

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS RURAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

Dágila Melo Rodrigues

**AVALIAÇÃO DA PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO
UTILIZANDO MODELOS DE APRENDIZADO DE MÁQUINA NAS
ETAPAS DE TRANSPORTE, SECAGEM E ARMAZENAGEM A
PARTIR DO MONITORAMENTO DE VARIÁVEIS MENSURÁVEIS**

Santa Maria, RS
2023

Dágila Melo Rodrigues

**AVALIAÇÃO DA PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO
UTILIZANDO MODELOS DE APRENDIZADO DE MÁQUINA NAS ETAPAS DE
TRANSPORTE, SECAGEM E ARMAZENAGEM A PARTIR DO
MONITORAMENTO DE VARIÁVEIS MENSURÁVEIS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do título de **Doutora em Engenharia Agrícola**.

Orientador: Prof.^o Dr. Paulo Carteri Coradi
Coorientadora: Prof.^a Dr.^a Larissa Pereira Ribeiro Teodoro

Santa Maria, RS
2023

This study was financed in part by the Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Finance Code 001

Rodrigues, Dágila
AVALIAÇÃO DA PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO
UTILIZANDO MODELOS DE APRENDIZADO DE MÁQUINA NAS ETAPAS
DE TRANSPORTE, SECAGEM E ARMAZENAGEM A PARTIR DO
MONITORAMENTO DE VARIÁVEIS MENSURÁVEIS / Dágila
Rodrigues.- 2023.
115 p.; 30 cm

Orientador: Paulo Carteri Coradi
Coorientadora: Larissa Pereira Ribeiro Teodoro
Tese (doutorado) - Universidade Federal de Santa
Maria, Centro de Ciências Rurais, Programa de Pós
Graduação em Engenharia Agrícola, RS, 2023

1. Algoritmos preditivos 2. Redução de perdas 3.
Conservação de grãos 4. Tecnologias de pós-colheita I.
Carteri Coradi, Paulo II. Pereira Ribeiro Teodoro,
Larissa III. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

Declaro, DÁGILA RODRIGUES, para os devidos fins e sob as penas da lei, que a pesquisa constante neste trabalho de conclusão de curso (Tese) foi por mim elaborada e que as informações necessárias objeto de consulta em literatura e outras fontes estão devidamente referenciadas. Declaro, ainda, que este trabalho ou parte dele não foi apresentado anteriormente para obtenção de qualquer outro grau acadêmico, estando ciente de que a inveracidade da presente declaração poderá resultar na anulação da titulação pela Universidade, entre outras consequências legais.

Dágila Melo Rodrigues

**AVALIAÇÃO DA PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO
UTILIZANDO MODELOS DE APRENDIZADO DE MÁQUINA NAS ETAPAS DE
TRANSPORTE, SECAGEM E ARMAZENAGEM A PARTIR DO
MONITORAMENTO DE VARIÁVEIS MENSURÁVEIS**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Doutora em Engenharia Agrícola**.

Aprovada em 16 de junho de 2023.



Prof. Dr. Paulo Carteri Coradi
UFSM Campus Cachoeira do Sul
SIAPE 1895482

**Prof. Paulo Carteri Coradi, Dr. (UFSM-CS)
(Presidente/Orientador)**

Documento assinado digitalmente
gov.br PAULO EDUARDO TEODORO
Data: 19/06/2023 17:18:23-0300
Verifique em <https://validar.iti.gov.br>

**Prof. Paulo Eduardo Teodoro, Dr. (UFMS-CPCS) - videoconferência
(Membro Externo)**

Documento assinado digitalmente
gov.br DOUGLAS ROMEU DA COSTA
Data: 16/06/2023 14:37:28-0300
Verifique em <https://validar.iti.gov.br>

**Profa. Douglas Romeu da Costa, Dr. (UFS-CSC) - videoconferência
(Membro Externo)**

Documento assinado digitalmente
gov.br FABIO LUIZ ZANATTA
Data: 19/06/2023 14:19:57-0300
Verifique em <https://validar.iti.gov.br>

**Prof. Fábio Luiz Zanatta, Dr. (UFPI-CPCE) - videoconferência
(Membro Externo)**

Documento assinado digitalmente
gov.br EVERTON LUTZ
Data: 20/06/2023 08:15:46-0300
Verifique em <https://validar.iti.gov.br>

**Prof. Éverton Lutz, Dr. (IFFar-Campus Panambi) - videoconferência
(Membro Externo)**

Santa Maria, RS
2023

A minha mãe Maria de Fátima, pois se doou integralmente para atender as minhas necessidades, dedico.

AGRADECIMENTOS

À Deus, pelas inúmeras graças concebidas, entre elas a saúde do corpo físico e mental. Agradeço por possibilitar ter amizades valiosas os quais me mostraram culturas diferentes.

Aos meus pais, José Castro Rodrigues (in *memoriam*) e Maria de Fátima Rodrigues.

Aos meus irmãos, Eliane Rodrigues, Maria Rodrigues, Leidiane Rodrigues, Fabiano Rodrigues. E também meus cunhados (a), Edmar Pantoja, Elenilson Lopes e Marilene Nunes, pelo apoio e incentivo. A vida construída com vocês se resume em humildade.

Ao professor Dr. Paulo Carteri Coradi, pela construção integral desta pesquisa, possibilitando que alguém do norte do Brasil tivesse a oportunidade de aprender novos conhecimentos na área da pós-colheita de produtos agrícolas, no sul do Brasil. Conhecimentos estes, que poderei retornar à região de origem, aplicando-as em outras culturas agrícolas. Agradeço pela sua orientação e paciência. Meu respeito e minha gratidão.

À professora Dra. Larissa Pereira Ribeiro Teodoro, pelo conhecimento estatístico repassado, o qual foi a base para elaboração deste estudo. Agradeço pela sua coorientação e paciência. Meu respeito e minha gratidão.

Aos colegas, Rosana Moraes, Rodrigo Menezes e Marisa Leal pelo apoio que me conceberam durante minha estadia na cidade de Cachoeira do Sul, RS. Agradeço por disponibilizarem seu dia a me auxiliar. Em especial a Rosana, pois se tornou minha irmã de coração, dividindo sua família, e estando ao meu lado nos momentos bons e ruins.

Aos Engenheiros Agrícolas, Jonatas Steinhaus e Leticia Oliveira pelo apoio durante as coletas de campo.

Aos colegas Jhonathan Albuquerque, Michele Fornari, Matheus Amâncio, Nairiane Bilhalva, Valéria Neres e família, Celi Rodrigues e família, Elisângela e família.

Aos meus pastores, Macilene Oliveira, Sílvia Correa, Edinaldo Correa, Luciano Vieira e todo corpo cristã. Sou grata pelas orações, afinal, “nem só de pão vive o homem”.

À Universidade Federal de Santa Maria, ao grupo de professores e técnicos, aos quais contribuem para o crescimento do Programa de Pós-Graduação em Engenharia Agrícola.

Ao Grupo de Pesquisa e ao Laboratório de Pós-colheita de Grãos - LAPOS, campus de Cachoeira do Sul, pela estrutura física e tecnológica e pela participação integral da pesquisa.

A CAPES pelo auxílio financeiro.

OBRIGADA

RESUMO

AVALIAÇÃO DA PREDIÇÃO DA QUALIDADE DE GRÃOS DE MILHO UTILIZANDO MODELOS DE APRENDIZADO DE MÁQUINA NAS ETAPAS DE TRANSPORTE, SECAGEM E ARMAZENAGEM A PARTIR DO MONITORAMENTO DE VARIÁVEIS MENSURÁVEIS

AUTORA: Dágila Melo Rodrigues
ORIENTADOR: Prof. Dr. Paulo Carteri Coradi

Este trabalho teve como objetivo aplicar modelos preditivos de Aprendizado de Máquina para o monitoramento da qualidade e predição precoce de perdas nas etapas de transporte, secagem e armazenagem de grãos de milho. Este estudo foi dividido em três capítulos. O primeiro capítulo abordou revisão de literatura científica sobre fundamentos e estruturas tecnológicas da pós-colheita e seus impactos sobre qualidade de grãos de milho. O segundo capítulo foi uma revisão acerca de ferramentas computacionais e algoritmos de inteligência artificial para tomada de decisão antecipada para controle da qualidade dos grãos de milho na pós-colheita. O terceiro capítulo fundamentou-se no monitoramento da qualidade dos grãos de milho nas etapas de transporte, secagem e armazenagem, utilizando modelos de Aprendizado de Máquina para previsão da qualidade e perdas de grãos. O monitoramento demonstrou que o teor de água, a umidade relativa intergranular alteram a umidade de equilíbrio higroscópico dos grãos, contribuindo para o aumento da respiração e por consequência perdas de matéria seca ao longo do transporte. Na secagem, a temperatura do ar provocou danos térmicos aos grãos, elevando o índice de condutividade elétrica. No armazenamento, as condições do ambiente alteraram os teores de água, provocando redução na massa específica aparente, germinação e nos teores de proteína bruta, fibra bruta e gordura dos grãos de milho. Na etapa de transporte, o modelo de redes neurais artificiais foi o mais indicado para prever a condutividade elétrica, a massa específica aparente e a germinação. Já o modelo de floresta aleatória estimou satisfatoriamente a perda de matéria seca. Na etapa de secagem, os modelos de redes neurais artificiais e floresta aleatória foram os mais indicados para a predição das variáveis. No armazenamento, as redes neurais artificiais e floresta aleatória foram os mais indicados para prever os teores de água e a germinação, no entanto, o modelo de árvore de decisão foi aquele que melhor predisseram os resultados de massa específica aparente, condutividade elétrica e amido.

Palavras-Chave: Algoritmos preditivos. Redução de perdas e conservação de grãos. Tecnologias de pós-colheita.

ABSTRACT

MONITORING AND PREDICTING THE QUALITY OF CORN GRAINS USING PREDICTIVE LEARNING MACHINE MODELS IN THE STAGES OF TRANSPORTATION, DRYING AND STORAGE

AUTHOR: Dágila Melo Rodrigues
ADVISOR: Prof. Dr. Paulo Carteri Coradi

This work aimed to apply predictive models of Machine Learning to monitor the quality and early prediction of losses in the stages of transport, drying and storage of maize grains. This study was divided into three chapters. The first chapter addressed the review of the scientific literature on fundamentals and technological structures of post-harvest and its impacts on the quality of corn grains. The second chapter was a review of computational tools and artificial intelligence algorithms for early decision making to control the quality of corn grains in the post-harvest period. The third chapter was based on monitoring the quality of corn grains in the stages of transport, drying and storage, using Machine Learning models to predict quality and grain losses. The monitoring showed that the water content, the intergranular relative humidity alter the hygroscopic balance moisture of the grains, confident for the increase of the rhythm and consequently losses of dry matter during the transport. During drying, the air temperature caused thermal damage to the grains, increasing the electrical conductivity index. During storage, environmental conditions altered water content, causing a reduction in apparent specific mass, germination and crude protein, crude fiber and fat content of corn grains. In the transport stage, the model of artificial neural networks was the most indicated to predict the electrical conductivity, the apparent specific mass and the germination. The random forest model satisfactorily estimated the loss of dry matter. In the drying step, the models of artificial neural networks and random forest were the most suitable for predicting the variables. In storage, artificial neural networks and random forest were the most suitable to predict water content and germination, however, the decision tree model was the one that best predicted the results of apparent specific mass, electrical conductivity and starch.

Keywords: Predictive Algorithms. Reduction of losses and conservation of grains. Post-harvest technologies.

LISTA DE FIGURAS

CAPÍTULO I - ESTRUTURA DE PÓS-COLHEITA E QUALIDADE DE GRÃOS DE MILHO

Figura 1 - Etapas de pré-processamento e armazenamento de grãos	20
Figura 2 - Sistema de pré-limpeza e limpeza	22
Figura 3 - Métodos e formas de secagem	24
Figura 4 - Secadores estacionários (A.) e silo-secador (B.)	25
Figura 5 - Secador intermitente (A.) e secador contínuo (B.)	27
Figura 6 - Silos armazenadores de fundo plano (A.) e fundo cônico (B.).....	33

CAPÍTULO II - TECNOLOGIAS PARA MONITORAMENTO E PREDIÇÃO DE PERDAS NA PÓS-COLHEITA

Figura 1 - Ilustração de uma sonda para monitoramento de temperatura, umidade relativa, níveis de dióxido de carbono e informações logísticas durante o transporte de grãos	46
Figura 2 - Ilustração de um sistema de monitoramento de grãos durante a secagem.....	48
Figura 3 - Ilustração de um sistema de monitoramento de grãos durante o armazenamento ...	50

CAPÍTULO III - PREDIÇÃO PRECOCE DA QUALIDADE DE GRÃOS DE MILHO NAS OPERAÇÕES DE TRANSPORTE, SECAGEM E ARMAZENAGEM ATRAVÉS DO MONITORAMENTO DE VARIÁVEIS INTERGRANULARES E APLICAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA

Figura 1 - Caracterização experimental nas etapas de pós-colheita, transporte, secagem e armazenamento de grãos de milho	67
Figura 2 - Caracterização experimental do monitoramento e da coleta de dados na etapa de transporte de grãos de milho. Esquematização do transporte graneleiro com 12% b.u. e 16% b.u. (A.) e Vista do tubo amostrador metálico + Sonda inserida na massa de grãos (B.)	68
Figura 3 - Representação esquemática do diagrama de blocos das partes constituintes do sistema de controle do equipamento (A.), conexão dos componentes ao micro controlador por meio de cabos jumper (B.) e Fixação dos sensores e acondicionamento do conjunto de sensores a sonda de policloreto de vinila (C.)	70
Figura 4 - Representação esquemática do tubo amostrador de grãos para acondicionamento da sonda. Vista interna e externa do tubo (A.), Peças para vedação (B.), Vista superior do tubo	

amostrador (C.), Vista completa do tubo (D.), Aplicação do sistema de monitoramento na massa de grãos de milho (E.)..... 71

Figura 5 - Caracterização experimental do monitoramento e coleta de dados através de sensores termopares instalados no secador intermitente. 1 - Sensor de nível máximo, 2 - Sensor nível mínimo, 3 - Sensor de entrada ar quente, 4 - Sensor de parada, 5 - Sensor de massa, 6 - Sensor de massa, 7 - Sensor de massa, 8 - Produto de entrada, 9 - Caixa de carga, 10 - Câmara de secagem, 11- Torre de secagem, 12 - Mesa de descarga 72

Figura 6 - Caracterização experimental do monitoramento e coleta de dados na etapa de armazenagem em silo horizontal (graneleiro) de grãos de milho. Esquematização do silo graneleiro (A.) e Vista da sonda inserida na massa de grãos (B.)..... 73

