

## MONITORAMENTO E PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO NO TRANSPORTE UTILIZANDO SENSORES E ALGORITMOS DE APRENDIZADO DE MÁQUINA

**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>, RONEY ELOY LIMA<sup>5</sup>, BRUNO PASSADOR LOMBARDI<sup>6</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)

<sup>3</sup>Eng<sup>a</sup>. Agrícola, Doutoranda em Engenharia Agrícola, UFSM/PPGEA

<sup>5</sup>Eng<sup>a</sup>. Agrícola, Mestranda em Engenharia Agrícola, UFSM/PPGEA

<sup>5</sup>Eng<sup>o</sup>. Agrônomo, Doutorando em Engenharia Agrícola, UFSM/PPGEA

<sup>6</sup>Estudante de Graduação em Engenharia Agrícola, Bolsista Iniciação Científica, UFSM-CS

Apresentado no

LII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2023

18 a 21 de outubro de 2023 – Ribeirão Preto - SP, Brasil

**RESUMO:** A logística de transporte e os fatores ambientais contribuem para a perda de qualidade na pós-colheita. O objetivo do estudo foi monitorar variáveis intergranulares, como temperatura, umidade relativa e dióxido de carbono da massa de grãos de milho durante a operação de transporte, para prever a qualidade, utilizando sensores e software desenvolvidos no Laboratório de Pós-Colheita da UFSM, Campus Cachoeira do Sul. Analisou-se a predição da perda de matéria seca, massa específica aparente e a condutividade elétrica utilizando modelos de aprendizado de máquina. A umidade de equilíbrio higroscópico dos grãos variou com a temperatura e a umidade relativa intergranular, aumentando a respiração e por consequência as perdas de matéria seca ao longo do transporte. O modelo de Redes Neurais Artificiais predisse satisfatoriamente a massa específica aparente e a condutividade elétrica. Já o modelo Floresta Aleatória estimou adequadamente a perda de matéria seca. Concluiu-se que o uso de sensores para monitoramento de variáveis intergranulares, associados à aplicação de algoritmos de aprendizado de máquina pode ser uma boa alternativa para controle de perdas na operação de transporte de grãos.

**PALAVRAS-CHAVE:** inteligência artificial, monitoramento, grãos.

### MONITORING AND PREDICTING CORN GRAIN QUALITY IN TRANSPORT USING SENSORS AND MACHINE LEARNING ALGORITHMS

**ABSTRACT:** Transport logistics and environmental factors contribute to post-harvest quality loss. The objective of the study was to monitor intergranular variables, such as temperature, relative humidity and carbon dioxide of the corn grain mass during the transport operation, to predict quality, using sensors and software developed at the Post-Harvest Laboratory of UFSM, Campus Cachoeira of South. The prediction of dry matter loss, apparent specific mass and electrical conductivity was analyzed using machine learning models. The hygroscopic equilibrium moisture of the grains varied with temperature and intergranular relative humidity, increasing respiration and, consequently, dry matter losses during transport. The Artificial Neural Network model satisfactorily predicted apparent specific mass and electrical conductivity. The Random Forest model adequately estimated the loss of dry matter. It was concluded that the use of sensors to monitor intergranular variables, associated with the application of machine learning algorithms, can be a good alternative for controlling losses in the grain transport operation.

**KEYWORDS:** artificial intelligence, monitoring, grains.

**INTRODUÇÃO:** O aumento da produtividade de grãos reflete no volume de grãos pós-colheita, os quais necessitam ser escoados até as unidades armazenadoras (TOOSI et al., 2022). O transporte de grãos, por sua vez, ocorre muitas vezes por longas distâncias e o produto em más condições. Desta forma, as perdas na qualidade de grãos são mais intensificadas, sendo resultantes das alterações físicas causadas pelo aumento da atividade metabólica do milho, causados pelo excesso de umidade e aumento da temperatura intergranular. A variação da temperatura e umidade relativa do ar intergranular provocam mudanças na umidade de equilíbrio higroscópico dos grãos, que entre outras, pode causar alterações na respiração celular (ALI, 2020). A resposta deste processo pode estar nas elevadas concentrações de dióxido de carbono e no consumo de matéria seca do grão. Assim, o monitoramento de variáveis intergranulares como dados de entrada de modelos preditivos de aprendizado de máquina podem ser uma boa alternativa para estimar possíveis perdas de grãos de milho no transporte, para tomada de decisão. O objetivo deste estudo foi monitorar a temperatura, umidade relativa e a concentração de dióxido de carbono para prever a qualidade de grãos de milho no transporte utilizando sensores e algoritmos de aprendizado de máquina.

