

MONITORAMENTO E PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO NA SECAGEM

DÁGILA MELO RODRIGUES¹, PAULO CARTERI CORADI², MARISA MENEZES LEAL³, ROSANA SANTOS DE MORAES⁴, NAIRIANE DOS SANTOS BILHALVA⁴, ANDERSON HENRIQUE SOARES⁵

¹Eng^a. Agrônoma, Doutoranda em Engenharia Agrícola, UFSM/PPGEA, dagila.rodrigues2012@gmail.com

²Eng^o. Agrícola, Professor Associado, UFSM/CS, Laboratório de Pós-Colheita (LAPOS), paulo.coradi@ufsm.br

³Eng^a. Agrícola, Mestranda em Engenharia Agrícola, UFSM/PPGEA, etecmarisa@gmail.com

⁴Eng^a. Agrícola, Doutoranda em Engenharia Agrícola, UFSM/PPGEA, rosana-moraes95@hotmail.com, nairiane@gmail.com

⁵Estudante de Graduação em Engenharia Agrícola, Bolsista Iniciação Científica, UFSM-CS, andersonhenriquesoares@hotmail.com

Apresentado no
LII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2023
18 a 21 de outubro de 2023 – Ribeirão Preto - SP, Brasil

RESUMO: O objetivo do estudo foi monitorar o efeito da temperatura do ar e o tempo de secagem para prever as perdas na qualidade dos grãos de milho através do uso de modelos de aprendizado de máquina. Monitorou-se a temperatura do ar de secagem em um secador intermitente, onde foram avaliadas as temperaturas 80, 100 e 120 °C. Mediu-se a contração volumétrica dos grãos, alterações na membrana celular pelo teste de condutividade elétrica e o rendimento de amido nos grãos. Para predição das perdas, aplicaram-se os modelos de aprendizado de máquina, sendo eles: Redes Neurais Artificiais (RNAs), algoritmo M5P e Floresta aleatória (FA), em comparação ao modelo de Regressão Linear Múltipla (RLM). A temperatura do ar de secagem provocou danos térmicos nos grãos e nos tecidos celulares. A partir dos dados de entrada monitorados, os modelos de Redes Neurais Artificiais (RNAs) ajustaram satisfatoriamente para predição da contração volumétrica, condutividade elétrica e amido nos grãos.

PALAVRAS-CHAVE: drying air temperature, monitoramento, predição de perdas.

MONITORING AND PREDICTING THE QUALITY OF CORN GRAINS DURING DRYING

ABSTRACT: The aim of the study was to monitor the effect of air temperature and drying time to predict losses in corn grain quality through the use of machine learning models. The drying air temperature was monitored in an intermittent dryer, where temperatures 80, 100 and 120 °C were evaluated. The volumetric contraction of the grains, alterations in the cell membrane by the electrical conductivity test and the yield of starch in the grains were measured. To predict losses, machine learning models were applied, namely: Artificial Neural Networks (ANNs), M5P algorithm and Random Forest (FA), in comparison with the Multiple Linear Regression model (MLR). The temperature of the drying air caused thermal damage to the grains and cellular tissues. From the monitored input data, the models of Artificial Neural Networks (ANNs) adjusted satisfactorily for predicting the volumetric contraction, electrical conductivity and starch in the grains.

KEYWORDS: drying temperature, monitoring, loss prediction.

INTRODUÇÃO: A temperatura do ar e o tempo de secagem podem causar alterações na qualidade dos grãos, e por isto, são variáveis importantes a serem monitoradas. O aumento da temperatura do ar de secagem pode acelerar o processo de remoção de água, que normalmente é contrária à qualidade dos grãos. Por esse motivo, é importante que haja sincronização da tecnologia, manuseio e monitoramento dos grãos para encontrar as melhores condições de tempo de secagem e qualidade dos grãos. Para isso, o monitoramento de variáveis de secagem associado a aplicação de modelos de inteligência artificial pode auxiliar na prevenção e na tomada de decisão sobre a operação de secagem (SAID et al., 2022; VO-THANH et al., 2022; ACOSTA-GÓNGORA et al., 2022). Assim, este estudo teve como objetivo monitorar a secagem de grãos de milho em diferentes temperaturas do ar para prever a qualidade dos grãos através de modelos de aprendizado de máquina.