Figura 7 - Caracterização experimental do monitoramento e coleta de dados na etapa de armazenagem em silos protótipos metálicos de grãos de milho..... 74

Figura 8 - Caracterização experimental da aplicabilidade dos modelos de Aprendizado de Máquina nas variáveis monitoradas e preditas nas etapas de transporte, secagem e armazenagem de grãos de milho 78

Figura 9 - 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 83

Figura 10 - Rede de correlação de Pearson estabelecidas sobre variáveis de massa específica aparente (MEA), condutividade elétrica (CE), germinação (GERM) e perda de matéria seca (PMS) na qualidade de grão de milho nas etapas de transporte. Teor água (TA), tempo (TP), temperatura (TE), umidade relativa intergranular (UR), umidade de equilíbrio higroscópico (Ue) e concentrações de dióxido de carbono (CO₂)..... 85

Figura 11 - 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.), germinação-GERM (C.) e condutividade elétrica-CE (D.) do coeficiente de correlação (r) e do erro absoluto médio (MAE) em grãos de milho no transporte 87

Figura 12 - Arquitetura do modelo de redes neurais artificiais (RNAs) na predição da massa específica aparente-MEA (A.) e germinação-GERM (B.), em grãos de milho no transporte.. 88

Figura 13 - Curvas de secagem dos grãos de milho para diferentes temperaturas do ar de secagem 90

Figura 14 - Rede de correlação de Pearson estabelecidas entre as variáveis: contração volumétrica (CV), amido (A), condutividade elétrica (CE), temperatura do ar de secagem (TS), teor de água (TA) e tempo de secagem (TDS)..... 91

Figura 15 - 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..... 93

Figura 16 - Arquitetura do modelo de redes neurais artificiais (RNAs) na predição da contração volumétrica-CV (A.), amido-A (B.) e condutividade elétrica-CE (C.), em grãos de milho na secagem 94

Figura 17 - Monitoramento precoce da umidade relativa e da temperatura intergranular (A.), umidade de equilíbrio higroscópico (B.), concentrações de CO₂ (C.), e perda de matéria seca (D.), em grãos de milho no armazenamento..... 96

Figura 18 - Rede de correlação de Pearson estabelecidas entre as variáveis: tempo de armazenamento (TP), temperatura intergranular (TE), umidade relativa do ar intergranular (UR), teor de água (TA), massa específica aparente (MEA), germinação (GERM), condutividade elétrica (CE), proteína bruta (PB), fibra bruta (FB), gorduras (GD), cinzas (CZ) e amido (A), concentrações de dióxido de carbono (CO₂) e perda de matéria seca (PMS) 97

Figura 19 - 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..... 100

Figura 20 - 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 germinação-GERM (A.), gordura-GD (B.) e cinzas-CZ (C.) do coeficiente de correlação (r) e do erro absoluto médio (MAE) em grãos de milho armazenados 102

Figura 21 - 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 de amido-A (A.), proteína bruta-PB (B.) e fibra bruta-FB (C.) do coeficiente de correlação (r) e do erro absoluto médio (MAE) em grãos de milho armazenados..... 104

Figura 22 - Arquitetura do modelo de redes neurais artificiais (RNAs) na predição do teor de água-TA (A.), massa específica aparente-MEA (B.), condutividade elétrica-CE (C.), germinação-GERM (D.) e amido-A (E.), em grãos de milho armazenados 105

LISTA DE TABELAS

CAPÍTULO I - ESTRUTURA DE PÓS-COLHEITA E QUALIDADE DE GRÃOS DE MILHO

Tabela 1 - Equipamentos comerciais de pré-limpeza e limpeza	23
Tabela 2 - Equipamentos comerciais de secagem	28
Tabela 3 - Influência da secagem na qualidade de grãos de milho	30
Tabela 4 - Equipamentos comerciais de armazenagem.....	34
Tabela 5 - Condições de armazenamento na qualidade de grãos de milho	35

CAPÍTULO II - TECNOLOGIAS PARA MONITORAMENTO E PREDIÇÃO DE PERDAS NA PÓS-COLHEITA

Tabela 1 - Estudos sobre as técnicas de sensoriamento remoto utilizadas para monitoramento de grãos nas etapas de pós-colheita	47
--	----

CAPÍTULO III - PREDIÇÃO PRECOCE DA QUALIDADE DE GRÃOS DE MILHO NAS OPERAÇÕES DE TRANSPORTE, SECAGEM E ARMAZENAGEM ATRAVÉS DO MONITORAMENTO DE VARIÁVEIS INTERGRANULARES E APLICAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA

Tabela 1 - Caracterização tecnológica do equipamento para monitoramento da temperatura, umidade relativa e concentrações de dióxido de carbono na porosidade intergranular de milho durante o transporte	69
Tabela 2 - Parâmetros utilizados para prever as variáveis de qualidade na etapa de transporte de grãos de milho.....	79
Tabela 3 - Parâmetros utilizados para prever as variáveis de qualidade na etapa de secagem de grãos de milho.....	79
Tabela 4 - Parâmetros utilizados para prever as variáveis de qualidade na etapa de armazenagem de grãos de milho	80
Tabela 5 - Médias para coeficiente de correlação (r), erro absoluto médio (MAE), coeficiente de determinação (R ²) entre os valores observados e estimados das variáveis de qualidade dos grãos de milho no transporte, para os diferentes modelos de Aprendizado de Máquina	86
Tabela 6 - Médias para os coeficientes de correlação (r), erro absoluto médio (MAE), coeficiente de determinação (R ²) entre os valores observados e estimados das variáveis de qualidade dos grãos de milho na secagem, para os diferentes modelos de Aprendizado de Máquina.....	92

Tabela 7 - Médias para os coeficientes de correlação (r), erro absoluto médio (MAE), coeficiente de determinação (R^2) entre os valores observados e estimados das variáveis de qualidade dos grãos de milho no armazenamento, para os diferentes modelos de Aprendizado de Máquina 98

SUMÁRIO

1. INTRODUÇÃO GERAL	16
1.1 Hipóteses científicas	17
1.2 Objetivo geral	17
1.3 Objetivos específicos.....	18
CAPÍTULO I - REVISÃO BIBLIOGRÁFICA “ESTRUTURA DE PÓS-COLHEITA E QUALIDADE DE GRÃOS DE MILHO”	19
1. INTRODUÇÃO.....	20
2. LIMPEZA	21
3. SECAGEM	24
4. ARMAZENAGEM.....	33
REFERÊNCIAS BIBLIOGRÁFICAS	38
CAPÍTULO II - REVISÃO BIBLIOGRÁFICA “TECNOLOGIAS PARA MONITORAMENTO E PREDIÇÃO DE PERDAS NA PÓS-COLHEITA”	44
1. MONITORAMENTO DA MASSA DE GRÃOS NAS ETAPAS DE PÓS-COLHEITA...	45
2. INTERNET DAS COISAS (IOT) E INTELIGÊNCIA ARTIFICIAL APLICADA NA PÓS-COLHEITA DE GRÃOS.....	53
3. CONCLUSÕES E PROPOSTA DE MONITORAMENTO E PREDIÇÃO DE DADOS NA PÓS-COLHEITA.....	57
REFERÊNCIAS BIBLIOGRÁFICAS	57
CAPÍTULO III – PREDIÇÃO PRECOCE DA QUALIDADE DE GRÃOS DE MILHO NAS OPERAÇÕES DE TRANSPORTE, SECAGEM E ARMAZENAGEM ATRAVÉS DO MONITORAMENTO DE VARIÁVEIS INTERGRANULARES E APLICAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA	62
1. INTRODUÇÃO	64
2. MATERIAL E MÉTODOS	66
2.1 CARACTERIZAÇÃO EXPERIMENTAL	66
2.2 TECNOLOGIA E MONITORAMENTO DA MASSA DE GRÃOS DE MILHO NO TRANSPORTE	68
2.3 TECNOLOGIA E MONITORAMENTO DA MASSA DE GRÃOS DE MILHO NA SECAGEM.....	71
2.4 TECNOLOGIA E MONITORAMENTO DA MASSA DE GRÃOS NO ARMAZENAMENTO	72
2.5 AVALIAÇÕES DA QUALIDADE DOS GRÃOS DE MILHO	74

2.6 ANÁLISES DE CORRELAÇÃO DE PEARSON	76
2.7 APRENDIZADO DE MÁQUINA	76
2.8 ANÁLISES ESTATÍSTICAS	82
3. RESULTADOS E DISCUSSÃO	82
3.1 MONITORAMENTO E PREDIÇÃO DA QUALIDADE DOS GRÃOS DE MILHO NO TRANSPORTE	82
3.2 MONITORAMENTO E PREDIÇÃO DA QUALIDADE DOS GRÃOS DE MILHO NA SECAGEM	90
3.3 MONITORAMENTO E PREDIÇÃO DA QUALIDADE DOS GRÃOS DE MILHO ARMAZENADOS	95
4. CONCLUSÕES	106
5. CONSIDERAÇÕES GERAIS.....	106
REFERÊNCIAS BIBLIOGRÁFICAS	107

1. INTRODUÇÃO GERAL

O milho (*Zea mays* L.) está entre as culturas agrícolas mais produzidas no mundo, sendo base para a alimentação humana e animal. De acordo com levantamento da CONAB (2023), a safra 2022/2023, produziu 125.715,3 mil toneladas, representando uma produtividade de 5.675 kg/ha. Porém, com o aumento na produção é fundamental que o setor de pós-colheita tenha infraestrutura suficiente para receber e armazenar os grãos com qualidade. Nas etapas de pós-colheita, a FAO (2019) recomendou que a capacidade de armazenamento de um país seja pelo menos 20% superior à sua produção anual, cenário bastante diferente do observado em muitos países produtores de grãos (DUYSAK & YIGIT, 2020).

O déficit na estrutura física nas etapas de pós-colheita, impacta negativamente na qualidade da massa de grãos de milho. As perdas estão em função da falta de monitoramento e controle nos sistemas de transporte, nas operações de secagem e armazenagem. O teor de água do grão, a temperatura e a umidade relativa do ar e do ambiente intergranular são variáveis importantes a serem monitoradas para garantir a qualidade dos grãos. Uma vez que a através da umidade relativa e a temperatura na massa de grãos, se determina a umidade de equilíbrio higroscópico. Neste caso, quando alterada a umidade de equilíbrio, contribui com uma atmosfera propícia a outros fatores que degradam a massa de grãos no armazenamento (LEAL et al., 2023).

A perda de matéria seca, está entre os principais problemas durante o armazenamento de grãos. Devido ao processo respiratório, ocasionado pelas reações químicas de oxidação, ocorre perdas de peso dos grãos, a quebra técnica, propriamente dita (NEVES & SAVELLI, 2017). Apesar de comum, as normas técnicas de armazenagem, estabelecem um padrão de 0,01% ao dia, o que representa 0,3% ao mês na perda de matéria seca. Desse modo, quando estes percentuais ultrapassam as normas, se configura perdas econômicas. Por isso, o monitoramento de variáveis de medição indireta, são importantes.

Os avanços nas técnicas de aquisição e processamento de dados têm sido aplicados com sucesso, para auxiliar na tomada de decisão em diferentes processos agrícolas. Ficando mais comum o uso de sensores de cultura, capazes de estimar a produtividade de grãos antes da colheita (DONG et al., 2019; SEGARRA et al., 2020). Estimar o estado nutricional de plantas e ocorrência de plantas daninhas (HUNT & DAUGHTRY, 2018). Adubação nitrogenada de cobertura e estresse hídrico (VANINO et al., 2018). Determinar o teor de proteína de grãos (ZHOU et al., 2018; ARANGUREN et al., 2020). Estimar o aumentando de produtividade de grãos, a qualidade, a eficiência na aplicação de insumos, reduzindo as perdas de nutrientes e

diminuindo os impactos ambientais negativos (BONGIOVANNI & LOWENBERG-DEBOER, 2004; AUBERT et al., 2012).

O uso de sensores associados à Internet das Coisas (IoT) e à Inteligência Artificial (IA) pode auxiliar no monitoramento e na previsão da qualidade dos grãos e nos processos de pós-colheita. Assim, a aplicação de ferramentas de agricultura de precisão pode auxiliar na consideração dos processos pós-colheita, utilizando um conjunto de técnicas avançadas de informação, comunicação, análise e processamento de dados, como análise de Big Data, plataformas digitais, nuvem, processamento, inteligência artificial, que permitem extrair uma abundância de informações sobre os dados coletados no processo de tomada de decisão (BERRY et al., 2003; HUANG et al., 2020; DELGADO et al., 2019).

Embora atualmente já seja uma realidade em muitas operações agrícolas, no atual cenário pós-colheita ainda existe uma lacuna de conhecimento sobre o uso dessas tecnologias. Com o intuito de reduzir perdas dessa magnitude, o uso de ferramentas tecnológicas para monitoramento em tempo real, pode auxiliar para prevenção e tomadas de decisões sobre a qualidade dos grãos (SAID et al., 2022; VO-THANH et al., 2022; ACOSTA-GÓNGORA et al., 2022).

Assim, este estudo fundamenta-se na aplicação de tecnologias para o monitoramento de variáveis de medição indireta da qualidade de grãos, no transporte, na secagem e no armazenamento. Além disso, recorre algoritmos de Aprendizado de Máquina (AM), visando a predição de perdas, para a manutenção da qualidade dos grãos de milho.

1.1 Hipóteses científicas

A aplicação de tecnologias de monitoramento de variáveis de medição indireta da qualidade de grãos de milho associados com algoritmos de Aprendizado de Máquina (AM) pode auxiliar na predição em perdas de grãos de milho nas operações de transporte, secagem e armazenamento.

1.2 Objetivo geral

Objetivou-se analisar a qualidade de grãos de milho nas operações de transporte, secagem e armazenagem com base no monitoramento da temperatura intergranular, umidade relativa intergranular, umidade de equilíbrio higroscópico e respiração da massa de grãos associados ao uso de algoritmos de Aprendizado de Máquina (AM).

1.3 Objetivos específicos

- Identificar as estruturas tecnológicas na etapa de pós-colheita e seus respectivos impactos sobre a qualidade dos grãos.
- Apresentar tecnologias de monitoramento e predição de perdas de grãos de milho durante etapas do processo de pós-colheita.
- Avaliar a predição da qualidade de grãos de milho nas etapas de transporte, secagem e armazenagem, utilizando-se modelos de Aprendizado de Máquina a partir do monitoramento intergranular de temperatura, umidade relativa, umidade de equilíbrio higroscópico e respiração da massa de grãos.

