, sendo a recomendada.

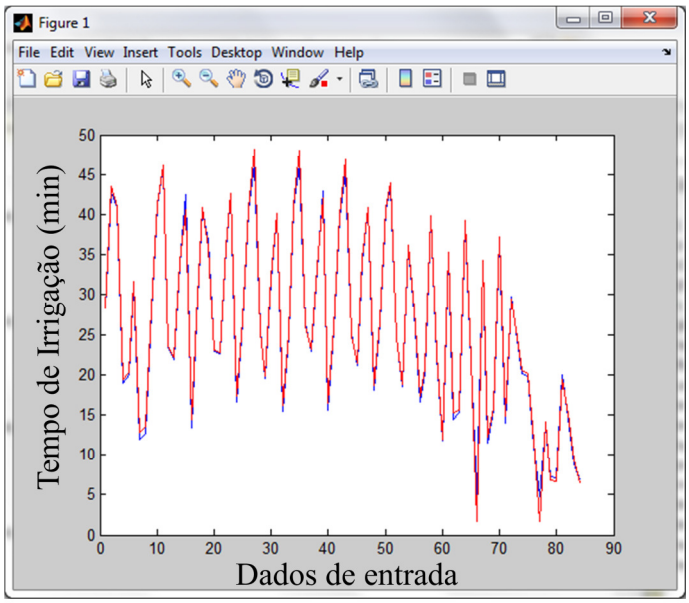

Figura 31. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5 neurônios na camada intermediária.

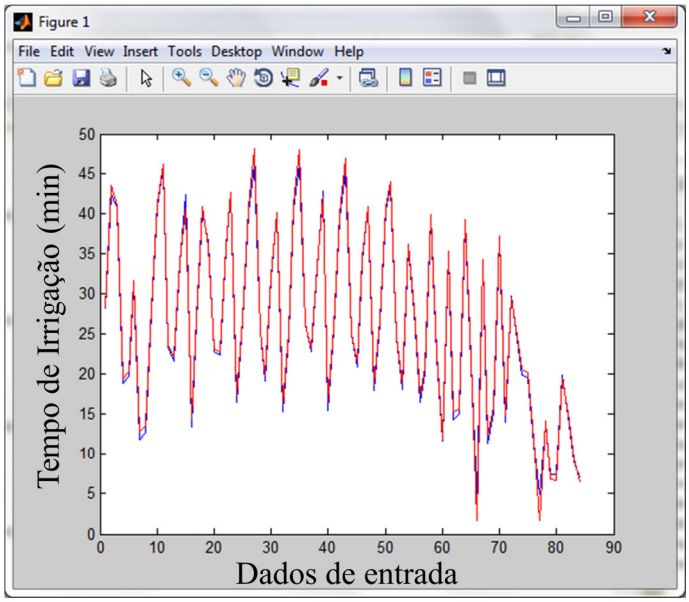

Figura 32. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 10 neurônios na camada intermediária.

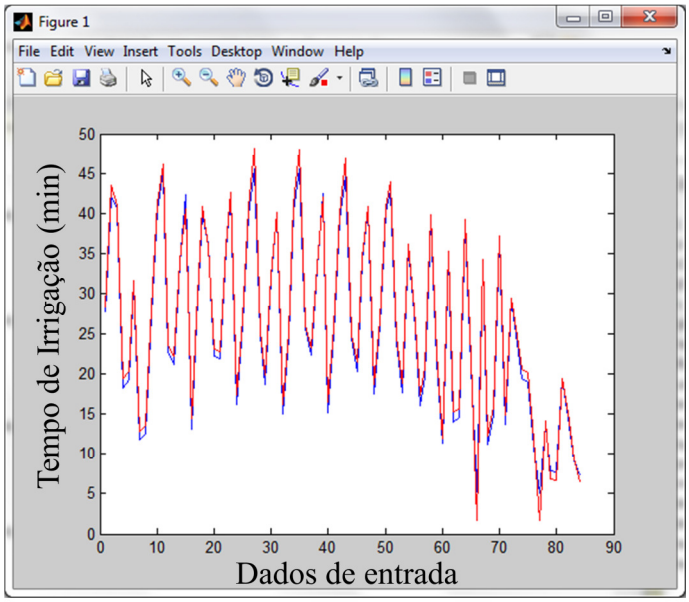

Figura 33. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 15 neurônios na camada intermediária.

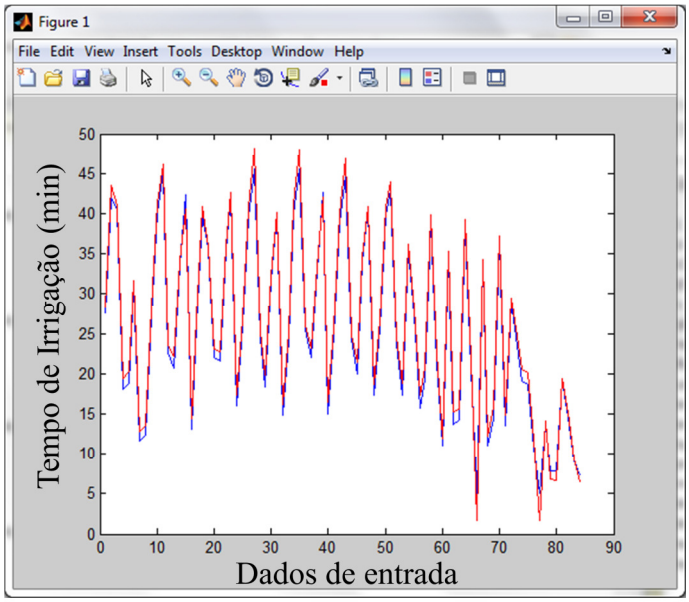

Figura 34. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 20 neurônios na camada intermediária.

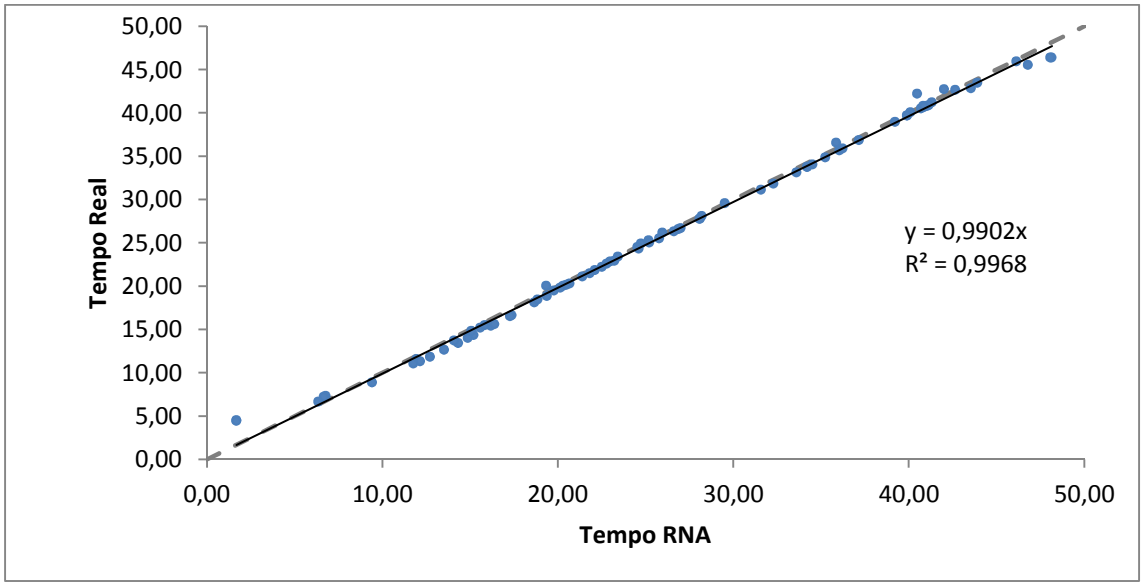

Figura 35. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5 neurônios na camada intermediária para a primeira fase da cultura.

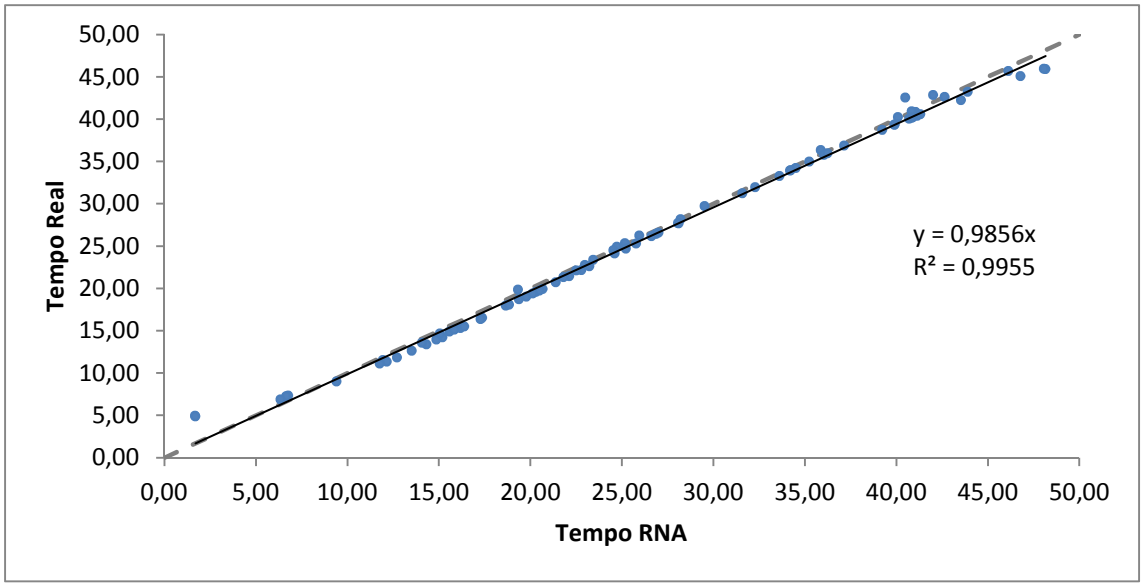

Figura 36. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10 neurônios na camada intermediária para a primeira fase da cultura.

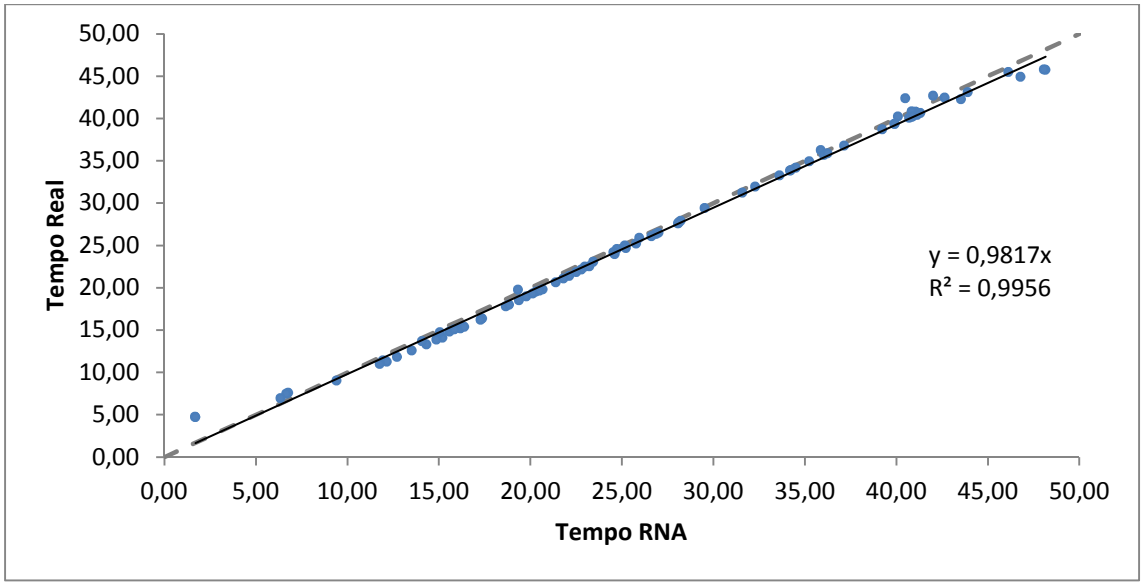

Figura 37. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 15 neurônios na camada intermediária para a primeira fase da cultura.

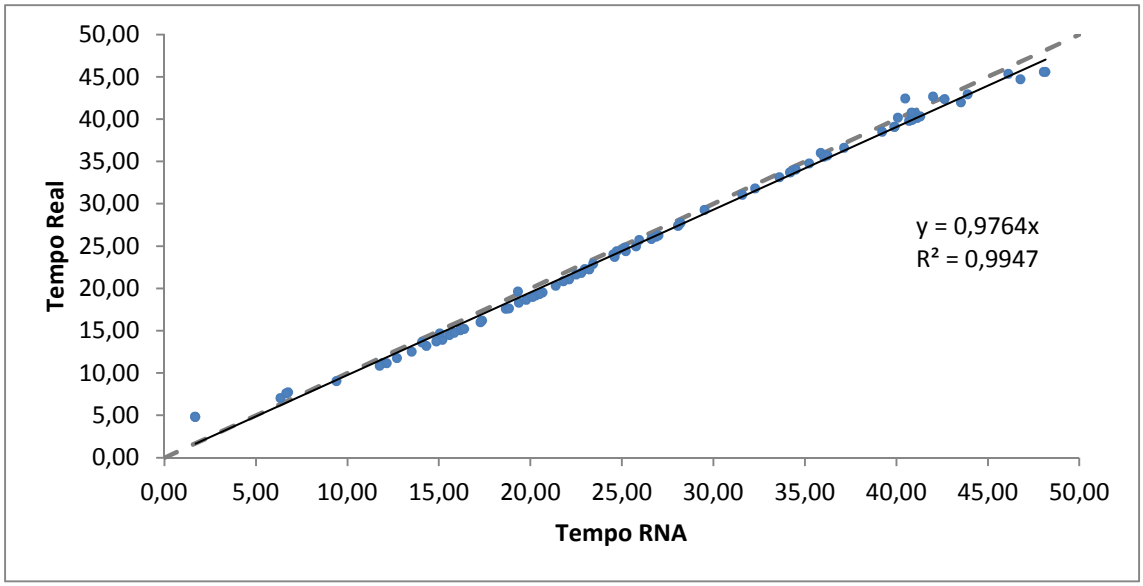

Figura 38. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 20 neurônios na camada intermediária para a primeira fase da cultura.

Assim, como conclusão pode-se dizer que a rede neural artificial com a arquitetura 4-5-1, taxa de aprendizagem de 0,9 e 10.000 épocas de treinamento, representa a de melhor resposta para a primeira fase da cultura.

4.2. Testes das RNAs para a segunda fase da cultura (31 - 60 DAS)

Nesta seção serão abordados os resultados dos treinamentos para a primeira fase da cultura para cada um dos elementos da arquitetura avaliados. Inicialmente foram testadas redes variando o número de entradas, mas com o número de neurônios (5) e número de épocas (5.000) constantes. Em seguida os testes para a definição do número de épocas utilizando o número de entradas de melhor resposta e 5 neurônios na camada intermediária. Posteriormente testando o número de neurônios na camada intermediária utilizando o número de entradas e épocas definidos nos testes anteriores.

