

USO DE REDE NEURAL ARTIFICIAL PARA PREDIÇÃO DA PRODUÇÃO NA CULTURA DO FEIJOEIRO

FÁTIMA C. SOARES¹, JUMAR L. RUSSI², ADROALDO DIAS ROBAINA³, MARCIA XAVIER PEITER⁴, ANA R. COSTENARO PARIZI⁵

¹Eng^a Agrícola, Prof^a Adjunta, Curso de Eng. Agrícola, Universidade Federal do Pampa – Campus de Alegrete/ Alegrete-RS; ²Eng^o Eletricista, Prof^o Adjunto, Universidade Federal do Pampa – Campus de Alegrete/Alegrete-RS, fone (55)8117-7002, jrussi@gmail.com; ³Eng^o Agrônomo, Prof^o Titular, Universidade Federal de Santa Maria/Santa Maria-RS, ⁴Eng^a Agrônomo, Prof^a Adjunta, Universidade Federal de Santa Maria/Santa Maria-RS; ⁵Eng^a Agrícola, Prof^a Adjunta, Instituto Federal Farroupilha – Campus de Alegrete/Alegrete-RS;

Apresentado no
XLIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2014
27 a 31 de julho de 2014- Campo Grande- MS, Brasil

RESUMO: Este estudo objetivou avaliar o desempenho de redes neurais artificiais na predição da produtividade da cultura do feijão, na região Fronteira Oeste do Estado do Rio Grande do Sul, com base em variáveis morfológicas da cultura. Para treinamento e validação das redes neurais, utilizaram-se dados de experimento conduzido no município de Alegrete/RS, na safra 2012/2013, em área com 720 m² e suplementação hídrica. Testou-se diversas arquiteturas de redes neurais (variando-se o número de neurônios na camada escondida), do tipo perceptron multicamadas com algoritmo backpropagation otimizado (Levenberg-Marquardt). As mesmas tiveram como variáveis na camada de entrada: matéria seca total (g); altura de planta (cm) e n^o de planta.m⁻², na camada de saída: produção de grãos (kg.ha⁻¹). 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 graficamente pela relação 1:1, entre os dados estimados versus os observados e, por meio de indicadores estatísticos. A rede neural artificial implementada obteve um desempenho ótimo na previsão de produção, sendo que a rede que obteve melhor resultado possui a arquitetura: 3-30-1.

PALAVRAS-CHAVE: inteligência artificial, produção, feijoeiro.

USE OF ARTIFICIAL NEURAL NETWORK FOR PREDICTION OF PRODUCTION IN CULTURE BEAN

ABSTRACT: This study aimed to evaluate the performance of artificial neural networks in predicting the productivity of the bean in West Frontier region of Rio Grande do Sul, based on morphological traits of the crop. The training and validation of neural networks, we used data from an experiment conducted in the municipality of Alegrete/RS, the 2012/2013 harvest, with 720 m² in area and water supplementation. We tested several neural network architectures (varying the number of neurons in the hidden layer) of the multilayer perceptron type with optimized backpropagation algorithm (Marquardt - Levenberg). Were the same as variables in the input layer: Total dry matter (g), plant height (cm) and number of planta.m⁻²,

and in the output layer: grain yield (kg ha^{-1}). Each architecture was trained 10 times, by choosing the end of training the one with lower mean relative error and less variance in relation to data validation. The efficiency of the network was analyzed graphically by the ratio 1:1 between the estimated and the observed versus data by means of statistical indicators. The implemented neural network achieved a great performance in the production forecast, and the network that had the best result has the architecture: 3-30-1.

KEYWORDS: artificial intelligence, production, bean.

