

## APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS COM DIFERENTES FUNÇÕES DE ATIVAÇÃO PARA ESTIMAR O COEFICIENTE DE UNIFORMIDADE EM SISTEMAS DE IRRIGAÇÃO POR MICROASPERSÃO

EVERTON SCHNEIDER DOS SANTOS<sup>1</sup>, PAULO LOPES DE MENEZES<sup>2</sup>, FABIANA COSTA DE ARAUJO SCHUTZ<sup>3</sup>

<sup>1</sup> Pós-Graduando, Universidade Tecnológica Federal do Paraná, (45)99846-0978, everton\_schneider1@hotmail.com

<sup>2</sup> Doutor, Universidade Tecnológica Federal do Paraná, (45)98821-2214, plopes@utfpr.edu.br

<sup>3</sup> Doutor, Universidade Tecnológica Federal do Paraná, (45)98803-7662, fabianaschutz@utfpr.edu.br

Apresentado no  
XLIX Congresso Brasileiro de Engenharia Agrícola - CONBEA 2020  
23 a 25 de novembro de 2020 - Congresso On-line

**RESUMO:** Os sistemas de irrigação por microaspersão são um dos tipos de irrigação mais utilizados atualmente e uma forma de avaliar sua qualidade é através do Coeficiente de Uniformidade de Christiansen (CUC). Este trabalho tem como objetivo desenvolver um modelo baseado em redes neurais artificiais para realizar a predição do coeficiente CUC utilizando dados de precipitação de microaspersores coletados em uma fazenda localizada no município de Medianeira-PR. Neste trabalho foi desenvolvida uma rede do tipo *feed-forward* utilizando o algoritmo de aprendizado *resilient backpropagation* com retorno de pesos. As funções de ativação sigmoide e *softplus* foram implementadas e comparadas para verificar se existem diferenças nos resultados utilizando diferentes funções. Os resultados alcançados demonstram o potencial do modelo desenvolvido, com ambas as funções alcançando um valor do coeficiente  $R^2$  acima dos 90%.

**PALAVRAS-CHAVE:** agricultura irrigada; aprendizado de máquina; microaspersores;

### APPLICATION OF ARTIFICIAL NEURAL NETWORKS WITH DIFFERENT ACTIVATION FUNCTIONS IN ESTIMATING THE UNIFORMITY COEFFICIENT IN MICRO SPRINKLER IRRIGATION SYSTEMS

**ABSTRACT:** Micro sprinkler irrigation systems are one of the most used types of irrigation today and one way to assess its quality is through Christiansen's Uniformity Coefficient (CUC). The objective of this study is to develop an artificial neural network based model to predict the CUC coefficient using micro sprinkler precipitation data collected in a farm localized in the municipality of Medianeira-PR. In this work a feed-forward network was developed, using the resilient backpropagation with weight backtracking learning algorithm. The sigmoid and softplus activation function were implemented and compared to verify if there were any differences in the results using different functions. The results show the model's potential, with both activation functions achieving a  $R^2$  value above 90%.

**KEYWORDS:** irrigated agriculture; machine learning; micro sprinkler;

**INTRODUÇÃO:** Como a irrigação é uma prática crucial em diversos tipos de cultura, a manutenção da eficiência da irrigação através da utilização de sistemas de informações complexos são preocupações chave para a agricultura (MOHAPATRA; LENKA; KESWANI, 2019).

Sistemas de irrigação por microaspersão utilizam pequenos emissores que lançam jatos de água no ar e que viajam pequenas distâncias até chegar ao solo. Esse tipo de sistema possui uma capacidade maior de irrigação devido a sua vazão superior (TESTEZLAF, 2017). Esse tipo de sistema, quando planejado corretamente, aborda a aplicação uniforme da irrigação em tempo hábil e aplica a quantidade necessária para atender a demanda de água (SORRENTINO; PÉREZ, 2005). A uniformidade de distribuição da água é um parâmetro muito importante para medir o desempenho de sistemas de irrigação por aspersão e métodos como o Coeficiente de Uniformidade de Christiansen (CUC), apresentado na Equação 1, são utilizados para expressar a uniformidade de aplicação da água, considerada um dos principais indicadores de qualidade da irrigação (BELLIDO; MARTÍNEZ; URRESTARAZU, 2019).