**MATERIAL E MÉTODOS:** O monitoramento da massa de grãos de milho ocorreu através da aplicação de um amostrador metálico com sonda não destrutiva e sensores de temperatura (T), umidade relativa do ar (UR) e dióxido de carbono (CO<sub>2</sub>) desenvolvido por Jaques et al. (2022), os quais foram inseridos em caminhões graneleiros com 12 e 16% (b.u.) de umidade. A sonda ficou inserida na massa de grãos por vinte e quatro horas para leitura das variáveis no intervalo de 1,87 segundos. Realizaram-se amostragens de grãos nas camadas centrais através do próprio tubo amostrador, nos tempos 0, 120, 480 e 1440 minutos para avaliação da massa específica aparente e a condutividade elétrica. Em seguida, determinou-se a umidade 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).

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

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.

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:** No monitoramento dos grãos com 12% de teores de água (Fig. 1A), a umidade relativa intergranular manteve-se constante e próxima a 70%. No

entanto, a temperatura do ar intergranular oscilou ao longo do tempo de monitoramento. Já para os grãos com teores de água a 16% (Fig. 1B), a temperatura intergranular manteve-se, enquanto, a umidade relativa intergranular aumentou para 86%. Além disto, verificou-se que a umidade de equilíbrio higroscópico se elevou para próximos a 20%, mantendo-se constante (Fig. 1C). As variáveis intergranulares indicaram uma possível respiração celular naquele microclima. Estas por sua vez desencadearam picos de dióxido de carbono (CO<sub>2</sub>) na massa de grãos ao longo transporte, demonstrando que o metabolismo do grão esteve ativo com uma atividade respiratória elevada (CORADI et al., 2016; JAQUES et al., 2022a; JAQUES et al., 2022b). Nas condições de 12% de teor de água (Fig. 1D) a massa de grãos não teve respiração acentuada, mantendo-se abaixo e próxima dos níveis aceitáveis do ambiente natural de 420 ppm. Porém, com 16% de teor de água (Fig. 1E), os níveis de CO<sub>2</sub> foram elevados, chegando a 4960 ppm, indicando uma alta intensidade respiratória dos grãos com riscos elevados de deterioração. Com teores de água a 16% o milho ficou metabolicamente ativo, favorecendo o aumento da umidade relativa intergranular e intensificando o aquecimento da massa de grãos havendo perdas de matéria seca próximos a 0,06%.

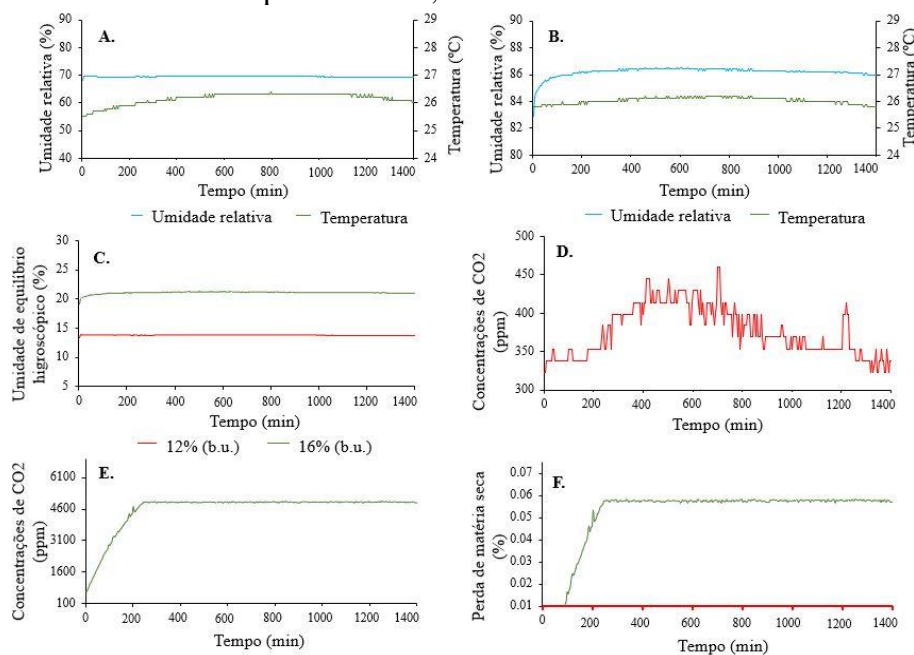


FIGURA 1. Monitoramento da umidade relativa e da temperatura do ar intergranular a 12% (A) e 16% (B) de teores de água, umidade de equilíbrio higroscópico a 12% e 16% de teores de água (C), concentrações de dióxido de carbono a 12% (D) e 16% (E) de teores de água e perda de matéria seca (F) com 12% e 16% de teores de água em grãos de milho ao longo do transporte.

