



UNIVERSIDADE FEDERAL DE MATO GROSSO – UFMT
INSTITUTO DE BIOCÊNCIAS – IB
CURSO DE PÓS-GRADUAÇÃO “Lato Sensu” ESPECIALIZAÇÃO EM GESTÃO E
PERÍCIA AMBIENTAL – Turma IV

RICARDO SILVA DE SOUZA

GERENCIAMENTO DA IRRIGAÇÃO NA CULTURA DA UVA APLICANDO-SE
REDES NEURAS ARTIFICIAIS

CUIABÁ – MT
MARÇO DE 2016

RICARDO SILVA DE SOUZA

**GERENCIAMENTO DA IRRIGAÇÃO NA CULTURA DA UVA APLICANDO-SE
REDES NEURAIAS ARTIFICIAIS**

**Monografia apresentada ao Deptº. de
Botânica e Ecologia do Instituto de
Biociências da Universidade Federal de
Mato Grosso, como requisito final para
obtenção do Grau de Especialista em Gestão
e Perícia Ambiental.**

Orientador: Prof. Dr. Pedro Hurtado de Mendoza Borges

Universidade Federal de Mato Grosso – UFMT

CUIABÁ – MT

MARÇO DE 2016

RICARDO SILVA DE SOUZA

**GERENCIAMENTO DA IRRIGAÇÃO NA CULTURA DA UVA APLICANDO-SE
REDES NEURAIS ARTIFICIAIS**

Monografia apresentada ao Deptº. de Botânica e Ecologia do Instituto de Biociências da Universidade Federal de Mato Grosso, como requisito final para obtenção do Grau de Especialista em Gestão e Perícia Ambiental.

Banca Examinadora:

Profº. Dr. Pedro Hurtado de Mendoza Borges – Orientador

Profª. Dra. Rosina Djunko Miyazaki. – Examinadora

Profª. MSc. Iolanda Antônia da Silva - Examinadora

CUIABÁ - MT
DATA DE APROVAÇÃO: 30 / 03 /2016

Dedico

“A Deus,

por todos ensinamentos que me propôs durante esta nova etapa da minha vida.”

“Aos meus pais,

Romeu Alves de Souza,

Maria dos Santos Silva Souza.”

“A minha irmã,

Ana Paula Silva de Souza.”

“A minha mulher,

Lara Becker.”

“Ao meus Amigos e Familiares

Naiara Camila Ril, Will Kazu, Robson Padilha, Paulo Maciel, Marcelo Arruda, Eduardo Arruda, Virtes Arruda, Anderson Silva, Talita Ferreira, Elizabeth Ferreira, Fernanda Ferreira, Roselea Scheremeta, Paulo Scheremeta e Jéssica Scheremeta que nos momentos mais difíceis que poderia passar eles estiveram do meu lado e não deixaram eu desistir.”

O homem erudito é um descobridor de fatos que já existem - mas o homem sábio é um criador de valores que não existem e que ele faz existir.

Albert Einstein

AGRADECIMENTOS

Em primeiro lugar, agradeço a Deus, pelos ensinamentos e oportunidades proporcionadas ao longo deste meu caminho.

Especialmente em memória da minha mãe, Maria dos Santos Silva Souza, cujo amor nunca falhou. Mesmo não estando entre mais nós, nunca estive fora do alcance do teu amor. Sou grato a ela por tudo, que sempre fora um retrato de mãe trabalhadora e cansada, com a fisionomia grave e meiga, e ao mesmo tempo fora um majestoso anjo com a forma cheia de graça.

Grato ao amor dado por ela antes de nascer, me carregando por longos meses e perto do coração, e ao concluir o tempo, ter atravessado pelo vale das sombras juntamente com Deus para me dar a vida. Ela que cuidou de mim durante os desamparados anos de minha infância e nos poucos menos dependentes anos de meninice. Conforme crescia, ela teve incontáveis atenções, cuidando da minha saúde, me ajudando e me incentivando, e várias outras coisas que, de alguma maneira, somente ela como mãe parece saber fazer.

Agradecer também ao Professor Doutor Pedro Hurtado de Mendoza Borges por ter sido meu orientador, companheiro e amigo nesta fase final de aprendizagem, e pela confiança depositada.

Por fim deixo esta frase como forma de agradecimento a todos que me ajudaram de alguma forma para a conclusão deste trabalho:

“Não existe nenhum homem tão totalmente vil, tão completamente baixo, que não guarde em seu coração um santuário sagrado, reservado à memória do amor de sua mãe.”

SUMÁRIO

DEDICATÓRIA	ii
AGRADECIMENTOS	iii
LISTA DE TABELAS	v
LISTA DE FIGURAS	vi
RESUMO	vii
ABSTRACT	viii
1. INTRODUÇÃO	1
2. MATERIAL E MÉTODOS	4
2.1. MATERIAL	4
2.2. MÉTODOS	4
2.2.1. COLETA DOS DADOS	4
2.2.2. DEFINIÇÃO DAS VARIÁVEIS	4
2.2.3. ARQUITETURA DAS REDES NEURAIIS ARTIFICIAIS	5
2.2.4. VERIFICAÇÃO DAS REDES NEURAIIS ARTIFICIAIS	5
3. RESULTADOS E DISCUSSÃO	8
4. CONCLUSÕES	19
5. REFERÊNCIAS BIBLIOGRÁFICAS	20

LISTA DE TABELAS

Tabela 1. Estatísticas descritivas para as lâminas de irrigação, em função do mês de aplicação..	8
Tabela 2. Estatísticas descritivas para a média mensal de chuvas e a produtividade das uvas.....	9
Tabela 3. Valores dos índices avaliados para cada arquitetura de rede neural artificial.....	10
Tabela 4. Resultados dos testes de normalidade para as redes neuronais artificiais.....	17
Tabela 5. Resultados do teste t-Student para as redes neuronais artificiais.....	17
Tabela 6. Resumo dos critérios estatísticos para avaliar a eficiência das redes neurais.....	18

LISTA DE FIGURAS

Figura 1. Histograma de frequência dos resíduos para a RNA 01.....	11
Figura 2. Histograma de frequência dos resíduos para a RNA 02.....	11
Figura 3. Histograma de frequência dos resíduos para a RNA 05.....	12
Figura 4. Histograma de frequência dos resíduos para a RNA 06.....	12
Figura 5. Histograma de frequência dos resíduos para a RNA 07.....	13
Figura 6. Histograma de frequência dos resíduos para a RNA 11.....	13
Figura 7. Valores dos resíduos, em função da produtividade de uvas para a RNA 01.....	14
Figura 8. Valores dos resíduos, em função da produtividade de uvas para a RNA 02.....	14
Figura 9. Valores dos resíduos, em função da produtividade de uvas para a RNA 05.....	15
Figura 10. Valores dos resíduos, em função da produtividade de uvas para a RNA 06.....	15
Figura 11. Valores dos resíduos, em função da produtividade de uvas para a RNA 07.....	16
Figura 12. Valores dos resíduos, em função da produtividade de uvas para a RNA 11.....	16

RESUMO

O uso correto da água na irrigação é uma importante estratégia para incrementar a produção e produtividade de culturas agrícolas, pois sendo aplicada de forma racional e sustentável pode contribuir significativamente para o aumento da rentabilidade da propriedade e a preservação do meio ambiente. A irrigação correta traz uma maior eficiência no uso da água, da energia e dos insumos, podendo, ainda, reduzir os riscos associados à atividade. Com base nos estudos percebe-se que as redes neurais artificiais constituem uma poderosa e viável ferramenta computacional no processamento de informações e que podem ser muito úteis para determinar as lâminas de água a serem aplicadas em culturas agrícolas a partir de medições da produtividade dos talhões e do volume de precipitação registrado nas instalações meteorológicas da região. Assim, esses modelos devem fornecer subsídios que permitam controlar o sistema de irrigação em termos de economia de água e proteção ao meio ambiente. Com isso o objetivo do trabalho é gerenciar a irrigação na cultura da uva, em função da precipitação mensal aplicando-se redes neurais artificiais. Este estudo foi realizado na Fazenda Melina, localizada no município de Nova Mutum, Mesorregião do Norte Mato-Grossense. Inicialmente, coletaram-se os dados de precipitação média mensal ao longo de quatro anos, bem como as lâminas de irrigação aplicadas aos talhões entre os meses de junho a setembro, e a produção de uvas correspondente. Foi reduzido o número de variáveis de entrada para evitar complexidade na arquitetura das redes e os dados de precipitação mensal foram resumidos num único valor. A variedade foi representada por meio de três variáveis independentes binárias (“dummy”), com valores de 0 ou 1 para os cultivares Isabel, Violeta e Niágara. A utilização das redes neurais artificiais foi com estrutura de múltiplas camadas. A princípio foi realizada uma estatísticas descritivas provenientes de 55 observações. Depois foram definidas e verificadas diferentes arquiteturas de redes neurais contendo até duas camadas intermediárias ou ocultas e cada uma tendo como máximo dezesseis neurônios, totalizando 80 combinações testadas. Entretanto, apenas 12 apresentaram índices satisfatórios, dados pela pequena diferença entre os parâmetros de seleção e teste do programa, o erro médio, o coeficiente de determinação ao quadrado e a raiz do erro quadrático médio. Após, optou-se por verificar analiticamente a normalidade e a eficiência das redes aplicando-se os testes de Kolmogorov-Smirnov, Lilliefors e Shapiro-Wilk, bem como o teste t (Student) entre os valores reais observados de produtividade de uvas e os estimados pelas redes, onde as redes 7 e 11 formadas por duas camadas ocultas manifestaram-se como as mais apropriadas para predizer a produtividade de uva, em função das variáveis que caracterizam a irrigação nos meses mais secos do ano, a precipitação total anual e a variedade. Estas redes foram consideradas as que mais se aproxima do valor real coletado, trazendo confiança para utilização dela em outros anos futuros, ocorrendo assim, a programação do uso racional de água.