$$CUC = \left( 1 - \sum_{i=1}^n \frac{|x_i - \bar{x}|}{n\bar{x}} \right) \times 100 \quad (1)$$

em que,

- $x_i$  – lâmina de água coletada no ponto  $i$ , em milímetros
- $\bar{x}$  – lâmina média de todas as observações, em milímetros
- $n$  – quantidade de coletores utilizados para realizar a medição

Soluções baseadas em Redes Neurais Artificiais (RNA), se popularizaram na agricultura nos últimos anos devido a sua capacidade em adquirir conhecimento através da experiência, reconhecer padrões e, em geral, realizar inferências de forma mais precisa em comparação a métodos de regressão lineares e não lineares (FERNANDES et al., 2019).

Esse trabalho, portanto, se propõe a utilizar RNAs para realizar a predição do coeficiente CUC utilizando dados de irrigação de microaspersores. Espera-se que essas informações possam servir de apoio a tomada de decisão para os gestores de sistemas de irrigação, contribuindo para a otimização desse processo, diminuindo gastos e melhorando a produtividade.

**MATERIAL E MÉTODOS:** O conjunto de dados utilizado nesse trabalho possui características de bocal, pressão ( $\text{kgf/cm}^3$ ), quebra jato, velocidade (m/s) e direção do vento (graus) aplicados a microaspersores da marca Fabrimar modelo Pingo giro completo e foi coletado por (MENEZES et al., 2015) na fazenda Ouro Verde, localizada no município de Medianeira, Brasil ( $25^\circ 12' 19,26''\text{S}$ ;  $54^\circ 3' 27,93''\text{W}$ ; 360m).

O cálculo do coeficiente CUC foi feito utilizando um espaçamento entre os aspersores de 12x12 m. Foram realizados 108 ensaios, e as configurações e seus respectivos coeficientes calculados foram então utilizados como os dados de entrada do modelo. Devido as diferentes escalas dos parâmetros do sistema, primeiro foi realizada uma normalização da amplitude, do tipo *min-max*, nos dados de entrada.

O conjunto de dados foi dividido em duas partes, com 86 ensaios formando o conjunto de treinamento e 22 ensaios formando o conjunto de teste. A proporção de divisão 80/20 do conjunto de dados em treinamento e teste é a mais comumente utilizada em aplicações de redes neurais e outras proporções de divisão similares, como a 70/30, não devem impactar de forma significativa o desempenho dos modelos desenvolvidos (FERENTINOS, 2018).

Nesse trabalho foi desenvolvida uma RNA do tipo *feed-forward* com um algoritmo de aprendizado do tipo *resilient backpropagation* com retorno de pesos. A rede criada possui duas camadas ocultas com três e quatro neurônios cada. As funções de ativação sigmoide e

*softplus* foram utilizadas e comparadas para verificar se existe alguma diferença nos resultados utilizando diferentes funções de ativação.

O cálculo do coeficiente CUC, a normalização de amplitude dos dados e o desenvolvimento da RNA foram realizados utilizando a ferramenta R, uma linguagem e ambiente para a computação estatística e geração de gráficos, altamente extensível, de fácil utilização e de distribuição livre sobre os termos de Licença Pública Geral (R Foundation, 2019).

As medidas de avaliação Erro Médio Absoluto (MAE), Erro Médio Quadrático (MSE), Raiz do Erro Médio Quadrático (RMSE) e o Coeficiente de Determinação ( $R^2$ ) foram utilizadas para avaliar a qualidade das previsões feitas pela rede neural utilizando ambas as funções de ativação.

**RESULTADOS E DISCUSSÃO:** A Figura 1 apresenta uma comparação dos valores observados e os valores simulados pela RNA utilizando a função de ativação sigmoide (A) e a função de ativação *softplus* (B). É possível verificar que os valores do coeficiente CUC preditos se aproximaram dos valores observados na maioria dos casos analisados, demonstrando uma boa capacidade de predição do modelo.




