

USO DE REDES NEURAS NA PREDIÇÃO DA PRODUTIVIDADE DE FLORES DO *KALANCHOE BLOSSFELDIANA* POELLN CULTIVADO EM AMBIENTE PROTEGIDO

FÁTIMA C. SOARES¹, JUMAR L. RUSSI², FRANCIELLE ALTÍSSIMO BORTOLÁS³, ANA R. COSTENARO PARIZI⁴; PAOLA DA ROSA LIRA⁵,

¹ Eng^a; Agrícola, prof^a Adjunta, curso de Engenharia Agrícola, Universidade Federal do Pampa – Campus de Alegrete, Alegrete-RS, fone (55)98117-7002, fatimasoares@unipampa.edu.br

² Eng^o; Eletricista, prof Adjunto, curso de Engenharia Elétrica, Universidade Federal do Pampa – Campus de Alegrete, Alegrete-RS.

³ Eng^a Agrícola, aluna de mestrado do Programa de Pós-Graduação em Engenharia Agrícola, Universidade Federal de Santa Maria, Santa Maria-RS.

⁴ Eng^a Agrícola, Prof^a Adjunto, Instituto Federal Farroupilha – Campus de Alegrete, Alegrete-RS

⁵ Acadêmica curso de Engenharia Agrícola, Universidade Federal do Pampa/Instituto Federal Farroupilha, Alegrete-RS

Apresentado no
XLVI Congresso Brasileiro de Engenharia Agrícola - CONBEA 2017
30 de julho a 03 de agosto de 2017 - Maceió - AL, Brasil

RESUMO: O uso de sistemas inteligentes no meio agrícola, a fim de prever a produtividade, é uma ferramenta de suporte à agricultura. Assim, objetivou-se através do uso de redes neurais artificiais prever a produtividade de flores do *Kalanchoe Blossfeldiana* Poelln. Os dados de campo foram obtidos na área experimental do curso de Engenharia Agrícola, Unipampa, Alegrete, RS. Foram testadas diversas redes neurais do tipo perceptron, multicamadas com algoritmo backpropagation otimizado (Levenberg-Marquardt). As variáveis de entrada foram: composição dos substratos (cinza da casca de arroz, solo, húmus, industrializado e pinha); irrigação total e evapotranspiração da cultura total. A variável de saída foi produtividade de flores. Os dados foram divididos em três conjuntos: treinamento, validação e teste. Cada arquitetura foi treinada 10 vezes, escolhendo-se, ao final do treinamento, aquela com menor erro relativo médio e menor variância em relação aos dados de validação. A eficiência das redes foi analisada por meio de indicadores estatísticos. A rede com 20 neurônios na camada escondida, apresentou os menores erros nos processos de treinamento e validação, dentre as diversas arquiteturas treinadas, com coeficiente de determinação de 0,90. Conclui-se que o uso de redes neurais artificiais propostas para prever a produtividade de flores do *Kalanchoe* foi satisfatório.

PALAVRAS-CHAVE: modelagem; floricultura; produtividade

USE OF NEURAL NETWORKS IN THE PREDICTION OF FLOWER PRODUCTIVITY OF *KALANCHOE BLOSSFELDIANA* POELLN CULTIVATED IN A PROTECTED ENVIRONMENT

ABSTRACT: The use of intelligent systems in the agricultural environment, aiming to predict productivity, is a support tool for agriculture. Thus, it was intended by using artificial neural networks to predict the flower productivity of *Kalanchoe Blossfeldiana* Poelln. Field data were obtained in the experimental area of the Agricultural Engineering course,

Unipampa, Alegrete, RS. Several neural networks of perceptron type, multilayer with optimized backpropagation algorithm (Levenberg-Marquardt) were tested. The input variables were: composition of the substrates (rice husk ash, soil, humus, industrialized and pineapple); total irrigation and total evapotranspiration of the crop. The output variable was flower yield. Data were divided into three groups: training, validation and testing. Each architecture was trained 10 times, choosing at the end of the training the one with the lowest average relative error and the lowest variance in relation to the validation data. The efficiency of the networks was analyzed through statistical indicators. The network with 20 neurons in the hidden layer presented the smallest errors in training and validation processes, among several trained architectures, with a coefficient of determination of 0.90. It was concluded that the use of the proposed artificial neural networks to predict the productivity of Kalanchoe flowers was satisfactory.