A  $p < 0,05$ , pelo teste SK, houve interação significativa entre os modelos de Aprendizado de máquina para as variáveis PMS, MEA e CE. Para a perda de matéria seca (PMS) da massa de grãos durante o transporte, verificou-se que o modelo de redes neurais artificiais (RNAs) e floresta aleatória (FA) expressaram maiores desempenhos (Fig. 2A). Para a variável massa específica aparente (MEA), os modelos de Aprendizado de Máquina (AM) que melhor se ajustaram foram as RNAs e algoritmo de M5P (Fig. 2B). Para a condutividade elétrica (CE), o modelo de M5P teve o melhor ajuste na predição desta variável (Fig. 2C). A massa de grãos durante transporte sofreu ações de diversas variantes, as quais são condicionantes para efeitos sobre a respiração celular dos grãos, entre elas o teor de água, a temperatura e a umidade relativa do ar intergranular. A intensificação metabólica fez com que a massa de grãos perdesse matéria seca (PMS) preditos pela resposta dos modelos de aprendizado de máquina, principalmente pela FA. Durante o tempo, a (MEA) sofreu alterações, também, influenciadas

pelas variáveis teores de água e temperatura. Além disso, os grãos que apresentaram danos refletiram na qualidade fisiológica pelo aumento dos resultados de CE.

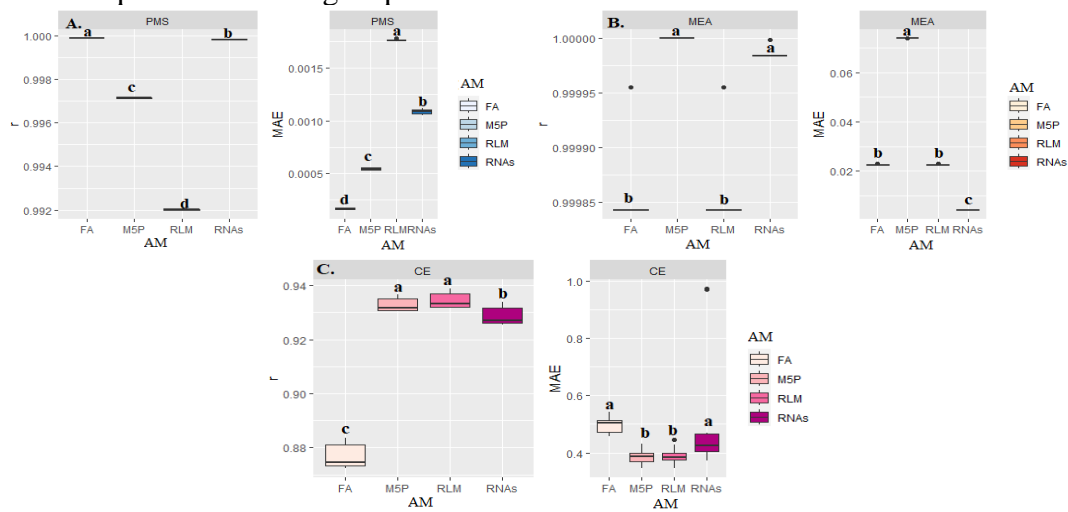


FIGURA 2. Boxplot para comparação de média entre o modelo de regressão linear múltipla (RLM) e modelos de Aprendizado de Máquina: Redes Neurais Artificiais (RNAs), Algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (FA) na predição da perda de matéria seca-PMS (A), massa específica aparente-MEA (B) e condutividade elétrica-CE (C) do coeficiente de correlação ( $r$ ) e do erro absoluto médio (MAE) em grãos de milho no transporte.

**CONCLUSÕES:** Na etapa de transporte de grãos, os modelos RNAs e FA obtiveram os melhores resultados de predição da perda de matéria seca, massa específica aparente e 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

- ALI, A., & IMRAN, M. M. Evaluating the potential of red edge position (REP) of hyperspectral remote sensing data for real time estimation of LAI & chlorophyll content of kinnow mandarin (*Citrus reticulata*) fruit orchards. *Scientia Horticulturae*, v. 267, n. 109326, 2020.
- CORADI, P. C., FERNANDES, C. H. P., & HELMICH, J. C. Adjustment of mathematical models and quality of soybean grains in the drying with high temperatures. *Revista Brasileira de Engenharia Agrícola e Ambiental*, 20(4), 385–392, 2016.
- 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, 2022a.
- JAQUES, L. B. A., CORADI, P. C., MULLER, A., RODRIGUES, H. E., TEODORO, L. P. R., TEODORO, P. E., TEIXEIRA, A. L., & STEINHAUS, J. I. Portable-Mechanical-Sampler System for Real-Time Monitoring and Predicting Soybean Quality in the Bulk Transport. *In IEEE Transactions on Instrumentation and Measurement*, vol. 71, p. 1-12, 2022b.
- TOOSI, H. A., LAVAGNA, M., LEONFORT, F., PERO, C.D., & ASTE, N. A novel LCSA-Machine learning based optimization model for sustainable building design-A case study of energy storage systems. *Building and Environment*, v.209, n.108656, 2022.