

Revista Agrária Acadêmica

Agrarian Academic Journal

Volume 2 – Número 3 – Mai/Jun (2019)

doi: 10.32406/v2n32019/96-105/agrariacad

Predição da área foliar em acerola por redes neurais e regressão múltipla. Prediction leaf area in acerola by neural networks and multiple regression.

Alcinei Místico de Azevedo¹, Vitor Alves da Silveira², Celso Mattes Oliveira³, Carlos Enrik Pedrosa⁴, Vinícius Teixeira Lemos⁴, Nemy Ribeiro Valadares¹, Amanda Gonçalves Guimarães^{5*}

¹- Instituto de Ciências Agrárias/Universidade Federal de Minas Gerais – UFMG - Montes Claros/ MG - Brasil.

²- Universidade Federal de Viçosa UFV - Viçosa/MG - Brasil.

³- Agro Carregal Pesquisa e Proteção de Plantas LTDA - Rio Verde/GO - Brasil.

⁴- Centro de Ciências Agrárias/ Universidade Federal de Lavras - UFLA - Lavras/MG - Brasil

⁵- Centro de Ciências Agrárias/ Universidade Federal dos Vales do Jequitinhonha e Mucuri - UFVJM - Diamantina/MG - Brasil - amandagguimaras@yahoo.com.br

Resumo

O objetivo do trabalho foi prever a área foliar em aceroleira por meio de redes neurais artificiais (RNAs) e verificar a eficiência desta metodologia em comparação com modelos de regressão múltipla. Foram avaliados o comprimento, largura e área de 350 folhas de acerola, testados 14 modelos de regressão múltipla e modelo de RNAs tipo perceptron multicamadas para predição da área foliar. A qualidade de ajuste entre os modelos de regressão múltipla e as RNAs foram próximas, porém as redes neurais artificiais foram mais eficientes na predição da área foliar em aceroleira com coeficiente de determinação superior a 0,98, sendo a rede com dois neurônios na camada intermediária a melhor predição.

Palavras-chave: *Malpighia emarginata*, perceptron multicamadas, importância relativa, método de Garson, inteligência computacional.

Abstract

The objective of this work was to predict the leaf area in acerola by means of artificial neural networks (ANNs) and verify the efficiency of this methodology in comparison to multiple regression models. The length, width and area of 350 leaves of acerola were evaluated, 14 models of multiple regression and model of multilayer perceptron type RNA were used to predict the leaf area. The quality of fit between the multiple regression models and the ANNs was close, but the artificial neural networks were more efficient in the prediction of the leaf area in acerola, with determination coefficient superior to 0,98, being the network with two neurons in the intermediate layer the best prediction

Keywords: *Malpighia emarginata*, multilayer perceptron, relative importance, Garson method, computational intelligence.

Introdução

Em pesquisas com a aceroleira (*Malpighia emarginata*), a obtenção da área foliar é importante, sendo fundamental para estudar aspectos fisiológicos que envolvam análise de crescimento, fotossíntese e transpiração, bem como quantificar os danos causados por pragas e doenças foliares (LUCENA et al., 2011). A área foliar é frequentemente determinada utilizando scanners de mesa ou portátil. Além destes equipamentos serem caros, este método demanda muito tempo, mão-de-obra e geralmente é destrutivo.

Uma alternativa para a obtenção da área foliar é sua estimativa por meio de medidas geométricas como o comprimento e largura do limbo (ODABAS et al., 2013). A vantagem deste método é que a mensuração da largura e comprimento pode ser feita com alta precisão em folhas de acerola, sendo um método barato, rápido, menos laborioso e não destrutivo. O comprimento e largura do limbo foliar tem sido utilizado para a estimativa da área foliar em diversas hortaliças como tomate e pepino (CHO et al., 2007), abobrinha (ROUPHAEL et al., 2006), pimenta (AHMADIAN-MOGHADAM, 2012) e couve (AZEVEDO et al., 2015).

A área foliar geralmente é estimada a partir do comprimento e largura do limbo foliar por regressão linear múltipla (ROUPHAEL et al., 2006, SILVA et al., 2008). Porém, a capacidade das redes neurais artificiais (RNAs) em modelar problemas complexos (AZEVEDO et al., 2015), frequentemente, as tornam mais úteis para este objetivo (AHMADIAN-MOGHADAM, 2012; ODABAS et al., 2013).

As RNAs podem ser descritas como um modelo computacional e matemático, baseado na estrutura e no funcionamento do sistema nervoso humano (BRAGA, et al., 2000; MOGHADAM, 2012). As RNAs tornam-se bastante vantajosas, pois são uma alternativa como aproximadores universais de funções complexas, são não paramétricas, não necessitam de informações detalhadas sobre o sistema a ser modelado, toleram perda de dados e possibilitam o ajuste de fenômenos de natureza linear e não linear (AZEVEDO et al., 2015). Seu processamento começa com a leitura de uma base de dados, que é basicamente a fonte de conhecimento a ser adquirido pela rede durante a etapa de aprendizagem, que por sua vez é responsável pelo processo de aquisição do conhecimento contido na base de dados através do ajuste dos pesos sinápticos (HAYKIN, 2001).