KEYWORDS: modeling; floriculture; productivity

INTRODUÇÃO

A floricultura no Brasil vem se expandindo, ganhando qualidade, competitividade e ramificando-se por todas às regiões do país (DE FRANÇA e MAIA, 2008). Considera-se atualmente uma importante atividade econômica no Brasil, com taxas de crescimento de 20% ao ano (BUAINAIN e BATALHA, 2007).

A produção de flores e plantas ornamentais vem tendo resultados positivos, devido a ampliação do consumo nos países desenvolvidos e, especialmente, em razão da expansão do mercado interno brasileiro. Isto se deve, principalmente, às condições climáticas favoráveis nas regiões produtoras, ao acesso facilitado a novas tecnologias e ao avanço das técnicas de cultivo avançadas. Entretanto, essas técnicas de manejo de cultivo, ainda precisam ser melhor estudadas, uma vez que há espécies ornamentais com grande potencial produtivos que deixa de ser explorada por falta de informação sobre seu manejo.

Segundo Buainain e Batalha (2007) a adoção de tecnologia de ponta precisa ser implementada no processo produtivo pelos floricultores a fim de melhorar a qualidade do produto. As mesmas apesar de disponíveis são utilizadas por uma minoria, a maioria dos produtores utilizam ainda na produção tecnologias rudimentares.

Na tentativa de auxiliar os produtores agrícolas em processos de tomada de decisão o uso da modelagem matemática vem gradativamente demonstrando eficiência na predição em sistemas agrícolas. Os modelos de simulação de culturas podem auxiliar no entendimento dos fatores que interferem em seu rendimento, assim como indicar alternativas no manejo da cultura perante diferentes cenários para o sistema de produção.

Previsões de safra e outras estimativas envolvendo culturas agrícolas podem ser utilizadas com grande êxito em diversas situações a partir de modelos de simulação de culturas (ANDRADE JUNIOR et al., 2006). Dentre as vantagens da utilização de modelos, destacam-se a economia de tempo, trabalho e quantidade de recursos para planejamento e tomada de decisões de manejo no setor agrícola.

A modelagem vem sendo utilizada na simulação do crescimento e rendimento de culturas, para quantificar o impacto de condições adversas de clima, visando auxiliar o monitoramento e a estimativa de safras em grandes áreas (YOUNG, 2008). A formulação de um modelo matemático, para a predição da produção de culturas agrícolas, é muito difícil e limitado devido à complexidade e a não linearidade nos dados dos parâmetros relacionados à mesma (BRAGA, et al., 2000). Dentro deste contexto, vários autores indicam a utilização de redes neurais artificiais (RNAs) quando se trata de sistemas complexos (SOARES, et al., 2015; SOARES, et al., 2014; YOUNG et al., 2001; ATTOH-OKINE e FEKPE, 1996).

Neste cenário, o uso de sistemas inteligentes no meio agrícola, a fim de prever a produtividade em função das técnicas de manejo aplicadas, vêm contribuindo para a maximização e otimização na agricultura. Assim, o uso de redes neurais artificiais, pode permitir correlacionar as variáveis que interferem na produtividade (ARRUDA et al., 2013), possibilitando o desenvolvimento de modelos que auxiliem na tomada de decisões quanto ao manejo. Diante do exposto, objetivou-se com este trabalho prever a produtividade de flores do *Kalanchoe Blossfeldiana* Poelln., através do uso de redes neurais artificiais.