Palavras-chaves: água, irrigação, inteligência artificial.

ABSTRACT

The correct use of water in irrigation is an important strategy to increment the production and productivity of agricultural cultures, because by being applied in a continuous and sustainable way, it can contribute significantly for the increase of the property profitability, and the environment preservation. The correct irrigation brings a higher efficiency in water, energy and raw material usage, being even able to reduce the risks linked to the activity. Based on the studies we can notice that the neural artificial nets constitute a powerful and viable computing tool in the process of information, and they can be very useful to determine the water volume to be used in agricultural cultures considering the measurement of the productivity of the plots and of the volume of precipitation registered in the meteorological installations in the area. So, these models must supply subsidies that permit to control the irrigation system in terms of water economy and environment protection. With that, the objective of the work is to manage the irrigation in the grape culture, due to the monthly precipitation, using artificial neural nets. This study was performed in Fazenda Melina (Melina Farm), located in the county of Nova Mutum, at the North of Mato Grosso State. Initially, monthly precipitation data were collected for four years, as well as the irrigation volume applied to the plots between the months of June and September, and the correspondent grape production. It was reduced the number of input variables to avoid complexity in the architecture of the nets and the monthly precipitation data were summed up to one single value. The variety was represented by three binary independent variables (“dummy”), with values of 0 or 1 for the fields of Isabel, Violeta and Niágara. The use of artificial neural nets was with the multiple layers structure. At first, it was made statistics based on 55 observations. After that, different neural net architectures having up to two intermediate or hidden layers and each having at most sixteen neurons were defined and verified, totaling 80 tested combinations. But only 12 presented satisfying numbers, due to the small difference among selection parameters and the test of the program, the average error, the coefficient of determination of the square and the root of the average squared error. Then, it was opted for verifying analytically the normality of the efficiency of the nets applying the tests Kolmogorov-Smirnov, Lilliefors and Shapiro-Wilk, as well as the test t (Student) between the real grape productivity observed values and the estimated by the nets ones, in which the nets 7 and 11 consisting of two hidden layers demonstrated to be as the most appropriated for predicting the grape productivity, due to the variables that characterize the irrigation in the drier months of the year, the total annual precipitation and the variety. Those nets were considered the one which were the closest to the real value collected, bringing trust for their use in future years, making it possible, the programming of rational use of water.

Palavras-chaves: water, irrigation, artificial intelligence.

1. INTRODUÇÃO

A irrigação tem-se tornado uma importante estratégia para incrementar a produção e produtividade de culturas agrícolas, pois se aplicada de forma racional e sustentável pode contribuir significativamente para o aumento da rentabilidade da propriedade e a preservação do meio ambiente. Também, o uso da irrigação visa uma maior eficiência no uso da água, da energia e dos insumos, podendo, ainda, reduzir os riscos associados à atividade. Por essa razão, o conhecimento das necessidades hídricas e nutricionais de máxima eficiência econômica para as culturas constitui o ponto de partida para a obtenção de sucesso no empreendimento frutícola, pois a água e os nutrientes são os fatores que mais limitam o rendimento da planta (Ruggiero et al., 1996). Deve-se ressaltar que o excesso ou a falta de água, antes ou depois do momento adequado em cada fase da cultura pode gerar prejuízos econômicos relevantes (SANTINATO et al, 1996).

De acordo com Mello (2008), o custo de produção de uvas depende de diversos fatores, tais como: a região, a cultivar escolhida, o sistema de condução, a finalidade da produção e o uso de irrigação, dentre outros. O custo de implantação de um hectare de videiras varia de 20 mil a 60 mil reais. Assim, tomando como referência o cultivo de uva de mesa, com uso de sombrite e sistema de irrigação, o custo de implantação pode ser de aproximadamente 60 mil reais e o custo de manutenção pode ultrapassar 20 mil reais por safra. Nesse sentido, os custos com equipamentos de irrigação elevam consideravelmente o investimento inicial da cultura, embora esta atividade apresenta-se como uma alternativa rentável para o produtor (LOPES et al, 2010).

Segundo Correia e Silva (2001), a irrigação, juntamente com o binômio clima-solo tem favorecido a produção de uvas na Região do Semiárido nordestino, nos estados de Pernambuco e Bahia. Essas condições diferenciadas possibilitam o crescimento da área destinada à referida cultura, devido a adaptação e o desempenho das plantas (Correia & Silva, 2001). Esses autores afirmam que o processo fisiológico acelerado, a propagação e o crescimento inicial das plantas são rápidos, o que possibilita realizar a primeira safra um ano e meio após o plantio. Para Leão & Possídio (2001), o manejo da água de irrigação e a poda são fatores determinantes na regulação do ciclo produtivo da videira. O novo ciclo inicia-se com a realização da poda, sendo que a partir desse momento pode-se estimar o período de duração de cada fase fenológica, levando em consideração que podem sofrer variações ao longo do ano, em função das condições climáticas (Leão & Possídio, 2001).

A videira se adapta a vários tipos de solos, desde que não permanecem por longos períodos sob condição de encharcamento (MELLO, 2008). Para Conceição & Mandelli (2008), na cultura da uva de mesa deve-se evitar a ocorrência de deficiência hídrica nas plantas. Contudo, deve-se salientar que tanto o excesso como a falta de água afetam de maneira marcante o desempenho dos estádios fenológicos da cultura comprometendo a produtividade e a qualidade dos frutos (PEDRO JÚNIOR et al, 1993; TEIXEIRA; ANJOS, 2001). Assim, a irrigação é essencial para elevada produção e lucratividade do vinhedo devido à influência de fatores como período de chuvas concentrado apenas em parte do ciclo, a ocorrência de veranicos e da estação seca, em fases importantes do crescimento (Terra et al, 1998).

O período crítico ao déficit hídrico nas videiras ocorre na fase de desenvolvimento vegetativo e floração, seguido da fase de enchimento das bagas. Se ocorrer estresse hídrico abrupto, o crescimento diminui e ocorre murchamento das folhas e necrose das bagas. Por outro lado, se o estresse for gradativo, a planta se ajusta por meio da diminuição do crescimento da parte aérea, o que pode acarretar menores produções e maturação precoce dos frutos. Da formação à maturação fisiológica, o déficit hídrico severo provoca murchamento dos frutos (PIRES et al., 2001). Logo, a irrigação exerce grande influência no sucesso da produtividade da uva, porém está estreitamente associada a variáveis meteorológicas, em especial à precipitação.

Os modelos empíricos para previsão de variáveis meteorológicas podem ser ajustados aos dados por meio de distribuições probabilísticas. Entretanto, um dos maiores inconvenientes nos modelos de simulação que envolve esse tipo de variável é a incapacidade de reconhecer a sua forma real, isto é, ignorar ou não distinguir a variabilidade do tempo de duração de uma determinada condição. Na tentativa de superar essas deficiências dos modelos matemáticos e estatísticos tradicionais, Bilgili & Sahin (2010); Wu et al (2010); Wu & Chau (2013), utilizaram redes neurais artificiais. Esses autores salientam, ainda, que os modelos de simulação com variáveis climáticas devem possuir uma grande variedade de dados observados para serem confiáveis.

A utilização de redes neurais artificiais (RNAs) vem sendo proposta por vários autores para a modelagem da precipitação (BILGILI & SAHIN, 2010; YASAR et al, 2012; DORNELES et al 2013; GHORBANI et al, 2013; OLIVEIRA et al 2013). Estes estudos mostram a viabilidade do uso destes modelos e a sua capacidade de previsão de dados com base em informações anteriores. Conforme Braga et al (1998, 2007), as Redes Neurais Artificiais são modelos matemáticos que se assemelham às estruturas neurais biológicas e que tem capacidade computacional adquirida por meio de aprendizado e generalização. O aprendizado

em RNA consiste na fase onde a rede neural absorve dados para modificar seus parâmetros de entrada. A generalização de uma RNA está associada à sua capacidade de dar respostas coerentes aos dados não apresentados durante o treinamento.

Com base nos estudos consultados infere-se que as redes neurais artificiais constituem uma poderosa e viável ferramenta computacional no processamento de informações e que podem ser muito úteis para determinar as lâminas de água a serem aplicadas na cultura da uva a partir de medições da produtividade dos talhões e do volume de precipitação registrado nas instalações meteorológicas da região. Deduz-se, ainda, que existe a possibilidade de extrair dependências implícitas entre esses dados e o desempenho produtivo das videiras. Assim, esses modelos devem fornecer subsídios que permitam controlar o sistema de irrigação em termos de economia de água e proteção ao meio ambiente. Esta problemática motivou a elaboração do presente trabalho, que tem como objetivo gerenciar a irrigação na cultura da uva, em função da precipitação mensal aplicando-se redes neurais artificiais.

2. MATERIAL E MÉTODOS

2.1. MATERIAL

Este estudo foi realizado na Fazenda Melina, localizada no município de Nova Mutum, Mesorregião do Norte Mato-Grossense, coordenadas geográficas 13^o 40' 14'' de Latitude Sul e 56^o 2' 30'' de Longitude Oeste e altitude média de aproximadamente 490 m. A região caracteriza-se pelo relevo plano com declividade inferior a 3%, predominando o clima tropical quente e semiúmido com duas estações: Seca (maio até setembro) e chuvas (outubro até abril estação seca de inverno, classificado como Aw (KÖPPEN & GEIGER, 1928). A temperatura média anual varia em torno de 24 °C com precipitação anual média de 2200 mm e umidade relativa média de 80% no período chuvoso e 35% durante a estiagem, determinado com base nos dados do Instituto Nacional de Meteorologia (INMET, 2016). Nesta Fazenda cultivam-se as variedades de uva Isabel, Violeta e Niágara.