No processo de aprendizagem das RNAs pode ser feito seguindo três paradigmas: supervisionado, não supervisionado e híbrido. No aprendizado supervisionado, o treinamento necessita da apresentação das variáveis independentes e da(s) variável(is) dependente(s). Neste caso, os pesos sinápticos são ajustados de forma a possibilitar que as respostas preditas sejam mais próximas o possível da resposta conhecida (JUTRAS et al., 2009).

Dentre os tipos de RNAs de aprendizado supervisionado está o perceptron multicamadas (MLP - Multi-Layer Perceptron). O MLP vêm sendo aplicadas em várias áreas da ciência, como Biologia, Ecologia, Física, Química, Economia, Medicina, Matemática e Ciências da Computação (SAMBORSKA et al., 2014). Suas potencialidades nas Ciências Agrárias são inúmeras, e tem sido aplicadas para a predição do volume de madeira em espécies florestais (NISKA et al., 2010), identificação automática de espécies daninhas (TYYSTJAVI et al., 2011), predição do teor de carotenoides em tomate e pimenta (PAN et al., 2013), identificação de deficiência nutricional em algodoeiro (SARTIN et al., 2014), identificação de deficiência nutricional em mamoeiro (SARTIN; SILVA, 2014), identificação de pragas em maçã (BONIECKI et al., 2015), etc.

Para o uso das RNAs algumas informações são importantes, como a eficiência da rede treinada, a melhor arquitetura de rede e a importância das variáveis explicativas no processo de predição

(AZEVEDO et al., 2015). O conhecimento da importância das variáveis explicativas na predição torna possível o melhor entendimento do processo biológico modelado. Além disso, quando são avaliadas muitas características, permite o descarte das variáveis menos importantes, reduzindo a complexidade das RNAs, o esforço computacional, o tempo para o treinamento da rede, e a mão-de-obra, tempo e gastos financeiros na obtenção dos dados (GEVREY et al., 2003).

Logo, objetivou-se prever a área foliar em aceroleira por meio de redes neurais artificiais e verificar a eficiência desta metodologia em comparação com modelos de regressão múltipla.

Materiais e métodos

Foram colhidas 350 folhas em plantas de aceroleira no município de Viçosa – MG. No processo de amostragem, as folhas foram selecionadas de forma aleatória, a fim de garantir a avaliação de folhas de diferentes tamanhos e formatos. Em cada folha foram mensurados a largura e comprimento do limbo. Posteriormente, as folhas foram escaneadas utilizando o Scanner HP Photosmart C4480, e a área foliar foi estimada com o auxílio do software Image Pro Plus 4.5.

Para a melhor eficiência no treinamento das redes tanto os dados de entrada (comprimento e largura do limbo) quanto os de saída (área foliar) foram normalizados para o intervalo entre 0 e 1 pela seguinte equação: $V_n = [1 + (V_{obs} - V_{max})] / (V_{max} - V_{min})$ em que: V_n é o valor normalizado, V_{obs} , o valor observado; V_{max} é o valor máximo da amostra; e, V_{min} , o valor mínimo da amostra. Os valores máximos e mínimos encontrados para cada uma das variáveis são apresentados no Quadro 1. Para a normalização, utilizou-se a função *normalizeData* do pacote *RSNNS* (BERGMEIR; BENÍTEZ, 2012), disponível no software R (R CORE TEAM, 2017).

No processo de treinamento das RNAs foram utilizados os dados de comprimento e largura do limbo foliar como variáveis de entrada e a área foliar observada como saída desejada. Foram utilizados 70% dos dados (informação de 245 folhas) para o treinamento da rede e 30% para teste (informação de 105 folhas). Para garantir que as amostras fossem distribuídas aleatoriamente entre o conjunto de treinamento e teste, as amostras foram aleatorizadas com auxílio da função *sample* do pacote *base*. Para dividir o conjunto de dados em amostras para treinamento e teste foi utilizada a função *splitForTrainingAndTest* do pacote *RSNNS*.