4.2.1. Número de entradas

Nas Figuras 39 e 40 são mostrados os gráficos do erro quadrático médio obtido para as redes neurais com duas e quatro entradas, respectivamente. Como visto no teste de redes neurais para a primeira fase da cultura, a rede com duas entradas atingiu erros quadráticos bem superiores comparados à rede neural com quatro entradas. O erro quadrático mínimo obtido pela RNA com duas entradas foi de 0,1685 em 5.000 épocas de aprendizagem, já para a rede neural com quatro entradas obteve um erro inferior a 0,001 em menos de 1.700 épocas de treinamento. Assim, visando ao manejo da irrigação, as RNAs com duas entradas mostram-se ineficientes para atingir o erro mínimo global da função, sendo necessários pelo menos 2 pares de dados para obter menores erros.

Nas Figuras 41 e 42 são mostrados os gráficos comparativos entre os tempos reais de irrigação e aqueles estimados pelas redes neurais artificiais com 2 e 4 entradas, respectivamente, e nas Figuras 43 e 44 observam-se as curvas de regressão entre os tempos observados de irrigação, usados para a validação, e os tempos obtidos pela RNA. Observa-se, pela análise das figuras, que a RNA com duas entradas não se mostrou eficiente para gerar valores condizentes de tempo de irrigação, obtendo baixo valor de R^2 (0,3848), comparada à RNA com quatro entradas (R^2 = 0,9816). Grande parte dessa perda de precisão deveu-se ao alto erro quadrático obtido pelo treinamento. Contudo, a RNA conseguiu manter a tendência da curva de tempo de irrigação. Assim, para esta aplicação, as redes com quatro entradas são mais promissoras que as redes com duas entradas.

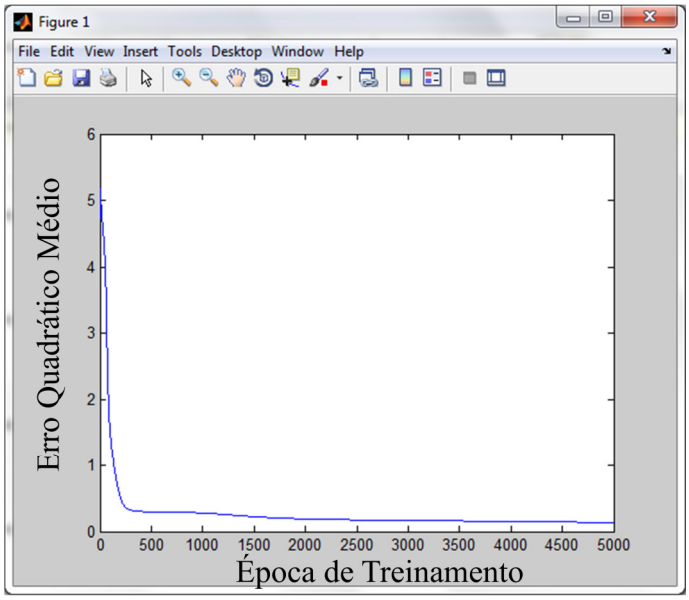

Figura 39. Gráfico do erro quadrático médio obtido para rede neural artificial com 2 entradas.

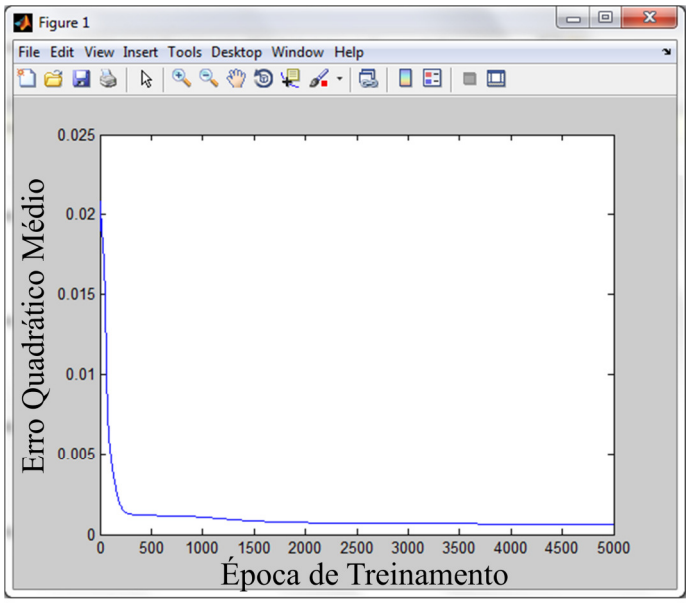

Figura 40. Gráfico do erro quadrático médio obtido para rede neural artificial com 4 entradas.

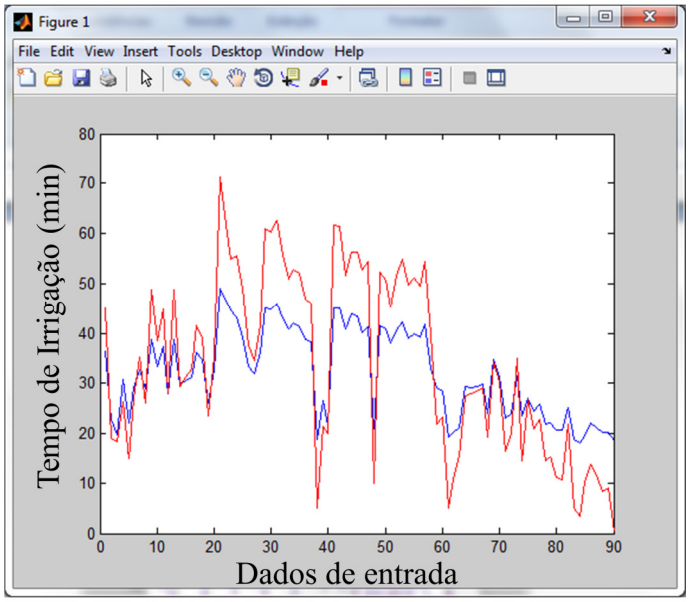

Figura 41. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 2 entradas.

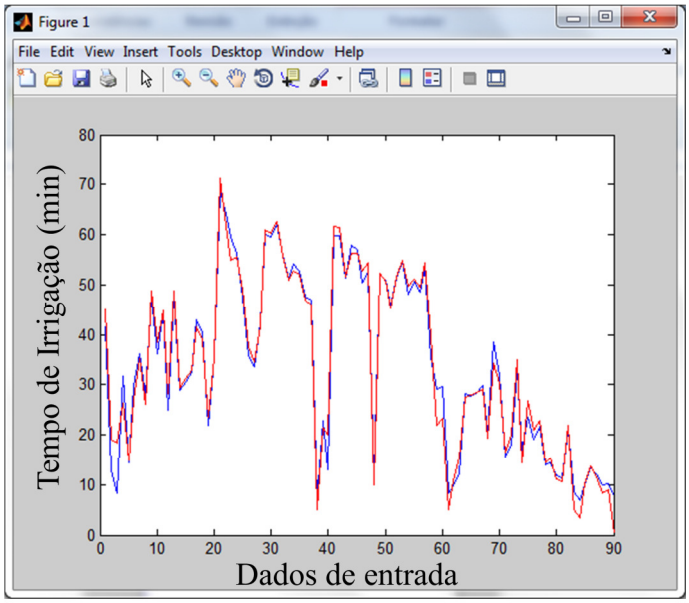

Figura 42. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 4 entradas.

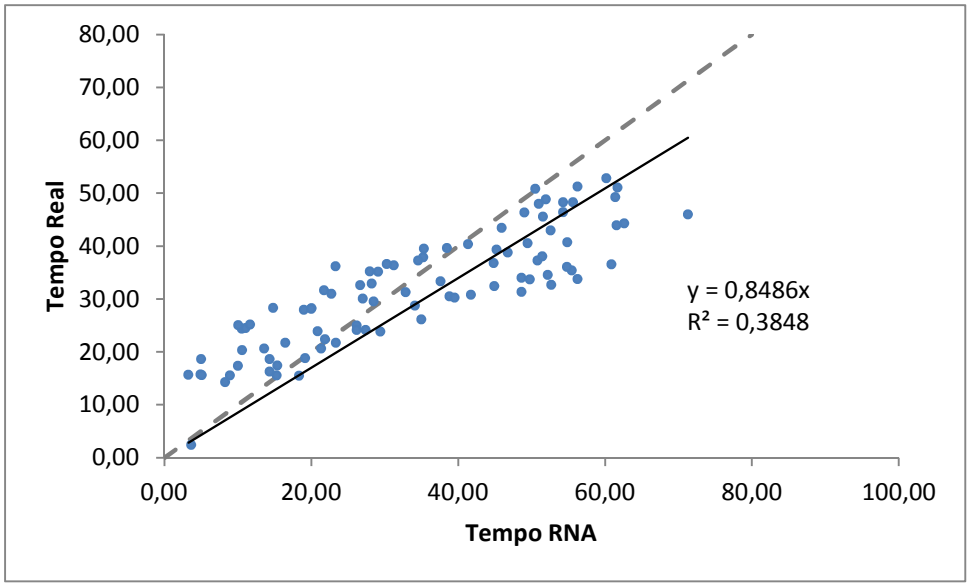

Figura 43. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 2 entradas para a segunda fase da cultura.

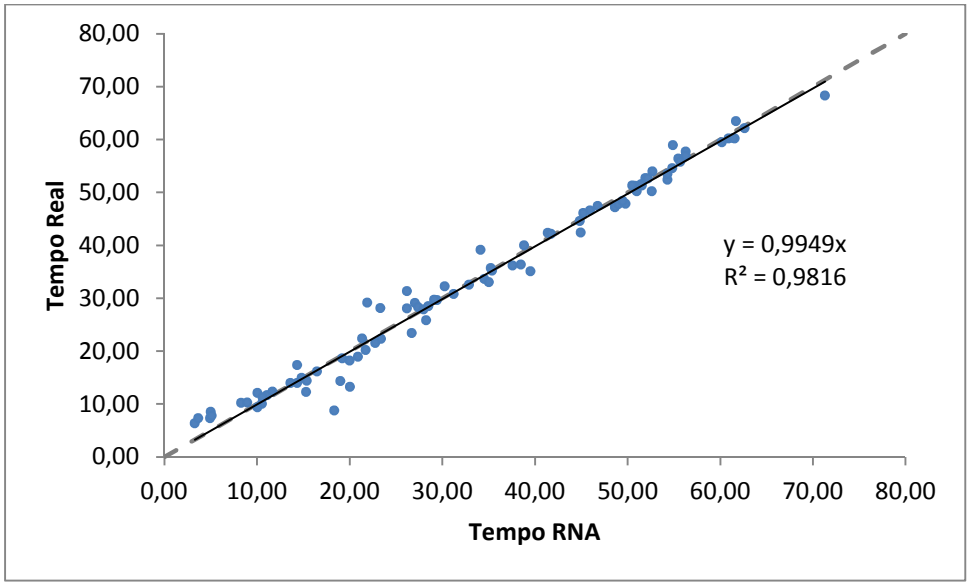

Figura 44. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 4 entradas para a segunda fase da cultura.

4.2.2. Número de épocas de treinamento

Nas Figuras 45, 46 e 47 observam-se os gráficos do erro quadrático médio obtido para as redes neurais com 1.000, 5.000 e 10.000 épocas de treinamento, respectivamente. Observa-se que o aumento do número de épocas se mostra vantajoso para a diminuição do erro quadrático até por volta de 1.700 épocas e que acima deste número, não se tem uma redução deste erro. Nas Figuras 48, 49 e 50, encontram-se os gráficos comparativos entre os tempos reais de irrigação (em vermelho) e o tempo de irrigação estimado pela rede neural artificial treinada (em azul) com 1.000, 5.000 e 10.000 épocas de treinamento respectivamente, e nas Figuras 51, 52 e 53 observam-se as curvas de regressão entre os tempos observados de irrigação, usados para a validação, e os tempos obtidos pela RNA. Há ganho na precisão das respostas das RNAs de 5.000 e 10.000 épocas, com R^2 superiores 0,979, em relação à rede com 1.000 épocas (R^2 = 0,9669), confirmando os resultados obtidos pela avaliação do erro quadrático médio.

FALQUETO (2007) relata a importância de determinar o número ideal de épocas de treinamento, pois se for estabelecido um parâmetro incorreto, a rede poderá perder a sua generalização devido ao fenômeno chamado *overtraining* (treinamento excessivo), deixando a RNA especialista em um determinado conjunto de dados. Assim, não havendo ganho na resposta das redes treinadas com 10.000 épocas em relação as redes treinadas com 5.000, recomenda-se treinar as RNAs com 5.000 épocas de treinamento.

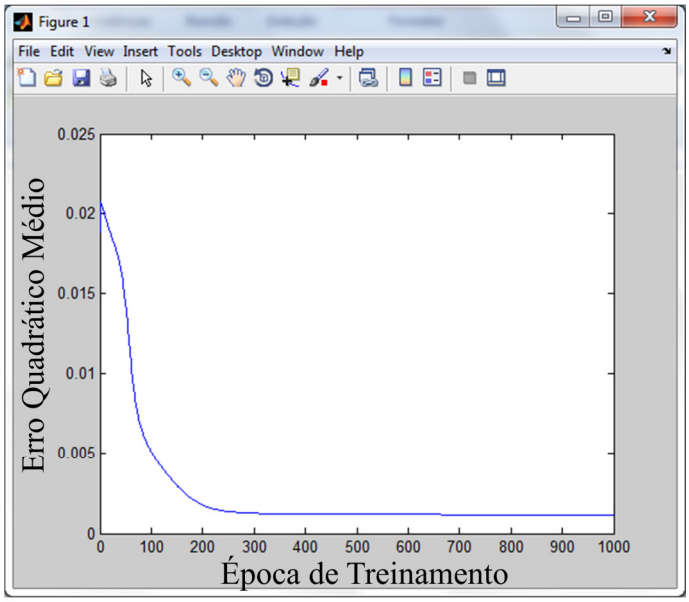

Figura 45. Gráfico do erro quadrático médio obtido para rede neural artificial com 1000 épocas de treinamento.

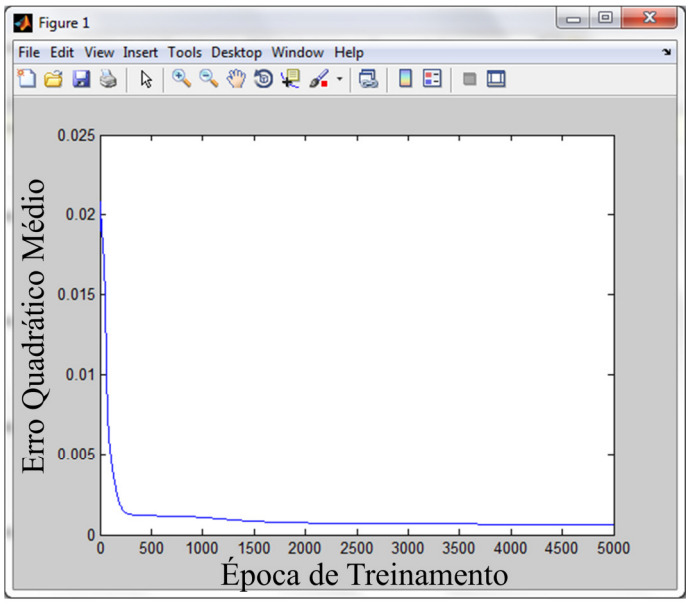

Figura 46. Gráfico do erro quadrático médio obtido para rede neural artificial com 5000 épocas de treinamento.