2.2. MÉTODOS

2.2.1. COLETA DOS DADOS

Inicialmente, coletaram-se os dados de precipitação média mensal ao longo de quatro anos, bem como as lâminas de irrigação aplicadas aos talhões entre os meses de junho a setembro durante esse período e a produção de uvas correspondente. Esses dados corresponderam às safras de 2012, 2013, 2014 e 2015 e foram armazenados em planilhas eletrônicas do programa EXCEL para serem utilizados posteriormente na elaboração das redes neurais artificiais.

2.2.2. DEFINIÇÃO DAS VARIÁVEIS

Para reduzir o número de variáveis de entrada e evitar complexidade na arquitetura das redes, os dados de precipitação mensal foram resumidos num único valor, a saber o volume de chuva total anual. Assim, a precipitação total anual, as lâminas de irrigação aplicadas nos meses de junho, julho, agosto e setembro foram consideradas como variáveis de entrada, entretanto a produção de uva por talhão definiu-se como a variável principal de saída. Também, para reduzir o efeito da escala de valores, as referidas variáveis foram normalizadas. A variedade foi representada por meio de três variáveis independentes binárias (“dummy”), com valores de 0 ou 1 para os cultivares Isabel, Violeta e Niágara.

2.2.3. ARQUITETURA DAS REDES NEURAIS ARTIFICIAIS

Com base nos trabalhos de TERRA & PASSADOR (2012), VENTURA et al. (2012), BINOTI et al. (2013, 2014 a, b) e VALENTE et al. (2014), utilizaram-se as redes neurais artificiais com estrutura de múltiplas camadas (MPL). Para definir a arquitetura foi variado o número de camadas intermediárias e o número de neurônios nas camadas, tomando como referência os critérios de TERRA & PASSADOR (2012) e VENTURA et al. (2012). Nesses procedimentos adotou-se o programa STATISTICA, versão 7.0.

2.2.4. VERIFICAÇÃO DAS REDES NEURAIS ARTIFICIAIS

Conforme as sugestões de CARVALHO et al. (2012), BINOTI et al. (2013, 2014 a, b), CANSIAN et al. (2014), GEORGENS et al. (2014), VALENTE et al. (2014), SUSDHA et al. (2016), para o treinamento e validação, os dados foram separados de forma aleatória em dois conjuntos, na proporção de 75% e 25%, respectivamente. Para todas as arquiteturas foi utilizada a função logística na ativação das redes, sendo os pesos iniciais gerados de forma aleatória entre -0,5 y 0,5. As camadas foram conectadas por sinapses completas, ou seja, cada neurônio da camada i foi conectado a todos os neurônios da camada seguinte ($i+1$), sendo as sinapses orientadas somente adiante (“*feed forward*”). Também, selecionou-se a retro propagação do erro como algoritmo de aprendizagem (“*back propagation*”).

De acordo com os critérios de SOUSA & MENEZES (2013), BINOTI et al. (2014 a, b), GEORGENS et al. (2014), para reduzir o número de redes obtidas e selecionar as mais adequadas, foram utilizados os próprios coeficientes e índices do programa “STATISTICA”, correspondentes ao treinamento e validação, assim como determinou-se o erro médio e a raiz do erro quadrático médio, dados por:

$$ME = \frac{\sum_{i=1}^N (Pest_i - Pobs_i)}{N} \quad (1)$$

em que,

ME – Erro médio (-);

N – Número total de observações (-);

Pobs_{*i*} – Produção de uva real medida na observação *i* (kg m⁻²);

Pest_{*i*} – Produção de uva estimada correspondente à observação *i* (kg m⁻²).

$$RMSE = 100 \cdot \sqrt{\frac{1}{N} \sum_{i=1}^N (Pobs_i - Pest_i)^2} \quad (2)$$

em que,

RMSE – Raiz do erro quadrático médio (%);

N – Número total de observações (-);

Pobs_i – Produção de uva real medida na observação i (kg m⁻²);

Pest_i – Produção de uva estimada correspondente à observação i (kg m⁻²).

As redes neurais classificadas como satisfatórias serão analisadas de forma mais rigorosa, aplicando-se o teste t (“*Student*”) e elaborando-se os diagramas de dispersão dos resíduos e o histograma correspondente, conforme sugerido por BORGES et al. (2013, 2014). Também, tomando como referência os trabalhos de BINOTI et al. (2014 a, b), GEORGENS et al. (2014) e LIMA et al. (2014) serão calculados os coeficientes de correlação e concordância de Willmott, bem como o índice de desempenho, que mede a proximidade entre os valores estimados pelas redes e os observados. Esses critérios expressam-se matematicamente por:

$$r = \frac{\sum_{i=1}^N (Pobs_i - PMobs) \cdot (Pest_i - PMest)}{\sqrt{\sum_{i=1}^N (Pobs_i - PMobs)^2 \cdot \sum_{i=1}^N (Pest_i - PMest)^2}} \quad (3)$$

em que,

r – Coeficiente de correlação (-);

N – Número total de observações (-);

Pobs_i – Produção de uva real medida na observação i (kg m⁻²);

Pest_i – Produção de uva estimada correspondente à observação i (kg m⁻²);

PMobs_i – Produção de uva real média (kg m⁻²);

PMest_i – Produção de uva estimada média (kg m⁻²).

$$Iw = 1 - \frac{\sum_{i=1}^N (Pobs_i - Pest_i)^2}{\sum_{i=1}^N (|Pobs_i - PMobs| + |Pest_i - PMest|)^2} \quad (4)$$

em que,

Iw – Coeficiente de concordância de Willmott (-);

N – Número total de observações (-);

Pobs_i – Produção de uva real medida na observação i (kg m⁻²);

Pest_i – Produção de uva estimada correspondente à observação i (kg m⁻²);

PMobs_i – Produção de uva real média (kg m⁻²);

PMest_i – Produção de uva estimada média (kg m⁻²).

$$Id = r \cdot Iw \quad (5)$$

em que,

Id – Índice de desempenho (-);

r – Coeficiente de correlação (-);

Iw – Coeficiente de concordância de Willmott (-).

3. RESULTADOS E DISCUSSÃO

Na Tabela 1 apresentam-se as estatísticas descritivas das lâminas de irrigação aplicadas durante os meses mais secos, provenientes de 55 observações. A pequena diferença entre a média e a mediana para o mês de julho indica, assim como o baixo coeficiente de assimetria indicam uma distribuição dos dados próxima da normal, entretanto muito achatada devido ao valor do coeficiente de curtose ser superior a 0,263. Também, obteve-se um coeficiente de variação satisfatório, pois a lâmina de irrigação é calculada considerando-se o volume de chuva e a necessidade hídrica das plantas, as quais apresentam grandes oscilações durante esse período. Já, o mês de setembro indicou a maior variabilidade nos valores das lâminas de irrigação aplicadas, dado principalmente pelos elevados valores de variância, coeficiente de variação e diferença entre a média e a mediana (Tabela 1).

Tabela 1. Estatísticas descritivas para as lâminas de irrigação, em função do mês de aplicação.

Estatística	Lâmina de irrigação aplicada no mês (mm)			
	Junho	Julho	Agosto	Setembro
Número de observações	55	55	55	55
Média	114,53	128,75	155,80	153,34
Mediana	120,40	129,50	148,75	140,00
Mínimo	0,00	41,30	61,25	0,00
Máximo	161,00	195,30	220,00	336,36
Intervalo	161,00	154,00	158,75	336,36
Desvio Padrão	28,73	22,17	27,40	97,58
Variância	825,70	491,34	750,90	9521,31
Curtose (adimensional)	3,78	4,40	2,06	-0,91
Assimetria (adimensional)	-1,58	-0,76	-0,13	0,44
Coeficiente de variação (%)	25,09	17,21	17,59	63,63

A Tabela 2 contém as estatísticas descritivas para a média mensal de precipitação e a produtividade das uvas, correspondentes a 55 observações. Pela própria Tabela deduz-se que os valores de precipitação apresentaram pouca variabilidade, indicado pela pequena diferença entre a média e a mediana, bem como pelo adequado coeficiente de variação. A pouca diferença entre a média e a mediana para a referida variável climatológica, assim como o baixo coeficiente de assimetria indicam uma distribuição dos dados próxima da normal, porém muito alargada devido ao valor do coeficiente de curtose ser inferior a 0,263. Também, a produtividade de uvas evidenciou pouca diferença entre a média e a mediana, entretanto houve uma elevada dispersão dos dados, caracterizada pelo amplo intervalo entre os valores extremos e pelo alto coeficiente de variação (Tabela 2).

Tabela 2. Estatísticas descritivas para a média mensal de chuvas e a produtividade das uvas.

Estatística	Média mensal de chuvas (mm)	Produtividade (Kg m ²)
Número de observações	55	55
Média	17,15	1,81
Mediana	18,10	1,84
Mínimo	14,10	0,01
Máximo	19,02	3,79
Intervalo	4,92	3,78
Desvio Padrão	1,93	1,06
Variância	3,74	1,12
Curtose (adimensional)	-1,06	-1,14
Assimetria (adimensional)	-0,71	0,03
Coefficiente de variação (%)	11,28	58,44

O coeficiente de variação para a média mensal de precipitação obtido nesta pesquisa foi inferior aos estimados por MORAES et al (2005) entre 15 e 30% no Pará, por VIEIRA et al (2009) de 22,43% para o Estado de São Paulo e por DINIZ (2015) de 12,6 a 58,80% para as cidades de Campina Grande e João Pessoa. Estas discrepâncias devem-se principalmente às características climáticas da região. Com base nesses resultados pode afirmar a referida variável teve um comportamento pouco oscilatório durante o período de coleta. Já, a produtividade média das uvas deste trabalho foi superior à estimada por LEÃO et al (2011) que variou entre 0,7 e 1,2 Kg m⁻², entretanto o coeficiente de variação do presente estudo foi superior a reportado por esses autores de 43,45 %. Como causas principais para essas diferenças podemos citar o número de variedades utilizadas, os tratos culturais, manejo da irrigação e condições climáticas.