INTRODUÇÃO: A estimativa da produtividade agrícola por meio de modelos matemáticos visa simular ou estabelecer relações entre as condições de crescimento das culturas e sua produtividade. Os modelos de estimativa de produtividade podem ser divididos em lineares e não lineares. Nos modelos lineares, a solução do problema é única, ou seja, obtém-se uma forma analítica de estimação dos parâmetros, e esta forma é igual para qualquer modelo e qualquer conjunto de dados, um exemplo são os modelos de regressão lineares (DRAPER e SMITH, 1966). Já os modelos não-lineares não fazem uma descrição puramente empírica do fenômeno em estudo, trabalham na obtenção de uma relação teórica entre as variáveis observáveis de interesse a partir de suposições importantes sobre o problema. Uma vantagem desses modelos não-lineares é adquirir parâmetros que são facilmente interpretáveis. Dentre os modelos não lineares, uma ferramenta que vem ganhando espaço no meio agrícola, são metodologias utilizando redes neurais artificiais (RNAs). O uso recente dos sistemas inteligentes neste setor, tem promovido interessantes respostas nos sistemas de produção agrícola (MURASE, 2000). O mesmo autor afirma que a aplicabilidade dessas novas técnicas é crescente e o custo de implantação sofre um decréscimo constante, permitindo sua inserção no meio rural. O sucesso das redes neurais está diretamente relacionado com a sua alta versatilidade, pois existem aplicações para as mais diversas áreas, e isto faz delas uma tecnologia bastante promissora para o desenvolvimento de aplicações na agropecuária. As redes neurais artificiais são algoritmos computacionais que apresentam um modelo matemático inspirado na estrutura neural de organismos inteligentes tentando emular em máquinas (computadores) o funcionamento do cérebro humano, ainda que de maneira simplificada. Assim como o cérebro humano, a RNA é capaz de aprender e tomar decisões baseadas em seu próprio aprendizado. Desta forma, a RNA pode ser interpretada como um esquema de processamento capaz de armazenar conhecimento baseado em aprendizagem (experiência) e disponibilizar este conhecimento para a aplicação em questão. As RNAs são amplamente utilizadas para soluções de problemas complexos, onde o comportamento das variáveis não é rigorosamente conhecido (AZEVEDO et al., 2000; BARRETO, 1997; BRAGA et al., 2000). Diante disto, o presente trabalho teve por objetivo avaliar o desempenho de redes neurais artificiais na predição da produtividade da cultura do feijão, na região Fronteira Oeste do Estado do Rio Grande do Sul, com base em variáveis morfológicas da cultura.

MATERIAL E MÉTODOS: Os dados utilizados para gerar o modelo de produção, foram obtidos de experimento desenvolvido no município de Alegrete, região Fronteira Oeste do Estado do Rio Grande do Sul, localizado na latitude de $29^{\circ}47'01,63''\text{S}$, longitude de $55^{\circ}47'27,54''\text{W}$ e a 102 m de altitude. A cultura do feijão foi semeada, na safra 2012/2013, em sistema plantio direto e, durante todo o ciclo foram aplicadas lâminas de irrigação, através de sistema de irrigação tipo aspersão. 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 três variáveis, variando-se o número de neurônios na camada intermediária, treinou-se redes com 10 a 50 neurônios na camada escondida, fazendo-se incremento de 10 neurônios. E um único neurônio na camada de saída. As variáveis de entrada na RNA foram: matéria seca total (g); altura de planta (cm) e número de planta por metro quadrado. A variável de saída foi produção de grãos (kg.ha⁻¹). As variáveis de entrada, foram coletadas no final do ciclo da cultura do feijão, aos 106 dias após a semeadura (DAS). A altura da planta foi realizada medindo-se a distância vertical entre a superfície do solo e o ponto de inserção da última folha utilizando-se trena graduada, obtendo-se assim a altura média por planta. As plantas utilizadas na avaliação anterior eram cortadas rente ao solo, e colocadas em estufa, a fim de observar-se a matéria seca total. A estimativa da produção de grãos (Kg.ha⁻¹), da cultura do feijão, foi realizada com a utilização dos componentes de produção, da seguinte forma:

$$\text{Produtividade} = 11,5 * \frac{\text{n}^\circ \text{ plantas}}{\text{m}^2} * \frac{\text{n}^\circ \text{ vagens}}{\text{planta}} * \frac{\text{n}^\circ \text{ grãos}}{\text{vagem}} * \text{peso médio do grão} \cdot \text{No neurônio da}$$

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 seguinte equação: $p_n = \frac{2(p - \min p)}{(\max p - \min p)} - 1$, em que: p_n é o valor

normalizado, adimensional; p o valor observado, de produção de grãos; $\min p$ 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 por: $r = \frac{\sum_{i=1}^n (E_i - E)(O_i - O)}{\sqrt{[\sum_{i=1}^n (E_i - E)] [\sum_{i=1}^n (O_i - O)]}}$, 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 (c) foi expresso por: $c = 1 - \frac{\sum_{i=1}^n (E_i - O_i)^2}{\sum_{i=1}^n (|E_i - O| + |O_i - O|)^2}$, sendo: E_i - valores

estimados; O_i - valores observados e O - média dos valores observados. O respectivo indicativo 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: $Id = r \cdot c$, onde: r é o coeficiente de correlação de Person e, c o índice de concordância.