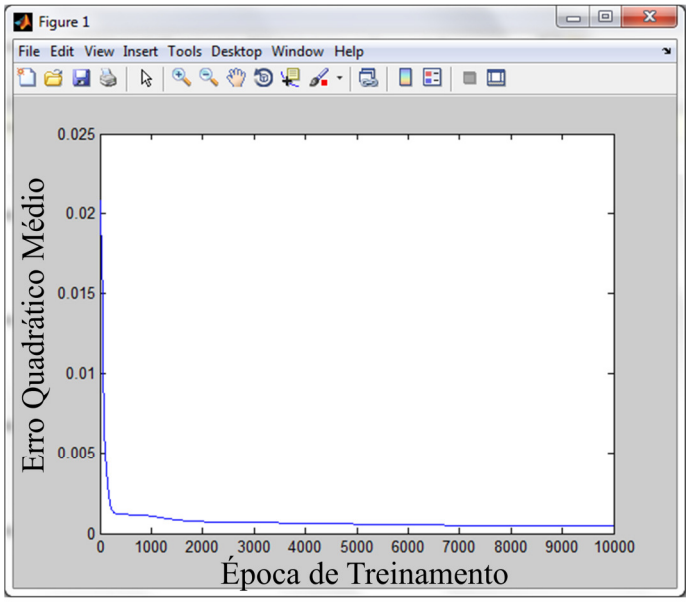

Figura 47. Gráfico do erro quadrático médio obtido para rede neural artificial com 10000 épocas de treinamento.

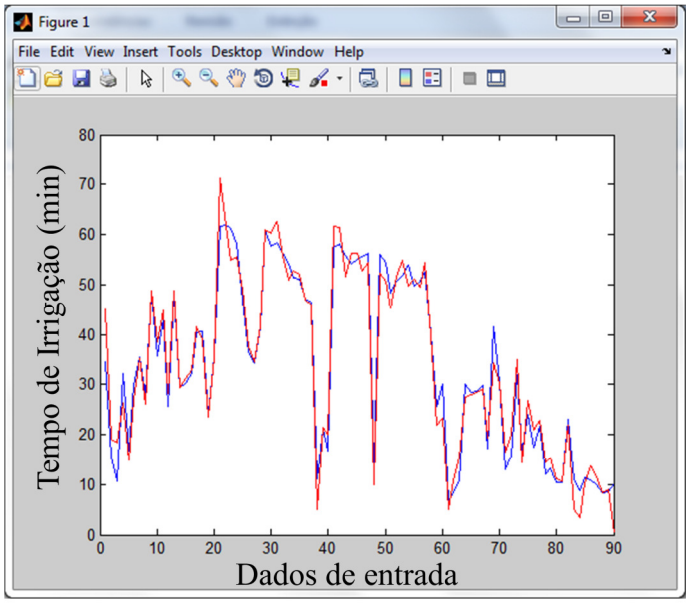

Figura 48. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para rede neural artificial com 1000 épocas de treinamento.

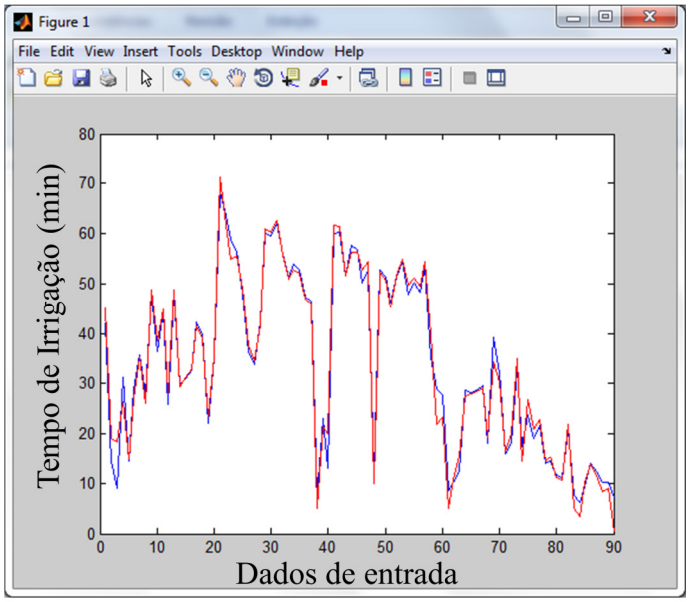

Figura 49. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5000 épocas de treinamento.

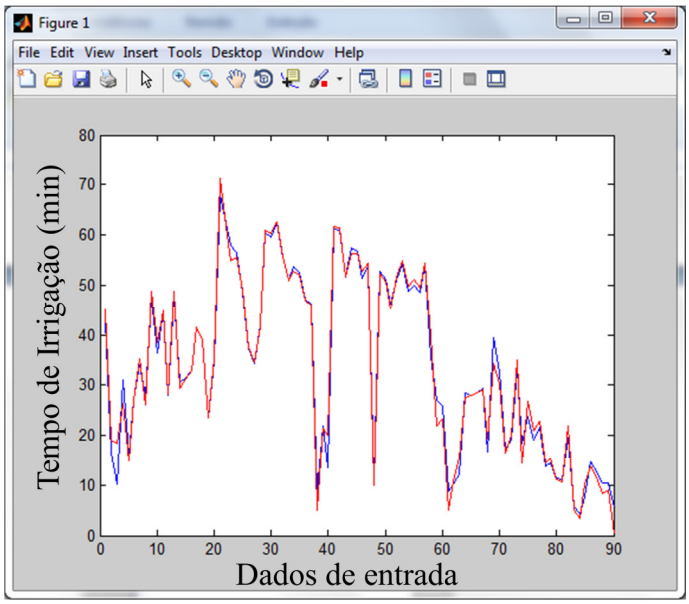

Figura 50. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para rede neural artificial com 10000 épocas de treinamento.

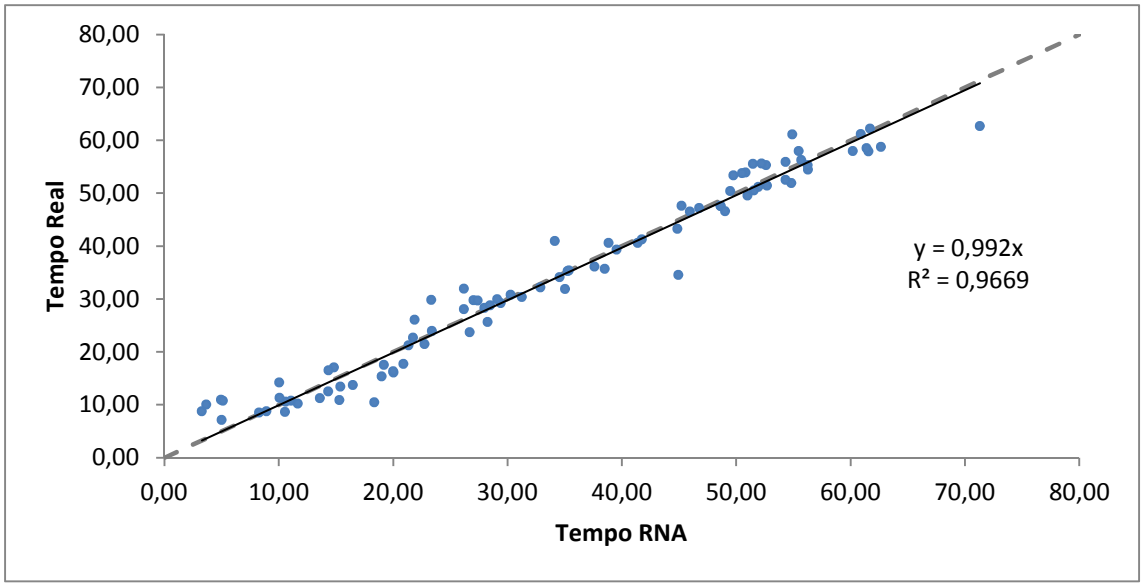

Figura 51. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 1.000 épocas de treinamento para a segunda fase da cultura.

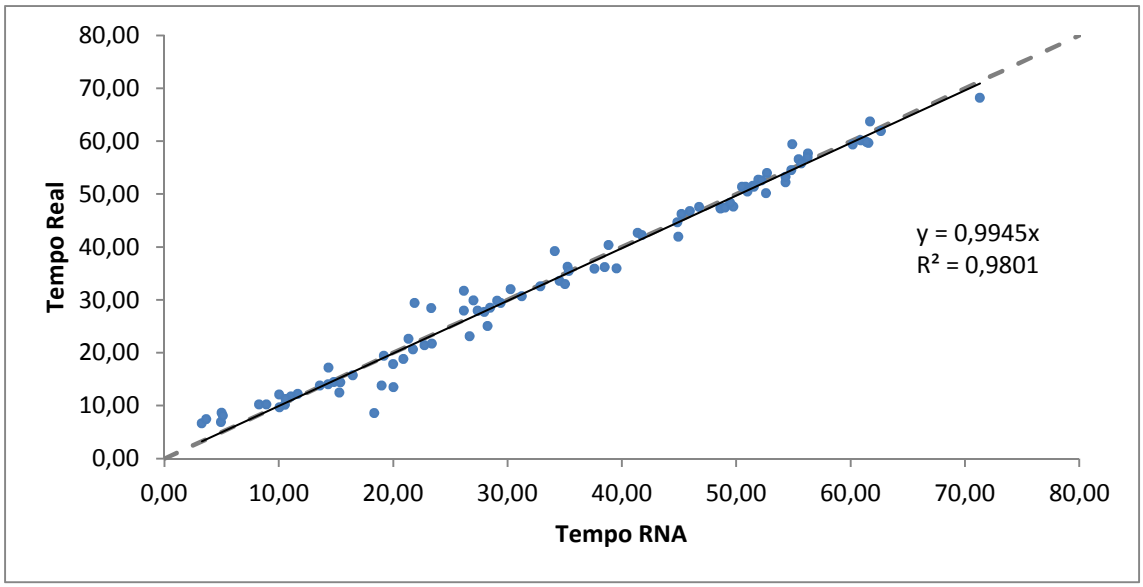

Figura 52. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5.000 épocas de treinamento para a segunda fase da cultura.

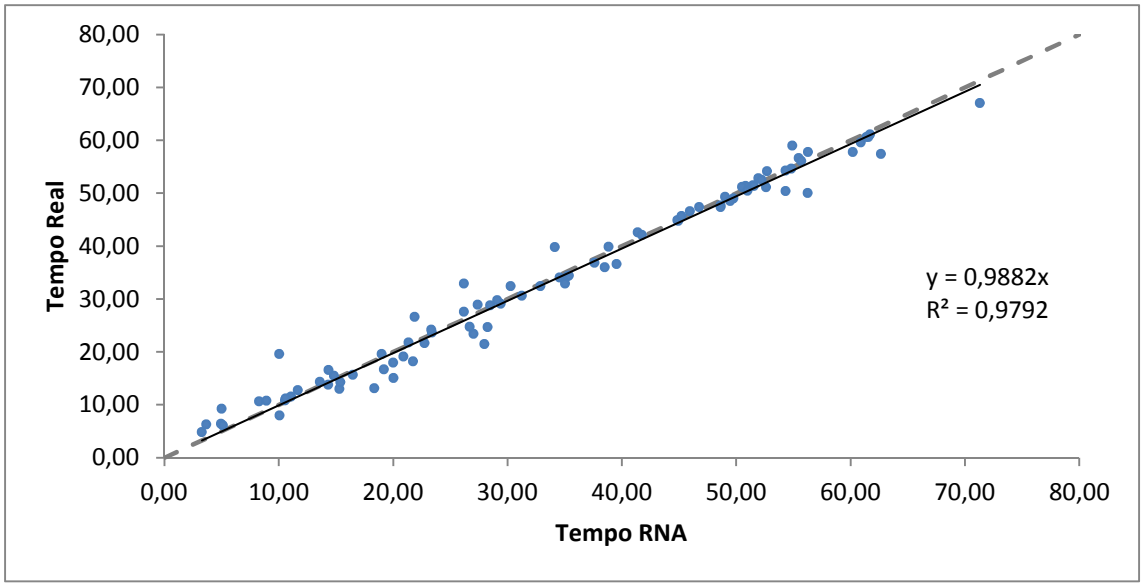

Figura 53. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10.000 épocas de treinamento para a segunda fase da cultura.

4.2.3. Número de neurônios na camada intermediária

Nas Figuras 54, 55, 56 e 57 observam-se os gráficos comparativos entre os tempos reais de irrigação (em vermelho) e o tempo de irrigação estimado pela rede neural artificial treinada (em azul) com 5, 10, 15 e 20 neurônios na camada intermediária, respectivamente, e nas Figuras 58, 59, 60 e 61 observam-se as curvas de regressão entre os tempos observados de irrigação, usados para a validação, e os tempos obtidos pela RNA. A RNA com 5 neurônios na camada intermediária obteve melhor resultado (R^2 = 9823). Corroborando com os resultados obtidos para as RNAs da primeira fase da cultura, não foram obtidas melhores respostas com o aumento do número de neurônios na camada intermediária não sendo interessante, portanto, uma RNA com mais de 5 neurônios na camada intermediária devido à diminuição do poder de generalização. LORENZI *et al*. (2004) relatam como outro problema em redes com um grande número de neurônios na camada intermediária é o aumento do esforço

computacional requerido para o seu treinamento. Com isso, para esta aplicação, recomenda-se a utilização de redes com 5 neurônios na camada intermediária.

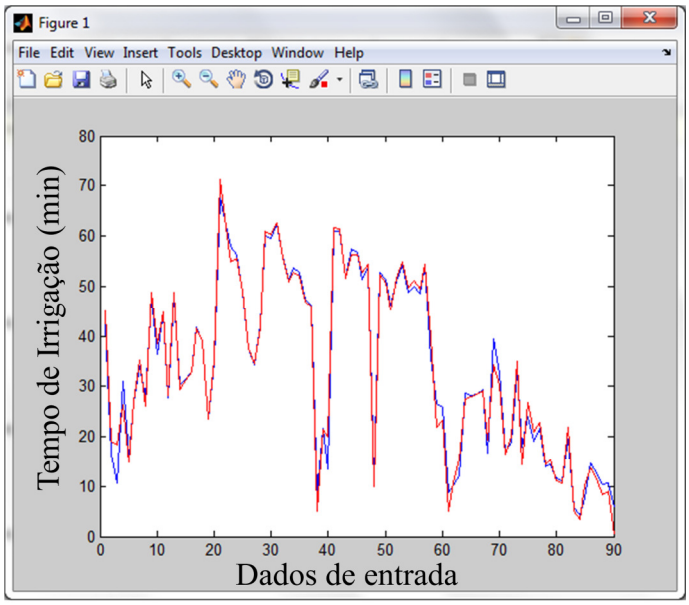

Figura 54. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 5 neurônios na camada intermediária.