MATERIAL E MÉTODOS: Com o auxílio de sensores termopares instalados em um secador intermitente, monitorou-se a temperatura do ar de secagem nas condições de 80, 100 e 120 °C, até atingirem um teor de água de 13% (b.u.). Durante os três testes de secagem foram coletadas amostras para determinação dos teores de água (U) (Brasil, 2009), contração volumétrica (CV) (Eq. 1) (Mohsenin, 1986), condutividade elétrica (CE) (Krzyzanowski, 1999) e amido (A).

$$V_g = \frac{\pi a b c}{6} \quad (1)$$

Em que: a: eixo principal do grão (mm), b: eixo médio do grão (mm), c: eixo menor do grão (mm).

As variáveis monitoradas foram utilizadas como dados de entrada nos modelos de redes neurais artificiais, algoritmo M5P e floresta aleatória para predição da qualidade de grãos, utilizando o software Weka versão 3.9.5. Todos os modelos foram comparados com a regressão linear múltipla.

RESULTADOS E DISCUSSÃO: As curvas de secagem dos grãos de milho mostraram que a temperatura de 80 °C prolongou o tempo de secagem até 4,83 horas (Fig. 1). Já na secagem com temperatura a 100 °C o tempo foi reduzido para 4,5, enquanto que, na temperatura de 120 °C o tempo de secagem foi de 3,5 horas. Para todas as condições de secagem, os grãos reduziram os teores de água até 11% (b.u.). A diferença do tempo de secagem de 1,83 horas da temperatura de 80 °C para a temperatura de 120 °C pode ser discutida sob a condição de velocidade de secagem e maior fluxo da massa de grãos nos processos que antecedem e precedem à secagem, e também os efeitos na qualidade física e físico-química dos grãos. Porém o aumento da temperatura do ar de secagem de 80 °C para 120 °C pode ter afetado a estrutura morfológica e os tecidos celulares dos grãos, causando mudanças no rendimento de amido (CORADI et al., 2014; TIMM et al., 2023). Na predição da variável (CV), os modelos RNAs apresentaram as maiores correlações r (0,99 e 0,98, respectivamente) não diferindo entre si pelo teste SK $p < 0,05$ da RLM (Fig. 2A). Porém, entre as médias de MAE (0,20 e 0,46, respectivamente) foi verificado que o modelo de RNAs obteve o melhor ajuste, uma vez que apresentou menor distanciamento entre as variáveis analisadas e preditas (Fig. 2A). As alterações da contração volumétrica é consequência do aumento da temperatura do ar de secagem que alterou o endosperma dos grãos, a partir da redução dos teores de água. Essas mudanças físico-químicas comprometeram a qualidade dos grãos (WEI et al., 2020).