De acordo com os critérios da bibliografia consultada, foram definidas e verificadas diferentes arquiteturas de redes neurais contendo até duas camadas intermediárias ou ocultas e cada uma tendo como máximo dezesseis neurônios, totalizando 80 combinações testadas. Entretanto, apenas doze apresentaram índices satisfatórios, dados pela pequena diferença entre os parâmetros de seleção e teste do programa, o erro médio, o coeficiente de determinação ao quadrado (R²) e a raiz do erro quadrático médio (Tabela 3). Nessa Tabela observa-se que os melhores resultados corresponderam às redes neurais artificiais 1, 2, 5, 6, 7 e 11. As redes 3, 4, 8, 9, 10 e 12 evidenciaram maior diferença entre os parâmetros do programa e elevado valor da raiz do erro quadrático médio (RMSE) e também, para as redes 9 e 12 obtiveram-se os menores valores do coeficiente de determinação (Tabela 3).

Tabela 3. Valores dos índices avaliados para cada arquitetura de rede neural artificial.

RNA	Arquitetura	Parâmetros do programa		Erro médio	R ²	RMSE
		Seleção	Teste			
1	MLP 8:8-8-1:1	0,5480	0,5341	-0,0519	0,8323	3,9478
2	MLP 8:8-6-1:1	0,7138	0,7828	0,0722	0,8497	3,9884
3	MLP 8:8-4-1:1	0,5446	0,4232	-0,0367	0,8104	4,3395
4	MLP 8:8-2-1:1	0,4177	0,7219	0,0005	0,8246	4,1306
5	MLP 8:8-8-2-1:1	0,8640	0,8495	-0,0080	0,8675	3,8939
6	MLP 8:8-6-2-1:1	0,6732	0,6301	0,1257	0,8348	3,8841
7	MLP 8:8-4-2-1:1	0,5638	0,5229	0,1272	0,8573	3,7797
8	MLP 8:8-2-2-1:1	0,4502	0,6963	0,0141	0,8151	4,3559
9	MLP 8:8-8-4-1:1	0,8234	0,9652	-0,0787	0,5426	6,5677
10	MLP 8:8-6-4-1:1	0,5779	0,7615	0,0282	0,8095	4,5960
11	MLP 8:8-4-4-1:1	0,4924	0,5275	0,0357	0,8697	3,9838
12	MLP 8:8-2-4-1:1	0,5777	0,7353	-0,0075	0,5996	4,6923

Com base na Tabela 3 deduz-se que o aumento do número de camadas ocultas e neurônios não interferiu na precisão, pois os melhores índices foram obtidos com as redes 1, 2, 5, 6, 7 e 11, cujas arquiteturas possuem uma ou duas camadas com número de neurônios variando de 4 a 8 e de 2 a 4, respectivamente, para a primeira e segunda camada. Estes resultados não concordam com as sugestões de TERRA & PASSADOR (2012), respeito ao número de neurônios nas camadas, uma vez que nenhum dos critérios propostos por esses autores foram adequados aos dados do presente estudo. Não obstante, confirmam-se as recomendações de BINOTI et al. (2013, 2014 a, b) e GEORGENS et al. (2014). Esses autores afirmam que não existe um critério preciso para definir o número de camadas, sendo necessário, portanto, o teste e a verificação de diversas redes por meio de tentativas.

Considerando-se que as redes neurais artificiais 1, 2, 5, 6, 7 e 11 proporcionaram os indicadores mais apropriados, somente essas redes foram objeto de uma análise complementar para verificação da sua eficiência e confiabilidade, tanto gráfico como analítico. Inicialmente elaboraram-se os histogramas de frequência dos resíduos, apresentados nas Figuras 1 a 6. Com base nessas Figuras deduz-se que, as diferenças entre a produtividade real medida e a estimada pelas redes neurais distribuíram-se com adequada simetria e próximo da curva normal, exceto as redes 1 e 6, isto é, a maioria dos resíduos de pequena magnitude concentraram-se no centro, ao redor de zero e os restantes com valores mais elevados nos extremos. Essa característica do histograma de frequência em relação à normal constitui uma premissa fundamental para definir critérios sobre a eficiência na predição das redes.

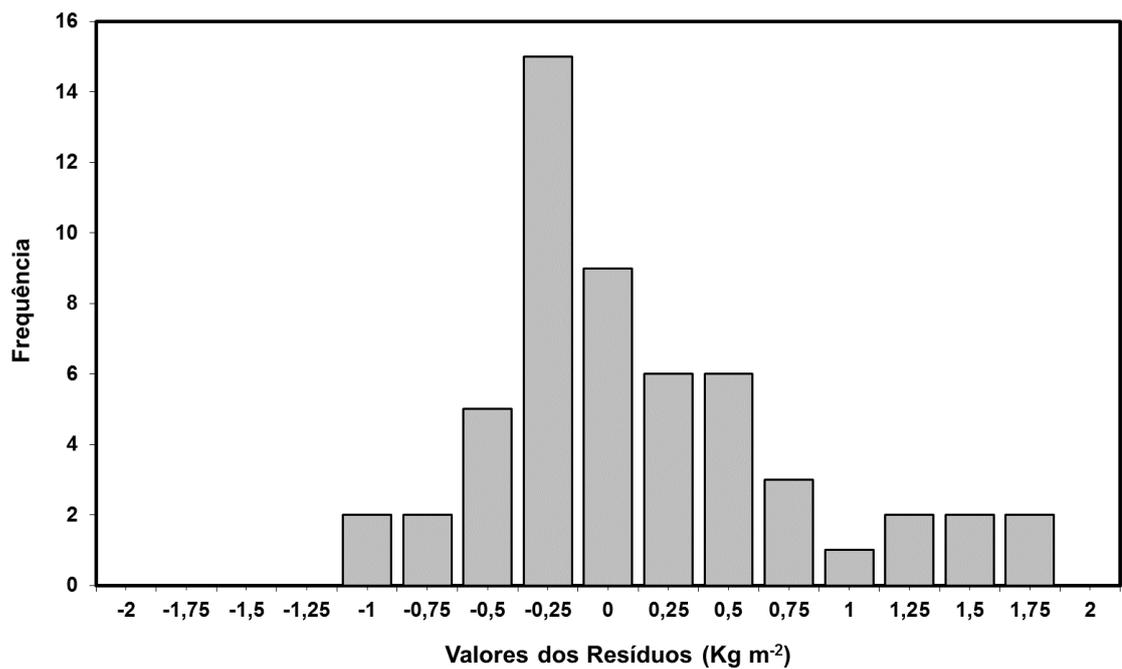


Figura 1. Histograma de frequência dos resíduos para a RNA 01.

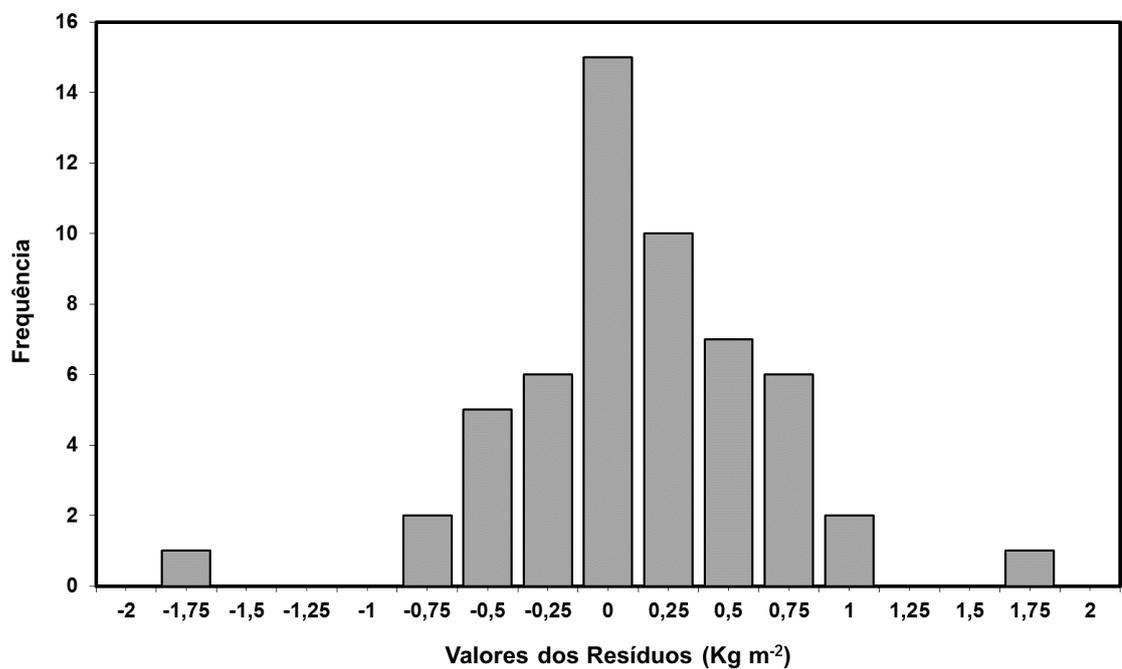


Figura 2. Histograma de frequência dos resíduos para a RNA 02.

