

## UTILIZAÇÃO DE SENSORES E MODELOS DE APRENDIZADO DE MÁQUINA PARA PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO ARMAZENADOS

**DÁGILA MELO RODRIGUES<sup>1</sup>, PAULO CARTERI CORADI<sup>2</sup>, ROSANA SANTOS DE MORAES<sup>3</sup>, MARISA MENEZES LEAL<sup>4</sup>, MARCELA TROJAHN NUNES<sup>3</sup>, TIAGO ARABITES VENDRUSCULO<sup>5</sup>**

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

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

<sup>3</sup>Eng<sup>a</sup>. Agrícola, Doutoranda em Engenharia Agrícola, UFSM/PPGEA, rosana-moraes95@hotmail.com, marcelatrojahn@gmail.com

<sup>4</sup>Eng<sup>a</sup>. Agrícola, Mestranda em Engenharia Agrícola, UFSM/PPGEA, etecmarisa@gmail.com

<sup>5</sup>Estudante de Graduação em Engenharia Agrícola, Bolsista Iniciação Científica, UFSM-CS, thyagoav@gmail.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 a temperatura, umidade relativa do ar intergranular e os níveis de dióxido de carbono para prever perdas na qualidade de grão de milho armazenados em silos horizontais. O monitoramento indireto destas variáveis intergranulares foi realizado através de sensores e software desenvolvidos no Laboratório de Pós-Colheita (LAPOS)-UFSM-CS. Para predição dos teores de água, massa específica aparente e condutividade elétrica aplicou os modelos preditivos de Redes Neurais Artificiais (RNAs), algoritmo M5P e Floresta Aleatória (FA), comparados com o modelo de Regressão Linear Múltipla (RLM). Durante o armazenamento dos grãos verificou-se que as condições do ambiente alteraram os teores de água dos grãos, modificando a atmosfera intergranular e a umidade de equilíbrio higroscópico, elevando a produção de dióxido de carbono, refletindo no consumo de matéria seca. As Redes Neurais Artificiais (RNAs) e Floresta Aleatória (FA) tiveram ajustes satisfatórios na predição do teor de água, massa específica aparente a condutividade elétrica.

**PALAVRAS-CHAVE:** armazenamento de milho, monitoramento de variáveis, predição de qualidade de grãos.

### USE OF SENSORS AND MACHINE LEARNING MODELS TO PREDICT THE QUALITY OF STORED CORN GRAIN

**ABSTRACT:** The objective of the study was to monitor temperature, intergranular relative humidity and carbon dioxide levels to predict losses in the quality of corn grain stored in horizontal silos. The indirect monitoring of these intergranular variables was performed using sensors and software developed at the Post-Harvest Laboratory (LAPOS)-UFSM-CS. To predict water content, apparent specific gravity and electrical conductivity, predictive models of Artificial Neural Networks (ANNs), M5P algorithm and Random Forest (FA) were applied, compared with the Multiple Linear Regression model (MLR). During grain storage, it was verified that the environmental conditions altered the water content of the grains, modifying the intergranular atmosphere and the hygroscopic equilibrium humidity, increasing the production of carbon dioxide, reflecting on the consumption of dry matter. The Artificial Neural Networks (ANNs) and Random Forest (FA) had satisfactory adjustments in the prediction of water content, apparent density and electrical conductivity.

**KEYWORDS:** corn storage, variables monitoring, grain quality prediction.

**INTRODUÇÃO:** Mesmo em condições seguras de armazenamento, a forma, as condições e o tempo de armazenagem dos grãos podem elevar as taxas respiratórias do produto, provocando perdas (NYABAKO et al., 2020). A falta de controle e monitoramento da massa de grãos estão entre as principais causas da perda de matéria seca dos grãos de milho armazenados, configurando em quebra técnica, além disso, em alterações na qualidade físico-química dos grãos (GARCÍA-DÍAZ et al., 2020). O monitoramento de variáveis intergranulares, como a temperatura, a umidade relativa do ar intergranular a associada a concentração de dióxido de carbono pode fornecer informações determinantes para auxiliar na predição da qualidade dos grãos e possibilitar antever possíveis perdas dos grãos armazenados (ANDRÉ et al., 2022). Assim, é importante o uso de modelos de inteligência artificial, com base em dados de entrada para predição precoce das variáveis de fácil mensuração, e com isso, reduzir as possíveis perdas. O objetivo deste estudo foi monitorar e prever a qualidade física de grãos de milho armazenados em silos horizontais a partir da medição de variáveis intergranulares utilizando sensores e modelos de aprendizado de máquina.