MATERIAL E MÉTODOS

Os dados utilizados para, treinar e validar as redes neurais artificiais (RNAs), foram obtidos de experimento desenvolvido, com a cultura do *Kalanchoe Blossfeldiana* Poelln, no município de Alegrete, região centro oeste do Estado do Rio Grande do Sul, localizado na latitude 29° 47', longitude de 55° 46' e 91 m de altitude, publicados por Bortolás (2016). A cultivar utilizada no experimento foi a “Debbie”, está foi submetida a diferentes dosagens de irrigação e substratos, compostos por resíduos industriais e vegetais. Os substratos eram compostos pelos seguintes materiais: cinza da casca do arroz, solo, húmus, substrato comercial e semente de pinus triturada. Foram aplicadas lâminas de irrigação com as dosagens em relação a capacidade de retenção de água no vaso (CV), sendo estas, 70, 50, 30 e 20% da CV.

Para desenvolvimento da RNA multicamadas foi utilizado o Neural Network Toolbox do software Matlab (versão 7.12.0.635), as mesmas foram treinadas com o algoritmo backpropagation e otimização Levenberg-Marquadt, foi utilizado a regra de aprendizado por correção de erro (BRAGA et al., 2000). Para cada arquitetura de RNA, os dados foram divididos aleatoriamente em cerca de 70% para treinamento e 30 % para validação da mesma (NAGAOKA, et al., 2005; BRAGA et al., 2000).

Para o treinamento foi mantido constante o número de camadas (uma camada de entrada, uma intermediária e uma saída). As redes treinadas tinham na camada de entrada sete variáveis, variando-se o número de neurônios na camada intermediária, treinou-se redes com 5, 10, 20, 30, 40 e 50 neurônios na camada escondida. E um único neurônio na camada de saída.

As variáveis de entrada na RNA foram: composição dos substratos - cinza da casca de arroz (%), solo (%), húmus (%), comercial (%) e pinha (%); irrigação total (ml) e evapotranspiração da cultura total (mm), a variável de saída foi produtividade de flores (flores.planta⁻¹).

As variáveis de entrada, irrigação total e evapotranspiração total da cultura, ou seja, o consumo hídrico, foram computadas no final do ciclo da cultura do Kalanchoe, aos 163 dias após o transplante (DAT). O consumo de água pela planta foi determinado conforme equação 1, do balanço hídrico, proposta por Thornthwaite e Mather (1955):

$$E_{tr} = \sum_{i=1}^L M_i - \sum_{i=1}^L M_{i+1} + I - D \quad (1)$$

onde,

E_{tr} = evapotranspiração real da cultivar no início de um dado intervalo de tempo;

M_i = massa de substrato e água contida no vaso no início de um dado intervalo de tempo;

M_{i+1} = massa de substrato e água remanescente no final do intervalo de tempo considerado;

I = irrigação aplicado no intervalo Δt ;
 D = drenagem que ocorre no período Δt .

O método do balanço hídrico consiste na pesagem do vaso antes de ser irrigado e após, com retirada da água que percola no perfil (drenada), fazendo com que se obtenha a variação entre a massa de substrato e água contida no intervalo de tempo considerado, bem como a massa de substrato e água remanescente no final do intervalo de tempo considerado, sendo $M_i - M_{i+1}$, obtidos em balança de precisão de 0,01 g.

A contagem do número de flores por planta, obtida no final do ciclo, foi realizada manualmente.

No neurônio da camada de saída, empregou-se uma função de ativação linear. Visando garantir que cada parâmetro de entrada recebesse igual atenção durante o treinamento, aumentando, assim, sua eficiência, tanto os dados de entrada quanto os de saída foram padronizados para o intervalo entre -1 e 1 pela equação 2 (MATLAB, 2000):

$$p_n = \frac{2(p - \min p)}{(\max p - \min p)} - 1 \quad (2)$$

em que,

p_n é o valor normalizado, adimensional;
 p o valor observado;
 $\min p$ é o valor mínimo da amostra; e
 $\max p$ o valor máximo da amostra.

No desenvolvimento da RNA, manteve-se constante a função de ativação na camada intermediária (Tangente Hiperbólica sigmoide), a regra de treinamento (Levenberg-Marquardt) e o número de épocas.

Tendo em vista que, no início do treinamento, os parâmetros livres são gerados aleatoriamente e que esses valores iniciais podem influenciar o resultado final do treinamento, a RNA que representava cada combinação das variáveis, foi treinada 10 vezes. Sendo que em cada treino eram realizadas inúmeras iterações, até que o erro médio quadrático entre a saída desejada e calculada fosse minimizado.