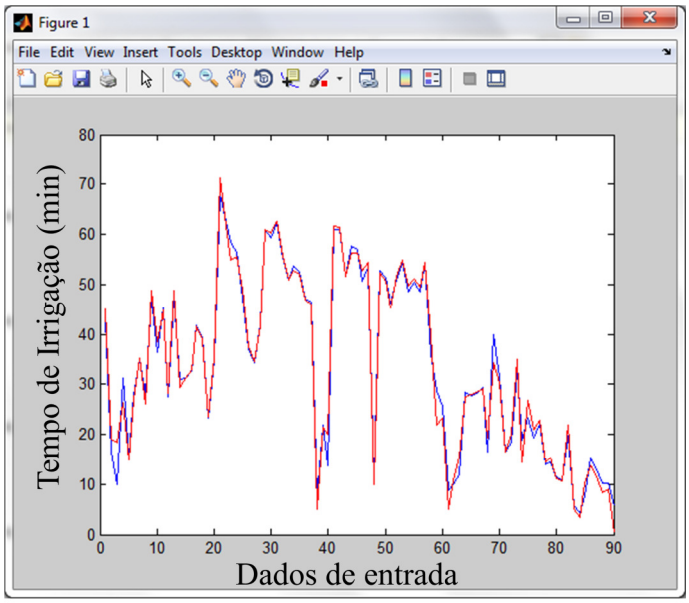

Figura 55. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 10 neurônios na camada intermediária.

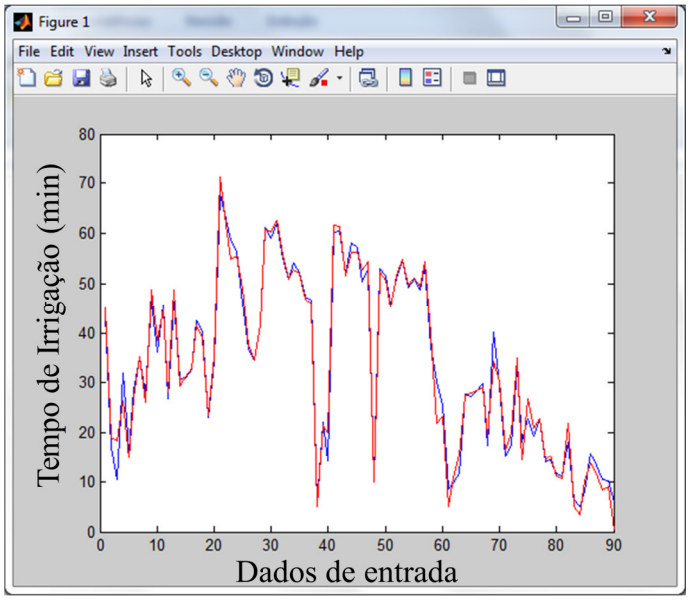

Figura 56. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 15 neurônios na camada intermediária.

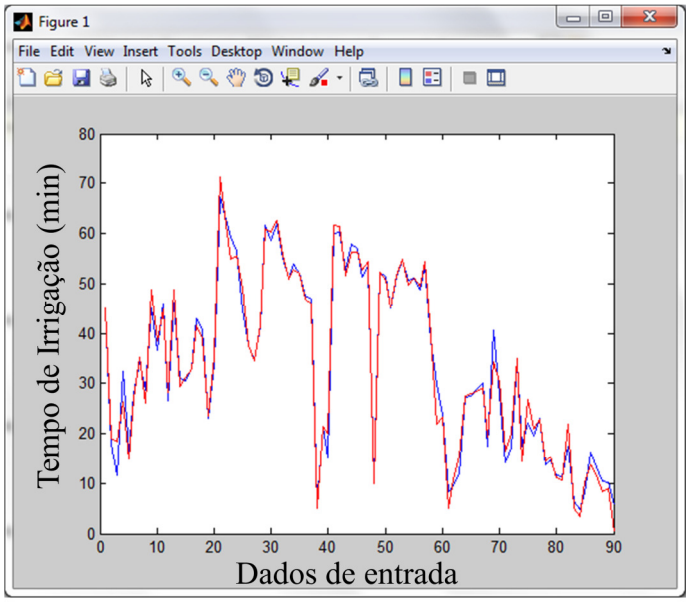

Figura 57. Gráfico comparativo das respostas da rede neural artificial (Azul) e os dados de validação (Vermelho) para a rede neural artificial com 20 neurônios na camada intermediária.

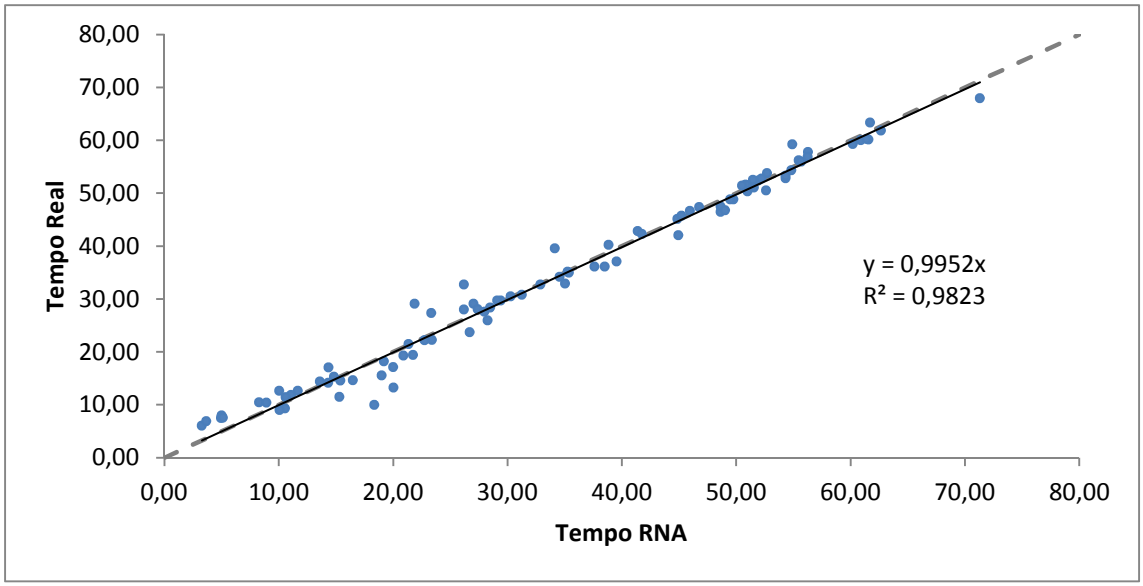

Figura 58. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 5 neurônios na camada intermediária para a segunda fase da cultura.

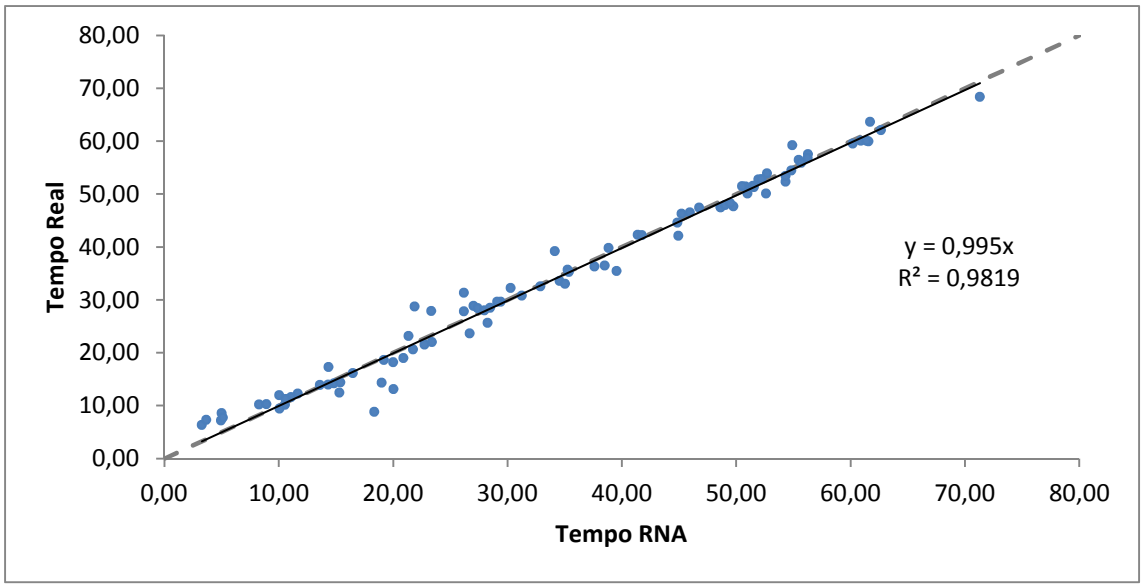

Figura 59. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 10 neurônios na camada intermediária para a segunda fase da cultura.

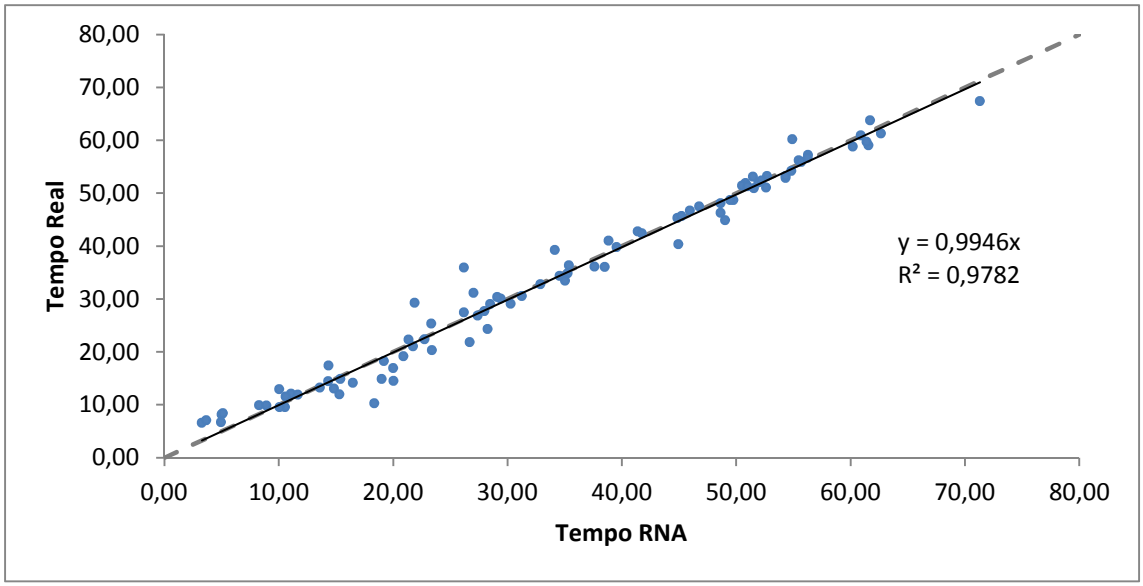

Figura 60. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 15 neurônios na camada intermediária para a segunda fase da cultura.

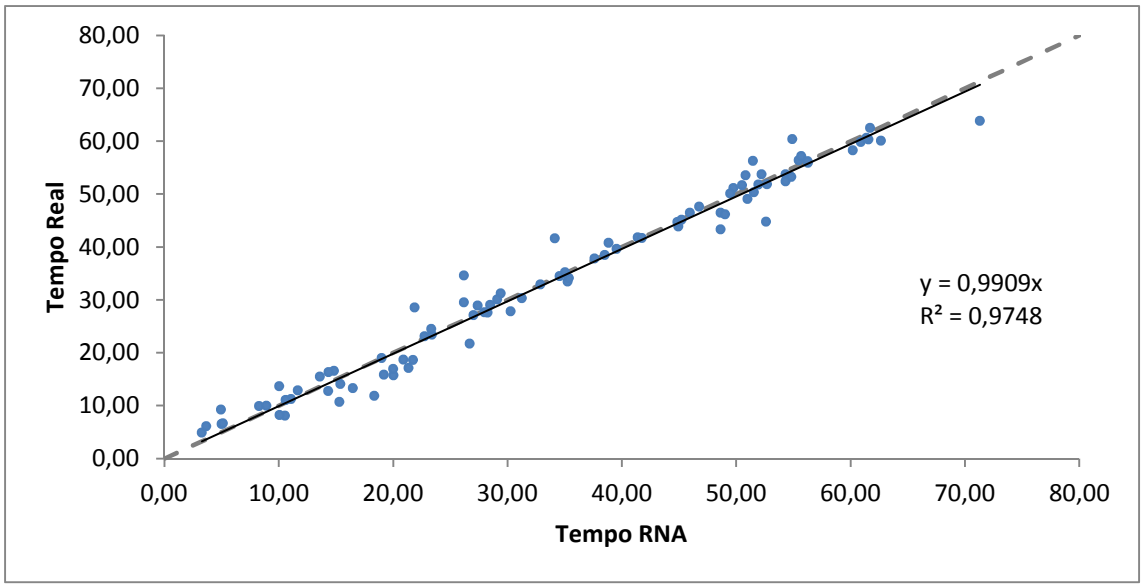

Figura 61. Regressão linear entre o tempo de irrigação observado e o estimado pela rede neural artificial com 20 neurônios na camada intermediária para a segunda fase da cultura.

Assim, conclui-se pela rede neural artificial com a arquitetura 4-5-1, com uma taxa de aprendizagem de 0,9 e com 5.000 épocas de treinamento, representa a de melhor resposta para a segunda fase da cultura.

4.3. Etapa de campo

A planta avaliada, para a segunda fase do cultivo, foi a melancia da variedade Crimson Sweet, com o tempo estimado para a colheita em torno de 64 dias após a semeadura. O plantio foi realizado no dia 11 de outubro de 2010. A diferenciação dos manejos da irrigação foi realizada no início da segunda fase da cultura, no dia 10 de novembro de 2010, 30º dia após a semeadura (DAS).

4.3.1. Acompanhamento da irrigação

Os valores de tempo de irrigação definidos pelos manejos foram convertidos em valores de lâmina, em mm dia^{-1}. As Figuras 62 e 63 ilustram as lâminas de irrigação aplicadas ao logo da segunda fase do cultivo em cada um dos manejos realizados. Na Figura 62 estão retratadas as lâminas aplicadas diariamente e na Figura 63 está ilustrada a lâmina acumulada.

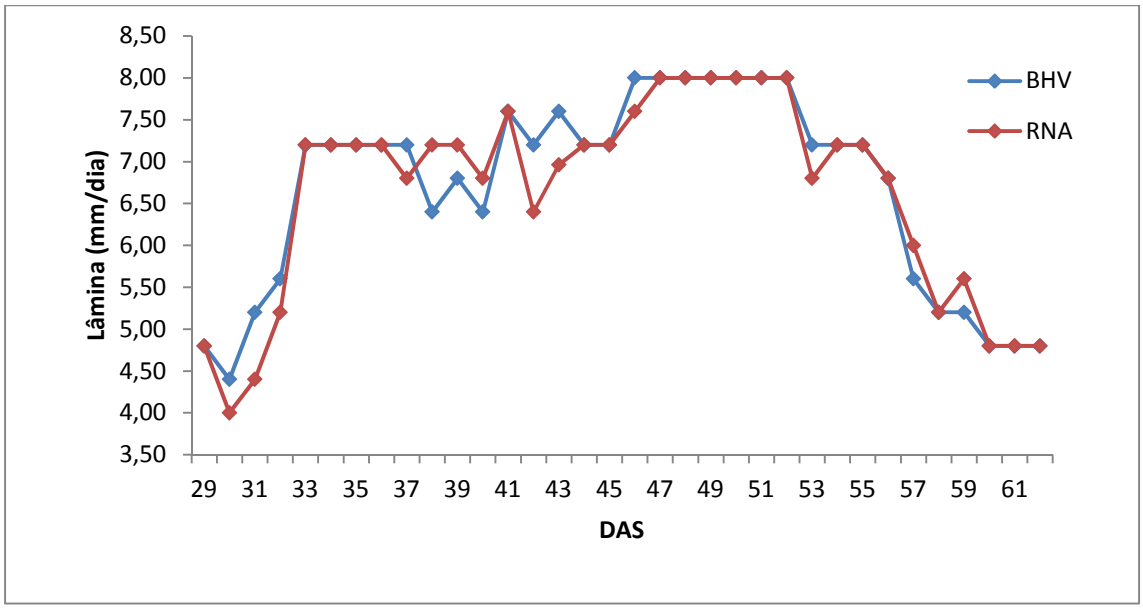

Figura 62. Gráfico comparativo de lâmina de água aplicada (mm/dia) entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico.