O desenvolvimento das redes MLP (*Multi-Layer-Perceptron*) foi utilizada a função *mlp* do pacote *RSNNS* com algoritmo *backpropagation* (*learnFunc = "Std_Backpropagation"*) e taxa de aprendizado de 0,1 (*learnFuncParams=0.1*). O número máximo de épocas de treinamento foi arbitrado como 500 (*maxit = 500*), a função de ativação para a camada intermediária foi a logística (*hiddenActFunc = "Act_Logistic"*) e da camada de saída foi linear (*linOut = TRUE*). Para saber qual é a melhor arquitetura de rede, foram testadas 10 configurações de rede (1, 2, 3, ..., 9 e 10 neurônios na camada intermediária). Cada arquitetura de rede foi testada 100 vezes, armazenando seus respectivos erros quadráticos médios (EQM) para a amostra de teste. Para o cálculo do EQM para a amostra de teste foi considerada a expressão $EQM = \sum_{i=1}^n (X_{pred_i} - X_{obs_i})^2 / n$, onde X_{pred_i} é o valor predito pela rede, X_{obs_i} é o valor real (mensurado) e n é o tamanho da amostra (105 folhas). A melhor arquitetura de rede foi estabelecida pela menor média do EQM. Foram feitos 1000 treinamentos para a melhor arquitetura de rede selecionada na etapa anterior. Destes 1000 treinamentos, foi selecionada a rede que apresentou o menor EQM na amostra de teste (AQUINO et al., 2016; AZEVEDO et al., 2015).

Para a melhor rede selecionada foi obtido o diagrama com a arquitetura da rede utilizando a função *plotnet* (pacote *NeuralNetTools*). Além disso, foi obtido o gráfico iterativo do EQM com a

função *plotIterativeError* (pacote RSNNS) e a importância relativa das características de entrada, utilizando o método de Garson (1991) pela função *garson* (pacote NeuralNetTools). A visualização da eficiência do treinamento das redes foi feita a regressão da área foliar predita com a observada para a amostra de treinamento e teste.

Para a obtenção dos dados para plotar os gráficos de superfície resposta da área foliar em função do comprimento e largura do limbo foram utilizadas as funções *expand.grid* e *predict* (pacote RSNNS). É válido lembrar que os valores preditos pelas RNAs são normalizados (escala variando entre 0 e 1), e consequentemente, devem ser desnormalizados para a obtenção da escala desejada (cm²). Para a desnormalização utilizou-se a função *denormalizeData* (pacote RSNNS), a qual considera a expressão $V_{dn} = V_{max} + (V_n - 1) * (V_{max} - V_{min})$ em que: V_n é o valor normalizado; V_n , o valor normalizado; V_{min} , é o valor mínimo da amostra e V_{max} o valor máximo da amostra. A partir dos dados preditos pela rede, foram feitos gráficos de superfície resposta com o auxílio do software Sigma Plot v.11.

Para verificar a eficiência das RNAs em comparação com métodos utilizados tradicionalmente, foram testados 14 modelos de regressão múltipla. Os modelos foram ajustados com os dados da amostra de treinamento, e a qualidade do ajuste foi comparado pelos coeficientes de determinação (R²) obtidos para a amostra de treinamento e teste. Para isso, foi utilizada no software R (R CORE TEAM, 2017) a função *lm* (pacote *stats*).

Resultados e discussão

Houve grande variação para o tamanho de folhas com área foliar, divergindo de 0,602 cm² a 22,424 cm² com coeficiente de variação de 65,254% (Quadro 1). Também foram encontradas altas estimativas para os coeficientes de variação do comprimento e largura do limbo foliar com 33,255% e 33,015%, respectivamente. Segundo Wang e Zhang (2012) e Fallovo et al. (2008) a eficiência e generalização na predição da área foliar pelas depende da variação do formato e dimensão da folha na amostra utilizada no treinamento, pode alterar o coeficiente dos modelos de estimação, nos quais estes autores utilizaram nas culturas de *Saussurea stoliczkai* C. B em Tibete na Ásia (WANG; ZHANG, 2012); e *Rubus idaeus* L., *Ribes rubrum* L., *Rubus fruticosus* L., *Ribes grossularia* L. e *Vaccinium corymbosum* L na Itália (FALLOVO et al., 2008).

Quadro 1. Análise descritiva e correlação de Pearson entre as características comprimento, largura e área do limbo foliar em aceroleira.

Parâmetros	Análise descritiva		
	Comprimento do limbo	Largura do limbo	Área foliar
Mínimo	1.100 cm	0.600 cm	0.602 cm ²
Máximo	7.800 cm	4.500 cm	22.424 cm ²
Média	3.778 cm	2.107 cm	5.912 cm ²
Desvio padrão	1.256 cm	0.696 cm	3.858 cm ²
Coeficiente de variação	33.255%	33.015%	65.254%
Características	Correlação de Pearson		
	Comprimento do limbo	Largura do limbo	Área foliar
Comprimento do limbo	1.000	0.921	0.957
Largura do limbo	0.921	1.000	0.951
Área foliar	0.957	0.951	1.000