CAPÍTULO I - REVISÃO BIBLIOGRÁFICA “ESTRUTURA DE PÓS-COLHEITA E QUALIDADE DE GRÃOS DE MILHO”

RESUMO

O controle dos processos de pós-colheita, principalmente nas etapas de secagem e armazenagem do milho, possibilita a conservação dos grãos. Esta pesquisa teve como objetivo apresentar diferentes tecnologias de secagem, formas e condições de armazenagem juntamente com estudos da literatura científica sobre a qualidade dos grãos de milho. Conforme a revisão realizada, a temperatura do ar de secagem foi o principal parâmetro monitorado na secagem. Os resultados de pesquisa indicam que a secagem seja realizada, entre temperaturas de 40 °C a 60 °C, para que ocorra uma melhor conservação das propriedades físico-químicas dos grãos, como amido, fibras, cinzas e proteínas. Para isto, se utiliza cada vez mais o processo de secagem a baixas temperaturas, com sistema de desumidificação do ar de secagem. Enquanto no armazenamento, foi observado que a conservação da qualidade dos grãos passa, principalmente, pelo controle dos teores de água e da temperatura da massa de grãos, bem como, da condição atmosférica e intergranular de armazenamento. Em geral, com o armazenamento de grãos de milho com teores de água próximos a 12% (b.u.) e o acondicionamento em temperaturas abaixo da condição ambiente, consegue conservar os grãos por períodos superiores a seis meses de armazenamento. Além disto, se utiliza cada vez mais a tecnologia de refrigeração artificial, no intuito de reduzir a temperatura e controlar a umidade relativa intergranular. Com essa tecnologia, mantêm-se os grãos em equilíbrio higroscópico com o ambiente de armazenamento conforme os teores de água desejáveis nos grãos, em regiões onde a temperatura e umidade relativa são extremas. Os estudos indicam que o controle das operações de secagem e de armazenagem preserva a qualidade nutricional dos grãos de milho, garantindo a indústria processadora maior rendimento e qualidade final do produto.


Palavras-Chave: Equipamentos. Tecnologia. Qualidade de grãos de milho.

1. INTRODUÇÃO

As etapas de pós-colheita de grãos são constituídas, basicamente, pelo recebimento, limpeza, secagem, armazenagem e expedição (Figura 1). A recepção dos grãos na unidade armazenada é fundamental para que seja realizada uma caracterização inicial do produto. Durante esta etapa são determinados os teores iniciais de água, de impurezas e dos defeitos dos grãos, respeitando a Instrução Normativa 60/2011 do Ministério da agricultura, Pecuária e Abastecimento.

Na sequência, os grãos são submetidos à etapa de pré-limpeza e/ou limpeza, para a remoção parcial de impurezas na massa de grãos, colaborando com a manutenção da qualidade dos grãos nas etapas seguintes. Uma vez que a presença de impurezas facilita a proliferação de microrganismos os quais modificam a atmosfera intergranular transferindo calor e umidade na massa de grãos. Por esse motivo é uma prática tecnológica necessária nas operações de pós-colheita.

Figura 1 - Etapas de pré-processamento e armazenamento de grãos



Fonte: Autora (2023).

Geralmente os grãos são colhidos na lavoura com teores de água entre (25-30% b.u.), o que configura um alto teor de água. Desta forma, são obrigatoriamente submetidos a tecnologia de secagem até os grãos atingirem um teor de água entre (12-14% b.u.). Estas


condições, além de representarem níveis seguros para o armazenamento, preservam as características físico-químicas e tecnológicas dos grãos de milho ao longo do tempo.

A etapa de armazenamento é uma continuidade das operações de pós-colheita responsável por condicionar os grãos por um determinado tempo. Geralmente o fluxo de armazenagem oscila com as condições produtivas da lavoura de milho no campo. Neste caso, ao ter ocorrência da supersafra, as UB (unidade de beneficiamento) não obtêm de um controle eficiente das operações. Assim, a interação entre duas ou mais variáveis, entre elas a umidade relativa e a temperatura do ar intergranular, desencadeiam reações na massa de grãos de milho, alterando as suas características qualitativas.

Por fim, a expedição configura a última etapa onde os grãos saem das UB e se distribuem para os variados fins. Desse modo, a qualidade do grão de milho expedido é resultante do manejo e da tecnologia empregada nas operações de pós-colheita. Por esse motivo, as exigências mercadológicas necessitam ser atendidas, a começar pela sincronização de equipamentos, técnicas e manejos estratégicos empregados nas unidades de beneficiamento. Assim, este capítulo consistiu em mostrar além das características e funcionamento dos equipamentos, os principais impactos destes sobre a qualidade dos grãos de milho na pós-colheita.

2. LIMPEZA

A limpeza de impurezas e matérias estranhas da massa de grãos é realizada por meio de uma máquina de ar e peneira (Figura 2). As impurezas forem removidas a um percentual que não interferiram nos processos de secagem e armazenagem. A presença de impurezas na massa de grãos dificulta a passagem do ar intergranular, causando diferentes pressões estáticas nos secadores e nos silos armazenadores. Além de possibilitar focos de transferência de calor e umidade na massa de grãos. As peneiras podem ser do tipo vibratório ou cilíndrico, com ventiladores radiais ou axiais. O processo pode ser dividido em pré-limpeza e limpeza (Tabela 1), onde a pré-limpeza visa diminuir os teores de impureza de 4% para aceitáveis 2% (sendo considerado adequado para o produto final), e, a limpeza para 1% da impureza total na massa de grãos.



Fonte: Autora (2023).

Tabela 1 - Equipamentos comerciais de pré-limpeza e limpeza

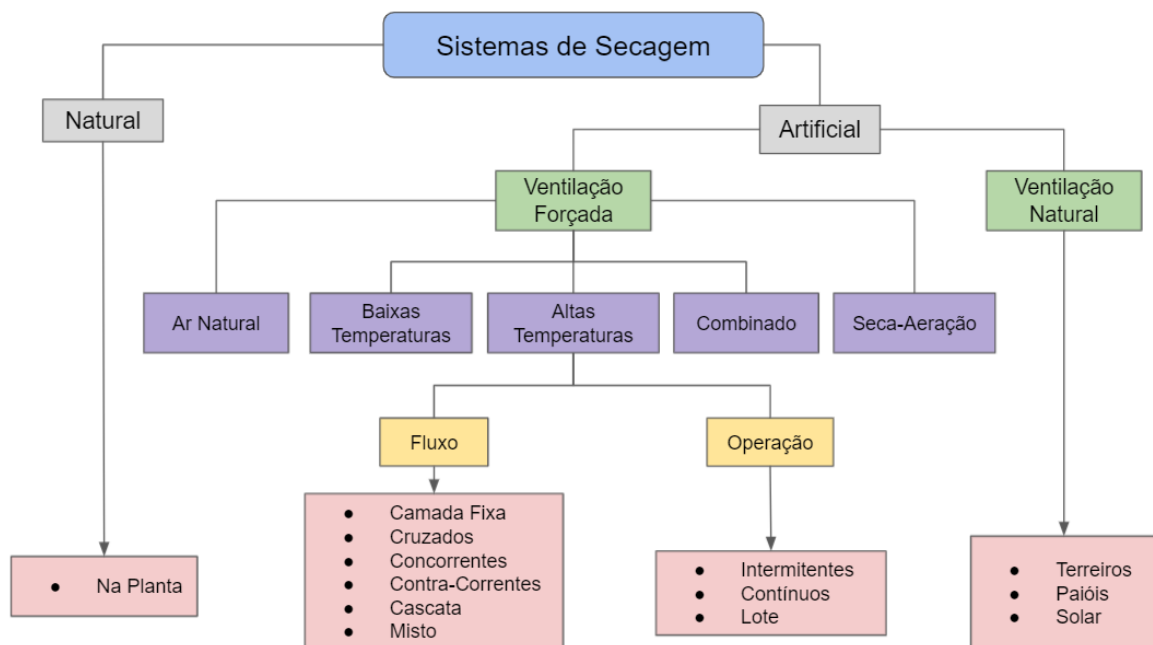
Equipamentos de Pré-Limpeza e Limpeza								
Fabricante	Intermediários	Capacidade (ton/h)		Potência (HP)		Dimensões (mm)	Peso (kg)	Produto
		Pré-Limpeza	Limpeza	Peneira	Ventilador			
A1	6	20-180	40-140	2,68-7,39	2,95-20,11	3493 x 2271 x 2742 a 6446 x 3790 x 4513	N/A	Grãos
A2	1	60-160	-	3,94-9,86	7,39-12,32	5110 x 3100 x 4180 a 5810 x 4100 x 5970	N/A	Soja, milho, trigo, arroz
B1	4	14-240	10-180	1-4	3-25	2562 x 1185 x 2237 a 4200 x 4900 x 8520	750-8520	Grãos e cereais
B2	2	60-270	-	1	2,95-4,02	3300 x 2630 x 2500 a 3700 x 3170 x 4350	4800-10300	Soja, milho, trigo, cevada, colza
C1	5	30-240	20-200	2,95-14,79	4,93-19,72	2300 x 2750 x 3770 a 5500 x 5500 x 6500	N/A	Grãos
C2	3	90-300	60-200	4,93-7,39	4,93-7,39	5550 x 3640 x 6820 a 900 x 4950 x 8000	N/A	Grãos
E1	3	6-60	-	1,47-3,94	1,47-7,39	2380 x 1410 x 1915 a 4560 x 2500 x 2550	N/A	Soja, milho, arroz
G1	3	30-170	40-240	N/A	N/A	3400 x 11300 x 6500 a 3800 x 13100 x 6900	N/A	Grãos
K1	1	50-120	38-90	N/A	N/A	N/A - Altura até 5,500	N/A	Grãos
K1	0	170-240	128-180	N/A	N/A	N/A - Altura até 9000	N/A	Grãos
P1	3	25-95	-	0,98-4,93	4,93-7,39	3095 x 2400 x 2675 a 5627 x 2500 x 4590	N/A	Soja, milho, trigo, arroz
P2	2	4,5-30	-	0,73-3,94	-	1425 x 748 x 1322 a 2150 x 1835 x 2980	100-640	Grãos
P3	1	4,8-18	8-30	1,97	4,93-7,39	2600 x 1200 x 3300 a 2600 x 2000 x 3300	900-1250	Grãos e cereais
S1	2	40-140	20-80	1,47-1,97	4,93-7,39	2950 x 2300 x 3890 a 5215 x 3720 x 7915	2000-8800	Grãos e cereais
Z1	0	7,2-14	7,2-14	1,47-1,97	2,95-3,94	2070 x 1480 x 2630 a 2310 x 2705 x 2890	750-990	Soja, milho, trigo, arroz, feijão, aveia, azevém, girassol, sorgo, cevada

3. SECAGEM

A secagem é aplicada para reduzir os teores de água dos grãos e proporcionar um armazenamento seguro. O processo de secagem consiste na retirada gradual da água dos grãos por meio da transferência simultânea de calor do ar para os grãos e escoamento da massa pelo vapor d'água para o ambiente (CORADI et al., 2019).

A transferência de umidade se dá pela diferença de pressão de vapor entre o ar e a superfície dos grãos. A secagem ocorre quando a pressão de vapor do ar for maior que a da superfície dos grãos. Assim, na massa de grãos úmidos, o vapor de água tende a ocupar todos os espaços intercelulares, gerando pressões em todas as direções (CORADI et al., 2019; CORADI et al., 2020). Para que a secagem seja executada corretamente, cuidados devem ser tomados durante esta etapa, pois os parâmetros de secagem interferem diretamente no processo: temperatura do ar de secagem, umidade relativa do ar intergranular, teor de água da massa de grãos, tempo de secagem e finalidade do uso dos grãos. Assim, os secadores podem ser classificados de diferentes formas (Figura 3).

Figura 3 - Métodos e formas de secagem



Fonte: Autora (2023).


Na tentativa de entender a importância do processo de secagem dos grãos de milho, é necessário conhecer a sua estrutura física. E, também, entender a umidade de equilíbrio

higroscópico, para a otimização da etapa de secagem no todo (GONÇALVES, 2017). Pois a temperatura do ar de secagem abaixo das condições médias do ambiente reduz a ocorrência de danos nas estruturas celulares do grão de milho. Porém, poderá causar o equilíbrio higroscópico dos grãos com o ar antes de alcançar os teores de água desejados para o armazenamento (WEI et al., 2020).

A secagem com ar aquecido sob ventilação forçada confere um processo mais rápido. Os equipamentos podem ser classificados conforme os fluxos de ar e do produto no interior do secador, bem como, quanto à operação. O sistema de secagem por ventilação forçada pode ser dividido quanto a altas ou baixas temperaturas. A secagem estacionária utiliza ventilação forçada com baixas temperaturas, o qual caracteriza o processo como lento. Neste sistema de secagem, o fluxo de ar é ascendente e a massa de grãos permanece estática (lote) no interior do equipamento.

Na Figura 4, é representado o modelo (A), a passagem do ar é feita de dentro para fora, em um secador de corpo cilíndrico com superfícies perfuradas para a passagem do ar. Para o modelo (B) a passagem do ar é feita de baixo para cima sob a divisão de uma chapa metálica perfurada. Nos silos-secadores, as secagens ocorrem em camada com avanço da frente de secagem. O processo continua até o momento de equilíbrio higroscópico com a umidade relativo do ar de secagem, estando relacionado com a temperatura e o fluxo de ar.

Figura 4 - Secadores estacionários (A.) e silo-secador (B.)



Fonte: Autora (2023).

O aumento da altura das camadas de grãos dificulta a secagem, exige um aumento do fluxo de ar que tem por finalidade avançar a frente de secagem e diminuir gradualmente a diferença de umidade. A secagem ocorre com os grãos em camadas de até 120 cm e com

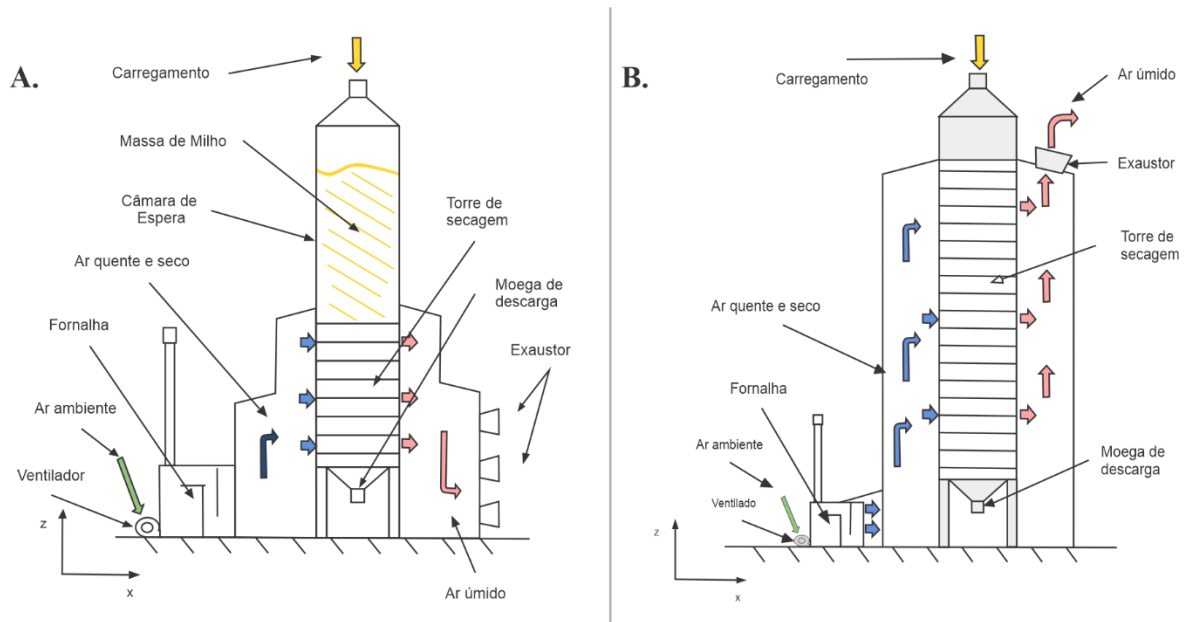
temperaturas que não excedam os (40 °C) (CORADI et al., 2019). Para Silva et al. (2008) três diferentes modos de carregamento podem ser empregados no silo secador: enchimento em uma etapa, enchimento por camadas e camada única.