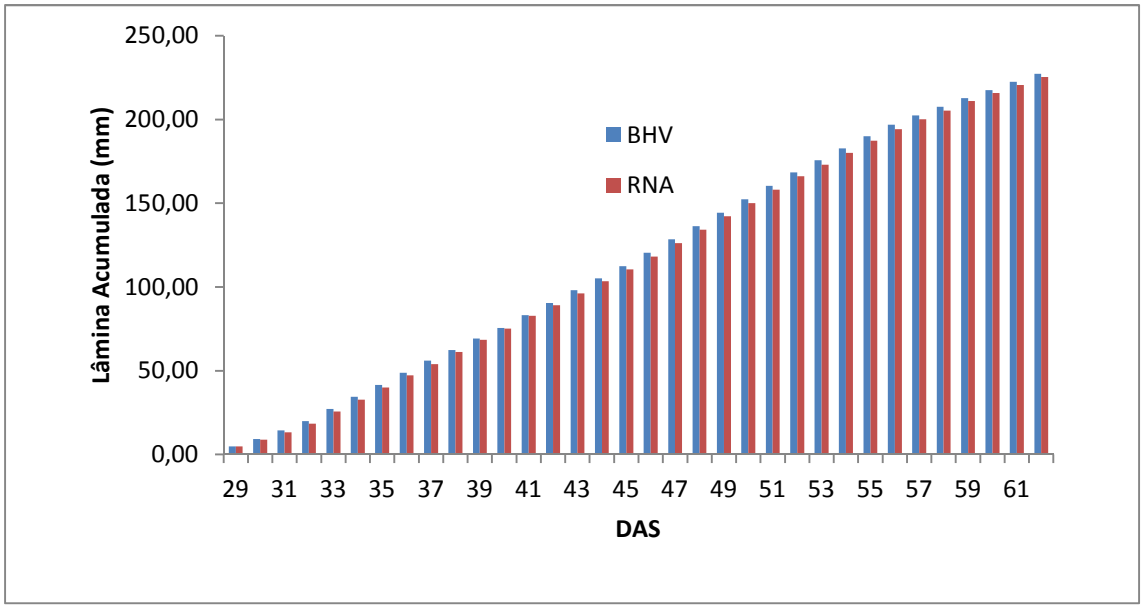

Figura 63. Gráfico comparativo de lâmina de água aplicada acumulado (mm) entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico.

Como se observa nas Figuras 62 e 63, o período mais crítico, aquele que exigiu altas lâminas de aplicação, compreendem entre o 33º e 57º dia após o plantio, do dia 13 de novembro a 07 de dezembro, quando foram registradas aplicações superiores a 7.0 mm dia^{-1}. Este período abrangeu o aumento acelerado do crescimento da cultura, o aparecimento e o enchimento dos frutos. Pode-se observar a cobertura da planta no 46º DAS na Figura 64. É portanto, importante o monitoramento da umidade do solo, especialmente neste período, quando o consumo hídrico se mostra mais intenso e havendo até a necessidade da fragmentação maior da irrigação ao longo do dia para suprir as suas necessidades sem que haja perdas por percolação profunda.

Na Figura 65 observa-se que o manejo utilizando a rede neural artificial obteve valores de lâmina próximos aos do manejo executado pelo balanço volumétrico, com R^2 = 0,9229, tendo variações em alguns dias na sua aplicação tanto para mais quanto para menos. As variações devem-se ao fato de que os valores observados de

umidade foram diferentes daqueles utilizados para o treinamento e validação, tendo verificado valores superiores no experimento. No entanto isso mostra que a rede se comportou bem ao lidar com valores inéditos a esta, conseguindo seguir a tendência sem perda de rendimento, mostrando assim a robustez do algoritmo neural para esta aplicação. Outra característica positiva obtida pelo manejo utilizando a RNA é a praticidade para se obter o tempo de irrigação utilizando a interface do aplicativo neural, Figura 9, comparada com a planilha para calcular o tempo pelo manejo do balanço volumétrico, Figura 12. Esta praticidade se deve a facilidade da inclusão dos dados para obtenção do tempo de irrigação.

Figura 64. Fotografia retirada no dia 26/11/2010 retratando a cobertura da planta sobre a área e o fruto em desenvolvimento.

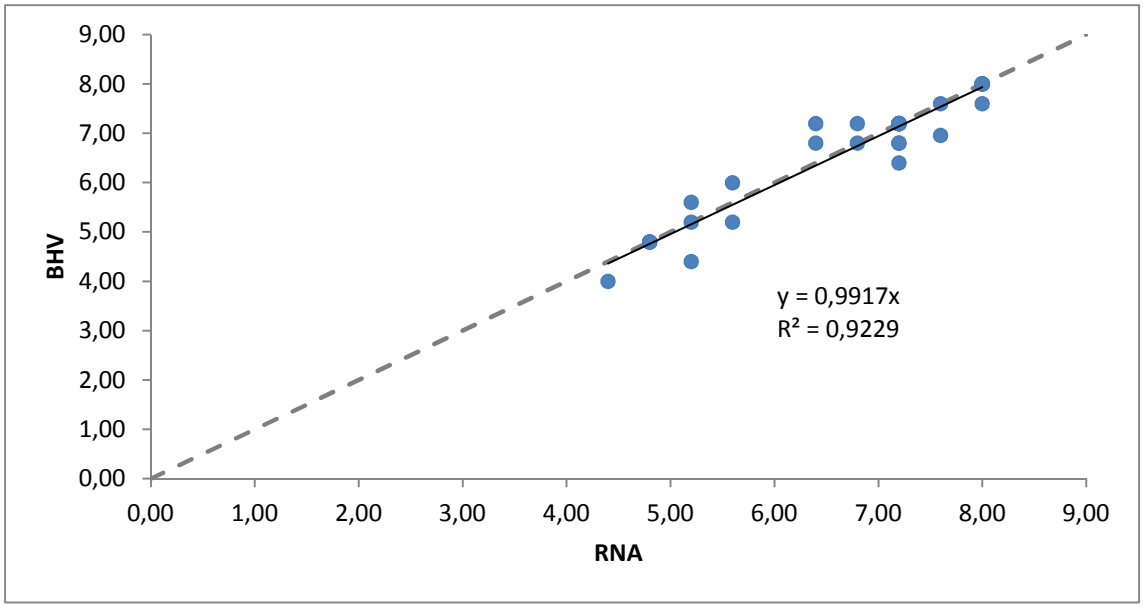

Figura 65. Regressão linear entre o tempo de irrigação obtido pelo método do Balanço Hídrico Volumétrico (BHV) e o estimado pela rede neural artificial (RNA) no campo.

4.3.2. Acompanhamento da umidade do solo antes da irrigação

As Figuras 66 e 67 ilustram o comportamento da umidade do solo ao longo do experimento nas camadas de 0 a 0,20 m e 0,20 a 0,40 m de profundidade, respectivamente, para os dois manejos de irrigação. Os valores foram obtidos antes da irrigação das 7 horas e obtidas pelos sensores capacitivos instalados a 10 e 30 cm de profundidade. Nas duas figuras observam-se as respostas dos sensores capacitivos convertidos em umidade do solo, utilizando as curvas de calibração desenvolvidas por CRUZ (2009), visualizadas nas Figuras 13 e 14.

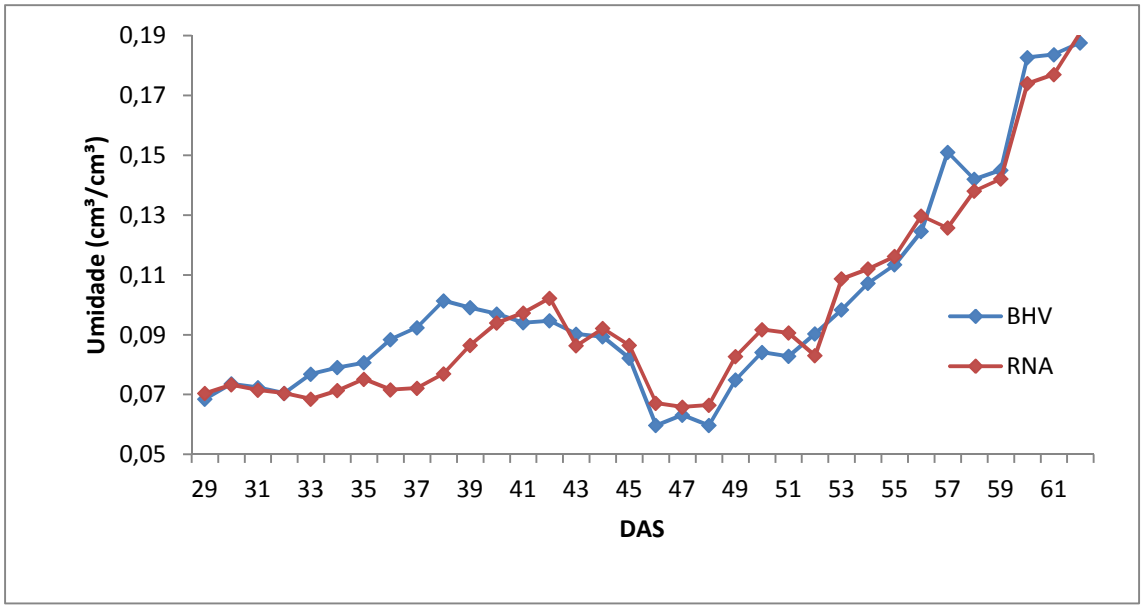

Figura 66. Variação da umidade do solo antes da irrigação na camada de 0-20 cm entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico no horário das 7 horas antes da irrigação.

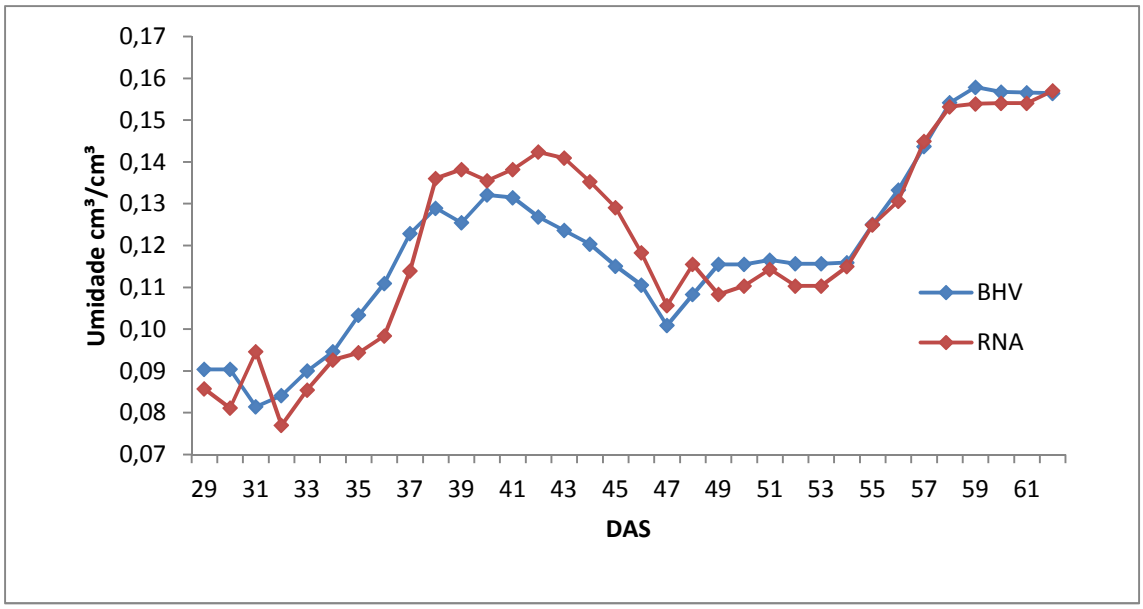

Figura 67. Variação da umidade do solo antes da irrigação na camada de 20-40 cm entre a área manejada utilizando as redes neurais artificiais e utilizando o método do balanço volumétrico no horário das 7 horas antes da irrigação.

Na Figura 66 observa-se que a umidade na camada de 0 a 0,20 m se manteve entre 0,05 e 0,10 cm³ cm^{-3} até o 52º DAS e após este período a umidade se tornou crescente nesta camada, atingindo no 62º DAS 0,19 cm³ cm^{-3}. Isso mostra o

efeito da cobertura da planta, retratada na Figura 68, na conservação da umidade na camada mais superficial. Na Figura 67 observa-se o aumento da umidade do solo entre 0,20 a 0,40 m de profundidade até o 43º DAS, com umidade abaixo de 0,14 cm^3 cm^{-3}. Então se mantendo por volta de 0,11 cm^3 cm^{-3} até o 56º DAS. FERREIRA (2010) encontrou comportamento semelhante em seu experimento onde houve uma menor umidade no solo em torno do 40º e 50º DAS e observou que neste período a evapotranspiração da melancia supera a evapotranspiração de referencia, constatando assim o aumento do consumo hídrico da planta. Esse período coincide com o mesmo período de crescimento mais intensificado dos frutos, determinante do seu tamanho final. Este período é o mais crítico para manter a umidade do solo sempre próxima à capacidade de campo, uma vez que é nesta fase que o fruto utiliza os recursos hídricos do solo para o ganho de peso e a produtividade e a rentabilidade da produção que estão diretamente relacionados ao peso dos frutos comercializados.

Como observado no comportamento da lâmina aplicada, o solo manejado com a rede neural artificial manteve os índices de umidade do solo próximos ao solo manejado utilizando o balanço volumétrico.

Figura 68. Fotografia retirada no 48º DAS retratando a cobertura da planta sobre a área de cultivo.

Nas Figuras 69 e 70 observam-se os comportamentos da umidade do solo e da lâmina aplicada, respectivamente, nos manejos pelo balanço volumétrico e rede neural artificial. Em ambos os casos, nos pontos onde houve aumento da lâmina aplicada, a umidade do solo diminuiu nas duas camadas, entre o 46º DAS e 54º DAS e após este período foi verificado o aumento da umidade do solo e a diminuição da lâmina aplicada, em ambos os tratamentos. Braga *et al.*(2011) observaram um crescimento máximo atingido pelos frutos em torno do 55º DAS. Assim, esse aumento do consumo se deve ao intenso crescimento dos frutos entre o 46º e 54º DAS.