FIGURA 1. Gráfico de comparação entre os valores observados e os valores simulados

A utilização da função de ativação *softplus* também apresentou resultados satisfatórios, com valores simulados pela RNA sendo bem próximos dos valores observados. Essa afirmação pode ser confirmada pela análise da Figura 2, que apresenta a comparação dos valores observados e os valores simulados pela RNA desenvolvida utilizando a função *softplus*.

A síntese dos resultados das medidas utilizadas para avaliar a qualidade do modelo desenvolvido, apresentada na Tabela 1, demonstra que a função *softplus* realizou previsões mais precisas, alcançando valores menores de MAE, MSE e RSME. Essa função também alcançou um valor maior de  $R^2$ , demonstrando sua capacidade superior de predição quando comparada a função sigmoide.

TABELA 1. Síntese dos resultados das medidas de avaliação das previsões feitas pelo modelo desenvolvido utilizando as funções de ativação sigmoide e *softplus*

Função de Ativação	MAE	MSE	RSME	$R^2$
Sigmoide	0,68	0,68	0,82	0,91
<i>Softplus</i>	0,67	0,64	0,90	0,92

Apesar de a função *softplus* ter alcançado valores superiores de predição do coeficiente CUC, o modelo utilizando a função sigmoide também é válido na resolução deste problema, alcançando um coeficiente  $R^2$  acima dos 90%.

**CONCLUSÕES:** Pela análise dos resultados das medidas de avaliação utilizadas, foi possível concluir que a função de ativação *softplus* produziu predições superiores quando comparada com a função sigmoide. Ambas as funções, porém, alcançaram valores do coeficiente  $R^2$  acima de 90%, demonstrando o potencial que as duas funções possuem na resolução desse tipo de problema.

Em trabalhos futuros poderá ser verificada a possibilidade de realizar a comparação de diferentes espaçamentos entre aspersores, aumentando assim a capacidade que o modelo poderá ter no apoio a tomada de decisão, especialmente na criação e manutenção de sistemas de irrigação por parte de seus gerenciadores.

## REFERÊNCIAS

BELLIDO, B. S.; MARTÍNEZ, J. M.; URRESTARAZU, L. P. Development of an automatic test bench to assess sprinkler irrigation uniformity in different wind conditions. **Computer and Electronics in Agriculture**, Chipiona, v. 151, p. 31-40, Maio 2019. ISSN 168-1699.

FERENTINOS, K. P. Deep learning models for plant disease detection and diagnosis. **Computers and Electronics in Agriculture**, Athens, v. 145, p. 311-318, Janeiro 2018. ISSN 0168-1699.

FERNANDES, M. M. H. et al. Estimation of soil organic matter content by modeling with artificial neural networks. **Geoderma**, Jaboticabal, v. 350, p. 46-51, Abril 2019. ISSN 0016-7061.

MENEZES, P. L. D. et al. Artificial neural network model for simulation of water distribution in sprinkle irrigation. **Revista Brasileira de Engenharia Agrícola e Ambiental**, Campina Grande, v. 19, p. 817-822, Setembro 2015. ISSN 1807-1929.

MOHAPATRA, A. G.; LENKA, S. K.; KESWANI, B. Neural Network and Fuzzy Logic Based Smart DSS Model for Irrigation Notification and Control in Precision Agriculture. **Proceedings of the National Academy of Sciences, India Section A: Physical Sciences**, v. 89, n. 1, p. 67-76, Janeiro 2019. ISSN 0369-8203.

SEGINER, I.; NIR, D.; BERNUTH, R. D. V. Simulation of Wind-Distorted Sprinkler Patterns. **Journal of Irrigation and Drainage Engineering**, v. 117, n. 2, Março 1991. ISSN 0733-9437.

SORRENTINO, M. B.; PÉREZ, R. **New Jersey Irrigation Guide**. Somerset, 2005.

TESTEZLAF, R. **Irrigação: métodos, sistemas e aplicações**. Campinas: [s.n.], 2017.  
USDA. **Irrigation Guide**. [S.l.]. 1997.