O secador intermitente é caracterizado pela separação em duas câmaras, sendo a primeira referente à secagem e a segunda ao repouso. A secagem é feita em períodos regulares de tempo intercalados com períodos de repouso (Figura 5A). Assim, durante os períodos de repouso, a água migra gradualmente do interior do grão para a superfície, facilitando à sua retirada posteriormente, resultando em menos danos por trincamento (menor chance de choques térmicos), melhor rendimento em grãos inteiros e melhor qualidade final. Nesse sistema de secagem, os períodos de permanência nas câmaras podem variar entre rápido e lento, sendo 1:1 a 1:3 lentos e 1:4 a 1:5 rápidos. Com isso, as temperaturas máximas usadas durante o processo podem passar dos (110 °C). Pelas características operacionais, o sistema é recomendado para secagem de arroz (mas serve para outros grãos) devido à secagem controlada. Nos secadores comerciais a secagem intermitente pode baixar até 2 pontos percentuais por hora.

Na secagem, parâmetros como temperatura e velocidade do ar da massa de grãos devem ser monitorados e controlados. Coradi et al. (2015) estudaram a secagem de milho em diferentes temperaturas (80 °C, 100 °C e 120 °C) e aplicaram diferentes modelos de secagem. Esses autores relataram que o aumento da temperatura do ar de secagem resultou na redução do tempo de secagem e o modelo matemático de Midilli foi o que melhor se ajustou às curvas de secagem do milho.

Alguns estudos mostram a importância da adaptação das condições de secagem. Temperaturas elevadas podem afetar as propriedades de pasta, físico-químicas, tecnológicas, térmicas e morfológicas do amido e da farinha de milho (TIMM et al., 2020). As condições de secagem também podem afetar as propriedades de digestibilidade da proteína e do amido de milho, o que altera o rendimento desse produto na alimentação animal (HUART et al., 2018). Além do uso na alimentação humana e animal, o milho é utilizado para a produção de etanol, que também é afetado pelas condições de secagem (CORADI et al., 2022).

Figura 5 - Secador intermitente (A.) e secador contínuo (B.)



Fonte: Autora (2023).

O secador contínuo é caracterizado por possuir pelo menos duas câmaras. A primeira referente à secagem, a segunda referente ao resfriamento, eventualmente podendo ter outras intermediárias. Neste sistema os grãos entram úmidos e saem secos e resfriados sem que ocorram interrupções durante a secagem. Os grãos caem por gravidade e são conduzidos por cavaletes, os quais compõem toda a coluna de secagem. Um modelo típico de secadores contínuos é apresentado na (Figura 5B). E uma das suas principais características é a entrada de ventilação de ar ambiente no último terço da coluna referente à secagem. Existe a possibilidade de usar dois sistemas de secagem, ou por corpo inteiro, ou então a normal. O que difere uma da outra é a escolha de usar ou não o sistema de resfriamento (Tabela 2).

Tabela 2 - Equipamentos comerciais de secagem

(Continua)

Equipamentos de Secagem										
Fabricante	Intermediário	Fluxo	Operação	Ventilação	Capacidade (ton/h)	Dimensões (m x m x m)	Vazão de ar (m³/h)	Temperatura máxima de secagem (°C)	Consumo de Combustível (kg/h)- Lenha	Uso
A1	4	Fluxo Concorrente	Contínuo/Intermittente/Lote	Forçada	10 – 100	5,75 x 2,00 x 10,45 – 8,45 x 6,00 x 27,00	25000 – 255000	100	N/A	Grãos
A2	6	Fluxo Misto (Cavalete)	Contínuo	Forçada	20 – 150	2,24 x 11,00 x 21,19 – 10,78 x 14,19 x 25,58	80000 – 560000	110	552 – 3024	Grãos
A2	3	Cascata	Contínuo	Forçada	20 – 80	2,24 x 11,00 x 15,01 – 5,48 x 12,00 x 22,14	60000 – 240000	110	552 – 3024	Semente
A2	6	Fluxo Cruzado (Coluna)	Contínuo	Forçada	20 - 150	2,26 x 11,55 x 20,51 – 10,88 x 14,72 x 27,14	80000 – 560000	110	552 – 3024	Grãos
B1	8	Fluxo Misto	Contínuo	Forçada	20 - 200	5,7 x 2,8 x 11,810 – 8,5 x 4,95 x 25,090	N/A	N/A	N/A	Soja, milho, trigo
B1	6	Fluxo Misto	Intermittente	Forçada	30 – 160	5,7 x 2,85 x 12,910 – 8,5 x 4,94 x 25,270	N/A	N/A	N/A	Arroz
B1	5	Fluxo Misto	Combinado	Forçada	20 – 240	5,7 x 2,85 x 12,912 – 8,5 x 4,95 x 26,65	N/A	N/A	N/A	Soja, arroz
C1	4	Fluxo Cruzado – Colunado	Contínuo	Forçada	30 – 150	4,64 x 7,65 x 16,8 – 7,65 x 9,65 x 29,67	96000 – 360000	110	643 – 2679	Soja, milho, trigo, arroz e cevada
C1	1	Secador de Cavalete – Fluxo Cruzado	Intermittente	Forçada	20 – 40	3,28 x 6,97 x 14,7 – 4,86 x 8,59 x 18,42	37000 – 100000	110	375 – 740	Grãos

C2	8	Fluxo Contracorrente – Colunar	Contínuo	Forçada	15 – 250	7,7 x 3,48 x 12,380 – 8,15 x 11,55 x 33,275	60000 – 684000	110	337 – 3844	Soja, milho
C2	5	Colunar – Fluxo Contracorrente	Contínuo	Forçada	40 – 200	7,7 x 5,09 x 17,34 – 8,15 x 9,93 x 32,26	120000 – 570000	110	674 – 3204	Soja, milho e arroz
D1	10	Fluxo Cruzado	Contínuo/Intermitente	Forçada	16 – 150	3,0 x 4,74 x 12,5 – 8,4 x 5,4 x 24,0	44800 – 448000	110	340 – 3140	Milho, soja, trigo, arroz e feijão
E1	11	Fluxo Concorrente	Contínuo/Intermitente	Forçada	5 – 250	6,498 x 3,24 x 11,19 – 6,786 x 12,96 x 28,58	45000 – 500000	110	N/A	Soja, arroz, milho e trigo
G1	8	Fluxo Cruzado	Contínuo	Forçada	12,4 – 116	12,13 x 4,00 x 10,8 – 29,5 x 7,80 x 22,09	49500 – 567000	110	130 – 1850	Grãos e semente
K1	.	Fluxo Misto/colunar (cavaletes)	Contínuo	Forçada	10 – 200	N/A	31000 – 407500	110	46 – 3389	Grãos
S1	7	Fluxo Cruzado – colunado	Contínuo	Forçada	7,5 – 150	4,03 x 12,98 x 14,10 – 6,92 x 7,05 x 26,30	48000 – 480000	60	70 – 2680	Grãos e sementes
S1	3	Fluxo Misto	Intermitente	Forçada	Estática 29,0 a 136,0 m ³	4,14 x 4,73 x 7,67 – 5,54 x 8,36 x 14,00	20000 – 150000	65	30 -642	Grãos e sementes

Fonte: Autora (2023).

A importância de adequar-se os equipamentos e métodos de secagem é devido auxiliar no controle e na qualidade na pós-colheita. Alguns estudos mostram os efeitos da secagem sobre a qualidade de grãos de milho (Tabela 3).

Iniciando os estudos sobre essa temática, para determinar os parâmetros de qualidade após a secagem em estufa de ar forçado nas temperaturas de (50 °C, 60 °C, 70 °C e 80 °C) em bioingrediente (farelo de milho + *rhizopus oligosporus*) após serem fermentados, Sousa et al. (2021) verificaram que os modelos matemáticos Valcam, Midilli, Wang e Singh obtiveram os melhores ajustes nas temperaturas (60 °C, 70 °C e 80 °C).

Tabela 3 - Influência da secagem na qualidade de grãos de milho

Autores	Títulos
Timm et al. (2020)	Efeitos da temperatura de secagem e do genótipo na morfologia e nas propriedades tecnológicas, térmicas e de pasta do amido de milho.
Coradi et al. (2020)	Influências da temperatura de secagem e das condições de armazenamento na preservação da qualidade pós-colheita de milho em escala de laboratório e de campo.
Wei et al. (2020)	Um modelo de transferência de calor e massa baseado na heterogeneidade de multicomponente para secagem de tâmara de grãos de milho: Desenvolvimento e aplicação.
Córdova-Noboa et al. (2020)	Temperatura de secagem do milho, o tamanho das partículas e a suplementação com amilase influenciam o desempenho de crescimento, o desenvolvimento do trato digestivo e a utilização de nutrientes dos frangos de corte.
Berlanga-Reyes et al. (2021)	Efeito do método de secagem e das condições do processo nas propriedades físico-químicas e reológicas de arabinosilanos extraídos do cozimento de milho.
Hassan et al. (2021)	Efeito do aquecimento por micro-ondas nas características físico-químicas, cor e propriedades de pasta do grão de milho (<i>Zea mays</i> L.).
Córdova-Noboa et al. (2021)	Efeitos da dureza do grão de milho e da temperatura de secagem do grão no tamanho da partícula e na durabilidade do pellet durante a moagem em moinho de rolos ou martelos.
Sousa et al. (2021)	Bioingrediente produzido a partir da fermentação de farelo de milho e subproduto utilizando (<i>Rhizopus oligosporus</i>) e secagem em estufa de ar forçado: Modelagem matemática e avaliação de parâmetros de qualidade.

Fonte: Autora (2023).

Entre essas temperaturas, a de (60 °C) foi a que refletiu na manutenção do fenólico total, na manutenção do conteúdo de proteína (9,1-13,1 g/100g) e na redução de antioxidante. Porém, a temperatura de (70 °C) foi a mais indicada neste estudo para as etapas de fermentação. Entre as justificativas que remetem a importância da lactose para a fermentação, está o fato de se transformar em ácido lático reduzindo o pH do meio. Esta qualidade obtida pela secagem, tida como ideal, facilita a conservação do grão de milho, podendo ser complementado com a refrigeração e ou outros métodos de armazenamento. Por essa razão,

há vantagens em desenvolver-se modelos matemáticos visando otimizar o tempo de secagem em grãos.

O modelo matemático 3D estudados por Zhao et al. (2016) e Wei et al. (2020), por exemplo, levou em consideração a heterogeneidade de componentes do milho como pericarpo, endosperma duro, endosperma mole e germe e avalia a capacidade de difusão de umidade de grãos de milho, e com isso proporcionar uma distribuição precisa de umidade em vários estágios da secagem. No modelo matemático obtido por Wei et al. (2020) mostraram que o germe concentrou maior teor de água e menor temperatura, revelando que a secagem em multiestágio aperfeiçoou o tempo de secagem, havendo redução de água (24,50% e 5,63%) em comparação aos outros parâmetros.

Com intuito de manter as propriedades benéficas de grãos de milho são analisados outros métodos de secagem como os por congelamento, por pulverização e por solventes. E podem ser observados em estudos de Berlanga-Reyes et al. (2021), onde as propriedades físico-químicas de tortilhas de milho, tais como as arabinosilans, não sofrem interferência nas propriedades. Estes relataram, apenas, que a secagem por pulverização foi mais econômica durante o processamento das tortilhas. Entre a importância das arabinosilans está na função estrutural nas células vegetais e são reservatórios de ácido fenólicos, estando envolvido na defesa da célula de grãos e cereais contra possíveis patógenos.

A busca por secagens ideais que não comprometem as propriedades bioquímicas dos grãos de milho é analisada em pesquisas científicas. Em estudos de Timm et al. (2020) usando diferentes temperaturas de secagem (30 °C, 50 °C, 70 °C e 90 °C) em milho farináceo com UR de (13%), no secador de leito fixo, tiveram sucesso no aumento de proteína residual (0,21% para 0,74%) e maior endurecimento dos grânulos até 70 °C.

Nesta mesma sequência de estudos Hassan et al. (2021) verificaram que a secagem em micro-ondas a (50 °C, 55 °C e 60 °C) com UR (10%, 14% e 18%) não alterou conteúdos de amido, proteína bruta, óleo bruto, teor livre de aminoácido e coloração. Porém, o aquecimento de micro-ondas causou mudanças nas propriedades dos ácidos graxos, o Oleico aumentou de (29,0% para 29,4%), ao passo que o Linoleico sofreu redução de (55,1% para 54,8%) a partir de 60 °C. Já em estudos de Coradi et al. (2020) aplicando temperaturas de (80, 100 e 120 °C) verificaram que a secagem mais acelerada (120 °C) culminou em menor acidez (1,94% para 1,31%) na massa de grãos, porém reduziu os teores de proteína bruta (8,0 para 7,67%) durante o armazenamento.

Poder elevar o nível de temperatura no momento da secagem e, garantir condições ideais de armazenamento, inibir o ataque de insetos e manter propriedades físico-químicas dos

grãos, estão relatadas como grandes objetos de estudo na engenharia da pós-colheita. Pois a presença de água acima de 13-14% ao depender da região, acelera as atividades metabólicas dos microrganismos, desencadeando no aumento de cinzas em função do consumo da matéria orgânica da massa de grãos (CHOTIKASATIAN et al., 2017).