RESULTADOS E DISCUSSÃO: Na Tabela 1 encontram-se as correlações entre os parâmetros da cultura e a produtividade final de grãos. O coeficiente de correlação de Pearson indica a força e a direção do relacionamento linear entre duas variáveis (MORETTIN e BUSSAB, 2010), este varia entre os valores -1 e 1. O valor 0 (zero) significa que não há relação linear, o valor 1 indica uma relação linear perfeita e o valor -1 também indica uma relação linear perfeita, porém inversa, ou seja, quando uma das variáveis aumenta a outra diminui. Quanto mais próxima estiver de 1 e -1, mais forte é a associação linear entre as duas variáveis. Observa-se que o nº de plantas.m⁻² foi a variável que melhor correlação (positiva) apresentou para a produção de grãos, seguida da altura de plantas, massa verde total (correlações negativas), respectivamente. Estes resultados estão de acordo com os encontrados por SOARES et al. (2012), onde observaram em modelo de estimativa da produção para a cultura do milho, que a produção da respectiva cultura, apresentou as maiores correlações com as variáveis, nº de plantas.m⁻², altura de plantas e matéria verde total, respectivamente.

TABELA 1. Coeficiente de correlação (r) entre as variáveis de entrada: Altura de planta (cm); Massa seca total (g) e número de plantas por metro quadrado com a produção da cultura do feijoeiro.

Variáveis		
Altura de planta	Massa seca total	Nº de plantas.m ⁻²
-0.2558	-0.1092	0.6368

A partir dos treinos realizados, observou-se que a arquitetura, com trinta neurônios na camada escondida, foi a que melhor capacidade preditiva apresentou para a produção de grãos da cultura do feijão. A seguir na Figura 1 é apresentado o gráfico que apresenta a relação 1:1 entre os valores de produção de grãos observados e os estimados pela RNAs com a arquitetura 3-30-1.

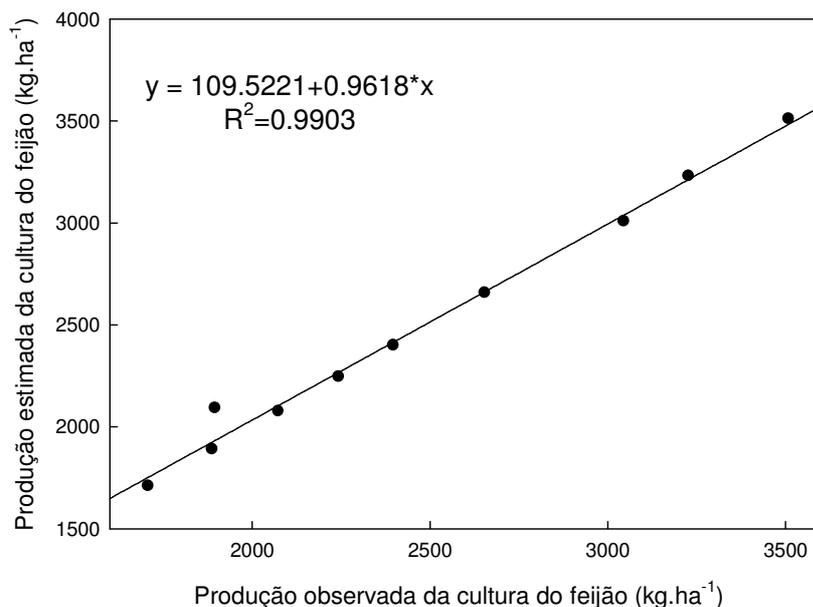


FIGURA 1. Comparação entre os valores observados e estimados da produção de grãos da cultura do feijoeiro.

Nota-se que o ajustamento dos valores obtidos em experimento com os estimados por RNAs, se distribuiu de forma muito próxima a linear, observando-se um coeficiente de determinação de 0,9903. A observação da forma de distribuição dos valores oriundos do ajustamento entre os valores de produção obtidos e estimados permitem deduzir que a estimativa da produção, da cultura do feijão para a região em estudo, pode ser estimada pela RNA treinada (arquitetura de 3-30-1). Nota-se ainda, que a RNA teve uma tendência de subestimativa, com os valores observados superiores aos estimados pela mesma. Esses resultados corroboram com os obtidos por 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. ANDRADE JUNIOR et al. (2006), parametrizando alguns modelos agrometeorológicos para estimativa da produtividade de grãos de milho no município de Parnaíba, PI, observou uma tendência dos mesmos à superestimativa. Os valores dos coeficientes de correlação “r”, índice de concordância “c”, índice de desempenho “id” e classe de desempenho para as diferentes arquiteturas testadas neste trabalho, em relação ao método experimental (M0), são apresentados na Tabela 2. A partir dos valores do índice de desempenho “id”, nota-se que as arquiteturas 3-10-1, 3-20-1 e 3-50-1, apresentaram valores de “id” abaixo de 0,76, o que as classifica como desempenho igual ou inferior a bom. Já as redes com arquitetura de 3-30-1 e 3-40-1 classificaram-se com desempenho ótimo e muito bom, respectivamente. Assim, a produção de grãos, para região em estudo, pode ser estimada através da RNA com arquitetura 3-30-1. Os resultados encontrados estão de acordo os valores obtidos de ANDRADE JUNIOR et al (2006), estes encontraram índices de desempenho semelhantes, quando buscavam a parametrização de alguns modelos agrometeorológicos, a fim de estimativa da produtividade de grãos de milho nas condições de solo e clima do município de Parnaíba, PI.