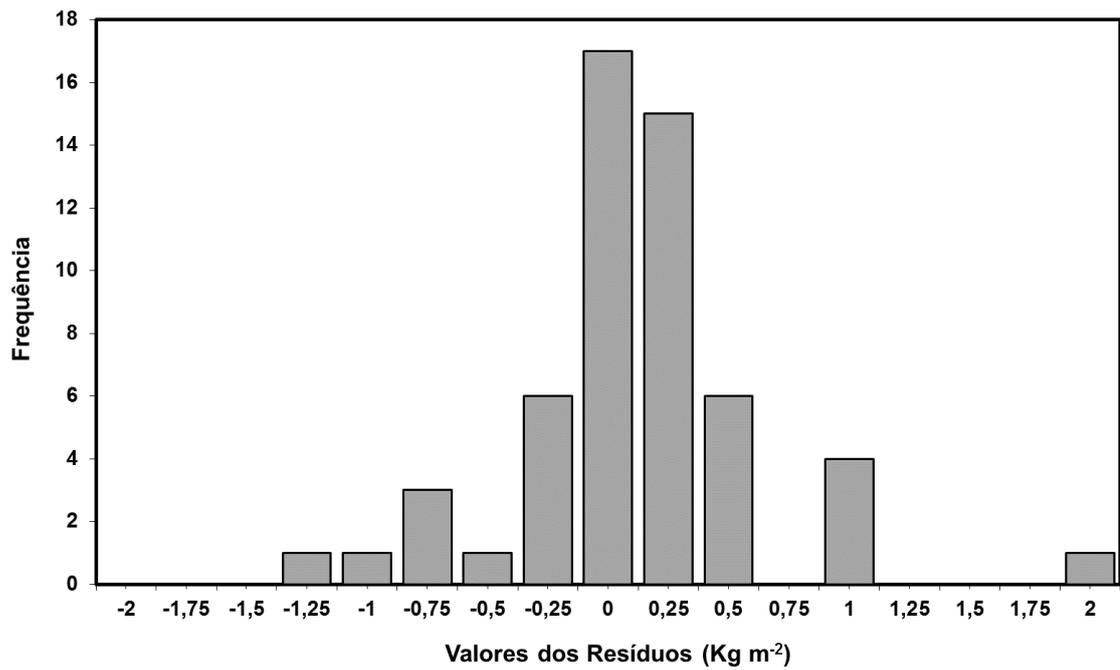


Figura 3. Histograma de frequência dos resíduos para a RNA 05.

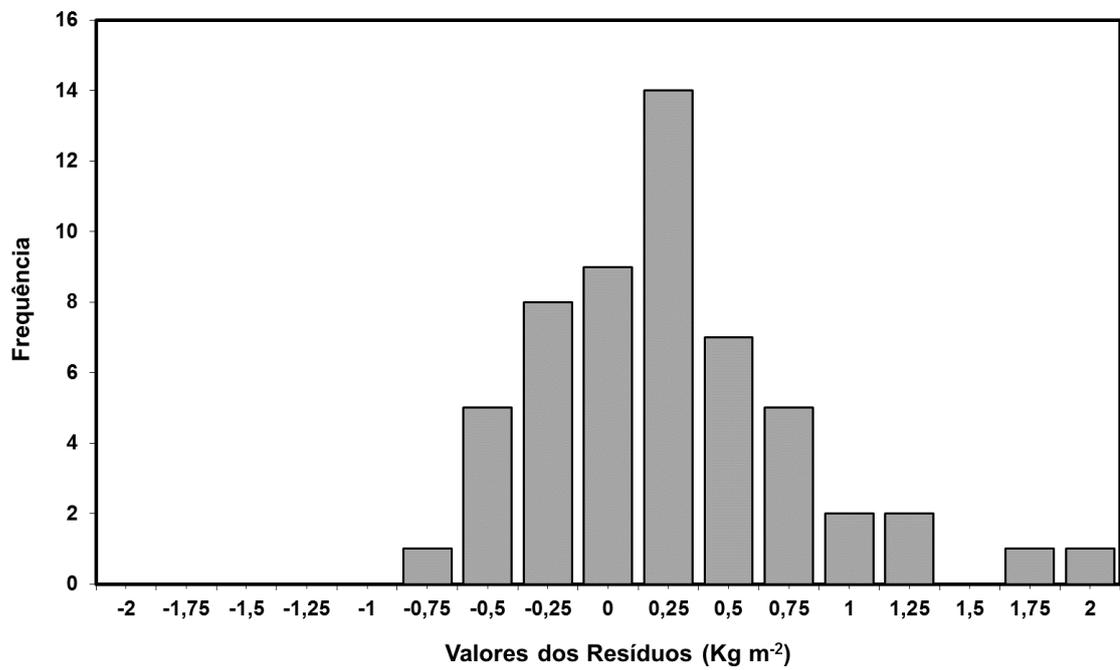


Figura 4. Histograma de frequência dos resíduos para a RNA 06.

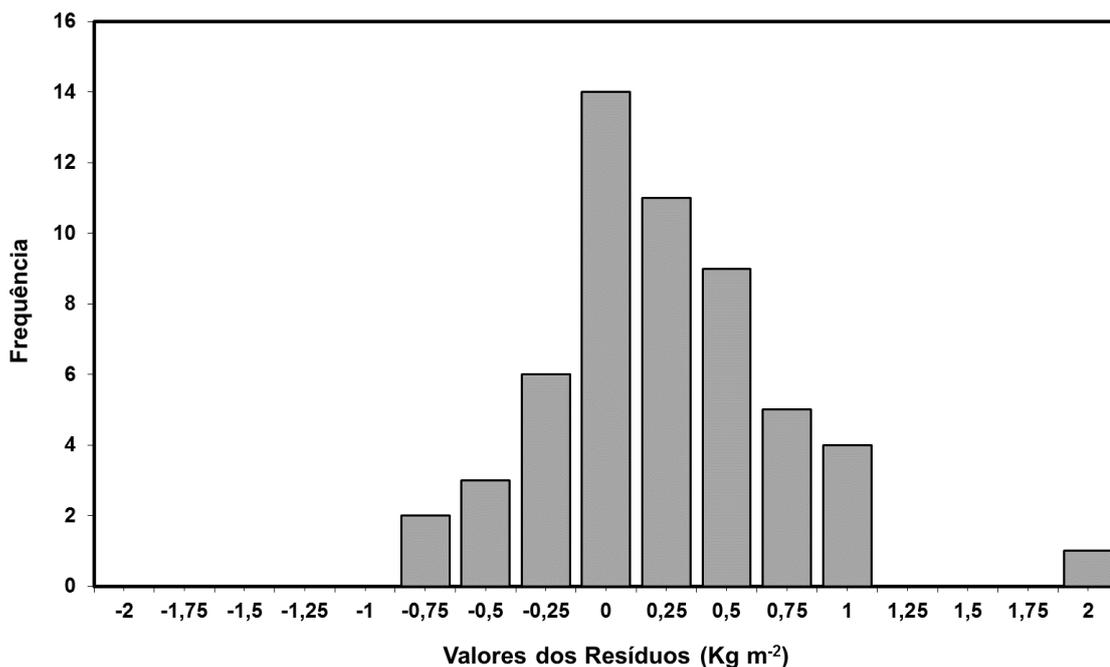


Figura 5. Histograma de frequência dos resíduos para a RNA 07.

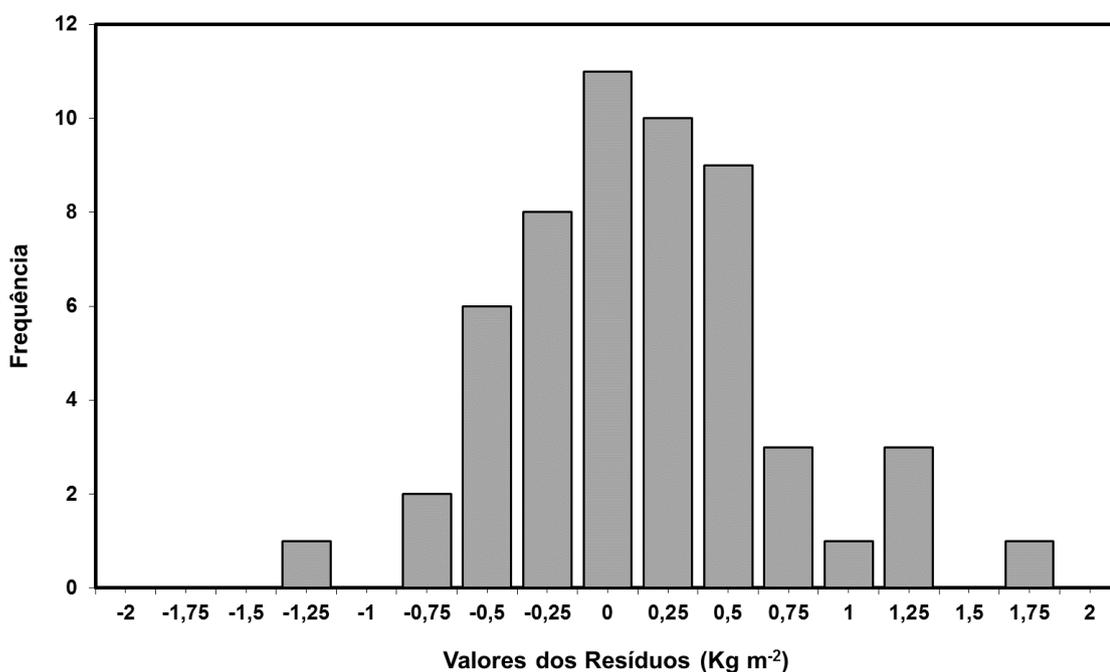


Figura 6. Histograma de frequência dos resíduos para a RNA 11.

Em seguida foram construídos os diagramas de dispersão dos resíduos como função da produtividade real observada para cada rede neural artificial (Figuras 7 a 12). De acordo com essas Figuras infere-se que não há relação entre os resíduos e as variáveis consideradas nas redes desenvolvidas, pois os pontos situam-se aleatoriamente ao longo do eixo horizontal e não

existem evidências de algum padrão de dependência funcional. Pode-se constatar, ainda, que as redes neurais 2 e 7 apresentaram o menor número de pontos fora do intervalo compreendido entre -1 e 1 kg m⁻² de valores para os resíduos, o que significa um forte indício de maior precisão nas estimativas da produtividade por meio dessas redes.