O sucesso da secagem também reflete na qualidade do processamento de rações animal, e já podem ser encontrados na literatura seus efeitos em rações de frangos de corte. Em estudos de Huart et al. (2018), o impacto da secagem a (54 °C, 90 °C e 139 °C) em grãos de milho com UR de (36% e 29%) causa interferência na digestibilidade in vitro de frango de corte, pois rações processadas a uma secagem à (130 °C) à UR (36%), reduz o amido e por consequência a energia, levando a uma baixa digestibilidade, interrompendo o crescimento de frangos já que as partículas são prejudicadas.

A alteração na temperatura de secagem de milho pode resultar na produção de complexos indigestos que irão prejudicar a digestibilidade dos nutrientes e no desempenho de frangos de corte (HUART et al., 2018). E quando se aplica a secagem em milho para processamento de ração, a qualidade do produto final é umas das exigências neste setor. Tendo em vista que a dureza dos grãos de milho e a temperatura de secagem afeta o tamanho e a distribuição das partículas após a moagem, impactando a produtividade da fábrica de ração (CÓRDOVA-NOBOA et al., 2021).

Córdova-Noboa et al. (2021) analisando duas variedades de milho, nas temperaturas de (35 °C, 80 °C e 120 °C), verificaram que a fragmentação do milho na moagem foi afetada pela dureza do milho e que as temperaturas de secagem afetaram a distribuição dos tamanhos das partículas, e que o milho com dureza média seco a temperatura de 35 °C, o índice de durabilidade das pelotas (IDP) foi melhor para dietas dos frangos quando comparadas às temperaturas de (80 °C e 120 °C).

Córdova-Noboa et al. (2020) analisando as temperaturas de secagem de (35 °C e 120 °C) e tamanhos de partículas grosseiro e fino em três níveis de suplementação de (0, 133 e 266 g/ton⁻¹) em frangos de corte, relatavam que a temperatura de (120 °C) interferiu na moagem do milho e afetavam as propriedades da ração, sendo necessário o incremento da enzima amilase. O tamanho da partícula do grão é um importante fator, pois pode influenciar a fisiologia gastrointestinal em frangos de corte (CELI et al., 2017). E a amilase, por ser uma enzima responsável pela digestibilidade do amido do milho, fez com que o fígado e moela dos frangos neste estudo, apresentassem tamanhos maiores quando comparados aos animais suplementados apenas com dieta à base de milho. E estes sugerem o uso da secagem por


aeração juntamente com a utilização de sistema hermético de armazenagem como melhores estratégias para manter essas propriedades preservadas.

4. ARMAZENAGEM

A etapa de armazenagem visa conservar a qualidade dos grãos até a comercialização, diminuindo o metabolismo dos grãos, a incidência de microrganismos. Os silos metálicos podem ser divididos em silos de fundo plano (Figura 6A) e silos de fundo cônico (Figura 6B), de 45° e 60° (Tabela 4). Os silos de fundo plano contam com sistema de aeração e são ideais para a armazenagem por longos períodos. Já os silos de fundo cônico são sistemas de armazenagem temporários (silos pulmão), os quais servem como recurso técnico para evitar gargalos durante o processo de secagem, além disso, podem ser usados para uniformizar as temperaturas e umidade durante o recebimento e intervalos de secagem.

Durante o armazenamento, ocorrem também mudanças nas propriedades físico-químicas do milho e seus derivados, como farinha, amido, ração animal e etanol. As mudanças estão relacionadas ao tempo de armazenamento, associado à temperatura e teor de umidade dos grãos (SETIAWAN et al., 2010). Além dos efeitos causados pelas condições de armazenamento, algumas alterações no milho e derivados também podem advir das condições de secagem utilizadas, piorando no armazenamento (CORADI et al., 2020a).

Figura 6 - Silos armazenadores de fundo plano (A.) e fundo cônico (B.)



Fonte: Autora (2023).

Nas indústrias alimentícias, o milho é processado por meio da moagem a seco e úmida. Na moagem a seco ocorre a separação do endosperma, pericarpo e germe. Neste caso, o

endosperma é destinado à produção da farinha, o pericarpo à produção de farinhas ricas em fibras e o gérmen para a extração do óleo, resultando em farelo desengordurado. Além disso, o milho pode ser moído sem essa separação, resultando em farinhas integrais. A moagem úmida destina-se principalmente à extração de amido. Na moagem úmida, o gérmen também é separado e destinado à extração do óleo, resultando no farelo de milho que é destinado à ração animal (ALMEIDA, 2019; RAUSCH et al., 2019).

Tabela 4 - Equipamentos comerciais de armazenagem

Equipamentos de armazenagem					
Silos Metálicos Fundo Plano					
Fabricante	Intermediários	Diâmetro (m)	Altura (m)	Volume (m³)	Capacidade (ton)
A1	142	3,63 – 32,73	3,05 – 29,73	25 – 19221	19 – 15137
A2	264	5,46 – 32,74	7,16 – 33,92	143 – 23197	114 – 18442
B1	176	4,64 – 32,48	4,96 – 29,02	67 – 18516	53 – 14720
C1	-	4,54 – 36,38	3,26 – 33,34	38 – 26140	-
C2	-	4,60 – 33,15	4,07 – 31,63	52,1 – 19748	39,0 – 14811
C3	62	4,58 – 14,65	3,62 – 19,99	44,21 – 2870	33 – 2153
E1	80	7,45 – 22	5,49 – 23,68	145 -6991	134 – 5894
E2	148	4,55 – 32,74	5,03 – 32,49	67,45 – 21680	52 – 16545
G1	197	5,45 – 31,8	4,9 – 35,2	78 – 22227	71 – 21327
K1	150	7,27 – 47,29	5,72 – 29,97	183 – 36205	138 – 27154
P1	95	5,5 – 16,5	3,66 – 12,8	98 – 3036	58,8 – 2277
P2	7	2,8 – 14,87	3,80 – 16,8	-	14,75 – 1822,5
S2	135	3,95 – 32,72	3,05 – 29,73	25 – 19221	19 – 15137
Silos Metálicos Fundo Cônico (45°) – (Pulmão/Elevador)					
Fabricante	Intermediários	Diâmetro (m)	Altura (m)	Volume (m³)	Capacidade (ton)
A1	58	1,81 – 9,09	3,62 – 23,74	4 – 1145	4 – 902
A2	35	4,55 – 9,1	8,52 – 18,36	91 – 867	72 – 689
B1	35	3,71 – 9,28	9 – 10	19,5 - 1006	15 – 755
C1	16	2,73 – 10,91	5,25 – 26,05	14 – 1800	-
C2	-	3,68 – 11,05	5,93 – 26,33	29,3 – 1841	22 – 1380
E2	28	4,55 – 9,09	8,14 – 21,7	79,63 – 1046	61 – 799
G1	30	3,64 – 9,144	5,13 – 26,33	26,7 – 1320	20 – 990
K1	45	3,64 – 9,09	5,85 - 22,09	29 – 1040	17 – 780
P1	54	2,56 – 9,15	4,57 – 6,291	7,7 – 936	4,6 – 702,2
S2	57	3,67 – 9,17	5,35 – 25,38	22,08 – 1262	17 – 947
Silos Metálicos Fundo Cônico (60°) – (Pulmão/Elevador)					
Fabricante	Intermediários	Diâmetro (m)	Altura (m)	Volume (m³)	Capacidade (ton)
A	18	3,71 – 5,57	5,32 – 14,40	24,3 – 223,1	15,8 – 145,1
C	30	3,64 – 9,144	6,55 – 29,20	31,8 – 1380	24 – 1035
D	11	4,55 – 5,45	10,17 – 15,85	88,64 – 242,52	68 – 185
E	57	3,67 – 9,17	6,78 – 28,77	26,81 – 1335	20 – 1002
H	58	1,81 – 9,09	4,29 – 27,06	5 – 1212	4 – 954
I	10	1,86 – 7,27	4,45 – 20,24	6 - 570	-

Fonte: Autora (2023).

A eficiência de armazenagem de grãos é dependente das tecnologias empregadas e manejadas nessa etapa de pós-colheita. Alguns estudos relataram que as condições de armazenamento interferem na qualidade de grãos de milho (Tabela 5).

Tabela 5 - Condições de armazenamento na qualidade de grãos de milho

Autores	Títulos
Maina et al. (2016)	Práticas pós-colheita de agricultores de milho no distrito de Kaiti, no Quênia, e o impacto do armazenamento hermético nas populações de (<i>Aspergillus Spp.</i>) e contaminação por aflatoxina.
Chotikasatian et al. (2017)	Estudo sobre a viabilidade de quantificar a densidade populacional de insetos em grãos armazenados em silos herméticos através de medições de concentrações de CO ₂ .
Fleurat-Lessard (2017)	Gestão integrada dos riscos de deterioração de grãos armazenados, por micotoxinas de fungos transmitidos por sementes durante o armazenamento – Uma atualização.
Wang et al. (2019)	Mudanças na distribuição e migração de umidade em espigas frescas de milho durante o armazenamento.
Alvarez et al. (2019)	Armazenamento de WDGS em condições herméticas e não herméticas: Efeito nas propriedades sensoriais, microrganismos, micotoxinas e valor nutricional.
Wang et al. (2019)	Efeitos das condições de armazenamento de fardos secos ao ar livre na palha de milho e na subsequente produção de biogás da digestão anaeróbica.
Córdova-Noboa et al. (2020)	A temperatura de secagem do milho, o tamanho das partículas e suplementação com amilase influenciam o desempenho de crescimento, o desenvolvimento do trato digestivo e a utilização de nutrientes dos frangos de corte.
García-Díaz et al. (2020)	Um estudo abrangente sobre a ocorrência de micotoxinas e seus fungos produtores durante o ciclo de produção de milho na Espanha.
Shaikh et al. (2020)	Características estruturais, funcionais e digestibilidade de extrusados de sorgo e amido de milho (RS ₃) afetado pelo tempo de armazenamento a frio.
Calvo-Brenes & O'Hare (2020)	Efeito do congelamento e armazenamento sob refrigeração no teor de carotenoides e na qualidade de milho doce amarelo e biofortificado com zeaxantina (<i>Zea mays</i> L.).
Kumar et al. (2020)	Estabilidade de armazenamento e caracterização de características bioquímicas, de reidratação e de cor de grãos de milho doce desidratado.
Fernandes et al. (2021)	Influência do híbrido, umidade e tempo de armazenamento no perfil de fermentação e digestibilidade do amido de silagens de grãos de milho.
Marcos Valle et al. (2021)	Evolução da microbiota de grãos durante o armazenamento hermético de milho (<i>Zea mays</i> L.).
Mubarak & Keta (2021)	Estudo de fungos em milho armazenado (<i>Zea mays</i> L.) no estado de Kebbi, Nigéri.

Fonte: Autora (2023).

Quando o produto passa pela secagem a temperaturas mais baixas, o tempo para realizar a secagem é também maior, induzindo ao grão de milho entrar em equilíbrio higroscópico, refletindo na estabilidade do teor de água no armazenamento (MAINA et al., 2016). Por essa razão, adotar a prática de armazenagem e ao mesmo tempo manter as principais propriedades físico-químicas são algumas das prioridades no processamento de grãos de milho para ração.

Este armazenamento pode ser realizado de diversas formas, podendo ser a “seco” e a “frio”. Em estudo de Calvo Brenes & O’Hare (2020) foi analisado o armazenamento a fresco e congelante no conteúdo de carotenoides em milho-doce e verificaram que a temperatura congelante a partir de (-20 °C e -80 °C) até três meses, promove o declínio de carotenoides, ao passo que a temperatura fresca de armazenamento a (4 °C) até quinze dias, os teores de carotenoides permaneceram adequados. Aspectos relacionados como, teor, cor e amido não foram afetados pelo armazenamento a (4 °C) até quinze dias, porém observou-se uma redução nos açúcares e sólidos solúveis totais.

O armazenamento em temperaturas baixas revela as opções de sucesso que podem ser empregadas nas unidades armazenadoras em regiões com baixo índice de umidade relativa. O sistema de aeração, apesar de oneroso, está entre essas alternativas para regiões quentes, pois simula as condições anteriores.

Estudos com silagens de milho evidenciam que a umidade dos grãos alterou negativamente a fermentação e a digestibilidade de nutrientes quando o armazenamento se prolongou, por um período de 60 dias. Neste estudo, houve uma redução nos teores de ácido butírico (1355,48 mg/kg) (FERNANDES et al., 2021). Entre a importância do ácido butírico para frangos de corte, está em manter ativa a mucosa intestinal e ainda, acelera a multiplicação celular que por consequência aumenta a digestibilidade do amido e de outros nutrientes por essa espécie.

A aplicação de novas tecnologias de armazenamento usando atmosfera modificada x atmosfera controlada nas temperaturas (18 °C e 20 °C) e umidade intersticial (77% e 79%), respectivamente, tiveram resultados diferentes quanto aos parâmetros de qualidade. Este estudo mostrou que o aumento de CO₂ até 180 dias, reduziu a quantidade de insetos vivos da atmosfera modificada (3050) comparado ao standard (307510), mantendo a qualidade do milho em (0,8% e 1,0%, respectivamente).

O uso de atmosfera hermética está entre as mais importantes tecnologias para conservação de grãos de milho e seus derivados. E pode ser observado em estudo de Alvarez et al. (2019), onde comparando a eficiência do armazenamento hermético (60 dias) e não hermético (29 dias) a 16 °C, respectivamente, em grão de milho. Os sistemas com atmosfera modificada foram os que mais preservaram as propriedades bioquímicas tais como proteína bruta (66,8% para 62,1%) ao passo que não herméticos estes mesmos valores de proteína bruta foi de (66,8% para 10,6%).

A verificação da cinética de degradação de propriedades bioquímicas no grão de milho armazenados em diferentes embalagens durante três meses, reduziu os conteúdos açúcares

totais (10,50 g/100g para 9,73 g/100g), no ácido ascórbico (9,36 g/100g para 8,86 g/100 g), nos sólidos solúveis totais (83 a 51 °Brix), e a taxa de coeficiente e reidratação reduziu de (90,28 para 75,27), de (2,64 para 1,56), respectivamente (KUMAR et al., 2020). Neste estudo, a umidade nas embalagens de papel alumínio a vácuo foram de 2,12 para 3,92% indicando o alto potencial de armazenamento até 90 dias.

Avaliando o efeito do armazenamento de grão de milho em fardos secos no ambiente ao ar fresco e fechado, e seus efeitos sobre o teor de hemicelulose durante um ano mostraram que esse carboidrato foi reduzido em (22,2% e 13%, respectivamente), assim como para os valores de metano (23% e 13%, respectivamente) (WANG et al., 2019). Neste estudo, quando se avaliou o tamanho das partículas, foi verificada uma redução 26,4% nestas propriedades quando a partícula saiu de (12,7 mm para 1mm) após o armazenamento.