A partir da média do $EQM_{(med)}$ dos 100 treinamentos de cada arquitetura de rede, observam-se valores entre $5,54 \times 10^{-4}$ e $7,24 \times 10^{-4}$ (Figura 1a). As menores médias para o $EQM_{(med)}$ foram encontradas para as redes com dois e três neurônios na camada intermediária, com $5,54 \times 10^{-4}$ e $5,56 \times 10^{-4}$, respectivamente. Menores estimativas para o EQM indicam a maior proximidade entre os valores reais e os preditos pelas RNAs, ou seja, indica a maior eficiência das redes. O EQM é ser usado como uma medida do erro de previsão. Quando a previsão é muito baixa fornece uma melhor percepção sobre o quão precisa pode ser a previsão (STEVENSON, 1996). Desta forma, a melhor arquitetura de rede testada neste estudo foi com dois neurônios na camada intermediária (Figura 1b). Sabendo que com dois neurônios na camada intermediária têm-se em média melhores resultados, pode-se efetuar um número maior de treinamentos com esta arquitetura, a fim de aumentar a possibilidade de encontrar uma rede de melhor ajuste (com menor EQM). Esta estratégia é viável por reduzir o esforço computacional com muitos treinamentos em redes de arquitetura com baixo desempenho.

O aumento do número de neurônios por camada nem sempre garante o melhor desempenho da rede. Isso, porque, muitos neurônios nessa camada podem fornecer excelentes resultados para os dados de treinamento, mas, para os dados de validação, os resultados podem ser totalmente imprecisos (SILVA et al., 2010). SOARES et al. (2014) e AZEVEDO et al. (2015), encontraram resultados semelhantes no presente trabalho, em que o aumento do número de neurônios na camada não proporcionou uma redução expressiva do erro do quadrado médio.

Verifica-se que o EQM para a amostra de treinamento e teste reduziu de acordo com o aumento do número de iterações (Figura 1c). A redução do EQM para a amostra de treinamento com o desenvolvimento do processo iterativo é esperado, porém, nem sempre isso ocorre na amostra de teste devido a um problema denominado *overfitting*. O *overfitting* ocorre quando no processo de treinamento a rede decora os dados da amostra de treinamento, e não identifica as associações existentes entre os dados apresentados na camada de entrada e de saída (SILVA et al., 2010). Neste caso, é encontrado bom ajuste para a amostra de treinamento, porém para a amostra de teste é encontrado ajuste menor, devido o problema *overfitting*. Desta forma, a eficiência da rede deve ser sempre verificada com uma amostra cujos dados não foram utilizados no processo de treinamento, que é a amostra de teste.