Escolheu-se como melhor resultado a rede que obteve menor erro relativo médio e menor variância em relação aos dados de validação. Havendo resultados próximos na escolha da arquitetura, selecionou-se aquela com menor erro quadrático médio em relação os dados de treino e menor número de neurônios (BRAGA et al., 2000).

Após o treinamento, com os 30% dos dados restantes foi realizada a validação da RNA, e a eficiência da estimativa da produtividade, pela mesma, foi analisada graficamente pela relação 1:1, entre os dados estimados versus os observados e, por meio dos seguintes indicadores estatísticos: coeficiente de correlação (r); índice de concordância de Wilmont (c); coeficiente de determinação (r^2) e índice de desempenho (id).

O coeficiente de correlação (r) permite quantificar o grau de associação entre as duas variáveis envolvidas na análise (SCHNEIDER, 1998), sendo seu campo de variação de -1 a 1 e quanto maior o seu valor absoluto maior o grau de associação entre os valores observados e os valores estimados. O respectivo coeficiente foi obtido pela expressão 3:

$$r = \frac{\sum_{i=1}^n (E_i - E)(O_i - O)}{\sqrt{[\sum_{i=1}^n (E_i - E)] [\sum_{i=1}^n (O_i - O)]}} \quad (3)$$

sendo:

r = coeficiente de correlação de Person;

E_i - valores estimados;

O_i - valores observados;

E - média dos valores estimados;

O - média dos valores observados; e

n - quantidade de padrões de teste.

O índice de concordância, foi expresso pela equação 4

$$c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - O| + |O_i - O|)^2} \quad (4)$$

em que:

c = índice de concordância;

E_i - valores estimados;

O_i - valores observados;

O - média dos valores observados; e

n - quantidade de padrões de teste.

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

Conhecendo-se esses indicadores foi determinado o índice de desempenho id, segundo Camargo e Sentelhas (1997), calculado por: $Id = r.c$.

RESULTADOS E DISCUSSÃO

Foram treinadas 6 redes, com 3 camadas (uma camada de entrada, uma camada intermediária e uma camada de saída). Para representar a arquitetura de uma rede foi utilizada a notação “NE → NCE → NS”, onde NE é o número de entradas da camada de entrada da rede, NCE é o número de neurônios da camada escondida, e NS é o número de neurônios da camada de saída.

A seguir, na tabela 1, são apresentados os resultados dos melhores treinos, após 10 ciclos de treinamento, obtidos em cada arquitetura testada. Nota-se que as redes com arquitetura de 7→20→1 e 7→50→1, apresentaram os menores valores de erro quadrático médio, porém houve um aumento do erro relativo médio e da variância, quando comparadas com as redes de arquiteturas 4→10→1 e 4→30→1, onde se observou uma redução dos valores de erro relativo médio. Isto é, o erro para os dados de treinamento diminui, mas não necessariamente ocorrerá redução para os valores de validação. Deve-se ter cuidado neste caso, pois a rede com muitos neurônios na camada intermediária pode memorizar os padrões de treinamento, ao invés de extrair características para a generalização (produzir saídas adequadas para entradas que não estavam presentes no treinamento) (BRAGA et al., 2000).

Tabela 1. Valores de erro quadrático médio, para dados de treinamento, erro relativo médio e variância para dados de validação, nas diferentes arquiteturas treinadas.

Arquitetura NE→NCE→NS	Erro quadrático médio (treinamento)	Erro relativo médio (validação)	Variância (validação)
7-5-1	16393,63	0,4282	421298,36

7-10-1	20861,05	0,2418	433382,58
7-20-1	14063,53	0,5316	371739,88
7-30-1	14864,26	0,2799	458679,51
7-40-1	16638,33	0,3028	176734,80
7-50-1	9016,35	0,7949	564251,87

Assim, a partir dos menores valores do erro relativo médio e variância para os dados de validação, além do menor número de neurônio na camada escondida, a rede com arquitetura de 7→20→1, foi a que melhor capacidade preditiva apresentou para a produção de flores da cultura do Kalanchoe (tabela 1).

