

## Estimativa da Produtividade de Cana-de-Açúcar com um Sistema *Neuro-Fuzzy* Adaptativo

Ulcilea A. S. Leal<sup>1</sup>, Aguinaldo J. F. Leal<sup>2</sup>, Maria E. F. Correa<sup>3</sup>

ICAEBI, UFTM, Iturama, MG

Gino G. M. Hauman<sup>4</sup>

UNSAAC, Perú

O Brasil é o maior produtor mundial de cana-de-açúcar, com uma produção de aproximadamente 480 milhões de toneladas cultivadas em mais de sete milhões de hectares. Essa produção é, em sua maioria, processada industrialmente para a obtenção de açúcar e etanol. Nesse contexto, a utilização de métodos para a estimativa da produtividade dos canaviais é fundamental para o planejamento do setor sucroenergético. Segundo Leal et al. [3], técnicas de modelagem matemática são essenciais para a análise de processos que envolvem múltiplos fatores. Além disso, Simões e Shaw [4] destacam que a modelagem de sistemas reais é crucial, pois reduz custos ao permitir a realização de ensaios e experimentos de forma mais acessível. Dada a complexidade dos modelos matemáticos envolvidos, têm sido empregadas técnicas computacionais que possibilitam ajustes cada vez mais refinados. Entre essas abordagens, destaca-se o uso de sistemas híbridos de inteligência artificial, como o sistema *neuro-fuzzy*, que combina redes neurais artificiais e lógica *fuzzy* [1].

A pesquisa foi conduzida em parceria com a empresa Coruripe *Ltda.*, com base em dados da safra 2018/2019 da cultivar RB855156, no segundo corte. As variáveis analisadas incluíram: número de colmos por metro linear, massa média de 20 colmos, produtividade de colmos por hectare, diâmetro médio do colmo, graus Brix, porcentagem de sacarose no caldo, porcentagem de fibra no colmo, pureza, porcentagem de açúcares redutores (AR), estimativa dos açúcares totais recuperáveis (ATR) e estimativa da produção de ATR por hectare.

Inicialmente, foi realizada a análise descritiva de cada variável, seguida de uma análise de correlações lineares simples utilizando o *software* R. Posteriormente, ainda no *software* R, foram ajustadas regressões múltiplas para modelar a produção de ATR por hectare (variável dependente) em função de variáveis biométricas e de qualidade tecnológica. O objetivo foi selecionar as variáveis que resultassem nas melhores equações para estimar a produção de ATR por hectare, empregando o método *stepwise*, com um nível de significância de 10% para inclusão e exclusão de variáveis no modelo. Após essas análises preliminares, foi aplicado um sistema híbrido de inteligência artificial, especificamente o sistema *neuro-fuzzy* adaptativo (*Adaptive Network-Based Fuzzy Inference System* – ANFIS), desenvolvido por Jang [2]. O ANFIS combina a capacidade de aprendizado das redes neurais artificiais com o poder interpretativo da lógica *fuzzy*. A implementação do sistema foi realizada no *software* MATLAB. O método *stepwise* selecionou as seguintes variáveis preditoras: número de colmos por metro linear, massa de 20 colmos, teor de sacarose, teor de fibra e ATR. Essas variáveis foram utilizadas como entradas no sistema *neuro-fuzzy*, enquanto a produtividade de ATR por hectare foi definida como a variável de saída. A estrutura do sistema de inferência *neuro-fuzzy* está representada na Figura 1.

---

<sup>1</sup>ulcilea.leal@uftm.edu.br

<sup>2</sup>aguinaldo.leal@uftm.edu.br

<sup>3</sup>d202210795@uftm.edu.br

<sup>4</sup>ginomaqui@gmail.com

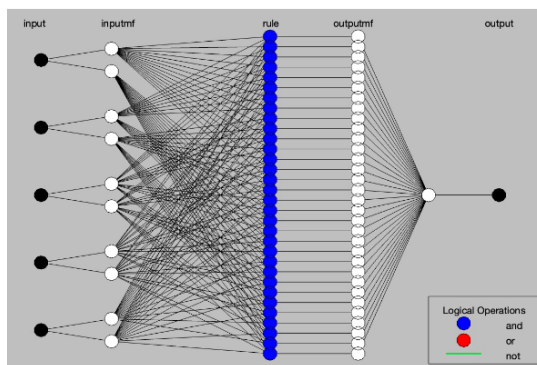


Figura 1: Sistema de inferência *neuro-fuzzy*. Fonte: autor.

A Figura 2 apresenta a superfície de resposta gerada pelo sistema de inferência *neuro-fuzzy* adaptativo, considerando as variáveis de entrada: número de colmos por metro linear e massa de 20 colmos. Observa-se que o aumento dessas variáveis resulta em um incremento na produtividade de ATR por hectare. Além disso, essa tendência pode ser analisada individualmente para cada variável, evidenciando a influência isolada da massa de 20 colmos e do número de colmos por metro na produtividade de ATR, conforme ilustrado na Figura 2. Dessa forma, os resultados obtidos demonstram que o modelo ANFIS constitui uma abordagem eficiente para a estimativa da produtividade de ATR por hectare, considerando múltiplas variáveis predictoras.




Figura 2: Superfície de resposta com variáveis de entrada colmos e massa de 20 colmos. Fonte: autor.

## Referências

- [1] R. Fullér. **Introduction to neuro-fuzzy systems**. Vol. 2. Springer Science & Business Media, 2000.
- [2] J. S. R. Jang. “ANFIS: adaptive-network-based fuzzy inference system”. Em: **IEEE transactions on systems, man, and cybernetics** 23.3 (1993), pp. 665–685.
- [3] A. J. F. Leal, E. P. Miguel, F. H. R. Baio, D. C. Neves e U. A. S. Leal. “Redes neurais artificiais na predição da produtividade de milho e definição de sítios de manejo diferenciado por meio de atributos do solo”. Em: **Bragantia** 74 (2015), pp. 436–444.
- [4] M. G. Simões e I. S. Shaw. **Controle e modelagem fuzzy**. São Paulo: Editora Blucher, 2007.