Os fungos toxigênicos podem ser encontrados na lavoura e se estender ao armazenamento e é neste processo que deve proceder a cuidados rigorosos de modo que todas as etapas da pós-colheita possam eliminá-los. García Díaz et al. (2020) mostraram que durante a colheita de milho, foram encontrados a presença (89%) da espécie (*Aspergillus flavus*), seguida pelas espécies agregadas (*Aspergillus niger*) (52%), (*Aspergillus parasiticus*) (11%). Ainda na espiga de milho, foram encontradas (*Aspergillus niger*) (16,60%) e (*Penicillium*) (9,77%) (MUBARAK & KETA, 2021). E são justamente esses esporos que são transportados para as unidades armazenadoras. Estudos com grãos de milho armazenado por três meses em sacos herméticos de tripla camada-PICS e polipropileno-PP e em celeiros fechados e ao ar livre, os autores verificaram que a população de (*Aspergillus flavi*) e (*Aspergillus parasiticus*) em sacos de polipropileno foram mais suscetível à proliferação, com mais de (71%) (MAINA et al., 2016).

Em grãos de arroz, por exemplo, estão sendo estudadas ferramentas capazes de determinar a densidade populacional de insetos nos silos, por meio do monitoramento dos níveis de CO₂. Neste estudo, em uma quantidade de 125 g de arroz com presença de 100 insetos, foi obtido uma taxa de respiração dos (*Sitophilus zeamais*), (*Rhyzopertha dominica*) e (*Tribolium castaneum*) (9,57-14,13, 1,96-3,93 e 4,59-11,76 µl/inseto-h, respectivamente) a partir do cálculo da curva de CO₂ (CHOTIKASATIAN et al., 2017). A atividade hídrica elevada somada ao tempo de armazenamento determinaram os ambientes propícios para a ação de organismos. Porém, quando se estabelecem uma atmosfera protegida, tais como frascos de vidros armazenados, nas temperaturas (15 °C, 25 °C e 35 °C), ocorreu redução de fungos e de bactérias de (0,72% e 0,48%, respectivamente), pois essa alta atividade hídrica (0,85%) dentro do ambiente armazenador hermético culmina no aumento de CO₂ (0,86%),

que por consequência inibiu o crescimento microbiano, pois passa a ter a presença do ácido láctico pela ação de bactérias anaeróbicas prevenindo os grãos de milho (MARCOS VALLE et al., 2021).

A exigência da qualidade de grãos armazenados excede todas as propriedades que por algum motivo necessitam ser preservadas para produção de frangos de corte. Características como a digestibilidade do amido resistente criado a partir de grãos de milho extrusados sobre altas temperaturas, estão sob os efeitos do armazenamento (SHAIKH et al., 2020). Quando armazenados esses estudados no período de (7 e 14 dias) a (4 °C), a digestibilidade do amido resistente no milho comum é de (64,90%), enquanto, que a do milho sorgo foi de (70,64%) ao (14° dia). Ressaltando ainda que a digestibilidade está diretamente relacionada com a cristalização desses amidos. No trato digestivo de frangos de corte, por exemplo, o “amido resistente” é um tipo de carboidrato que tem comportamento fibroso no organismo dos animais. Em frangos, por exemplo, quando esse tipo de amido chega no intestino grosso, ele é fermentado por bactérias do tipo (*Acidophilus*) benéfica.

O milheto, por exemplo, possui propriedades semelhantes ao grão de milho, dos quais exigem cuidados no armazenamento em substituição ao milho comum, participa do desempenho corporal de frango de corte em (13%) entre os (21° a 42° d). Seus teores de carboidratos e proteínas representam (72,2% e 13,09%), respectivamente, quando acondicionados em ambientes não apropriados alteram a digestibilidade e desempenho de aves.

Desta forma é estritamente recomendado o uso de boas práticas de armazenagem para preservar a qualidade da matéria-prima (grãos de milho) afim de evitar a multiplicação de fungos, pois grande parte da deterioração fúngica de grãos de milho armazenado ocorre quando a atividade de água (aw) excede o limite crítico que permite instalação de espécie toxigênicas (*Aspergillus* e *Penicillium*) (FLEURAT-LESSARD, 2017). A única maneira é trabalhar com medidas preventivas que inibem esse processo, como os processos de secagem a temperaturas baixas dos grãos de milho e o armazenamento controlado ou com atmosfera modificada.

REFERÊNCIAS BIBLIOGRÁFICAS

AGUIRRE, M., KIEGLE, E., LEO, G., & EZQUER, I. Carbohydrate reserves and seed development: an overview. **Plant Reproduction**, v.31, n.3, p.263–290, 2018. <https://doi.org/10.1007/s00497-018-0336-3>

AUBERT, B. A, SCHROEDER, A., & GRIMAUDDO J. IT as enabler of sustainable farming: An empirical analysis of farmers adoption decision of precision agriculture technology. **Decision Support Systems**, v.54, p.510–520, 2012. <https://doi.org/10.1016/j.dss.2012.07.002>

ALVAREZ, E., CARDOSO, M., DEPETRIS, G., CASTELLARI, C., CRISTOS, D., MONTIEL, M. D., & BARTOSIK, R. Storage of WDGS under hermetic and non-hermetic conditions: Effect on sensory properties, microorganisms, mycotoxins and nutritional value. **Journal of Stored Products Research**, v.80, p.65–70, 2019. <https://doi.org/10.1016/j.jspr.2018.11.011>

AMINU, M & JIBRIN, N. K. Study of Fungi on Stored Maize (*Zea mays* L.) in Kebbi State, Nigeria Mubarak. **Journal of Current Opinion in Crop Science**, v.2, n.1, p.55–59, 2021. <https://jcoocs.com/index.php/ej/article/view/40>

ARANGUREN, M., CASTELLÓN, A., & AIZPURUA, A. Crop Sensor Based Non-destructive Estimation of Nitrogen Nutritional Status, Yield, and Grain Protein Content in Wheat. **Agriculture**, v.10, n.148, 2020. <https://doi.org/10.3390/agriculture10050148>

BERLANGA-REYES, C., GUERRERO-ELIAS, H. Y., IGNACIO-PACHECO, M., CONTRERAS-JÁCQUEZ, V., CAMACHO-RUIZ, R., MATEOS-DÍAZ, J. C., NEVÁREZ-MOORILLÓN, V., & ASAFF-TORRES, A. Effect of drying method and process conditions on physicochemical and rheological properties of arabinoxylans extracted from corn-lime-cooking-liquor on a pilot plant scale. **Food Hydrocolloids**, v.119, n.106819, 2021. <https://doi.org/10.1016/j.foodhyd.2021.106819>

BERNARDI, A., LIMA, J.D., OLIVEIRA, G. A., TRENTIN, M. G. Análise de investimento em segregação de milho: estudo de caso em agroindústria produtora de rações para frangos de corte. **Custos e gronegocio**, v.13, n.4, 2017. ISSN 1808-2882 <http://www.custoseagronegocioonline.com.br/>

BERRY, J. K., DELGADO, J. A., KHOSLA, R., & PIERCE, F. J. Precision conservation for environmental sustainability. **Journal of Soil and Water Conservation**, v.58, p.332–339, 2003. <https://www.jswconline.org/content/58/6/332>

BONGIOVANNI, R., & LOWENBERG-DEBOER J. Precision agriculture and sustainability. **Precision Agriculture**, v.5, p.359–387, 2004. <https://doi:10.1023/B:PRAG.0000040806.39604.aa>

CALVO-BRENES, P., & O'HARE, T. Effect of freezing and cool storage on carotenoid content and quality of zeaxanthin-biofortified and standard yellow sweet-corn (*Zzea mays* L.). **Journal of Food Composition and Analysis**, v.86, n.103353, 2020. <https://doi.org/10.1016/j.jfca.2019.103353>

CELI, P., COWIESON, A. J., FRU-NJI, F., STEINERT, R. E., KLUENTER, A. M., & VERLHAC, V. Gastrointestinal functionality in animal nutrition and health: New opportunities for sustainable animal production. **Animal Feed Science and Technology**, v.234, p.88–100, 2017. <https://doi.org/10.1016/j.anifeedsci.2017.09.012>

CHOTIKASATIAN, C., CHAYAPRASERT, W., & PATHAVEERAT, S. A study on the feasibility of quantifying the population density of stored product insects in air-tight grain storage using CO₂ concentration measurements. **Journal of Stored Products Research**, v.73, p.21–29, 2017. <https://doi.org/10.1016/j.jspr.2017.05.005>

CORADI, P. C., FEDERAL, U., & MARIA, D. S. 2019. Digestibilidade de frangos de corte em função de dietas com milho armazenados em diferentes condições. Disponível em: https://www.researchgate.net/publication/330970665_digestibilidade_de_frangos_de_corte_e_m_funcao_de_dietas_com_milho_armazenados_em_diferentes_condicoes/citation/download

CORADI, P. C., MALDANER, V., LUTZ, É., DA SILVA DAÍ, P. V., & TEODORO, P. E. Influences of drying temperature and storage conditions for preserving the quality of maize postharvest on laboratory and field scales. **Scientific Reports**, v.10, n.1, p.1–15, 2020. <https://doi.org/10.1038/s41598-020-78914-x>

CÓRDOVA-NOBOA, H. A., OVIEDO-RONDÓN, E. O., ORTIZ, A., MATTA, Y., HOYOS, J. S., BUITRAGO, G. D., MARTINEZ, J. D., YANQUEN, J. J., CHICO, M., MARTIN, V. E. S., FAHRENHOLZ, A., OSPINA-ROJAS, I. C., & PEÑUELA, L. Effects of corn kernel hardness and grain drying temperature on particle size and pellet durability when grinding using a roller mill or hammermill. **Animal Feed Science and Technology**, v.271, n.114715, 2021. <https://doi.org/10.1016/j.anifeedsci.2020.114715>

CÓRDOVA-NOBOA, H. A., OVIEDO-RONDÓN, E. O., ORTIZ, A., MATTA, Y., HOYOS, S., BUITRAGO, G. D., MARTINEZ, J. D., YANQUEN, J., PEÑUELA, L., SORBARA, J. O. B., & COWIESON, A. J. Corn drying temperature, particle size, and amylase supplementation influence growth performance, digestive tract development, and nutrient utilization of broilers. **Poultry Science**, v.99, n.11, p.5681–5696, 2020. <https://doi.org/10.1016/j.psj.2020.07.010>

DELGADO, J., SHORT, N. M., ROBERTS, D. P., & VANDENBERG, B. Big data analysis for sustainable agriculture. *Frontiers in Sustainable Food Systems*, v.3, n.54. 2019. <https://doi.org/10.3389/fsufs.2019.00054>

DONG, T., LIU, J., SHANG, J., QIAN, B., MA, B., KOVACS, J. M., WALTERS, D., JIAO, X., GENG, X., & SHI, Y. Assessment of red-edge vegetation indices for crop leaf area index estimation. **Remote Sensing of Environment**, v.222, n.1, p.133-143, 2019. <https://doi.org/10.1016/j.rse.2018.12.032>

DUYSAK, H., & YIGIT, E. Machine learning based quantity measurement method for grain silos. **Measurement**, v.152, n.107279, 2020. <https://doi.org/10.1016/j.measurement.2019.107279>

FAO. The Future of Food and Agriculture - Trends and Challenges. Food and Agriculture Organization of the United Nations, Rome, 2019.

FERNANDES, J., DA SILVA, É. B., CARVALHO-ESTRADA, P. DE A., DANIEL, J. L. P., & NUSSIO, L. G. (2021). Influence of hybrid, moisture, and length of storage on the fermentation profile and starch digestibility of corn grain silages. **Animal Feed Science and Technology**, v.271, n.114707, 2021. <https://doi.org/10.1016/j.anifeedsci.2020.114707>

FLEURAT-LESSARD, F. Integrated management of the risks of stored grain spoilage by seedborne fungi and contamination by storage mould mycotoxins – An update. **Journal of Stored Products Research**, v.71, p.22–40, 2017. <https://doi.org/10.1016/j.jspr.2016.10.002>

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.

<https://doi.org/10.3390/microorganisms8010141>

HASSAN, A. B., PAWELZIK, E., & VON HOERSTEN, D. (2021). Effect of microwave heating on the physiochemical characteristics, colour and pasting properties of corn (*Zea mays* L.) grain. **Lwt-Food Science and Technology**, v.138, n.110703, 2021.

<https://doi.org/10.1016/j.lwt.2020.110703>

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.

<https://doi.org/10.1080/00071668.2018.1477253>

HUANG, J., MA, Q., CAI, Z., XIA, Q., LI, S., JIA, J., CHU, L., LIAN, T., NIAN, H., & CHENG, Y. Identification and mapping of stable qtls for seed oil and protein content in soybean [*Glycine max* (L.) Merr.]. **Journal of Agricultural and Food Chemistry**, v.68, n.23, p.6448–6460, 2020. <https://doi.org/10.1021/acs.jafc.0c01271>

HUNT, E. R., & DAUGHTRY, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? **International Journal of Remote Sensing**, v.39, p.5345–5376, 2018. <https://doi.org/10.1080/01431161.2017.1410300>

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**, v.71, n.2517412, 2022.

<https://doi:10.1109/TIM.2022.3204078>

KUMAR, N., KACHHADIYA, S., & NAYI, P. Storage stability and characterization of biochemical, rehydration and colour characteristics of dehydrated sweet corn kernels. **Journal of Stored Products Research**, v.87, n.101619, 2020.

<https://doi.org/10.1016/j.jspr.2020.101619>

LEAL, M. M., RODRIGUES, D. M., MORAES, R. S., JAQUES, L. B. A., TIMM, N. S., CORADI, P. C. Monitoring of intergranular variables for predicting technical breakage of wheat grains stored in vertical silos. **Journal of Stored Products Research**, v.102, n.102115, 2023. <https://doi.org/10.1016/j.jspr.2023.102115>

MAINA, A. W., WAGACHA, J. M., MWAURA, F. B., MUTHOMI, J. W., & WOLOSHUK, C. P. Postharvest Practices of Maize Farmers in Kaiti District, Kenya and the Impact of Hermetic Storage on Populations of *Aspergillus* Spp. and Aflatoxin Contamination. **Journal of Food Research**, v.5, n.6, 2016. <https://doi.org/10.5539/jfr.v5n6p53>

MARCOS VALLE, F. J., CASTELLARI, C., YOMMI, A., PEREYRA, M. A., & BARTOSIK, R. Evolution of grain microbiota during hermetic storage of corn (*Zea mays* L.). **Journal of Stored Products Research**, v.92, n.101788, 2021.