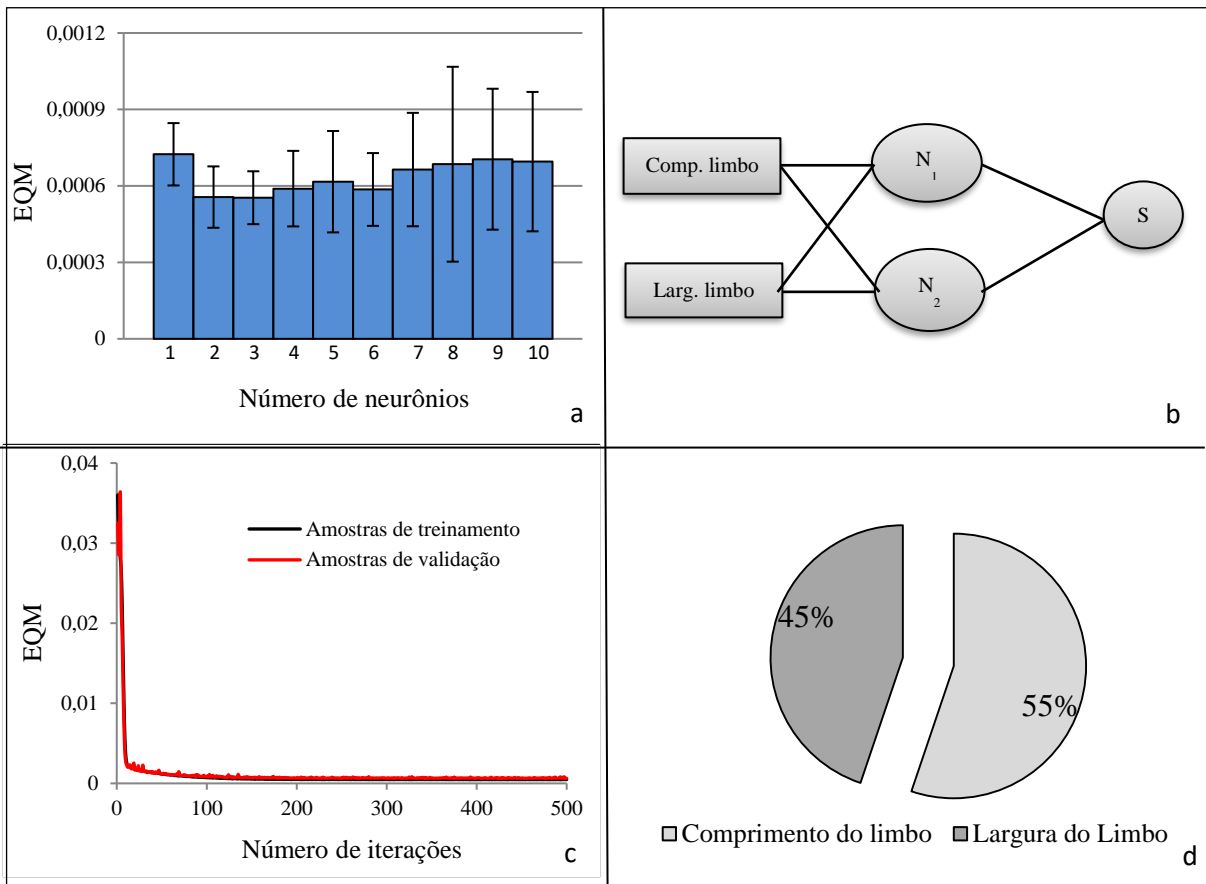


Figura 1. Média e desvio padrão do erro quadrático médio (EQM) para diferentes números de neurônios na camada intermediária (a), diagrama da rede selecionada (b), gráfico iterativo do EQM (c) e contribuição relativa pelo método Garson (1991) das características apresentadas na camada de entrada (d).

Neste trabalho foi utilizado o comprimento e largura do limbo como informações da camada de entrada (variáveis explicativas) e a área foliar observada na camada de saída (variável dependente). Uma informação útil é saber qual variável explicativa têm maior importância no processo de predição pelas RNAs. Para isso, uma alternativa é o uso do método Garson (1991) que indicou como mais importante o comprimento do limbo foliar, com importância relativa de 55% (Figura 1d).

A maior importância do comprimento do limbo na predição da área foliar é esperada, pois há maior correlação entre estas características (0,957) quando comparada com a estimativa entre a largura e área foliar (0,951) (Quadro 1). Este tipo de estudo ganha maior importância quando é avaliado um maior número de características, principalmente quando se torna vantajoso a exclusão de características para a redução de mão-de-obra e esforço computacional (PALIWAL; KUMAR, 2011).