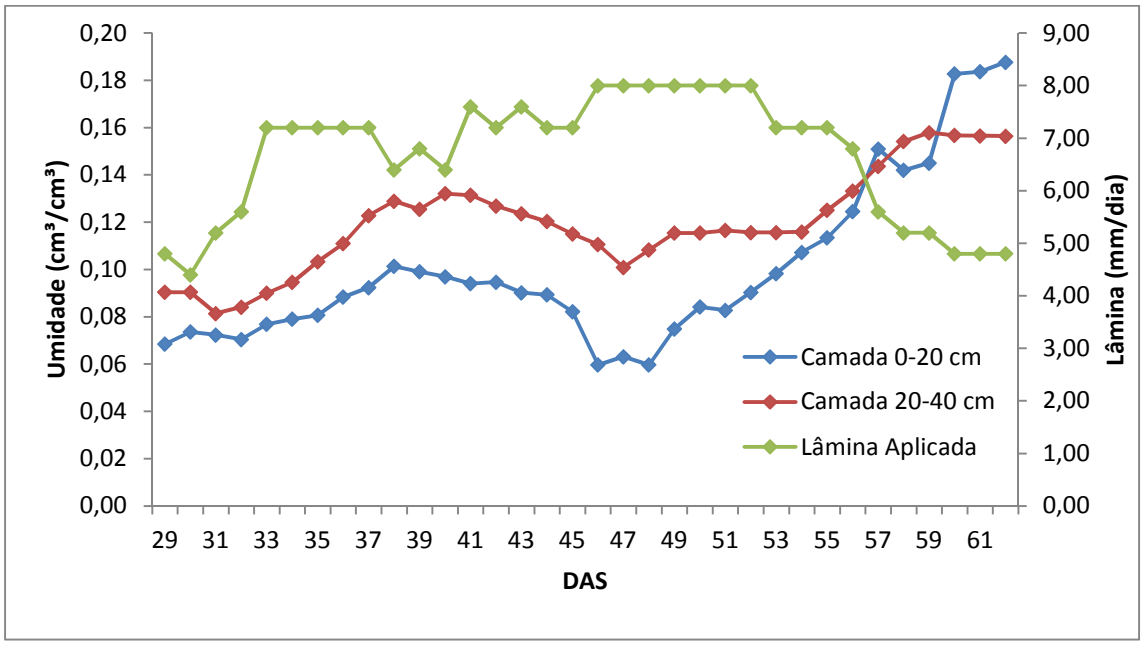

Figura 69. Gráfico de acompanhamento da umidade do solo nas camadas de 0-20 e 20-40 para a área utilizada para o manejo através do Balanço Volumétrico no horário das 7 horas antes da irrigação e a lâmina diária aplicada nesta área.

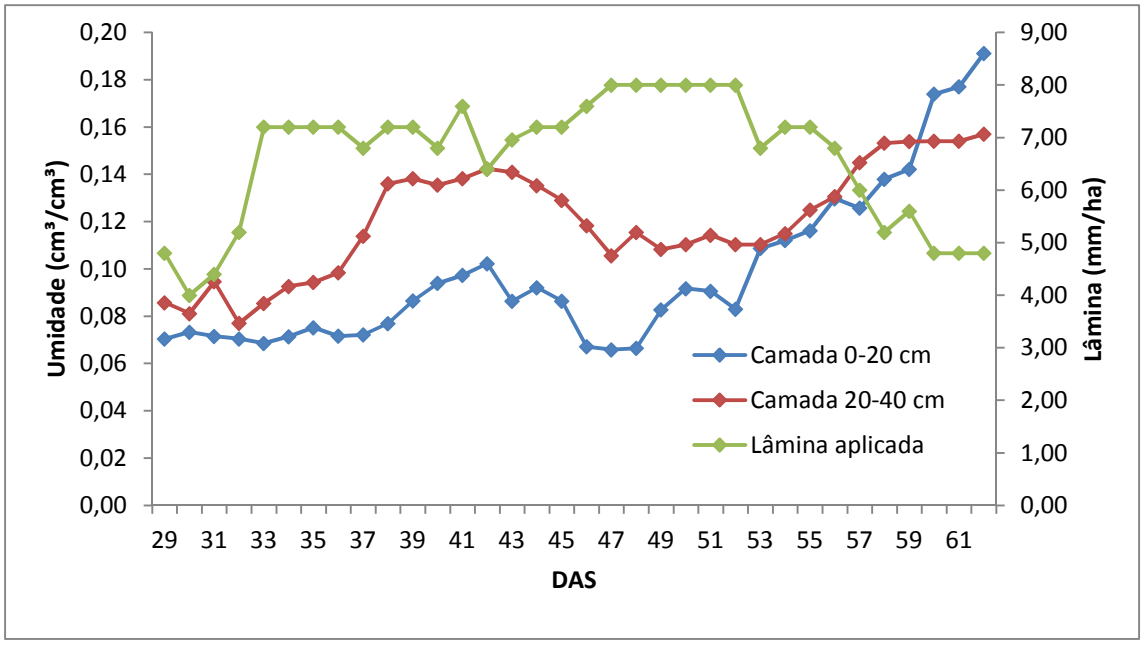

Figura 70. Gráfico de acompanhamento da umidade do solo nas camadas de 0-20 e 20-40 para a área utilizada para o manejo através das Redes Neurais Artificiais no horário das 7 horas.

4.3.3. Taxa de crescimento

Nas Figuras 71, 74, 77 e 80 são reveladas as curvas de crescimento linear médio do ramo principal das plantas avaliadas por cada tratamento no 18º, 25º, 39º e 46º dia após a semeadura, respectivamente, e o consumo hídrico obtido de acordo com a Equação 11, para a camada de 0,00 a 0,40 m, no horário das medições com base nas leituras dos sensores capacitivos convertidos em umidade por meio das curvas de calibração para cada uma das profundidades (Figuras 13 e 14). Nas Figuras 72, 75, 78 e 81 mostram-se estas relações em forma de taxa de crescimento, relação entre o crescimento linear, em cm, e o tempo deste crescimento, em horas. Para comparação com taxa de crescimento, também está disposta em cada figura a taxa de consumo hídrico, obtida pela razão entre o consumo e o período deste. Nas Figuras 73, 76, 79 e

82 são fotografias onde se vê o desenvolvimento da cultura nos dias das medições, mostrando o preenchimento entre duas linhas de cultivo pela planta.

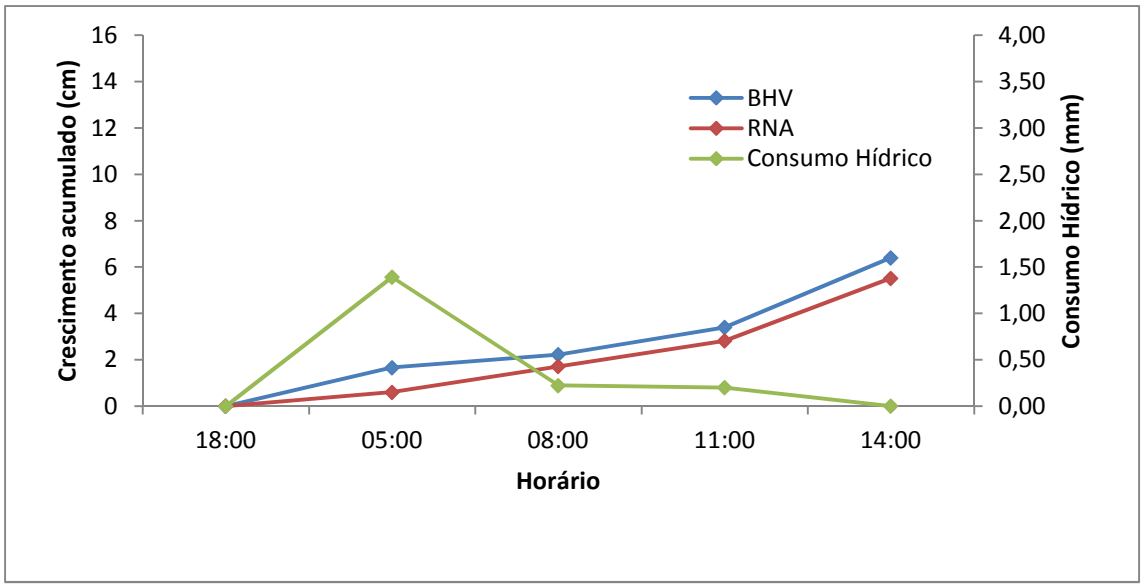

Figura 71. Acompanhamento do crescimento linear do ramo principal ao longo do 18º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura.

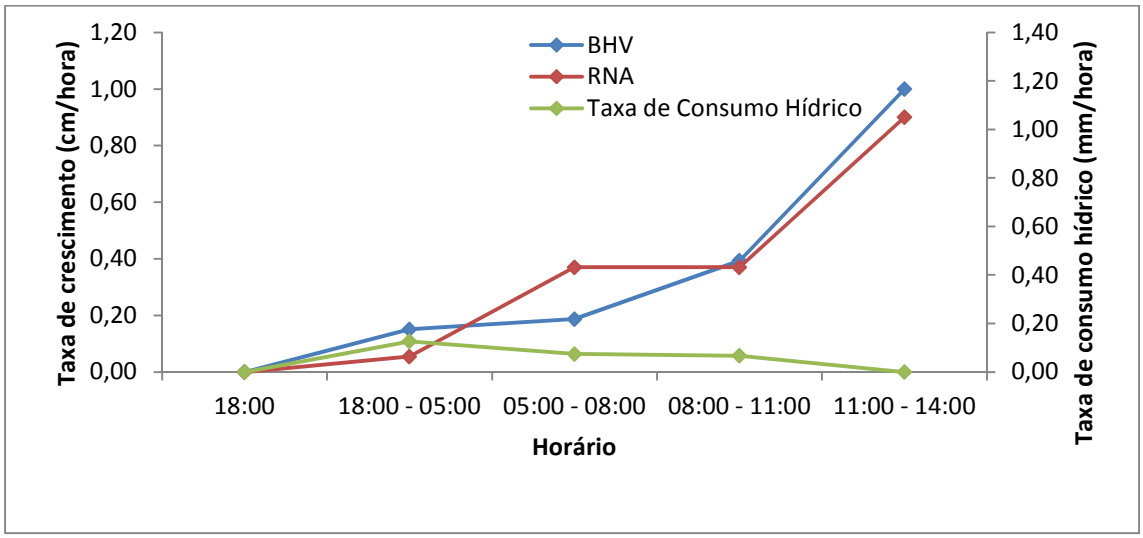

Figura 72. Taxa de crescimento linear do ramo principal no 18º DAS comparado com a taxa de consumo hídrico (mm hora^{-1}).

Figura 73. Fotografia tirada entre duas linhas de cultivo no 18º DAS.

A taxa de crescimento no 18º DAS foi superior a 0,0029 m h^{-1} ao longo do período de avaliação, tendo o período entre 18 e 05 horas apresentando a menor taxa, com 0,001 m h^{-1} e o período compreendendo entre 11 e 14 horas com a maior taxa do dia, em torno de 0.01 m h^{-1}. O consumo hídrico apresentou a maior taxa, representando 69% do consumo observado, no período entre 18 e 05 horas. Já o período entre 11 e 14 horas apresentou em torno de 0.6 % do consumo hídrico do dia avaliado. De acordo com MELO *et al.*(2010), o período do começo da tarde, entre 12 e 14 horas, é evidenciado na cultura da melancia um alto fechamento estomático de modo a evitar severos danos no sistema de condução de água pela planta. A principal componente de retirada da umidade do solo, neste período é a evaporação.

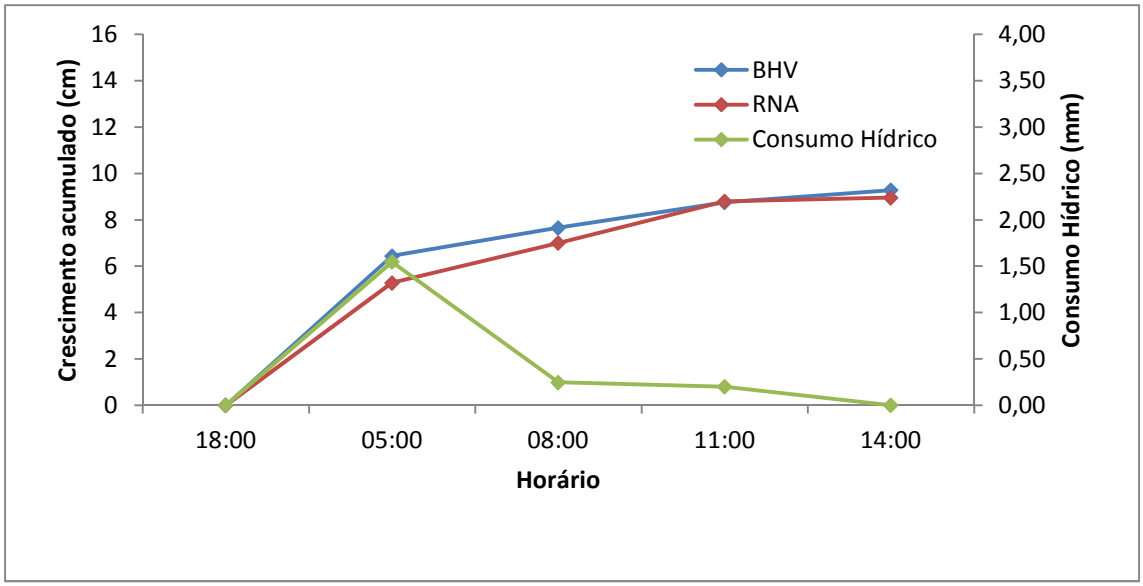

Figura 74. Acompanhamento do crescimento linear do ramo principal ao longo do 25º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura.

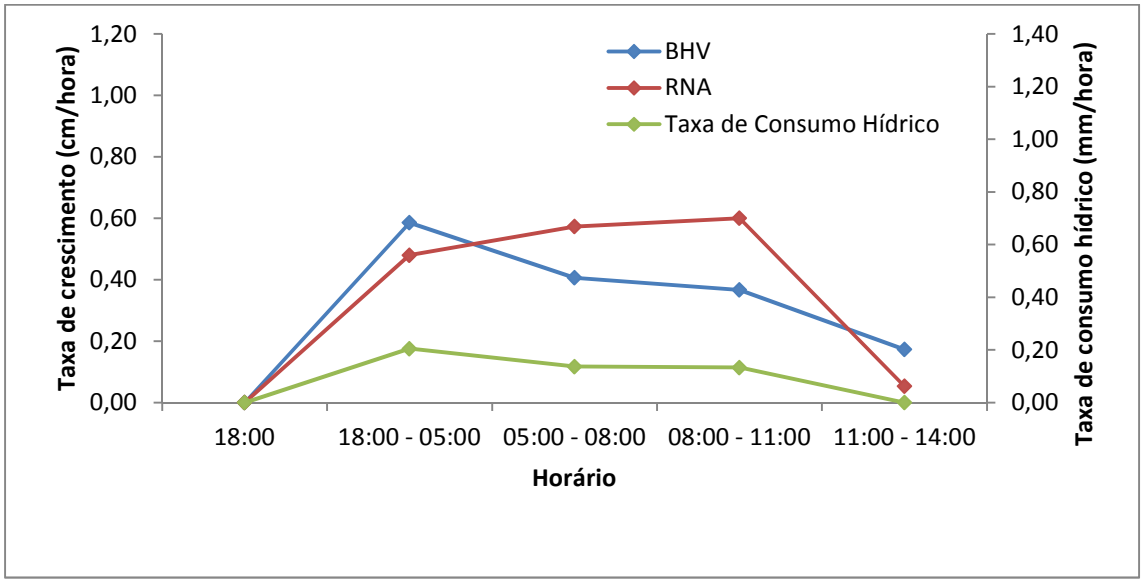

Figura 75. Taxa de crescimento linear do ramo principal no 25º DAS comparado com a taxa de consumo hídrico (mm hora^{-1}).