A relação entre a produtividade observada, obtida no experimento, e estimada pela RNA com a arquitetura 7→20→1, no momento da validação, é apresentada na figura 1.




Figura 1. Comparação entre os valores da produção de flores da cultura do Kalanchoe observados, experimentalmente, e estimados, pela rede 7-20-1.

Observa-se que o coeficiente de determinação (R^2) obtido da análise de regressão foi de 0,9003, indicando que considerável parte da variância total dos valores de produtividade da cultura é explicada pela RNA treinada. Contudo, de acordo com Andrade Junior et al. (2006) a adoção do R^2 , como único critério de definição da qualidade do método, não é muito adequada, pois não estabelece o tipo e a magnitude de possíveis covariâncias.

A observação da forma de distribuição dos valores oriundos do ajustamento entre os valores de produção obtidos e estimados, notados na Figura 1, permite deduzir que a estimativa da produção, da cultura do Kalanchoe para a região em estudo, pode ser estimada pela RNA treinada (arquitetura de 7-20-1) Uma vez que existe pequena dispersão dos pontos e, poucos deles estão distantes da reta de inclinação de 45°, sendo que quanto menos distantes estiverem os pontos desta reta, menor é o erro relativo.

Os valores dos coeficientes de correlação “r”, índice de concordância “c”, índice de desempenho “id”, classe de desempenho e erro médio (Δ), no treinamento e validação da rede 7-20-1, são apresentados na tabela 2. Observa-se que ambos os índices estatísticos apresentaram-se elevados, com valores de id superiores a 0,90, o que as classifica quanto ao desempenho comparativo como ótimo. Nota-se, que no treinamento a RNAs apresentou característica de subestimar a produção de flores, enquanto na validação ela superestimou a variável.

Tabela 2. Valores médios de produtividade de flores por planta obtidos experimentalmente e no treinamento e validação da rede neural de arquitetura 7-20-1, para o *Kalanchoe*. Valores do coeficiente de correlação de Person (r), índice de concordância (c) e índice de desempenho (id), obtidos na comparação entre a produtividade de flores, adquiridos em experimento de campo e pela RNA.

Produtividade de flores/planta			Parâmetros estatísticos			
Experimento	RNA	Δ (%)	r	c	id	desempenho
treinamento						
455,07	449,91	1,15	0,9426	0,9695	0,9138	Ótimo
validação						
438,30	489,99	-10,55	0,9488	0,9684	0,9188	ótimo

Guiselini, et al. (2010) utilizando modelo de simulação, com redes neurais artificiais, aplicado à agricultura de precisão, voltado principalmente para a otimização do manejo e reposição de água no solo por meio da predição da evapotranspiração, na produção da *Gerbera jamesonii* cultivada em ambiente protegido, observaram a viabilidade de utilização de RNAs para a predição da evapotranspiração da cultura da *Gérbera* em ambiente protegido com base nas variáveis, temperatura do ar, umidade relativa e radiação solar global.

Andrade Junior et al. (2006), observou que os modelos de simulação testados em seu trabalho, tenderam à superestimativa. Freitas et al. (2004), quando simulando a produtividade do milho pelo modelo CERES-Maize, observou que o modelo subestima a produtividade da cultura, nos tratamentos em que ocorreram déficit hídrico acentuado e, para os tratamentos em que houve aplicação de uma lâmina d'água superior à adequada, o modelo simulou valores pouco superiores aos experimentais.

Assim, a produção de flores do *Kalanchoe*, para região em estudo, pode ser estimada através da RNA com arquitetura 7-20-1. Os resultados encontrados estão de acordo os valores obtidos de Soares et al., (2015), estes encontraram índices de desempenho semelhantes, quando avaliaram o desempenho de redes neurais artificiais na predição da produtividade da cultura do milho, para as condições climáticas de Jaguari/RS.

CONCLUSÕES

Redes neurais artificiais do tipo Perceptron de Múltiplas Camadas são eficientes, podendo ser utilizadas como ferramenta para estimar a produção de flores do *Kalanchoe Blossfeldiana* Poelln.