<https://doi.org/10.1016/j.jspr.2021.101788>

NEVES, E & SAVELLI, R. A. M. Determinação da perda de peso de grãos de milho armazenados através de diferentes métodos. **Enciclopédia biosfera**, v.14, n.26, 2017.

https://doi.org/10.18677/EnciBio_2017B22

SAID, Z., SHARMA, P., ASLFATTAHI, N., GHODBANE. Experimental analysis of novel

ionic liquid-MXene hybrid nanofluid's energy storage properties: Model-prediction using modern ensemble machine learning methods. **Journal of Energy Storage**, v.52, n.104858, 2022. <https://doi.org/10.1016/j.est.2022.104858>

SHAIKH, F., ALI, T. M., MUSTAFA, G., & HASNAIN, A. Structural, functional and digestibility characteristics of sorghum and corn starch extrudates (RS3) as affected by cold storage time. **International Journal of Biological Macromolecules**, v.164, p.3048–3054, 2020. <https://doi.org/10.1016/j.ijbiomac.2020.08.105>

SOUSA, T. L. DE, SOUSA, K. A. DE, SANTOS, D. C. DOS, ALMEIDA, A. B. DE, REZENDE, T. A. M. DE, SANTANA, R. V., & EGEEA, M. B. Bioingredient produced with fermentation of corn bran and “Cerrado” cashew byproduct using *Rhizopus oligosporus* and forced-air oven drying: Mathematical modeling and evaluation of quality parameters. **Bioactive Carbohydrates and Dietary Fibre**, v.26, n.100262, 2021. <https://doi.org/10.1016/j.bcdf.2021.100262>

TIMM, N. DA S., RAMOS, A. H., FERREIRA, C. D., BIDUSKI, B., EICHOLZ, E. D., & OLIVEIRA, M. Effects of drying temperature and genotype on morphology and technological, thermal, and pasting properties of corn starch. **International Journal of Biological Macromolecules**, v.165, p.354–364, 2020. <https://doi.org/10.1016/j.ijbiomac.2020.09.197>

VANINO, S., NINO, P., DE MICHELE, C., FALANGA, S. B., D'URSO, G., DI BENE, C., PENNELLI, B., VUOLO, F., FARINA, R., & PULIGHE, G. Capability of Sentinel-2 data for estimating maximum evapotranspiration and irrigation requirements for tomato crop in Central Italy. **Remote Sensing of Environment**, v.215, p.452–470, 2018. <https://doi.org/10.1016/j.rse.2018.06.035>

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. <https://doi.org/10.1016/j.fuel.2022.123391>

WANG, H., LIU, J. SHENG, MIN, W. HONG, ZHENG, M. ZHU, & LI, H. Changes of moisture distribution and migration in fresh ear corn during storage. **Journal of Integrative Agriculture**, v.18, n.11, p.2644–2651, 2019. [https://doi.org/10.1016/S2095-3119\(19\)62715-2](https://doi.org/10.1016/S2095-3119(19)62715-2)

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. <https://doi.org/10.1016/j.compag.2020.105335>

YANG, J., ZHANG, C., WANG, Z., SUN, S., ZHAN, R., ZHAO, Y., MA, B., MA, F., & LI, M. Melatonin-mediated sugar accumulation and growth inhibition in apple plants involves down-regulation of fructokinase 2 expression and activity. **Frontiers in Plant Science**, v.10, 2019. <https://doi.org/10.3389/fpls.2019.00150>

ZHAO, H., SU, T., HUO, L., WEI, H., JIANG, Y., XU, L., & MA, F. Unveiling the mechanism of melatonin impacts on maize seedling growth: sugar metabolism as a case. **Journal of Pineal Research**, v.59, n.2, p.255–266, 2015. <https://doi.org/10.1111/jpi.12258>

ZHAO, L., PAN, T., CAI, C., WANG, J., & WEI, C. Application of whole sections of mature cereal seeds to visualize the morphology of endosperm cell and starch and the distribution of

storage protein. **Journal of Cereal Science**, v.71, p.19–27, 2016.
<https://doi.org/10.1016/j.jcs.2016.07.010>

ZHOU, G., HAO, D., XUE, L., CHEN, G., LU, H., ZHANG, Z., SHI, M., HUANG, X., & MAO, Y. Genome-wide association study of kernel moisture content at harvest stage in maize. **Breeding Science**, v.68, p.622-628, 2018. <https://doi.org/10.1270/jsbbs.18102>

CAPÍTULO II - REVISÃO BIBLIOGRÁFICA “TECNOLOGIAS PARA MONITORAMENTO E PREDIÇÃO DE PERDAS NA PÓS-COLHEITA”

RESUMO

O uso de tecnologias de sensoriamento remoto na agricultura aumentou rapidamente nos últimos anos. A disponibilidade de sensores capazes de capturar as ondas eletromagnéticas e/ou calor emitidos pelos alvos, melhorou os processos de pré-colheita e por isso vem se tornando ferramentas essenciais nas fases de pós-colheita. Nesta revisão, objetivou-se apresentar tecnologias de monitoramento e previsão de perdas de grãos de milho durante etapas do processo de pós-colheita. O uso de sensores nos processos de pós-colheita permite o monitoramento preciso das operações e da qualidade do grão, em tempo real, que com o suporte da Internet das Coisas (IoT) e as ferramentas computacionais como algoritmos de inteligência artificial (IA) permitem tomar decisões com antecedência, rastrear e reduzir perdas e garantir a qualidade dos grãos desde o campo até o consumidor. A expansão da IoT e o crescente uso de técnicas de IA, poderão corroborar como estratégias nas fases de transporte, secagem e armazenagem pós-colheita, criando novas perspectivas para o desenvolvimento tecnológico de monitoramento da qualidade de grãos.

Palavras-chaves: Internet das coisas, Inteligência artificial, Monitoramento pós-colheita, Predição de resultados, Tecnologia pós-colheita.

1. MONITORAMENTO DA MASSA DE GRÃOS NAS ETAPAS DE PÓS-COLHEITA

Embora a viabilidade do uso de técnicas de sensoriamento remoto no campo da agricultura tenha sido demonstrada desde a década de 1980, o uso operacional de dados de sensoriamento remoto foi recentemente intensificado e utilizado operacionalmente para uma variedade de aplicações agrícolas (DEFOURNY et al., 2019), entre elas aplicações na pós-colheita de grãos. O uso de sensores pode auxiliar no monitoramento da qualidade e na redução de perdas (CORADI et al., 2020a). Sensores de temperatura podem ser usados próximos aos grãos como um indicador indireto da qualidade do produto durante o transporte, a secagem e o armazenamento. A obtenção de informações em tempo real sobre as condições dos grãos auxilia na tomada de decisões nas etapas de pós-colheita.

A Tabela 1 apresenta estudos que utilizaram técnicas de sensoriamento remoto aplicadas ao monitoramento e controle da qualidade pós-colheita de grãos. Para o monitoramento de grãos durante o transporte do campo para as unidades de armazenamento e das unidades de armazenamento para a indústria, Danao et al. (2015) estudaram o desenvolvimento de uma sonda para monitorar temperatura, umidade relativa, níveis de dióxido de carbono (CO₂) e informações logísticas durante o transporte da soja.


A Figura 1 ilustra uma sonda para monitorar esses parâmetros durante o transporte de grãos. A sonda de monitoramento de grãos foi projetada para ser colocada dentro dos veículos responsáveis pelo transporte dos grãos, permitindo o monitoramento dos parâmetros durante a movimentação do produto. As sondas foram construídas com quatro câmaras espaçadas verticalmente na massa de grãos e uma quinta câmara opcional para o espaço superior acima da massa de grãos dentro da parte de carregamento do veículo de transporte. Cada câmara continha um pacote de sensor Modelo K33-BLG contendo um sensor infravermelho de CO₂ e um sensor integrado de temperatura e umidade relativa. Além disso, a sonda foi equipada com um receptor GPS.

Os sinais de nível lógico RS232 do receptor GPS foram convertidos em sinais lógicos de transistor para transistor (TTL) de 0 a 5 V, para permitir a conexão a uma porta serial secundária na placa de aquisição de dados. Essas sondas são úteis para entender melhor as condições durante o transporte da soja, o que pode levar a um melhor gerenciamento das operações de manuseio e transporte de grãos para minimizar a perda de qualidade da soja no período pós-colheita (DANAo et al., 2015; CORADI et al., 2021).

Além de monitorar a temperatura e outros parâmetros durante o transporte, esse tipo de sensor de massa de grãos contribui para a tomada de decisão na unidade de armazenamento.

Quando o produto chega ao destino, os operadores conhecem antecipadamente suas principais características, tornando os processos de industrialização mais eficientes. Ao desenvolverem um amostrador mecânico portátil para monitorar os grãos de soja transportados, Jaques et al. (2022), verificaram que essa tecnologia apresentando (diâmetro de furo 6,5 mm, altura de perfuração de 235 mm), além de conferir proteção aos sensores de umidade, temperatura e CO₂, permitiu uma leitura intergranular em soja eficiente, no curto espaço de tempo.

Figura 1 - Ilustração de uma sonda para monitoramento de temperatura, umidade relativa, níveis de dióxido de carbono e informações logísticas durante o transporte de grãos



Fonte: Autora (2023).

Quando os lotes de grãos são descarregados nas unidades de armazenamento, os grãos são submetidos à limpeza. Para isso, Wallays et al. (2009) usaram uma seleção de banda de onda hiperespectral para a verificação online da limpeza de grãos. Para permitir o monitoramento online da porcentagem de impurezas junto aos grãos, esses autores desenvolveram um sensor de visão multiespectral, capaz de criar uma imagem virtual com contraste máximo entre os grãos e as impurezas, permitindo a classificação de cada pixel individualmente. As bandas selecionadas foram 465–475 nm, 522–532 nm, 676–705 nm, 849–858 nm e 906–945 nm, o que permitiu a discriminação de grãos para impureza


Tabela 1 - Estudos sobre as técnicas de sensoriamento remoto utilizadas para monitoramento de grãos nas etapas de pós-colheita

Método de detecção	Estágio pós-colheita	Referências
Amostrador mecânico portátil - sensor de CO ₂ , sensor de temperatura e umidade	Transporte de grãos	Jaques et al. (2022)
Pacote de sensores – sensor de CO ₂ , sensor de temperatura e sensor de umidade relativa	Transporte de grãos	Danao et al. (2015)
Sensor de visão multispectral	Limpeza de grãos	Wallays et al. (2009)
Sensor de umidade de microondas	Secagem de grãos	Lewis et al. (2019)
Sensor de umidade	Secagem de grãos	Li et al. (2020)
Detector de Umidade Online Baseado na Conversão V/F	Secagem de grãos	Liu et al. (2015)
Sensor de CO ₂	Grãos armazenados	Neethirajan et al. (2010)
Sensor de CO ₂	Grãos armazenados	Ubhi e Sadaka (2015)
A rede sem fio do sensor de temperatura, sensor de umidade e sensor de luz	Grãos armazenados	Onibonoje et al. (2019)
Internet das Coisas (IoT) – microcontrolador e vários sensores	Grãos armazenados	Kodali et al. (2020)
Internet das Coisas (IoT) – sensor de temperatura, sensor de umidade e sensor de CO ₂	Grãos armazenados	Sindwani et al. (2020)
Sistema Ciber-Físico (CPS) - sensor de temperatura e umidade	Grãos armazenados	Parvin et al. (2018)
Dispositivo de micro-ondas compacto - sensor de atividade de insetos	Grãos armazenados	Reimer et al. (2018)
Sensores de fosfina sem fio	Grãos armazenados	Brabec et al. (2019)
Protótipo de sensores sem fio e Internet das Coisas (IoT) – sensores de temperatura, umidade relativa e CO ₂	Grãos armazenados	Coradi et al. (2022)
Sensor de temperatura, sensor de umidade e sensor de CO ₂	Grãos armazenados	Kumar et al. (2020)
Imagens eletromagnéticas	Grãos armazenados	Asefi et al. (2015)
Imagens eletromagnéticas	Grãos armazenados	Gilmore et al. (2017)
Imagens eletromagnéticas	Grãos armazenados	Asefi et al. (2017)
Imagens eletromagnéticas	Grãos armazenados	Gilmore et al. (2019)

Fonte: Autora (2023).

Os grãos limpos são então levados para a etapa de secagem. Esta etapa também requer monitoramento constante. A Figura 2 ilustra um sistema de monitoramento dos grãos durante a secagem. Lewis et al. (2019) desenvolveram um sistema de secagem de grãos com monitoramento da redução do teor de umidade utilizando um sensor de micro-ondas operando a 5,8 GHz. Lewis et al. (2019) relataram que foi possível determinar o teor de umidade em tempo real e com erro padrão de calibração inferior a 0,54% do teor de umidade quando comparado ao método de referência realizado no forno.

Figura 2 - Ilustração de um sistema de monitoramento de grãos durante a secagem



Fonte: Autora (2023).

Da mesma forma, Li et al. (2020) desenvolveram um dispositivo online para medir o teor de umidade dos grãos durante o processo de secagem. O sensor desenvolvido por Li et al. (2020) determinou o teor de umidade de um único grão por vez, através da aplicação de uma corrente contínua. O circuito elétrico gerado mede a resistência elétrica do grão, que por meio de equações matemáticas projetadas para cada espécie permite atingir o teor de umidade do produto. A resistividade do grão com diferentes teores de umidade difere significativamente,

de modo que a faixa de resistência do volume específico pode atingir 10-3–1015 Ω .cm. Os resultados apresentados por Li et al. (2020) mostraram que o dispositivo tem excelente desempenho em grãos com teor de água (10 – 35% b.u.) e temperatura (-20 – +50 °C) variados, com erro absoluto de medição dentro de 0,5%. Os dados obtidos com o aparelho são adequados para caracterizar a uniformidade do processo de secagem dos grãos. O sensor de monitoramento de secagem baseado na resistência elétrica dos grãos melhora a precisão e confiabilidade da medição e pode ser útil em outros equipamentos inteligentes para secagem dos grãos.


Como a maioria dos grãos são produzidos em períodos específicos do ano e ainda são necessários pelas indústrias ao longo do ano, grande parte dos grãos secos é armazenada. A Figura 6 ilustra um sistema de monitoramento dos grãos durante o armazenamento e os avanços ao longo dos anos. Neethirajan et al. (2010) desenvolveram um sensor de CO₂ para monitorar remotamente a qualidade dos grãos armazenados. O sensor foi desenvolvido usando um polímero condutor de polianilina de ácido borônico como região eletricamente condutora do sensor. O sensor desenvolvido mediu os níveis de CO₂ na faixa de 380 –2400 ppm, detectados em diferentes temperaturas (entre 25 a 55 °C), o que requer água no ar para operar, permitindo a detecção de CO₂ entre 20 e 70% relativo a umidade do ar. Durante o armazenamento dos grãos, fatores como a temperatura e a umidade relativa do ar, o teor de umidade dos grãos, o teor de CO₂ e concentração de insetos devem ser monitorados e controlados, sempre buscando as melhores condições para a conservação dos grãos.