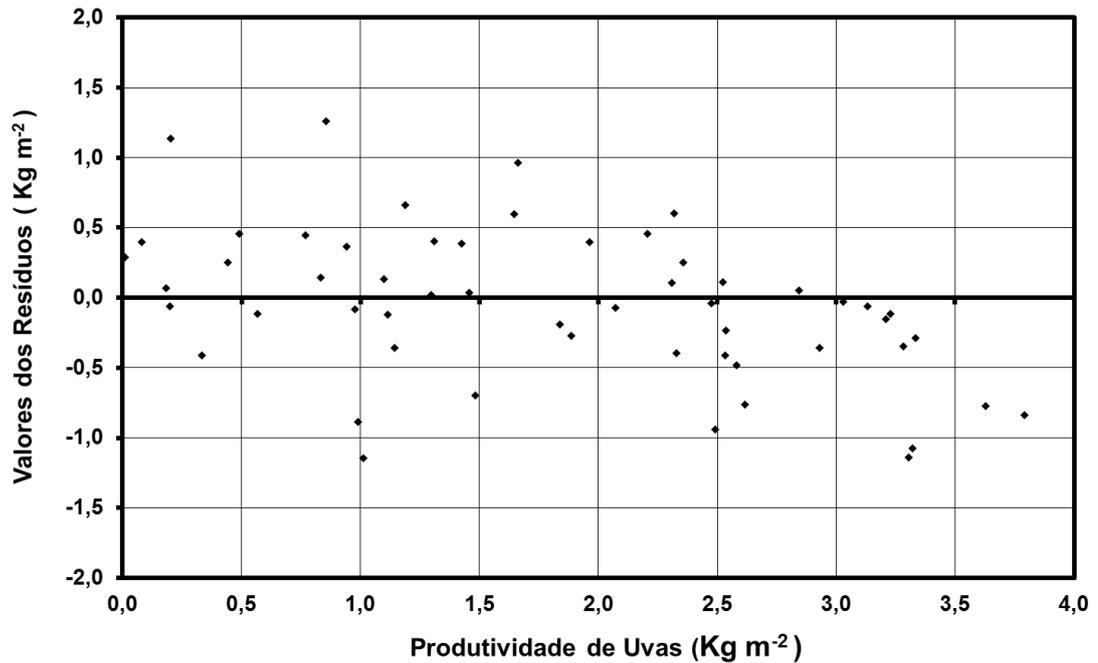


Figura 7. Valores dos resíduos, em função da produtividade de uvas para a RNA 01.

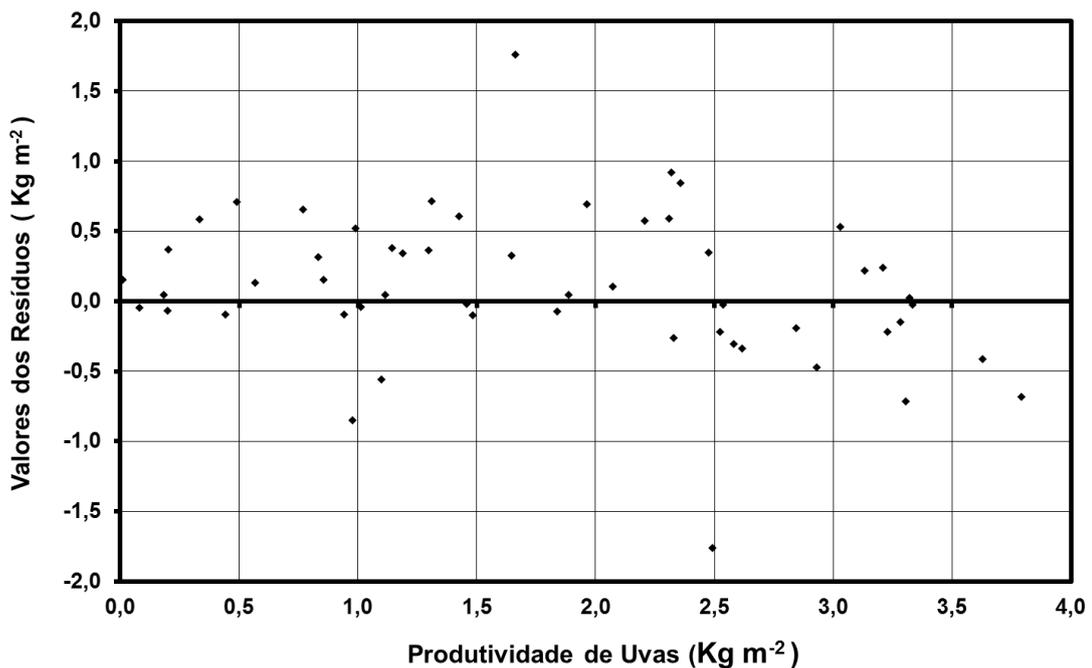


Figura 8. Valores dos resíduos, em função da produtividade de uvas para a RNA 02.

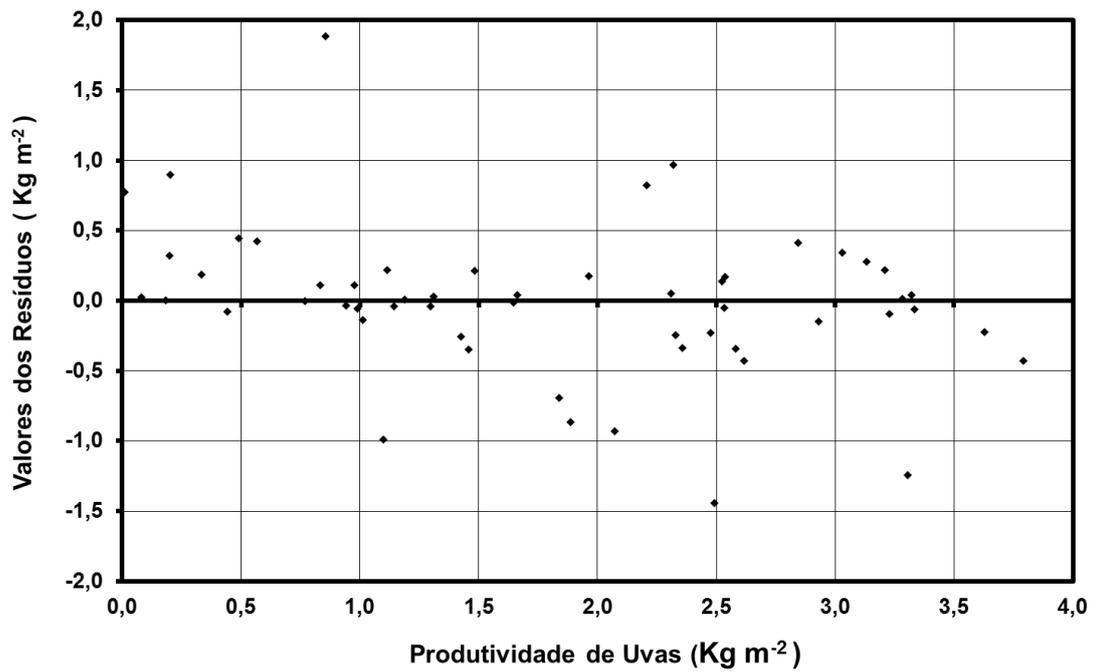


Figura 9. Valores dos resíduos, em função da produtividade de uvas para a RNA 05.

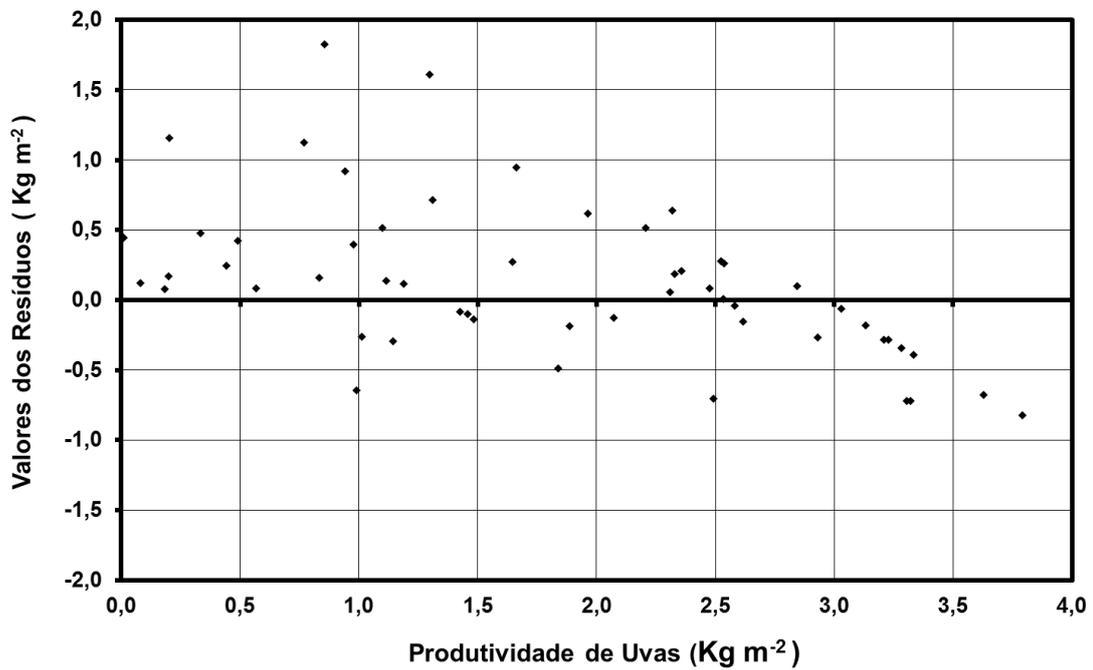


Figura 10. Valores dos resíduos, em função da produtividade de uvas para a RNA 06.