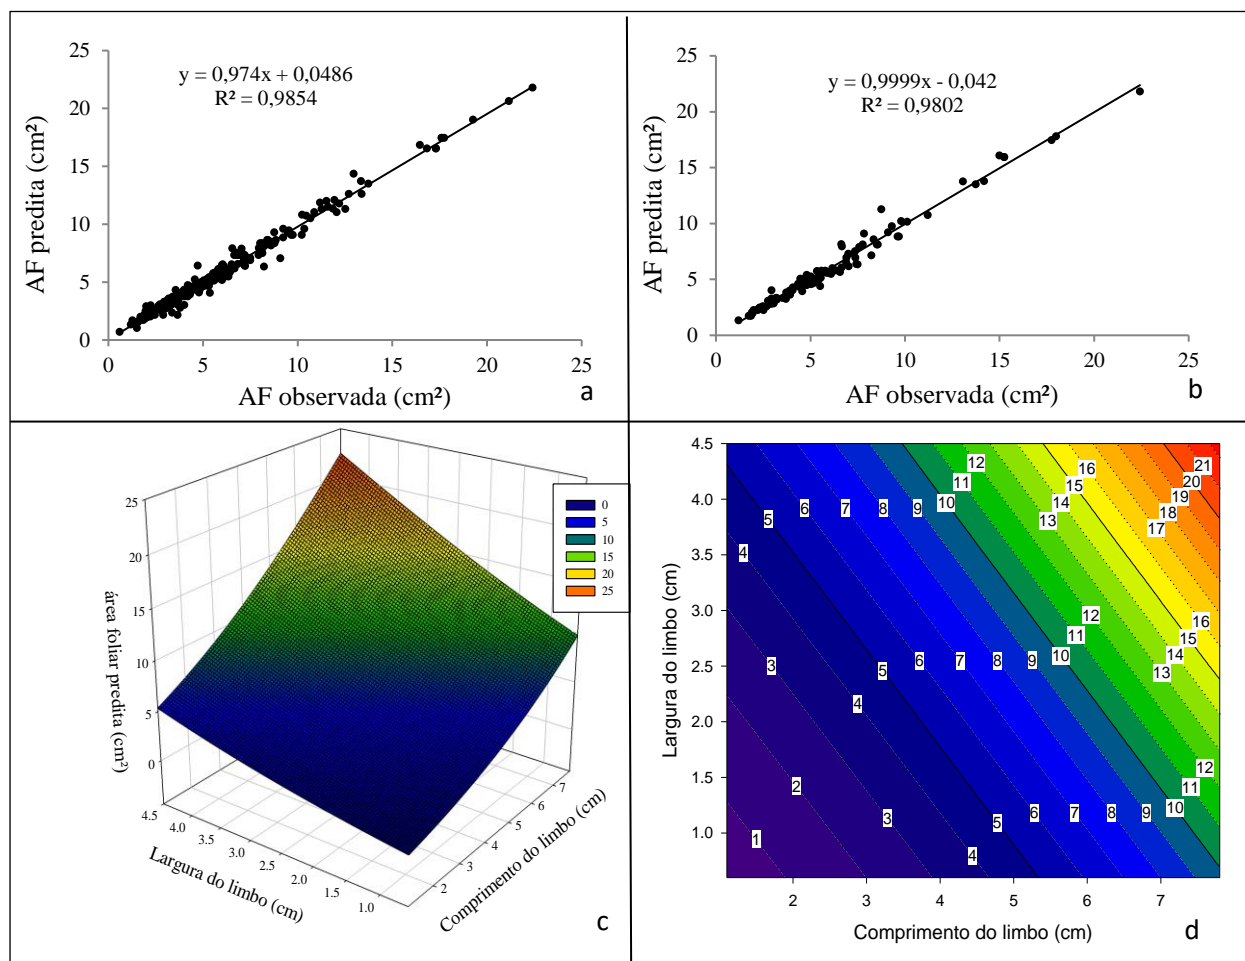


Figura 2. Regressão entre as estimativas da área foliar (AF) predita e observada para a amostra de treinamento (a) e amostra de teste (b) e gráficos de superfície resposta da área foliar predita (cm^2) em função da largura e comprimento do limbo (c e d).

Uma alta estimativa de correlação (0,9927) foi encontrada entre os valores preditos e observados da área foliar na amostra de treinamento, resultando no coeficiente de determinação de 0,9854 (Figura 2a). Estas estimativas são superiores às encontradas por Lucena et al. (2011) na predição da área foliar em aceroleira utilizando papel quadriculado ($R^2 = 0,923$), regressão linear ($R^2 = 0,910$), integrador de área foliar ($R^2 = 0,977$) e métodos dos discos foliares ($R^2 = 0,858$). Para a amostra de teste foi encontrado o coeficiente de determinação de 0,9802 (Figura 2b). Em trabalho similar com a cultura da pimenta, Ahmadian (2012) encontrou resultados próximos ao encontrado neste trabalho na amostra de teste ($R^2=98\%$). Odabas et al. (2013) estudando a predição da área foliar em plantas de milho por RNAs também encontraram coeficiente de determinação de 98%.

Neste trabalho, verificou-se ligeira superioridade das RNAs em relação à modelagem por meio de regressão múltipla (Quadro 2), possibilitando maiores estimativas do coeficiente de determinação. Isto concorda com Odabas et al. (2013), os quais afirmam que a RNA é uma ferramenta fácil e eficiente para estimar a área foliar a partir de medidas do limbo foliar. Para a melhor aplicabilidade deste trabalho, é apresentado nas figuras 2c e 2d a área foliar predita por RNAs em função de diferentes valores de comprimento e largura do limbo. A partir destas figuras é possível que pesquisadores consigam prever a área foliar em aceroleiras conhecendo apenas o comprimento e largura do limbo.

Quadro 2. Modelos de regressão múltipla ajustados para a predição da área foliar (z_i) em aceroleira por meio do comprimento (x_i) e largura (y_i) do limbo foliar.

Modelos	Função	R ²	
		Amostra de treinamento	Amostra de teste
1	$z_i = -5,2565^{***} + 2,9581^{***} x_i$	0,9041	0,9139
2	$z_i = -5,2032^{***} + 5,2559^{***} y_i$	0,8766	0,9407
3	$z_i = -5,7367^{***} + 1,7887^{***} x_i + 2,3156^{***} y_i$	0,9334	0,9492
4	$z_i = 0,1733^{ns} - 0,9523^{***} x_i + 0,3572^{***} x_i^2 + 1,7323^{***} y_i$	0,9723	0,9738
5	$z_i = -0,3718^{ns} + 1,886^{***} x_i - 2,7342^{***} y_i + 0,9948^{***} y_i^2$	0,9639	0,9711
6	$z_i = 0,2553^{ns} - 0,7386^{**} x_i + 0,3306^{***} x_i^2 + 1,2842^{**} y_i + 0,0968^{ns} y_i^2$	0,9723	0,9740
7	$z_i = 0,4241^{ns} + 0,3303^{***} x_i - 0,7037^{***} y_i + 0,6507^{***} x_i y_i$	0,9738	0,9748
8	$z_i = 0,4431^{ns} + 0,0143^{ns} x_i + 0,0829^{ns} x_i^2 - 0,1762^{ns} y_i + 0,5078^{***} x_i y_i$	0,9740	0,9749
9	$z_i = 0,1624^{ns} - 0,8167^{***} x_i + 1,5645^{***} y_i - 0,8795^{***} y_i^2 + 1,1241^{***} x_i y_i$	0,9763	0,9758
10	$z_i = 0,0363^{ns} - 0,4834^{*} x_i - 0,1838^{**} x_i^2 + 1,1213^{**} y_i + 1,1613^{***} y_i^2 + 1,5926^{***} x_i y_i$	0,9767	0,9759
11	$z_i = -2,0032^{**} + 0,5107^{ns} x_i - 0,3006^{***} x_i^2 + 2,2327^{***} y_i - 1,1891^{***} y_i^2 + 1,1167^{***} x_i y_i + 0,0520^{**} x_i^2 y_i$	0,9774	0,9760
12	$z_i = -1,9364^{**} + 0,0013^{ns} x_i - 0,1587^{*} x_i^2 + 3,0245^{***} y_i - 1,5032^{***} y_i^2 + 1,0712^{***} x_i y_i + 0,0881^{***} x_i y_i^2$	0,9773	0,9760
13	$z_i = -2,0189^{**} + 0,3627^{ns} x_i - 0,2564^{ns} x_i^2 + 2,5117^{*} y_i - 1,2922^{***} y_i^2 + 1,0931^{***} x_i y_i + 0,0360^{ns} x_i^2 y_i + 0,0288^{ns} x_i y_i^2$	0,9774	0,9760
14	$z_i = 2,0664^{ns} - 1,7876^{ns} x_i - 0,0322^{ns} x_i^2 - 1,5208^{ns} y_i - 0,4228^{ns} y_i^2 + 3,1704^{***} x_i y_i - 0,1829^{*} x_i^2 y_i - 0,4076^{*} x_i y_i^2 + 0,0455^{**} x_i^2 y_i^2$	0,9778	0,9765