**MATERIAL E MÉTODOS:** O monitoramento da massa de grãos de milho ocorreu em uma unidade de armazenamento comercial de milho, localizada nas proximidades de Cachoeira do Sul, RS. O grão de milho foi armazenado em silo horizontal (graneleiro) com teor de água de 12% (b.u.). Para o monitoramento, foi utilizado um microcontrolador Arduino Mega (modelo 2560, Arduino LLC, Itália), desenvolvido por Jaques et al. (2022). A sonda ficou inserida na massa de milho por vinte e quatro horas para coleta de dados de temperatura (T), umidade relativa do ar intergranular (UR) e concentrações de dióxido de carbono (CO<sub>2</sub>). Em seguida, determinou-se a unidade de equilíbrio higroscópico pelas equações 1 e 2 e a perda de matéria seca pela equação 3.

$$U_e = \frac{3,96 * UR^{0,492}}{\ln(T)} \quad 0 < UR \leq 55\% \quad (1)$$

$$U_e = \frac{6,21 * \exp(0,0274 * UR)}{\ln(T)} \quad 55 < UR < 100\% \quad (2)$$

Em que U<sub>e</sub>: umidade de equilíbrio higroscópico (%), UR: umidade relativa (%), T: temperatura (°C).

$$PMS = 100 (C_{CO_2} - \Delta C_{O_2}) \left( \frac{\varepsilon P W_g}{2 P_g (1 - U) RT} \right) \quad (3)$$

Em que PMS: perda de matéria seca (%), C<sub>CO<sub>2</sub></sub>: concentração de C<sub>CO<sub>2</sub></sub> (v/v) medida no caminhão, ΔC<sub>O<sub>2</sub></sub>: variação da concentração de O<sub>2</sub>, ε: porosidade da massa granular (40%), P: pressão atmosférica local (96 kPa), W<sub>g</sub>: massa molar da glicose (180 kg kmol<sup>-1</sup>), P<sub>g</sub>: massa específica aparente (kg m<sup>-3</sup>) (750 kg m<sup>-3</sup>), U: teor de água (decimal, b.u.), R: constante dos gases perfeitos (8,314 KJ Kmol<sup>-1</sup> K<sup>-1</sup>), T: temperatura.

Foram coletadas amostras para determinação dos teores de água, massa específica aparente (MEA) e condutividade elétrica (CE). O teor de água dos grãos em (% b.u.) foi determinado pelo método gravimétrico (balança analítica 0,0001, modelo AUY-220-I). O teste de condutividade elétrica foi descrito conforme a metodologia de Krzyzanowski (1999). As variáveis monitoradas foram utilizadas como dados de entrada nos modelos de Redes Neurais Artificiais, algoritmo M5P e Floresta Aleatória para predição da qualidade dos grãos, utilizando o software Weka versão 3.9.5. Todos os modelos foram comparados com o modelo de regressão linear múltipla.

**RESULTADOS E DISCUSSÃO:** Nas Figuras 1A-B estão os resultados de temperatura, umidade relativa do ar intergranular (UR) para cálculo da umidade de equilíbrio higroscópico ( $U_e$ ) da massa de grãos de milho armazenados. Durante as vinte e quatro horas a temperatura manteve-se constante, porém elevada, entre 30 a 36 °C, enquanto que, a umidade relativa permaneceu próxima a 70%, alcançando 13% de umidade de equilíbrio higroscópico. A partir das 7,5 horas de monitoramento houve um aumento dos níveis de dióxido de carbono (Figura 1C) e conseqüentemente maiores perdas de matéria seca (Figura 1D) ao final do tempo de monitorando (a partir das 15 horas), acompanhando os picos de respiração dos grãos. As temperaturas elevadas associadas à alta umidade relativa intergranular desencadeia reações metabólicas, reduzindo a qualidade dos grãos do grão de milho (LUTZ & CORADI, 2022).