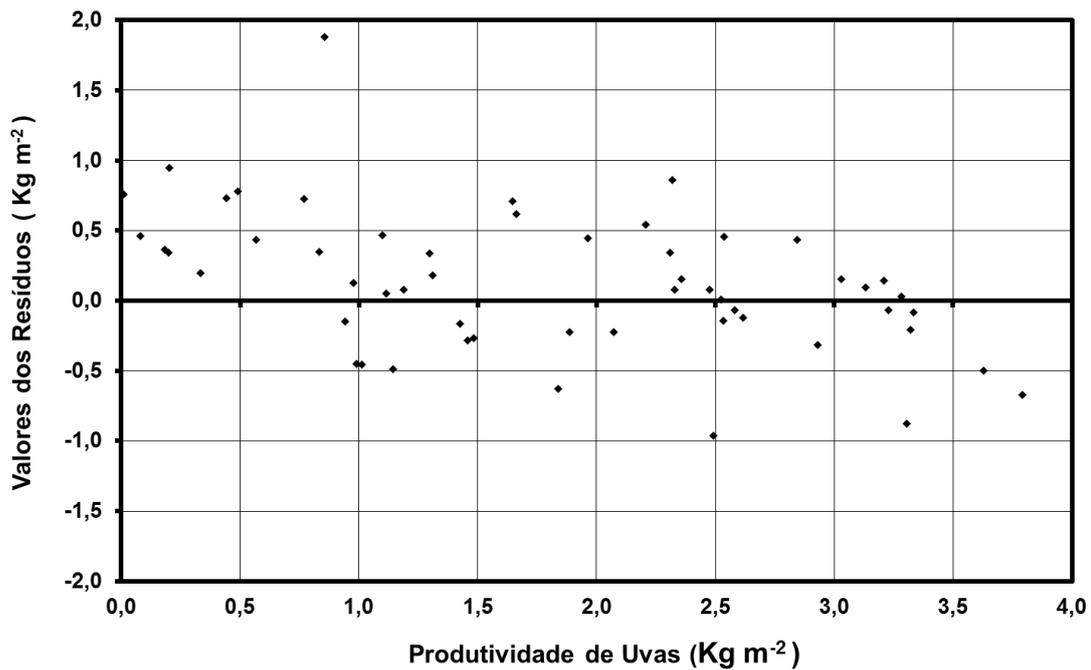


Figura 11. Valores dos resíduos, em função da produtividade de uvas para a RNA 07.

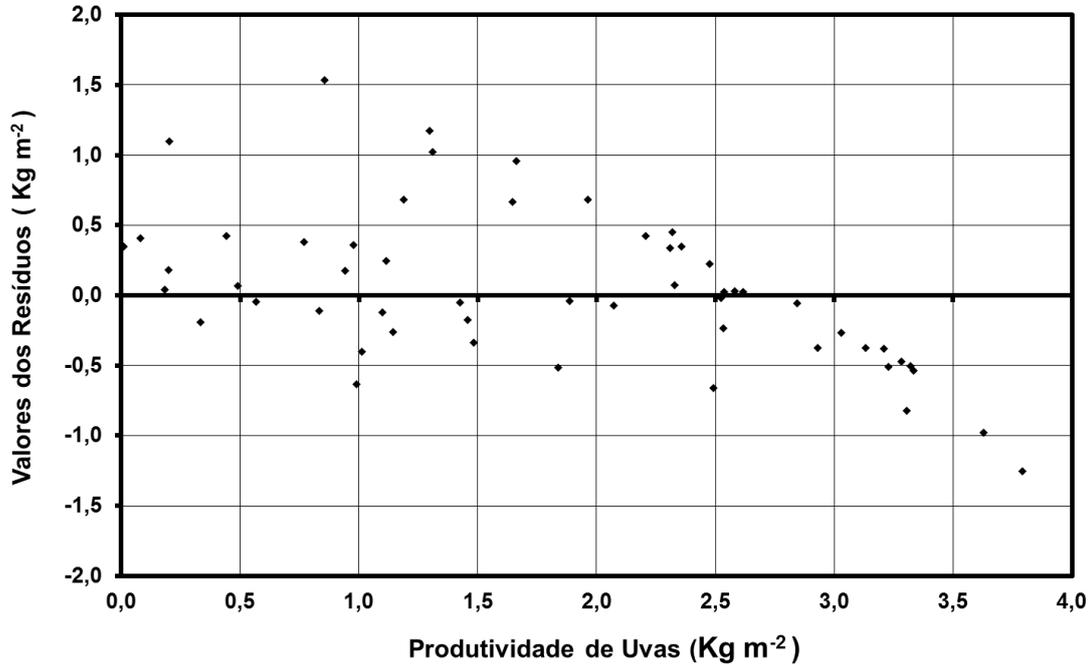


Figura 12. Valores dos resíduos, em função da produtividade de uvas para a RNA 11.

Embora, a distribuição dos resíduos apresentou características de normalidade e não foi evidenciado algum padrão de dependência funcional nos resíduos, a análise gráfica considera-se um procedimento subjetivo. Assim, optou-se por verificar analiticamente a normalidade e a eficiência das redes aplicando-se os testes de Kolmogorov-Smirnov, Lilliefors e Shapiro-Wilk,

bem como o teste t (Student) entre os valores reais observados de produtividade de uvas e os estimados pelas redes. Os resultados correspondentes a esses testes constam nas Tabelas 4 e 5.

Tabela 4. Resultados dos testes de normalidade para as redes neuronais artificiais.

RNA e Arquitetura	Teste de normalidade		
	Kolmogorov-Smirnov (Estatística D)	Lilliefors	Shapiro-Wilk (Estatística W)
1) MLP 8:8-8-1:1	D= 0,1355 p>0,20 ns	p<0,05 *	W= 0,9220 p=0,0016 **
2) MLP 8:8-6-1:1	D= 0,1204 p>0,20 ns	p<0,05 *	W= 0,9503 p=0,0236 **
5) MLP 8:8-8-2-1:1	D= 0,1355 p>0,20 ns	p<0,05 *	W= 0,9220 p=0,0016 **
6) MLP 8:8-6-2-1:1	D= 0,1204 p>0,20 ns	p<0,05 *	W= 0,9503 p=0,0236 **
7) MLP 8:8-4-2-1:1	D= 0,0695 p>0,20 ns	p>0,20 ns	W= 0,9717 p=0,2201 ns
11) MLP 8:8-4-4-1:1	D= 0,0926 p>0,20 ns	p>0,20 ns	W= 0,9827 p=0,6083 ns

Obs. p: Valor de probabilidade; ns: não significativo; * e **: Significativo a 5 y 1%.

Tabela 5. Resultados do teste t-Student para as redes neuronais artificiais.

RNA e Arquitetura	Valores de t-Student			Significância
	Calculado	Tabelado		
		$\alpha = 5 \%$	$\alpha = 1 \%$	
1) MLP 8:8-8-1:1	0,2707			ns
2) MLP 8:8-6-1:1	0,3569			ns
5) MLP 8:8-8-2-1:1	0,0401			ns
6) MLP 8:8-6-2-1:1	0,6712	1,6591	2,3614	ns
7) MLP 8:8-4-2-1:1	0,6652			ns
11) MLP 8:8-4-4-1:1	0,1902			ns

Obs. α : Nível de probabilidade; ns: no significativo

De acordo com a Tabela 4, somente os resíduos das redes neurais 7 (MLP 8:8-4-2-1:1) e 11 (MLP 8:8-4-4-1:1) evidenciaram normalidade. Tomando como referência os estudos de TORMAN et al (2012) e LOPES et al (2013), a não significância nos testes de normalidade

confere-lhe maior confiabilidade a essas redes. Entretanto, o teste t-Student indicou que não existem diferenças entre os valores de produtividade de uvas reais medidos e os estimados pelas seis redes neurais (Tabela 5). Estes resultados permitem afirmar que essas redes são adequadas, ainda que as redes 7 e 11 formadas por duas camadas ocultas manifestaram-se como as mais apropriadas para prever a produtividade de uva, em função das variáveis que caracterizam a irrigação nos meses mais secos do ano, a precipitação total anual e a variedade.

Na Tabela 6 encontra-se o resumo com os critérios estatísticos para avaliar a eficiência das seis redes neurais artificiais. Esses resultados demonstram que as mencionadas redes tiveram desempenho satisfatório, caracterizado pelos coeficientes obtidos, os quais superaram o valor mínimo de 0,7, sugerido por TERRA & PASSADOR (2012), BINOTI et al (2013, 2014 a, b) e GEORGENS et al (2014). Logo, confirma-se que as redes desenvolvidas apresentaram adequada confiabilidade e precisão nas estimativas para fins de planejamento, justificando-se a sua aplicação para o gerenciamento da irrigação na cultura da uva.

Tabela 6. Resumo dos critérios estatísticos para avaliar a eficiência das redes neurais.

RNA e Arquitetura	Critério estatístico		
	Coeficiente de correlação	Concordância de Willmont	Índice de desempenho
1) MLP 8:8-8-1:1	0,9123	0,8495	0,7750
2) MLP 8:8-6-1:1	0,9218	0,8931	0,8233
5) MLP 8:8-8-2-1:1	0,9314	0,8894	0,8284
6) MLP 8:8-6-2-1:1	0,9137	0,8753	0,7998
7) MLP 8:8-4-2-1:1	0,9259	0,8801	0,8149
11) MLP 8:8-4-4-1:1	0,9326	0,8947	0,8344

4. CONCLUSÕES

Com a utilização das RNAs nas próximas safras poderá haver uma maior eficiência no uso da água, da energia e dos insumos, pois aplicando de forma correta, elas contribuirão significativamente para o aumento da rentabilidade da propriedade e a preservação do meio ambiente.