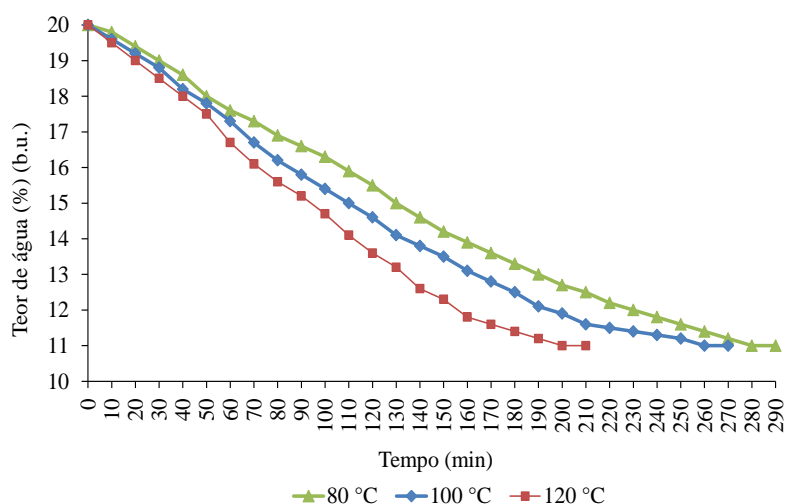


FIGURA 1. Curvas de secagem dos grãos de milho para diferentes temperaturas do ar durante o monitoramento.

Na predição do rendimento de amido (A) os modelos RNAs e RLM apresentaram os maiores coeficientes de correlação r (0,98 e 0,94, respectivamente) não diferindo entre si pelo teste SK $p < 0,05$ (Fig. 2B). Porém, foi verificado um ajuste satisfatório para o modelo de RNAs, para o erro aparente médio (MAE). Pelo fato do amido ser um carboidrato biomolecular, são propícios a modificação na sua estrutura quando submetidos a elevadas temperaturas de secagem. Neste caso, estando o grão a temperaturas de secagem acima de 80 °C, o amido pode ter sido afetado (HUART et al., 2018).

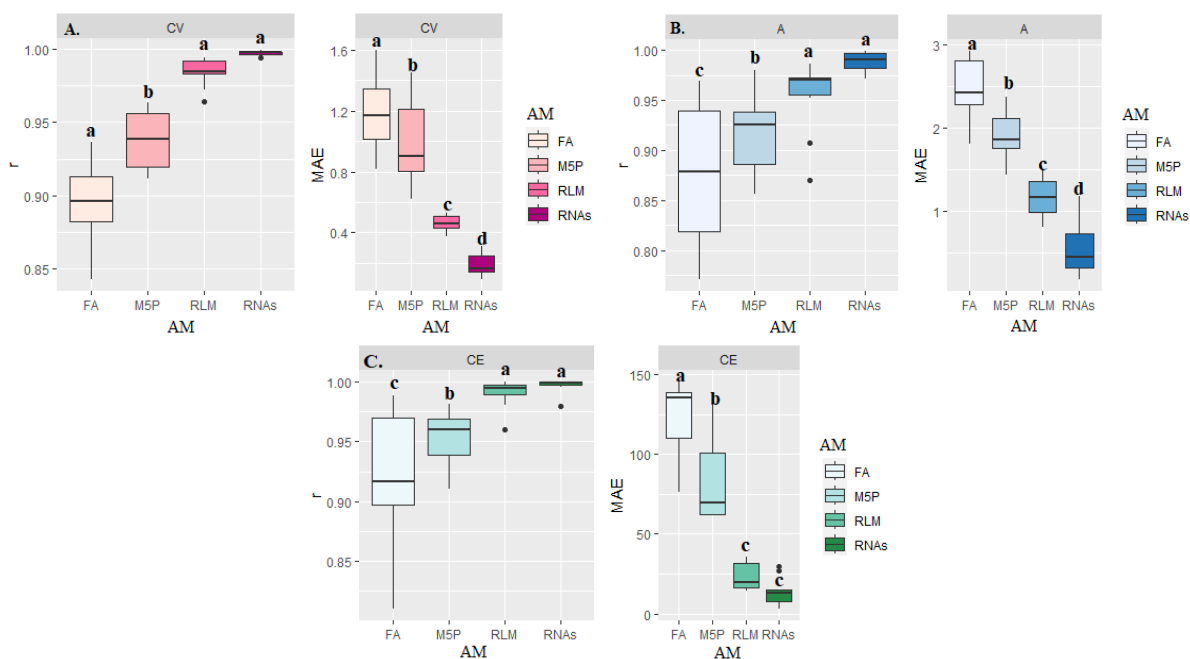


FIGURA 2. Boxplot para comparação de média entre o modelo de regressão linear múltipla (RLM) e modelos de Aprendizado de Máquina: Redes Neurais Artificiais (RNAs), Algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (FA) na predição da contração volumétrica-CV (A), amido-A (B) e condutividade elétrica-CE (C) do coeficiente de correlação (r) e do erro absoluto médio (MAE) em grãos de milho na secagem.