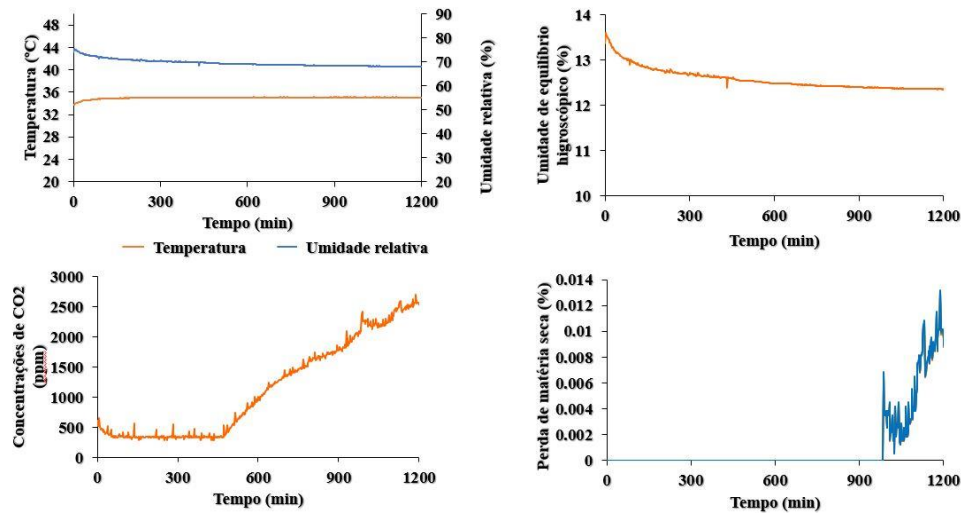


FIGURA 1. Monitoramento precoce da umidade relativa e da temperatura intergranular (A), umidade de equilíbrio higroscópico (B), concentrações de CO<sub>2</sub> (C), e perda de matéria seca (D), em grãos de milho no armazenamento.

Os modelos de RNAs e FA se destacaram na predição dos teores de água, apresentando uma correlação de  $r$  (0,96 e 0,97, respectivamente), porém não diferindo entre si pelo teste SK  $p < 0,05$  (Figura 2A). As menores médias de MAE (0,45 e 0,39) permitiram melhores ajustes dos dados observados e preditos, diferenciando-as dos modelos de M5P e RLM, uma vez que, estes, mesmos apresentando correlações relativamente altas  $r$  (0,84 e 0,93, respectivamente), seu erro médio aparente da MAE foi de 0,89 e 0,53, respectivamente. Mesmo o grão de milho sendo armazenado com teor de água entre 12% a 13% estiveram suscetíveis a variar na qualidade em função das condições estabelecidas na massa de grão. Pois a forma de armazenamento associadas às condições de umidade e temperatura, corroboram com a reabsorção da umidade no grão, que acionou a atividade biológica do grão (GARCÍA-DÍAZ et al., 2020). Os modelos RNAs, M5P e FA foram os melhores para a variável massa específica aparente, pois apresentaram os maiores valores de correlação  $r$  (0,98, 0,97 e 0,98, respectivamente), sem diferir entre si pelo teste SK  $p < 0,05$  (Figura 2B). Este resultado, apresentaram valores de MAE entre (1,43, 1,59 e 1,24, respectivamente), o que conferiu um ajuste destes modelos para a massa específica aparente. Os resultados indicaram que as massas específicas aparente dos grãos de milho tiveram influência da umidade relativa e da temperatura intergranular no armazenamento. Além disso, o tempo foi um fator que interferiu na massa específica do grão, sendo evidenciado por André et al. (2022). Mesmo não apresentando diferença significativa entre si, pelo teste SK  $p < 0,05$  (Figura 2C), os modelos RNAs, M5P e FA obtiveram os maiores valores de  $r$  (0,92, 0,91 e 0,94, respectivamente) para a variável condutividade elétrica e MAE (54,75, 57,33 e 46,41, respectivamente). No armazenamento dos grãos de milho, a temperatura, o tempo e os teores de água, influenciaram

no aumento de condutividade elétrica. Esta variável foi recorrente a danos causados na membrana da parede celular dos grãos (LUTZ & CORADI, 2022).