As redes neurais artificiais de múltiplas camadas do tipo perceptron foram apropriadas para estimar a produtividade de uvas, em função da lâmina de irrigação e precipitação anual. Também, foi possível definir e verificar arquiteturas para considerar a lâmina de irrigação, a precipitação total anual e a variedade de uva.

O uso de variáveis binárias para introduzir a variedade de uva nas arquiteturas elevou a generalização redes neuronais e as redes neurais artificiais desenvolvidas apresentaram adequada confiabilidade e precisão nas predições, o que justifica a sua aplicação.

As redes 7 e 11 formadas por duas camadas ocultas manifestaram-se como as mais apropriadas para predizer a produtividade de uva, em função das variáveis que caracterizam a irrigação nos meses mais secos do ano, a precipitação total anual e a variedade. Estas redes foram consideradas as que mais se aproxima do valor real coletado, trazendo confiança para utilização dela em outros anos futuros e inserindo ela no planejamento da próxima irrigação. Portanto, as redes neurais artificiais obtidas podem ser uma útil ferramenta para o planejamento e gerenciamento da irrigação na cultura da uva.

5. REFERÊNCIAS BIBLIOGRÁFICAS

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

BILGILI, M.; SAHIN, B. **Comparative analysis of regression and artificial neural network models for wind speed prediction.** Meteorology and Atmospheric Physics, v.109, n. 1-2, p. 61-72, 2010.

BINOTI, M. L. S.; BINOTI, D. H. B.; LEITE, H. G. **Aplicação de redes neurais artificiais para estimação da altura de povoamentos equiâneos de eucalipto.** Revista Árvore, Viçosa-MG, v.37, n.4, p.639-645, 2013.

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; FERREIRA, M. Z.; RODE, R.; SILVA, A. A. L. **Redes neurais artificiais para estimação do volume de árvores.** Revista Árvore, Viçosa-MG, v.38, n.2, p.283-288, 2014a.

BINOTI, M. L. M. S.; BINOTI, D. H. B.; LEITE, H. G.; GARCIA, S. L. R.; SILVA, A. A. L.; PONTES, C. **Utilização de redes neurais artificiais para a projeção da distribuição diamétrica de povoamento equiâneos.** Revista Árvore, Viçosa-MG, v.38, n.4, p.747-754, 2014b.

BORGES, P. H. M.; LEITE, H. G.; FERNÁNDEZ, H. C.; MARTINS, F. C. M.; MENDOZA, Z. M. S. H. **Descripción analítica de la resistencia del suelo a la penetración.** Revista Engenharia na Agricultura, Viçosa, v.21, n.1, p.39-51, jan./fev., 2013.

BORGES, P. H. M.; BIANCHINI, A.; MAIA, J. C. S.; FERNÁNDEZ, H. C.; MENDOZA Z. M. S. H. **Demanda tractiva en función de la resistencia mecánica del suelo a la penetración.** Revista Engenharia Agrícola, Jaboticabal, v.34, n.2, p.273-285, mar./abr. 2014.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDEMIR, T. B. **Fundamentos de redes neurais artificiais.** Rio de Janeiro: DCC/I, COPPE/ Sistemas, NCE/UFRJ, 1998. 246p.

BRAGA, A. P.; CARVALHO, A. P. L. F.; LUDERMIR, T. B. **Redes neurais artificiais: teoria e aplicações.** 2.ed. Rio de Janeiro: LTC, 2007.

CANSIAN, A. B. M.; COSTA, A. O. S.; COSTA JÚNIOR, E. F. **Utilização de redes neurais artificiais como estímulo ao aprendizado de matemática.** ENCICLOPÉDIA BIOSFERA, Centro Científico Conhecer - Goiânia, v.10, n.19; p. 2567-2580, 2014.

CARVALHO, D. F.; KHOURY JÚNIOR, J. K.; VARELLA, C. A. A.; GIORI, J. Z.; MACHADO, R. L. **Rainfall erosivity for the state of rio de janeiro estimated by artificial neural network.** Revista Engenharia Agrícola, Jaboticabal, v.32, n.1, p.197-207, jan./fev. 2012.

DINIZ, J. M. T. **Variabilidade da precipitação e do número de dias com chuvas de duas cidades distintas da Paraíba.** Holos, v. 3, n. 29, p. 171-180. 2013.

GEORGENS, E. B.; LEITE, H. G.; GLERIANI, J. M.; SOARES, C. P. B.; CEOLIN, A. **Influência da arquitetura na estimativa de volume de árvores individuais por meio de redes neurais artificiais.** Revista Árvore, Viçosa-MG, v.38, n.2, p.289-295, 2014.

IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Disponível em: <<http://www.ibge.gov.br/home/>> Acesso em: 30 jan. 2016.

IMEA – INSTITUTO MATOGROSSENSE DE ECONOMIA AGROPECUÁRIA. Disponível em: <<http://www.imea.com.br/site/principal.php>> Acesso em: 30 jan. 2016.

INMET – INSTITUTO NACIONAL DE METEOROLOGIA. Disponível em: <<http://www.inmet.gov.br/portal/>> Acesso em: 30 jan. 2016.

KÖPPEN, W.; GEIGER, R. **Klima der Erde.** Gotha: Verlag Justus Perthes. 1928.

LEÃO, P. C. S.; BRANDÃO, E. O.; GONÇALVES, N. P. S. **Produção e qualidade de uvas de mesa “Sugraone” sobre diferentes porta-enxertos no submédio do Vale do São Francisco.** Ciência Rural, v. 41, n. 9, p. 1526-1531. 2011

LOPES, M. M.; CASTELO BRANCO, V. T. F.; SOARES, J. B. **Utilização dos testes estatísticos de Kolmogorov-Smirnov e Shapiro-Wilk para verificação da normalidade para materiais de pavimentação.** Revista Transportes, v. 21, n. 1, p. 59–66, 2013.

MORAES, B. C.; COSTA, J. M. N.; COSTA, A. C. L.; COSTA, M. H. **Variação espacial e temporal da precipitação no Estado do Pará.** Acta Amazônica, v. 35, n. 2, p. 207-214. 2005.

PANDORFI, H.; SILVA, I. J. O.; SARNIGHAUSEN, V. C. R.; VIEIRA, F. M. C.; NASCIMENTO, S. T.; GUISELINI, C. **Uso de redes neurais artificiais para predição de índices zootécnicos nas fases de gestação e maternidade na suinocultura.** Revista Brasileira de Zootecnia, v.40, n.3, p.676-681, 2011.

SOUSA, A. P.; MENEZES, J. E. **Box-Jenkins e rede neural artificial para previsão de séries temporais: estudo comparativo entre modelos.** Revista do Instituto Mauro Borges de Estatísticas e Estudos Socioeconômicos, Goiânia, v. 24, p. 89-102, mar., 2013.

SUDHA, L.; DILLIBABU, R.; SRINIVAS, S. S.; ANNAMALAI, A. **Optimization of process parameters in feed manufacturing using artificial neural network.** Computers and electronics in agriculture. v. 120, p. 1-6, 2016.

TERRA, L. A. A.; PASSADOR, J. L. **Redes neurais artificiais na previsão da inflação: aplicação como ferramenta de apoio à análise de decisões financeiras em organizações de pequeno porte.** Revista de Administração Mackenzie, São Paulo, v.13, n.1, p.68-86, jan./fev., 2012.

TORMAN, V. B. L.; COSTER, R.; RIBOLDI, J. **Normalidade de variáveis: métodos de verificação e comparação de alguns testes não-paramétricos por simulação.** Revista HCPA, Porto Alegre, v.32, n.2, p.227-234, 2012.

VALENTE, G. F. S.; GUIMARÃES, D. C.; GASPARDI, A. L. A. OLIVEIRA, L. A. **Aplicação de redes neurais artificiais como teste de detecção de fraude de leite por adição de soro de**

queijo. Revista do Instituto de Laticínios Cândido Tostes, Juiz de Fora, v. 69, n. 6, p. 425-432, nov/dez, 2014.

VENTURA, R. V.; SILVA, M. A.; MEDEIROS, T. H.; DIONELLO, N. L.; MADALENA, F. E.; FRIDRICH, A. B.; VALENTE, B. D.; SANTOS, G. G.; FREITAS, L. S.; WENCESLAU, R. R.; FELIPE, V. P. S.; CORRÊA, G. S. **Uso de redes neurais artificiais na predição de valores genéticos para peso aos 205 dias em bovinos da raça Tabapuã.** Arquivo Brasileiro de Medicina Veterinária e Zootecnia, v.64, n.2, p.411-418, 2012.

VIEIRA, S. R.; CAMARGO, M. B. P.; SIQUEIRA, G. M. **Análise espacial da temperatura e da precipitação média anual no Estado de São Paulo.** Bio Engenharia. V. 3, n. 2, p. 87-97. 2009.

WU, C. L.; CHAU, K. W. **Prediction of rainfall time series using modular soft computing methods.** Engineering Application of Artificial Intelligence. V. 26, n. 3, p. 997-1007. 2013.

WU, C. L.; CHAU, K. W.; FAN, C. **Prediction of Rainfall Time Series Using Modular Artificial Neural Networks Coupled with Data-Preprocessing Techniques.** Journal of Hydrology, v.389, N.1-2, p. 146-167. 2010.

YASAR, A.; SIMSEK, E.; BILGILI, M.; YUCEL, A. **Estimation of relative humidity based on artificial neural network approach in the Aegean Region of Turkey.** Meteorology and Atmospheric Physics. V. 115, n. 1-2, p. 81-87. 2012.