TABELA 2 - Valores do coeficiente de correlação (r), índice de concordância (c), coeficiente de desempenho (id) e da classificação do desempenho da RNAs em relação ao método experimental (M0).

Método	r	c	id	Desempenho
M0 x 3-10-1	0.7296	0.8300	0.6056	regular
M0 x 3-20-1	0.7946	0.8898	0.7071	bom
M0 x 3-30-1	0.9951	0.9970	0.9922	ótimo
M0 x 3-40-1	0.8970	0.9372	0.8407	muito bom
M0 x 3-50-1	0.6440	0.8080	0.5204	fraco

CONCLUSÕES: dentre as diversas arquiteturas de redes neurais artificiais treinadas, a rede com 30 neurônios em apenas uma camada intermediária, obteve elevada capacidade preditiva, com ótimo coeficiente de desempenho. A respectiva rede neural artificial apresentou ótimo desempenho no desenvolvimento do trabalho, sendo eficiente na estimativa da produção de grãos na cultura do feijão, em município da região Fronteira Oeste do Estado do Rio Grande do Sul.

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.
- AZEVEDO, F. M., BRASIL, L. M. e OLIVEIRA, R. C. L. de; **Redes neurais com aplicações em controle e em sistemas especialistas**. Florianópolis: Visual Books Editora, 2000, 401p.
- BARRETO, J. M. Introdução às redes neurais artificiais, In: V Escola Regional de Informática da SBC Regional Sul, **Anais**, Santa Maria, Florianópolis, Maringá, p.41-71, 1997.
- BRAGA, A. P.; CARVALHO; A. P. L. F.; LUDEMIR; T. B. **Redes neurais artificiais: Teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. 262 p.
- BRAGA, A. P.; CARVALHO; A. P. L. F.; LUDEMIR; T. B. **Redes neurais artificiais: Teoria e aplicações**. Rio de Janeiro: Livros Técnicos e Científicos, 2000. 262 p.
- 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.
- DRAPER, N. R.; SMITH, H. **Applied regression analysis**. New York: John Wiley & Sons. 1966. 407 p.
- FREITAS, P. S. L. et al. Simulação da produtividade do milho pelo modelo CERES-Maize em função da lâmina e da uniformidade de aplicação de água. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.8, p.225-232, 2004.
- MORETTIN, P. A.; BUSSAB, W. O. **Estatística Básica**. 6a ed. São Paulo: Saraiva.
- MURASE, H. Editorial: Artificial intelligence in agriculture. **Computers and Electronics in Agriculture**, London, v.29, p.1-2, 2000.
- NAGAOKA, M. E. et al. Um método para estimar densidade de solo utilizando redes neurais artificiais. **Energia na Agricultura**, vol. 20, p.53-68, 2005.
- SCHNEIDER, P. R. **Análise de regressão aplicada à Engenharia Florestal**. 1.ed. Santa Maria: UFSM/CEPEF, 1998. 236p.

SCHNEIDER, P. R. **Análise de regressão aplicada à Engenharia Florestal**. 1.ed. Santa Maria: UFSM/CEPEF, 1998. 236p.

SOARES, F. C.; PEITER, M. X.; ROBAINA, A. D.; RUSSI, J. L.; PARIZI, A. R. C. Uso de rede neural artificial para predição da produção da cultura do milho, na região central do RS. In: X Congresso Latinoamericano y del Caribe de Ingeniería Agrícola - CLIA 2012 e XLI Congresso Brasileiro de Engenharia Agrícola - CONBEA 2012, 1. **Anais**. Londrina, 2012.

WILLMONT, C. J. On the validation of models. **Physical Geography**, v. 2, p. 184-194, 1981.