Estimativas de coeficientes seguidos de ^{***}, ^{**} e ^{*} referem-se à sua significância pelo teste t ao nível nominal de 0,1%, 1% e 5% de significância, respectivamente. Estimativas de coeficientes seguidos de ^{ns} referem-se à sua não significância pelo teste t ao nível nominal de 5% de significância. As letras e_i referem-se ao efeito do erro na i-ésima observação.

Conclusão

As redes neurais artificiais são mais eficientes na predição da área foliar em aceroleira que os modelos de regressão múltipla testados, com coeficiente de determinação superior a 0,98, sendo a arquitetura de rede com dois neurônios na camada intermediária a de melhor predição da área foliar. A regressão múltipla também pode ser utilizada para a predição com pouca perda na qualidade do ajuste, caso não se queira recorrer ao maior esforço computacional.

Referências bibliográficas

- AHMADIAN-MOGHADAM, H. Prediction of pepper (*Capsicum annuum* L.) leaf area using group method of data handling-type neural networks. **International Journal of AgriScience**, v. 2, n. 11, p. 993-999, 2012.
- AQUINO, C.F., SALOMÃO, L.C.C.; AZEVEDO, A.M. Qualidade pós-colheita de banana 'Maçã' tratada com ácido giberélico avaliada por redes neurais artificiais. **Pesquisa Agropecuária Brasileira**, v. 51, n. 7, p. 824-833, 2016.
- AZEVEDO, A.M.; ANDRADE JÚNIOR, V.C.; PEDROSA, C.E.; OLIVEIRA, C.M.; DORNAS, M.F.S.; CRUZ, C.D.; VALADARES, N.R. Application of artificial neural networks in indirect selection: a case study on the breeding of lettuce. **Bragantia**, v.74, n. 4, p. 10-28, 2015.