A rede neural artificial com sete variáveis na camada de entrada (composição dos substratos - cinza da casca de arroz, solo, húmus, comercial e pinha; irrigação total e evapotranspiração da cultura total) e 20 neurônios na camada escondida é capaz de estimar a produção de flores da cultivar ‘Debbie’ de *Kalanchoe*. Essa ferramenta de modelagem vem a somar-se as demais técnicas, na tomada de decisão dos manejos a serem adotados, na hora da implantação da cultura.

AGRADECIMENTOS

Os autores agradecem aos Programas de Desenvolvimento Acadêmico (PDA) e de Apoio a Grupos de Pesquisa (AGP) da Universidade Federal do Pampa pelo auxílio recebido.

REFERÊNCIAS

- ANDRADE JÚNIOR, A. S. et al. Parametrização de modelos agrometeorológicos para estimativa de produtividade da cultura do milho na região de Parnaíba, Piauí. **Revista Ciência Agronômica**, v.37, p.130-134, 2006.
- ARRUDA, G. P. de; DEMATTÊ, J. A. M.; DA SILVA CHAGAS, C. Mapeamento digital de solos por redes neurais artificiais com base na relação solo-paisagem. **Revista Brasileira de Ciência do Solo**, v. 37, n. 2, p. 327-338, 2013.
- ATTOH-OKINE, N. O.; FEKPE, E. K. Strength characteristics modeling of lateritic soils using adaptive neural networks. **Construction and building materials**, v.10, p. 577-582, 1996.
- BORTOLÁS, F. A. **Influência de distintas lâminas de irrigação e percentuais de cinza da casca do arroz em substratos no desenvolvimento de cultivar de *Kalanchoe Blofeldiana* Poelln.** 56 f. Trabalho de conclusão de curso. Curso de Engenharia Agrícola, Universidade Federal do Pampa, 2016.
- BRAGA, A. P. et al. **Redes Neurais Artificiais: teoria e aplicações.** 1 ed. Rio de Janeiro: LTC, 2000.
- CAMARGO, A. P.; SENTELHAS, P. C. Avaliação do desempenho de diferentes métodos de estimativa da evapotranspiração potencial no Estado de São Paulo, Brasil. **Revista Brasileira de Agrometeorologia**, v.5, p.89-97, 1997.
- BUAINAIN, A. M.; BATALHA, M. O. Cadeias produtivas de flores e mel. Brasília: IICA: MAPA/SPA, 2007
- DE FRANÇA, C. A. M. MAIA, M. B. R. Panorama do agronegócio de flores e plantas ornamentais no Brasil. XLVI Congresso da Sociedade Brasileira de Economia, Administração e Sociologia Rural. Universidade Federal de Rondônia, 2008.
- GUISELINI, C. et al. **Uso de redes neurais na predição da evapotranspiração da *Gerbera jamesonii* cultivada em ambiente protegido.** 2010. Disponível em <http://www.sbmet.org.br/cbmet2010/artigos/289_22363.pdf>. Acessado em 11 de maio de 2017.
- SCHNEIDER, P. R. **Análise de regressão aplicada à Engenharia Florestal.** 1.ed. Santa Maria: UFSM/CEPEF, 1998. 236p.
- SOARES, F. C. et al. Predição da produtividade da cultura do milho utilizando rede neural artificial. **Ciência Rural**, v. 45, n. 11, p. 1987-1993, 2015.
- SOARES, F. C. et al. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, Santa Maria, v.44, n.2, p.293-300, fev, 2014.
- Thorntwaite C. W, Mather J. R. **The water balance.** Publications in Climatology. New Jersey: Drexel Institute of Technology; 1955, 104p.
- WILLMONT, C. J. On the validation of models. **Physical Geography**, v. 2, p. 184-194, 1981.
- YOUNG, M. I. et al. New methods and models for characterizing structural heterogeneity of soil. **Soil & Tillage Research**, v. 61, p. 33-45, 2001.
- YOUNG, P. A. The based Culture Model: Constructing the Model of Culture. **Educational & Technology Society**, v. 11, n.2, 107-118, 2008.