Para a condutividade elétrica (CE), os modelos de RNAs e RLM obtiveram valores de r (0,98 e 0,99, respectivamente) e MAE (21,98 e 13,21, respectivamente) não diferindo entre si pelo teste SK $p < 0,05$ (Fig. 2C), com uma melhor acurácia de R^2 (98,04%) para a RNAs. Salienta-se que a elevação da CE esteve ligada a elevação da temperatura de secagem, que causaram rupturas das membranas, o que faz com os exsudatos fossem liberados.

CONCLUSÕES: Os modelos de RNAs foram os mais indicados para prever o amido, a contração volumétrica e a condutividade elétrica nos grãos de milho nas diferentes temperaturas de secagem.

AGRADECIMENTOS: Os autores agradecem a Universidade Federal de Santa Maria, Programa de Pós-Graduação em Engenharia Agrícola, ao Research Group at Postharvest Innovation: Technology, Quality & Sustainability (UFSM), Laboratório de Pós-Colheita (LAPOS-UFSM), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS) pela concessão de bolsas de estudos, recursos financeiros e espaços físicos para desenvolvimento dos experimentos.

REFERÊNCIAS

- ACOSTA-GÓNGORA, P. A., POTTER, E. G., LAWLEY, C. J. M., PETTS, D., SPARKES, G. Uraninite chemistry of the Central Mineral Belt, Labrador, Canada: Application of grain-scale unsupervised machine-learning. **Journal of Geochemical Exploration**, v.233, n. 106910, 2022.
- BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Defesa Agropecuária. **Regras para análise de sementes**. Brasília, DF: Mapa/ACS, p. 395, 2009.
- CORADI, P. C., CHAVES, J. B. P., DE LACERDA FILHO, A. F., & MOTA, T. O. Quality of stored grain of corn in different conditions. **Científica**, v. 42, n. 2, p. 118–133, 2014.
- HUART, F., MALUMBA, P., ODJO, S., AL-IZZI, W., BÉRA, F., & BECKERS, Y. In vitro and in vivo assessment of the effect of initial moisture content and drying temperature on the feeding value of maize grain. **British Poultry Science**, v. 59, n. 4, p. 452 – 462, 2018.
- KRZYŻANOWSKI, F. C. ET AL. **Vigor de sementes: conceitos e testes**. Londrina: ABRATES, cap. 2, p. 2-24, 1999.
- SAID, Z., SHARMA, P., ASLFATTAHI, N., GHODBANE. (2022). Experimental analysis of novel ionic liquid-MX ene hybrid nanofluid's energy storage properties: Model-prediction using modern ensemble machine learning methods. **Journal of Energy Storage**, v. 52, n. 104858, 2022.
- TIMM, N. S., CORADI, P. C., LANG, G. H., RAMOS, A. H., CAÑIZARES, L. D. C. C., FERREIRA, C. D., & DE OLIVEIRA, M. Effects of drying temperature of corn from the center and extremities of the corncob on morphology and technological, thermal, and pasting properties of isolated starch. **Journal of Food Engineering**, v. 336, 111215, 2023.
- VO-THANH, H., AMAR, M. N., LEE, K. K. Robust machine learning models of carbon dioxide trapping indexes at geological storage sites. **Fuel**, v. 316, n. 123391, 2022.
- WEI, S., WANG, Z., XIE, W., WANG, F., CHEN, P., & YANG, D. A heat and mass transfer model based on multi-component heterogeneity for corn kernel tempering drying: Development and application. **Computers and Electronics in Agriculture**, v. 171, n. 105335, 2020.