- BERGMEIR, C.; BENÍTEZ, M.J. Neural Networks in R Using the Stuttgart Neural Network Simulator: RSNNS. **Journal of Statistical Software**, v. 46, n. 7, p. 1-26, 2012.
- BONIECKI, P.; KOSZELA, K.; PIEKARSKA-BONIECKA, H.; WERES, J.; ZABOROWICZ, M.; KUJAWA, S.; MAJEWSKI, A.; RABA, B. Neural identification of selected apple pests. **Computers and Electronics in Agriculture**, v. 110, p. 9-16, 2015.
- BRAGA, A.; CARVALHO, A.; LUDERMIR, T. **Redes Neurais Artificiais: Teoria e Aplicações**, Rio de Janeiro: Livros Técnicos e Científicos, 2000.
- CHO, Y.Y.; OH, S.; OH, M.M.; SON, J.E. Estimation of individual leaf area, fresh weight, and dry weight of hydroponically grown cucumbers (*Cucumis sativus* L.) using leaf length, width, and SPAD value. **Scientia Horticulturae**, v. 111, n. 4, p. 330-334, 2007.
- FALLOVO, C.; CRISTOFORI, V.; GYVES, E. M.; RIVERA, C. M.; REA, R.; FANASCA, S. Leaf Area Estimation Model for Small Fruits from Linear Measurements. **Hortscience**, v. 43, n. 7, p. 2263-2267, 2008.
- GARSON, G.D. Interpreting neural-network connection weights. **Journal AI Expert**, v. 6, n.4, p. 47-51, 1981.
- GEVREY, M.; DIMOPOULOS, I.; LEK, S. Review and comparison of methods to study the contribution of variables in artificial neural network models. **Ecological Modelling**, v. 160, n. 3, p. 249-264, 2003.
- JUTRAS, P.; PRASHER, S.O.; MEHURYS, G.R. Prediction of street tree morphological parameters using artificial neural networks. **Computers and Electronics in Agriculture**, v. 67, n. 1-2, p. 9-17, 2009.
- HAYKIN, S. **Redes Neurais – Princípios e Práticas**. 2. ed. Porto Alegre: Bookman, 2001.
- LUCENA, R.R.M.; BATISTA, T.M.V.; DOMBROSKI, J.L.D.; LOPES, W.A.R.; RODRIGUES, G.S.O. Medição de área foliar de aceroleira. **Revista Caatinga**, v. 24, n. 2, p. 40-45, 2011.
- MOGHADAM, A. Prediction of Pepper (*Capsicum Annuum* L.) Leaf Area Using Group Method of Data Handling-type Neural Networks. **International Journal of AgriScience**, v. 2, p. 993-999, 2012.
- NISKA, H.; SKÖN, J.P.; PACKALÉN, P.; TOKOLA, T.; MALTAMO, M.; KOLEHMAINEN, M. Neural Networks for the Prediction of Species-Specific Plot Volumes Using Airborne Laser Scanning and Aerial Photographs. **IEEE Transactions on Geoscience and Remote Sensing**, v. 48, n. 3, p. 1076-1085, 2010.
- ODABAS, M.S.; ERGUN, E.; ONER, F. Artificial neural network approach for the prediction of the corn (*Zea mays* L.) leaf area. **Bulgarian Journal of Agricultural Science**, v. 19, n. 4, p. 766-769, 2013.
- PALIWAL, M.; KUMAR, U.A. Assessing the contribution of variables in feed forward neural network. **Applied Soft Computing**, v. 11, n. 4, p. 3690-3696, 2011.
- PAN, Y.; BRADLEY, G.; PYKE, K.; BALL, G.; LU, C.; FRAY, R.; MARSHALL, G.; JAYASUTA, S.; BAXTER, C. Network Inference Analysis Identifies an APRR2-Like Gene Linked to Pigment Accumulation in Tomato and Pepper Fruits. **Plant Physiology**, v. 161, n. 3, p. 1476-1485, 2013.
- R CORE TEAM. R: A language and environment for statistical computing. **R Foundation for Statistical Computing**, Vienna, Austria, 2017. Disponível em URL: <http://www.r-project.org/>.
- ROUPHAEL, Y.; RIVERA, C.M.; CARDARELLI, M.; FANASCA, S.; COLLA, G. Leaf area estimation from linear measurements in zucchini plants of different ages. **Journal of Horticultural Science and Biotechnology**, v. 81, n. 2, p. 238-241, 2006.
- SAMBORSKA, I.A.; ALEXANDROV, V.; SIECZKO, L.; GOLTSEV, B. K. V.; CETNER, M. D.; KALAJI, H.M. Artificial neural networks and their application in biological and agricultural research. **Signpost Open Access Journal Nano Photo Bio Sciences**, v. 2, p. 14-30, 2014.
- SARTIN, A.; SILVA, A.C.R. Evaluation of Image Segmentation and Filtering with Ann in the Papaya Leaf. **International Journal of Computer Science e Information Technology**, v. 6, n. 1, p. 47-58, 2014.

SARTIN, M.A.; DA SILVA, A.C.R.; KAPPES, C. Image segmentation with artificial neural network for nutrient deficiency in cotton crop. **Journal of Computer Science**, v. 10, n. 6, p. 1084-1093, 2014.

SILVA, S.H.M.G.; LIMA, J.D.; BENDINI, H.N.; NOMURA, E.S.; MORAES, W.S. Estimativa da área foliar do antúrio com o uso de funções de regressão. **Ciência Rural**, v. 38, n. 1, p. 243-246. 2008.

SILVA, I. N.; SPATTID.; FLAUZINO, R. Redes neurais artificiais para engenharia e ciências aplicadas: curso prático. São Paulo: Artliber Editora Ltda, 2010, 399p.

SOARES, F.C.; ROBAINA, A.D.; PEITER, M.X.; RUSSI, J.L.; VIVAN, G.A. Redes neurais artificiais na estimativa da retenção de água do solo. **Ciência Rural**, v. 44, n. 2, p. 293-300, 2014.

STEVENSON, W.J. **Production / operations management**. 5ª ed. Chicago: Irwin, 1996.

TYYSTJARVI, E.; NORREMARK, M.; MATTILA, H.; KERANEN, M.; HAKALA-YATKIN, M.; OTTOSEN, C.O.; ROSENQVIST, E. Automatic identification of crop and weed species with chlorophyll fluorescence induction curves. **Precision Agriculture**, v. 12, n. 4, p. 546–563, 2011.

WANG, Z.; ZHANG, L. Leaf shape alters the coefficients of leaf area estimation models for *Saussurea stoliczkai* in central Tibet. **Photosynthetica**, v. 50, n. 3, p. 337-342, 2012.

Recebido em 12 de março de 2019

Aceito em 05 de maio de 2019