Figura 76. Fotografia tirada entre duas linhas de cultivo no 25º DAS.

Para o 25º DAS, como observado nas Figuras 74 e 75, o crescimento da planta foi diferenciado em relação ao 18º DAS quanto ao período do dia com maior crescimento. A taxa de crescimento foi superior a 0,0045 m h^{-1} ao longo do período de avaliação, tendo o período entre 18 e 05 horas apresentando a maior taxa, 0,0053 m h^{-1}, representando 71% do crescimento do dia, e o período entre 11 e 14 horas, a menor taxa do dia, em torno de 0.001 m h^{-1}. O consumo hídrico apresentou o mesmo comportamento ao apresentado no 18º DAS, com a maior taxa, representando 67% do consumo observado, no período entre 18 e 05 horas. Já o período entre 11 e 14 horas apresentou menos que 0.5 % do consumo hídrico do dia avaliado. De acordo com BRAGA (2011), o período de floração da melancia se inicia em torno dos 25 DAS e tem neste período até em torno dos 55 DAS um aumento na concentração de matéria seca devido ao período de floração e frutificação.

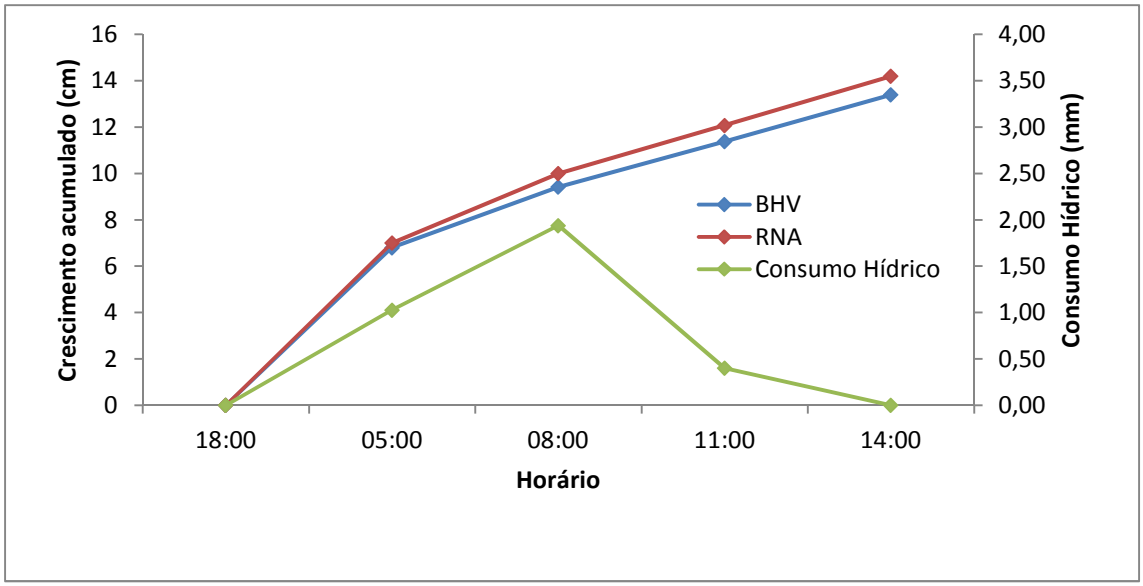

Figura 77. Acompanhamento do crescimento linear do ramo principal ao longo do 39º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura.

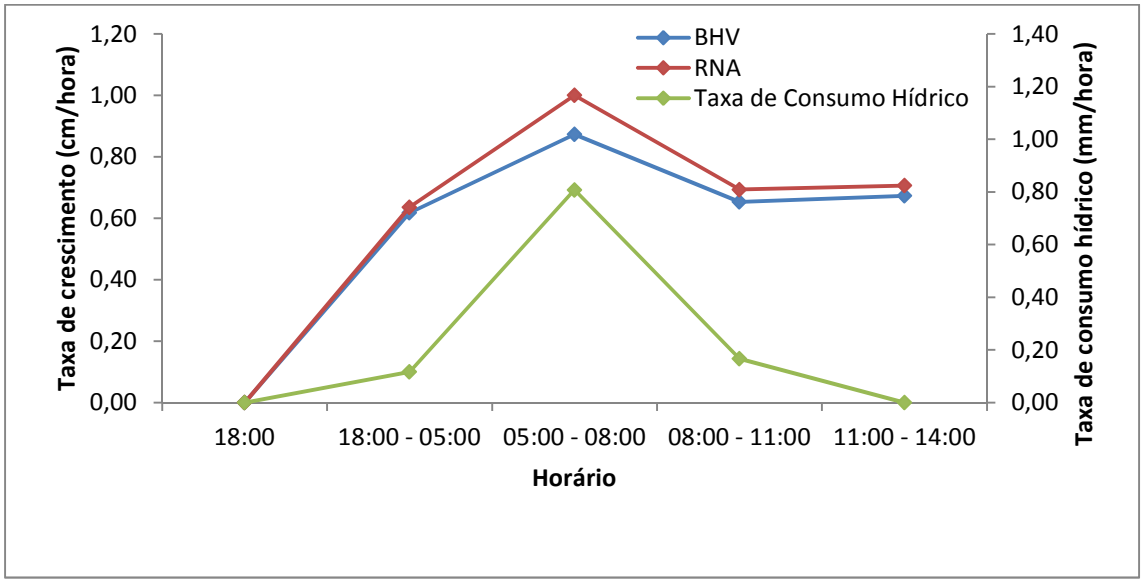

Figura 78. Taxa de crescimento linear do ramo principal no 39º DAP comparado com a taxa de consumo hídrico (mm hora^{-1}).

Figura 79. Fotografia tirada entre duas linhas de cultivo no 39º DAS.

O crescimento encontrado no 39º DAS foi superior aos demais períodos, quando a taxa de crescimento girou em torno de 0,007 m h^{-1} ao longo do período de avaliação, tendo o período entre 18 e 05 horas apresentado a menor taxa, com 0,006 m h^{-1} e o período compreendendo entre 05 e 08 horas com a maior taxa do dia, em torno de 0,01 m h^{-1}. O consumo hídrico, diferentemente do ocorrido nos demais dias de avaliação apresentou a maior taxa, representando 66% do consumo observado, no período entre 05 e 08 horas. Como ocorreu no 18º e no 25º DAS, o consumo ocorrido no período das 11 às 14 horas é mínimo, totalizando 3%, mostrando que, independente da fase da cultura ou de seu metabolismo, no período mais quente do dia praticamente não há consumo pela planta e este consumo, de 3%, provavelmente se refere mais à contribuição da evaporação do solo do que à da transpiração pela planta.

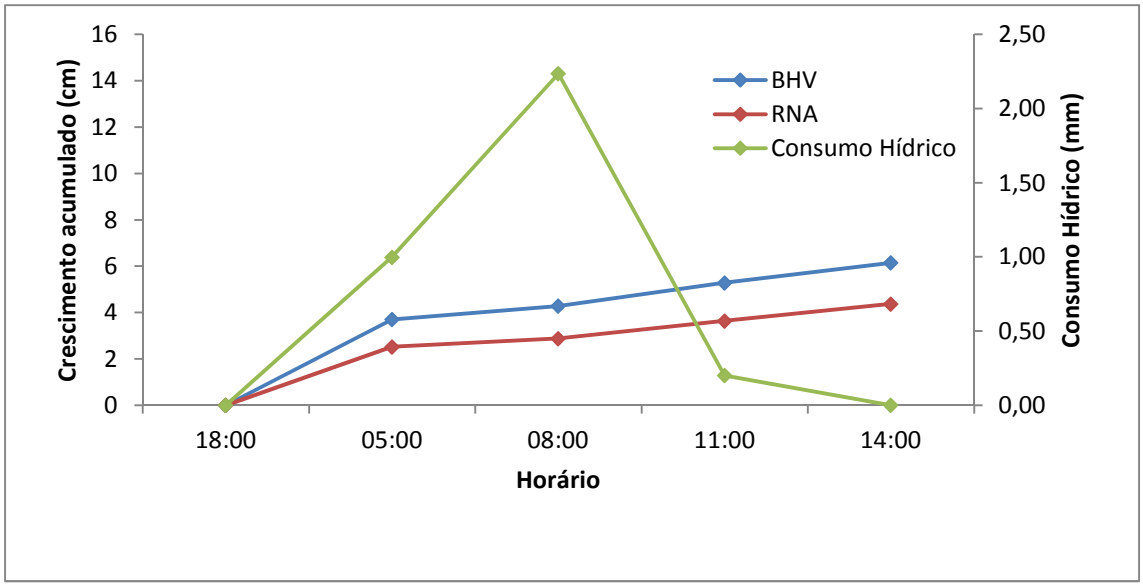

Figura 80. Acompanhamento do crescimento linear do ramo principal ao longo do 46º DAS comparado com o consumo hídrico do solo (mm) no mesmo horário da leitura.

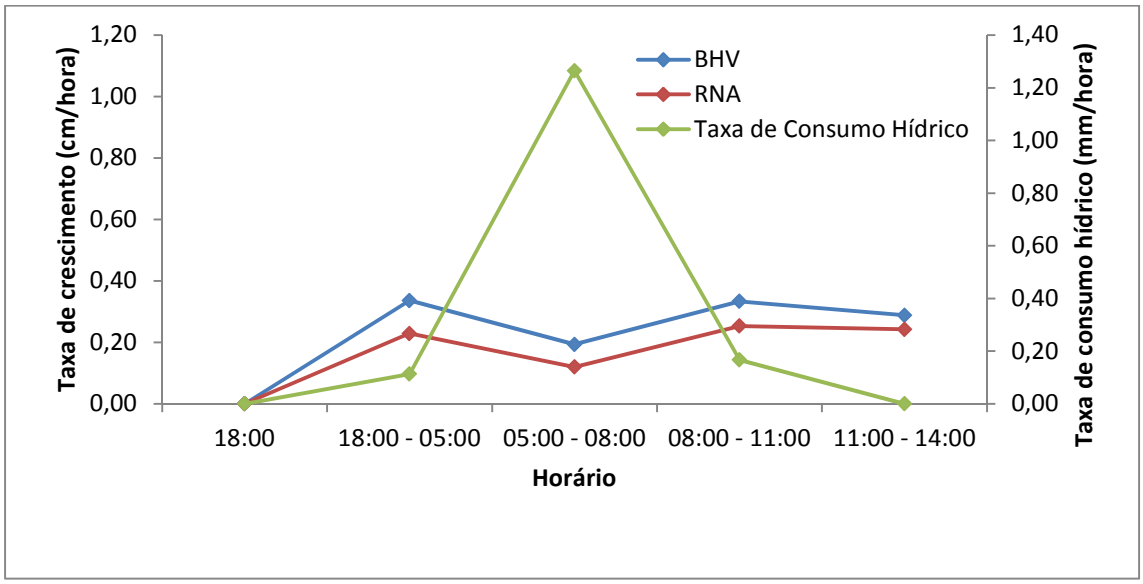

Figura 81. Taxa de crescimento linear do ramo principal no 46º DAS comparado com a taxa de consumo hídrico (mm hora^{-1}).

Figura 82. Fotografia tirada entre duas linhas de cultivo no 46º DAS.

Como pode ser observado pela Figura 82 e pelos resultados dos gráficos mostrados nas Figuras 80 e 81, a planta no 46º DAS, encontra-se na fase de florescimento, havendo uma diminuição drástica no crescimento do ramo principal e um aumento do consumo hídrico da planta, principalmente no horário compreendido entre 05 e 11 horas, com 83% do consumo do dia, sendo o horário de maior intensificação entre 05 e 08 horas, com 70% do consumo total observado. MIRANDA, OLIVEIRA e SOUZA (2004) relatam que o crescimento ocorrido pela fase vegetativa se concentra entre 20º e 40º DAS para a mesma variedade, mas que somente após o 54º DAS a ETc torna a adquirir valores decrescentes mostrando, que o 40º e 54º DAS o consumo hídrico se eleva devido ao crescimento dos frutos. Assim, durante este crescimento dos frutos aumenta a importância de se manter, principalmente neste horário entre 05 e 11 horas, a umidade do solo mais próxima à capacidade de campo. Desta forma, recomenda-se a intensificação das leituras de umidade do solo no referido período.

4.3.4. Produtividade

A produtividade alcançada foi da ordem de 33,4 t ha^{-1}, sendo aplicado, para obter essa produtividade, 657 m³ de água obtendo assim uma produtividade hídrica de 0,051 kg L^{-1}. Rendimento semelhante foi obtido por OLIVEIRA (2008) utilizando melancia de mesma variedade, em localidade próxima ao experimento realizado. Para DOORENBOS e KASSAN (1994), produtividades da ordem de 25 e 30 t ha^{-1}, em região de clima tropical, com alto nível de utilização de insumos agrícolas sob condições de agricultura irrigada, são consideradas boas em nível de comercialização.

Pela Tabela 4 observam-se os resultados obtidos pelo teste de normalidade da amostra de Kolmogorov-Smirnov (KS) a 5% de significância. Na coluna destinada à significância, sendo o valor inferior a 0,05, é rejeitada a hipótese nula e se aceita a hipótese alternativa, de que a amostra não tem distribuição normal. Como visto, o teste mostrou que há normalidade na distribuição da amostra analisada.

Tabela 4. Teste de normalidade de Kolmogorov-Smirnov obtido pelo programa SPSS para os dados de produção (kg/planta) para cada um dos manejos.

TESTE DE NORMALIDADE

	Área da amostra	Kolmogorov-Smirnov		
		Estatística	GL	Sig.
peso em kg/planta	Balanço Volumétrico	0.171223678	5	0.2*
	Rede Neural Artificial	0.199932108	5	0.2*

*Limite inferior da significância verdadeira.

Na Tabela 5 observam-se os resultados obtidos pelo teste de Levene para a normalidade da variância. De maneira análoga ao teste de KS, observam-se as respostas do teste na coluna da significância, e sendo este resultado for superior a 0,05 mostra-se que há normalidade nas variâncias das duas áreas. Se este resultado for inferior a 0,05

mostra que não há normalidade nas variâncias. Com isso, como visto na Tabela 5, há normalidade nas variâncias entre as duas amostras.

Tabela 5. Teste de homogeneidade da variância de Levene obtido pelo programa SPSS para os dados de produção (kg/planta) entre as áreas manejadas.

TESTE DE HOMOGENEIDADE DA VARIÂNCIA

	Base do Teste	Levene	GL1	GL2	Sig.
peso em kg/planta	Baseada na Média	0.398580706	1	8	0.545434914
	Baseada na Mediana	0.246749936	1	8	0.632733738
	Baseada na mediana e ajustada DP	0.246749936	1	7.741404216	0.633169246

Com isso foram atendidos os dois pré-requisitos básicos para a realização do teste de comparação de médias para dados não pareados "t". Os dados obtidos pela aplicação deste teste estão expostos na Tabela 6 e de maneira semelhante aos demais as respostas são observadas na coluna destinada aos valores de significância. Para este teste, se o valor obtido de significância for superior a 0,05, não há diferença entre as duas médias avaliadas, caso contrário é rejeitada a hipótese nula e há diferença entre as médias analisadas. Com os resultados obtidos, vê-se que não há diferença estatística entre as duas médias avaliadas. Concluindo-se então, que o programa neural se portou bem aos testes de campo e pode perfeitamente substituir os manejo adotado pelo balanço hídrico volumétrico.