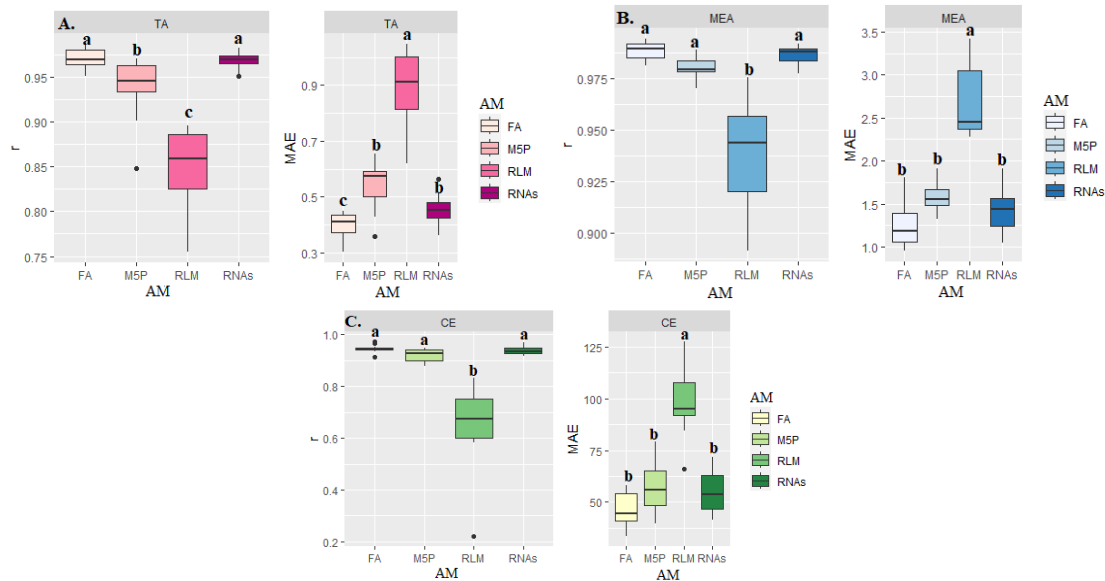


FIGURA 2. Boxplot para comparação de média entre o modelo de regressão linear múltipla (RLM) e modelos de Aprendizado de Máquina: Redes Neurais Artificiais (RNAs), Algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (FA) na predição dos teores de água-TA (A), massa específica aparente-MEA (B) e condutividade elétrica-CE (C) do coeficiente de correlação ( $r$ ) e do erro absoluto médio (MAE) em grãos de milho armazenados.

**CONCLUSÕES:** No armazenamento, os modelos de RNAs e FA são indicados para predizer as variáveis de teores de água, a massa específica aparente e a condutividade elétrica.

**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

- ANDRÉ, G., CORADI, P. C., TEODORO, L. P. R., & TEODORO, P. E. Predicting the quality of soybean seeds stored in different environments and packaging using machine learning. **Scientific Reports**, v. 12, n. 8793, 2022.
- GARCÍA-DÍAZ, M., GIL-SERNA, J., VÁZQUEZ, C., BOTIA, M. N., & PATIÑO, B. A comprehensive study on the occurrence of mycotoxins and their producing fungi during the Maize production cycle in Spain. **Microorganisms**, v. 8, n. 1, 2020.
- JAQUES, L. B. A., CORADI, P. C., LUTZ, É., TEODORO, P. E., JAEGER, D. V., & TEIXEIRA, A. L. Nondestructive Technology for Real-Time Monitoring and Prediction of Soybean Quality Using Machine Learning for a Bulk Transport Simulation. **In IEEE Sensors Journal**, vol. 23, n. 3, p. 3028-3040, 2022.
- KRZYŻANOWSKI, F. C. et al. **Vigor de sementes: conceitos e testes**. Londrina: ABRATES, cap. 2, p. 2-24, 1999.
- LUTZ, É & CORADI, P. C. Applications of new technologies for monitoring and predicting grains quality stored: Sensors, Internet of Things, and Artificial Intelligence. **Measurement**, v. 188, n. 110609, 2022.
- NYABAKO, T., MVUMI, B. M., STATHERS, T., MLAMBO, S., & MUBAYIWA, M. Predicting *Prostephanus truncatus* (Horn) (Coleoptera: Bostrichidae) populations and associated grain damage in smallholder farmers' maize stores: A machine learning approach. **Journal of Stored Products Research**, v. 87, n. 101592, 2020.