Tabela 6. Teste t para comparação de médias para dados não pareados obtido pelo programa SPSS para os dados de produção (kg/planta) para cada um dos manejos.

	t- Teste de Comparação de Médias		
	t	GL	Sig.
peso em kg/planta	-0.149864595	8	0.884580856

ZANETTI *et al.* (2008) afirmam que para uma rede neural substituir adequadamente outro método necessita-se de muitos dados a cerca do fenômeno. Isso mostra que a eficiência obtida da RNA do presente trabalho é devido ao número de

dados de treinamento para cada uma das etapas de cultivo, sendo necessário para se obter precisão no treinamento de uma rede neural artificial com uma cultura qualquer, pelo menos outro ciclo utilizando o método do balanço volumétrico.

PEREIRA *et al.* (2004) obtiveram por RNA o tempo de irrigação utilizando dados de temperatura e gerando valores de evapotranspiração de referência e constataram que uma RNA treinada adequadamente é capaz de substituir o método comparado. A validação eficaz traz enumeras vantagens. Entre essas vantagens citam a mensuração precisa do tempo de irrigação em relação a outros métodos convencionais, resultando em maior economia de água, principalmente quando há dificuldade de aplicação de métodos mais trabalhosos que possam dar respostas mais precisas.

5. CONCLUSÕES E RECOMENDAÇÕES

Conclui-se que a aplicação de uma rede neural artificial para o manejo da irrigação se mostra bastante eficiente, podendo substituir o método do balanço volumétrico, trazendo como vantagens a velocidade de resposta e a facilidade de sua implementação na automação.

Há duas topologias ideais, uma para cada uma das fases do ciclo da cultura, para obter tempo de irrigação utilizando sensores capacitivos de umidade do solo como dados de entrada. Para a primeira fase da cultura, 0-30 DAS, a arquitetura de melhor desempenho é a rede MLP 4-5-1, com uma taxa de aprendizagem de 0,9 e 10.000 épocas de treinamento. Para a segunda fase da cultura, 30-60 DAS, a rede que obteve melhor resposta é a MLP 4-5-1, com a taxa de aprendizagem de 0,9 e 5.000 épocas de treinamento.

A cultura da melancia mostrou diferenciação no seu padrão de crescimento e consumo hídrico de acordo com o estádio de crescimento da planta, sendo as fases de floração e crescimento dos frutos mais sensíveis para o processo de produção, exigindo do produtor mais atenção aos níveis hídricos do solo, principalmente no horário compreendido entre as 05 e 08 horas da manhã.

Para a aplicação de redes neurais artificiais ser bem sucedida na determinação do tempo de irrigação, o ideal é utilizar pelo menos dados de um ciclo da cultura para treinar a rede com o método padrão.

Recomenda-se repetir o experimento, utilizando-se as duas RNAs testadas, para outro ciclo da cultura e assim avaliar o poder de generalização da RNA proposta.

REFERÊNCIAS

ADECE, AGÊNCIA DE DESENVOLVIMENTO DO ESTADO DO CEARÁ S.A. **Exportações do Ceará no ano de 2010, com foco no agronegócio**. Fortaleza. 2011

ALMEIDA, D. P. F. **A cultura da melancia**. Porto: Universidade do Porto, 2008. Disponível em: <http://dalmeida.com/hortnet/Melancia.pdf>, Acesso em: 11 fevereiro de 2011.

ASADOLLAHFARDI, G. TAKLIFY, A. GHANBARI, A. Application of artificial neural network to predict TDS in Talkheh Rud river. **Journal of Irrigation and Drainage Engineering**. 2011.

BERNARDO, S. SOARES, A. A. MANTOVANI, E. C**. Manual de irrigação.** 8. ed. Viçosa: Ed. UFV, 2008. 625p.

BRAGA, A. P.; LUDERMIR, T. B.; CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais: Teoria e Aplicações**. LTC – Livros Técnicos e Científicos Editora S.A., 2000.

BRAGA, D. F. NEGREIROS, M. Z. de. LOPES, W. de A. R. TEÓFILO, T. M. da S. FREITAS, F. C. L. de, GRANGEIRO, L. C. ALVES, S. S. V. Crescimento de melancia 'MICKYLEE' cultivada sob fertirrigação. **Horticultura Brasileira.** v. 24. n.3. 2011.

COELHO, S. L. **Desenvolvimento de um tensiômetro eletrônico para monitoramento do potencial de água no solo**. 2003. 106 p. Dissertação (Mestrado em Irrigação e Drenagem). Universidade Federal do Ceará. Fortaleza.

CRUZ, T. M. L. **Estratégia de monitoramento e automação em sistemas de irrigação utilizando dispositivos de comunicação em redes de sensores sem fio**. 2009. p. 84. Dissertação (Mestrado em Engenharia Agrícola). Universidade Federal do Ceará. Fortaleza.

CYBENKO, G. Approximation by Superpositions of a Sigmoid Function. Mathematics of Control, Signals and Systems, 2:303-314, 1989.

DNOCS – Departamento Nacional de Obras Contra as Secas (Fortaleza – CE). **Perímetro Irrigado Baixo Acarau.** Disponível em:

http://www.dnocs.gov.br/~dnocs/doc/canais/perimetros_irrigados/ce/baixo_acarau.html Acesso em: 08 de agosto de 2011.

DETOMINI, E. R. **Técnicas de avaliação de água no solo baseadas no uso de refletômetro no domínio de frequência - FDR**. Piracicaba: 2007. 49p. (Relatório Técnico).

DOOREMBOS, J. KASSAN, A. H. **Efeitos da água do rendimento das culturas.** Estudos FAO- Irrigação e Drenagem. n.33. p. 306. 1994.

FALQUETO, D. **Rede neural artificial para reconhecimento de tabela de horários de arme/desarme no sistema SIGMA**. 2007. p. 54. TCC (graduação em Ciência da Computação). Universidade do Vale do Itajaí. São José.

FIGUEIRÊDO, L. S. **Modelagem e simulação do processo de caustificação**. Curso de Pós-graduação Latu Sensu em Tecnologia de Celulose e Papel (UFV). Belo Oriente, Cenibra, 2006.

FERREIRA, J. O. P. **Evapotranspiração e coeficientes de cultura da melancieira irrigada por gotejamento em alvorada do Gurgueia-PI.** 2010. p.121. Tese (doutorado em Agronomia). Universidade Estadual Paulista "Júlio de Mesquita Filho". Jaboticabal.

GUISELINI, C.; SENTELHAS, P. C.; PANDORFI, H.; RODRIGUES, V. C.; GOMES, R. J. **Uso de redes neurais na predição da evapotranspiração da Gerbera jamesonii cultivada em ambiente protegido**. In: XVI Congresso Brasileiro de Meteorologia, Belém, PA, Setembro, 2010.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. Prentice Hall. 2ª Edição, 1999.

IBGE, INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Culturas Temporárias e Permanentes 2009**. Produção Agrícola Municipal. Rio de Janeiro. V. 36. 93 páginas. 2009.

LAMPARELLI, R. A. C. **Agricultura de precisão.** 2008. Disponível em: http://www.agencia.cnptia.embrapa.br/gestor/cana-de-acucar/arvore/CONTAG01_72_711200516719.html. Acesso em: 12 Set. 2009.

LORENZI, A. SILVA FILHO, L. C. P. PASA, V. F. **Redes neurais para a modelagem de dados de ensaios não destrutivos.** II Seminário de Patologia das Edificações. Porto Alegre. Rio Grande do Sul. 2004.

LYRA, G. B. CECÍLIO, R. A. ZANETTI, S. S. LYRA, G. B. Coeficiente de rugosidade de Manning para o rio Paracatu**. Revista Brasileira de Engenharia Agrícola e Ambiente**. Campina Grande. PB. v.14. n.4. p.343–350. 2010.

MELO, A. S. de. SUASSUNA, J. F. FERNANDES P. D. BRITO, M. E. B. SUASSUNA, A. F. NETTO, A. de O. A. **Crescimento vegetativo, resistência estomática, eficiência fotossintética e rendimento do fruto da melancieira em diferentes níveis de água**. Acta Scientiarum. Agronomy. Maringá. v.32. n.1. p. 73-79. 2010.

MIRANDA, F. R. de. OLIVEIRA, J. J. G. SOUZA, F. de. Evapotranspiração máxima e coeficientes de cultivo para a cultura da melancia irrigada por gotejamento. **Revista Ciência Agronômica.** v. 35. n. 1. p.36-43. 2004.

MOLIN, J. P., **Agricultura de Precisão. Parte I: O que é o Estado da Arte em sensoriamento**. Engenharia Agrícola, Jaboticabal, v.17, n.2, p.97-107, dezembro. 2003.

MORAIS, P. F. T. B. de. **Estudo do uso da informação mútua na seleção de atributos para o treinamento de redes neurais**. 2009. 59 p. Monografia (Graduação em Ciência da Computação). Universidade Federal de Pernambuco. Recife.

MOREIRA, M. C.; CECÍLIO, R. A. Estimativa das temperaturas do ar utilizando redes neurais artificiais, para a região Nordeste do Brasil. **Revista Brasileira de Agrometeorologia**, Viçosa, v.16, n. 2, p.181-188, 2008.

MOREIRA, M. C.; PRUSKI, F. F.; OLIVEIRA, T. E. C. de; PINTO, F. de A. de C.; SILVA, D. D. da. **Redes Neurais Artificiais Para Estimativa Mensal Da Erosividade Da chuva No Estado De Minas Gerais**. Nota Técnica. Engenharia na Agricultura. Viçosa. MG. v. 17. n. 1. p. 75-83. 2009.

MURASE, H. Editorial: Artificial intelligence in agriculture. **Computers and Eletronics in Agriculture**, London, v.29, p.1-2, 2000.

NADLER, A.; LAPID, Y. An improved capacitance sensor for in situ monitoring of soil moisture. **Australian Journal of Soil Research**. Collingwood. v. 34. n. 3. p. 361- 368. 1996.

NETAFIM. **Streamline™**. Disponível em: http://www.netafim.com.br/product/ streamline. Acessos em: 20 de agosto de 2010.

OLIVEIRA, A. D. S. **Avaliação do sensor de umidade TOPDEA no manejo da irrigação.** 2008. 68 p. Dissertação (Mestrado em Irrigação e Drenagem), Universidade Federal do Ceará, Fortaleza.

PEREIRA, D. S.; FILHO, F. J.; PINTO, J. O. P.; SOBRINHO, T. A. **Sistema de irrigação inteligente.** XV Congresso Brasileiro de Automática. Departamento de Engenharia Elétrica. Universidade Federal do Mato Grosso do Sul. Campo Grande. MS. p. 1-6. 2004.

POKRAJAC, D. ; OBRADOVIC, Z. **Neural Network-Based Software for Fertilizer Optimization in Precision Farming.** Center for Information Science and Technology. Temple University. p. 2110-15. 2001.

QUEIRÓZ, M.A. **Influência africana na melancia nordestina**. 2008. Disponível em:<http://www.radiobras.gov.br/abrn/cet/artigos/2001/artigo_160201.htm>. Acesso em: 11 janeiro de 2011.

REBOUÇAS NETO, M. de O. **Rede de sensores sem fio aplicado ao manejo da irrigação com diferentes frequências na cultura da melancia**. 2010. 96 p. Dissertação (Mestrado em Irrigação e Drenagem), Universidade Federal do Ceará, Fortaleza.

REDONDO, D. M.; LÍBERO, V. L. Conceitos Básicos Sobre Capacitores e Indutores. **Revista Brasileira de Ensino de Física**. vol. 18. nº 2. p.137-142. Junho de 1996.

ROSSATO, L. *et al*. Avaliação da Umidade do Solo no Brasil Durante o Episódio El Niño (1982/83). **Rev. Bras. Agrometeorologia**. v. 13. n. 1. p. 143-153. 2005.

RIBEIRO, R. N**. Utilização de redes neurais artificiais e tecnologia FT-NIR para predição do número KAPPA em um processo KRAFT de cozimento de madeira em indústria de celulose.** 2007. p. 143. Dissertação (Mestrado em Engenharia Industrial). Centro Universitário do Leste de Minas Gerais. Coronel Fabriciano.

SANTOS, C. C**. Sistema de sensoriamento remoto de umidade e temperatura do solo para irrigação de precisão.** 2008. p. 130. Dissertação (Mestrado em Engenharia Elétrica). Universidade Federal do Ceará. Fortaleza.

SILVA, R. M. **Redes Neurais Artificiais aplicadas à Detecção de Intrusão em Redes TCP/IP**. 2005. p. 144. Dissertação (Mestrado em Engenharia Elétrica). Pontifícia Universidade Católica do Rio de Janeiro. Rio de Janeiro.

SILVA, S. H. M. G. da; CARVALHO, A. C. P. de L. F. de; ROMERO, R. A. F.; CRUVINEL, P. E.; NATALE, W. Redes Neurais Artificiais E Agricultura De Precisão Para Recomendação De Adubação Da Cultura Da Goiabeira. **Revista brasileira de Agrocomputação.** Ponta Grossa. v.2. n.1. p 37-42. 2004.

SOBRINHO, T. A. RODRIGUES, D. B. B. OLIVEIRA, P. T. S. de. REBUCCI, L. C. S. PERTUSSATI, C. A. Estimativa da evapotranspiração de referência através de redes neurais artificiais. **Revista Brasileira de Meteorologia**. vol.26. n.2. p. 197-203. 2011.

SOUZA, C.F.; MATSURA, E.E. Avaliação de sondas de TDR multi-haste segmentadas para estimativa da umidade do solo. **Revista Brasileira de Engenharia Agrícola e Ambiental**. Campina Grande. v.6. n.1. p.63-68. 2002.

TECHNOLOGIES, L.. **SPSS 13.0 for windows**. Disponível em: http://www.spss.com. Acessos em: 17 de janeiro de 2012.

TERRA, V. S. S.; REISSER JÚNIOR, C.; TIMM, L. C.; CARVALHO, G. C. **Calibração de uma sonda de capacitância em um argissolo vermelho amarelo em pelotas – RS**. In: CONGRESSO DE INICIAÇÃO CIENTÍFICA, 17. 2008.

TRIGO, T. R.; BATISTA JÚNIOR, P. C.; LIMA NETO, F. B. **Redes neurais artificiais em colheita de cana-de-açúcar**. In: V Congresso Brasileiro de Agroinformática, Londrina, PR, Outubro, 2005. Disponível em: http://www.uel.br/projetos/agroinformatica. Acesso em: 04 de maio de 2010.

UMAIR, S. M. USMAN, R. Automation of Irrigation System Using ANN based Controller. **International Journal of Electrical & Computer Sciences**. v. 10. n. 02. p. 45-51. 2010.

VIEIRA, R. C.; ROISENBERG, M. **Redes Neurais Artificiais: Um Breve Tutorial**. UFSC. Florianópolis. 17 p. 2000.

VILLA, W. **Cultura da Melancia**. Campinas: CATI, 2001. 52 p. Boletim Técnico, 243.

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