Liu et al. (2015), conseguem monitorando o teor de água, por meio de um com detector on-line, durante o processo de secagem, o qual atua com base na tensão. O sensor também consiste em detectar os valores da resistência elétrica do grão, que se baseia na tensão-frequência, seguida da conversão da teoria de umidade e da frequência, e uma correção não linear em função da temperatura. O mecanismo de operação deste detector é notavelmente semelhante ao descrito por Li et al. (2020) e os resultados são precisos para aplicação no monitoramento de grãos. A indústria precisa de boa precisão ao reduzir o teor de água no processo de secagem.

Uma avaliação da taxa de respiração em função do tempo de armazenamento foi estudada por Ubhi & Sadaka (2015) usando sensores de pressão de CO₂. Esses autores usaram módulos de sensores de pressão. Esses módulos podem medir a faixa de pressão cumulativa entre (-68,9 kPa e 3447,4 kPa) com uma precisão de ($\pm 1\%$) do valor medido. As leituras são comunicadas por meio de um sinal de radiofrequência a uma antena que se conecta a um PC por meio de uma conexão USB para permitir plotagem e visualização ao vivo, além da

gravação de dados em formato tabulado. Por fim, Ubhi & Sadaka (2015) relataram que a técnica de sensoriamento remoto usando um sensor de pressão foi considerada confiável e sensível para medir a taxa de respiração dos grãos nos parâmetros testados (Figura 3).

Figura 3 - Ilustração de um sistema de monitoramento de grãos durante o armazenamento



Fonte: Autora (2023).

Recentemente, Onibonoje et al. (2019) estudaram um sistema de rede de sensores sem fio para monitorar fatores ambientais (temperatura, umidade relativa e luz) que afetam a capacidade de armazenamento de grãos. Os sensores foram implantados em locais fixos perfeitamente distribuídos em um silo de armazenamento de grãos. Onibonoje et al. (2019) relataram que o sistema de rede de sensores sem fio desenvolvido ajuda a garantir a segurança alimentar, bons retornos econômicos e maior qualidade de grãos com instalações de armazenamento bem monitoradas, controladas e acessíveis.

Como mencionado até agora, as técnicas de armazenamento automático são amplamente utilizadas nas unidades de armazenamento para detectar a deterioração dos grãos, por meio da verificação da temperatura e umidade relativa do ar, teor de umidade dos grãos e concentração de CO₂. Dependendo do tamanho do silo, um ou mais cabos contendo uma série

de sensores são pendurados verticalmente. Em cada cabo, os sensores são normalmente separados por 1,2 m. O número de cabos em um silo depende de fatores como o tamanho do silo (especialmente seu diâmetro), as condições climáticas da região e as espécies de grãos a serem armazenados. Uma das principais vantagens deste sistema é sua capacidade de monitorar parâmetros de armazenamento em tempo real (ASEFI et al., 2015; CORADI et al., 2020b).

O espaçamento típico entre os sensores (1,2 m) no cabo resulta em baixa resolução espacial. Os sensores de temperatura e umidade são localmente sensíveis, fornecendo detecção limitada a um raio de 30 a 60 cm. Os grãos são um bom isolante térmico e um ponto quente longe do sensor leva tempo para ser detectado por ele. Além disso, os cabos que suportam os sensores são caros e requerem reforço estrutural na cobertura do silo para compensar as forças exercidas nos cabos durante o descarregamento (ASEFI et al., 2015; CORADI et al., 2020b).

Uma alternativa recente a esse método de monitoramento foi estudada por Asefi et al. (2015). Esses autores estudaram o monitoramento de grãos armazenados em silos por meio de imagens eletromagnéticas. Asefi et al. (2015) apresentou avanços com o desenvolvimento de uma nova técnica de monitoramento de grãos por meio de imagens eletromagnéticas, uma modalidade que pode fornecer imagens globais e quantitativas das propriedades dos grãos ao longo do silo. Antenas montadas na lateral iluminam o produto armazenado e um conjunto de receptores mede a energia eletromagnética dentro do silo em locais discretos.

As imagens eletromagnéticas oferecem vantagens, que incluem sensibilidade global, uso de radiação eletromagnética de baixo custo e a capacidade de fornecer imagens sem perturbar ou interagir com o grão. Outra característica que torna as imagens eletromagnéticas uma melhor alternativa às técnicas atuais de monitoramento de grãos é sua alta resolução espacial em comparação com as técnicas existentes. A maioria das tecnologias de monitoramento de contêineres de grãos são afetados por partículas de grãos e poeira. Embora essas partículas, ao longo do tempo, possam se acumular e revestir os sensores na caixa de armazenamento, a espessura limitada desse revestimento o torna invisível às imagens eletromagnéticas (ASEFI et al., 2015).

Seguindo o estudo desenvolvido por Asefi et al. (2015) e Gilmore et al. (2017) também estudaram o monitoramento das condições de armazenamento de grãos, porém, em escala real. De acordo com Gilmore et al. (2017), a criação de imagens eletromagnéticas é baseada na produção de um campo de interrogação conhecido dentro da região de medição e na medição precisa desse campo. Ambos os processos requerem sensores dentro do silo. Há uma

compensação de engenharia no projeto do sensor: o transmissor ideal comunicará eficientemente um padrão de campo conhecido ao silo, enquanto os receptores medirão esse campo em um único ponto sem perturbar esse campo.

O sistema de imagem eletromagnética demonstrou ser capaz de detectar uma região de deterioração na massa de grãos, que era de 25% de umidade, juntamente com uma massa de grãos com teor de umidade de 15%. Assim, sistemas baseados em imagens eletromagnéticas para monitoramento de grãos são viáveis industrialmente para monitoramento de grãos armazenados (GILMORE et al., 2017). Este método de sensoriamento também é capaz de detectar o aumento de temperatura na massa de grãos promovido pela presença de insetos próximos aos grãos. É uma tecnologia capaz de monitorar usando imagens de pequenas alterações no ambiente de armazenamento (ASEFI et al., 2017).

Um avanço no uso da técnica de imagem eletromagnética foi apresentado por Gilmore et al. (2019). Esses autores criaram um sistema de imagens eletromagnéticas 3D do teor de umidade dos grãos durante o armazenamento. Os resultados da imagem 3D foram comparados com os dados dos sensores de três pontos que foram incorporados ao compartimento. Os resultados mostraram que as imagens 3D seguem os sensores de ponto, com alguns artefatos de imagem devidos em parte a problemas com a modelagem do cabo do sensor de ponto na caixa. Esses artefatos foram eliminados usando um algoritmo de pós-processamento que divide a imagem em um pequeno número de camadas e calcula a média dos resultados dentro de cada camada. Gilmore et al. (2019) concluíram que o sistema de imagem eletromagnética pode monitorar a redução de umidade ao longo da secagem e armazenamento. Além disso, eles apontaram que a técnica foi capaz de mostrar quando os grãos atingiram condições seguras de armazenamento.

Além dos fatores climáticos, como temperatura e umidade relativa do ar, e dos próprios fatores intrínsecos aos grãos, como teor de umidade e taxa de respiração, fatores externos, como a presença de insetos, podem reduzir os padrões de qualidade dos grãos (LIMA et al., al. 2021). Por isso, a presença de insetos próximos aos grãos deve ser monitorada, manejada e interrompida. Assim, Reimer et al. (2018) criaram um dispositivo compacto para monitorar a atividade de insetos em amostras de grãos. Os autores demonstraram que o sensor é baseado em uma cavidade de micro-ondas ativa. O sensor desenvolvido por Reimer et al. (2018) tem potencial para uso no monitoramento da densidade populacional de insetos em grãos armazenados. Como a presença de insetos é uma característica negativa para indústrias que buscam boas condições de armazenamento de grãos, estudos promissores como este apresentam uma excelente perspectiva.

Esses sensores são essenciais para detectar a presença de insetos. No entanto, os insetos devem ser extintos da massa de grãos. Uma das principais técnicas utilizadas para isso é a submissão da fosfina junto aos grãos, técnica conhecida como fumigação. Por terem percebido durante a aplicação desta técnica, Brabec et al. (2019) realizaram a avaliação de sensores de fosfina sem fio para monitoramento do gás que é responsável pela fumigação de grãos armazenados. Os autores relataram que os dados de fumigação automatizados forneceram uma imagem detalhada do processo. Essas informações podem ajudar os responsáveis pela fumigação a avaliar melhor a operação e garantir o sucesso do controle de insetos.

Alternativas à fumigação química estão sendo exploradas à medida que fumigantes populares, como brometo de metila e fosfina, estão sendo eliminados devido à sua natureza destruidora da camada de ozônio e resistência a insetos, respectivamente. Assim, o armazenamento a vácuo hermético com auxílio de sensores surge como uma alternativa às práticas convencionais (KUMAR et al., 2020). Para substituir o uso de agentes químicos no controle de insetos em grãos armazenados, Kumar et al. (2020) realizaram o armazenamento hermético, removendo o oxigênio presente na célula de armazenamento e detectando os grãos usando sensores de temperatura e umidade relativa, pressão e CO₂. Kumar et al. (2020) relataram que o sensor de CO₂ pode indicar um status livre de insetos com os grãos. Portanto, um sistema de apoio à decisão baseado em multissensores, como temperatura, umidade relativa, além do sensor de CO₂, pode ser útil para indicar a qualidade do grão armazenado em um sistema hermético. Além disso, os autores relataram que o armazenamento hermético baseado na detecção dos fatores mencionados pode ser melhor para o manejo da fumigação com fosfina.

2. INTERNET DAS COISAS (IOT) E INTELIGÊNCIA ARTIFICIAL APLICADA NA PÓS-COLHEITA DE GRÃOS

Dando continuidade à busca pela conservação de grãos durante as etapas pós-colheita, a Internet das Coisas (IoT) pode ajudar a melhorar os métodos de monitoramento e rastreabilidade de produtos alimentícios. Kodali et al. (2020) descreveram um sistema que consiste em um microcontrolador e vários sensores que podem coletar informações como temperatura, umidade, CO₂ e qualidade dos alimentos e enviar essas informações para o operador responsável enquanto responde adequadamente para garantir que os produtos sejam mantidos em armazenamento em condições ideais. O dispositivo de monitoramento também modera os níveis de temperatura e o teor de umidade dos grãos usando ventiladores e

unidades de refrigeração controladas pelo sistema IoT. Qualquer infestação de mofo e/ou insetos, por exemplo, é notificada ao gestor para que sejam tomadas providências (KODALI et al. 2020).

Sindwani et al. (2020) também indicaram o uso de um sistema de monitoramento em tempo real baseado no sistema IoT, observando parâmetros de armazenamento como temperatura do ar, umidade relativa e concentração de CO₂. Esses autores utilizaram um dispositivo de hardware que contém dois sensores e uma bateria para alimentação. Os sensores foram utilizados para detectar os parâmetros de temperatura, umidade relativa e CO₂. O portal online foi criado para analisar e coletar dados em tempo real dos sensores. Este portal pode ser facilmente integrado ao portal digital já presente na maioria das unidades de armazenamento.

Neste mesmo sentido, Coradi et al. (2022) verificaram que protótipos de sensores sem fio associados as plataformas de Internet das Coisas (IoT) e modelos de redes neurais artificiais, em grãos de milho armazenados em silos de sacarias, foram eficientes para o monitoramento da temperatura, umidade relativa e concentrações de dióxido de carbono intergranular. Neste estudo verificou-se que a qualidade do milho armazenado consegue ser eficiente estando a 13% do teor de água nas condições de 17 °C de temperatura.

Além disso, Parvin et al. (2018) estudaram um sistema inteligente baseado em um sensor otimizado para o monitoramento eficiente de grãos armazenados. Esses autores usaram um sistema ciber-físico (CPSs), que é como a Internet das Coisas (IoT), mas fornece mecanismos inteligentes com maior coordenação e controle entre a comunicação física e os elementos computacionais. Uma aplicação típica de CPS seria monitorar um aspecto particular usando muitas redes de sensores sem fio e comunicar as informações processadas a um nó central. De acordo com Parvin et al. (2018), a função de monitoramento pode ser realizada por meio da detecção contínua de vários parâmetros, como temperatura e umidade do ar intersticial dentro do ambiente de armazenamento de grãos por uma rede de sensores sem fio e pela coleta, processamento e exibição de dados eficientes.

Uma vez coletados os dados, a unidade de gerenciamento e controle é utilizada para prever a distribuição da temperatura e do teor de umidade dos grãos, bem como a temperatura e a umidade do ar intersticial no armazenamento. Isso ajudará a reduzir efetivamente a temperatura e o teor de umidade dos grãos para garantir sua qualidade. Quando a temperatura e a umidade relativa do compartimento de armazenamento são superiores aos valores limite predefinidos, o nó sensor coordenador envia o comando ao nó sensor de controle através da porta serial. O nó de controle então executa as ações necessárias, como ligar o ventilador de

refrigeração ou aeração para reduzir a temperatura e a umidade relativa e, assim, manter a qualidade e segurança dos grãos armazenados (PARVIN et al., 2018).

A previsão de resultados também entra nas etapas de secagem e armazenamento dos grãos (Tabela 4). Para melhorar a precisão do teor de umidade dos grãos descarregados de secadores de grãos e o grau de automação e inteligência no processo de secagem de grãos, Li e Chen (2019) estudaram um esquema de controle preditivo baseado em uma rede neural para secadores de grãos. Um modelo matemático baseado na teoria da secagem de grãos é construído para um sistema real de secagem de grãos. Com este modelo, séries temporais suficientes de entrada e saída do secador de grãos sob diferentes condições podem ser obtidas rapidamente usando simulação. Como conjunto de treinamento, a série de dados é usada para treinar uma rede neural autorregressiva não linear que será usada como modelo preditivo em vez do modelo matemático.

No trabalho realizado por Li e Chen (2019) um modelo autorregressivo de rede neural não linear com entrada exógena (NARX) introduz feedback instantâneo de entrada e saída, baseado na rede neural estática. É uma proposta para representar a característica dinâmica de entrada-saída do secador de grãos ao invés do modelo matemático baseado em equações. Usando esta rede neural NARX como um modelo preditivo, um controlador de controle preditivo de modelo (MPC) com um algoritmo de otimização de enxame de partículas (PSO) projetado para realizar um controle preciso de malha fechada. Li e Chen (2019) concluíram que o desempenho do esquema de controle PSO-MPC foi comprovado utilizando simulações suficientes em diferentes situações, o que demonstrou que o erro no teor de umidade dos grãos foi inferior a 1% (w.b.).

Em outro estudo recente, Dai et al. (2018) estudaram a secagem de grãos usando um controlador inteligente. Primeiramente, um modelo matemático não linear de secagem em fluxo misto de trigo foi estabelecido e analisado com base nas leis fundamentais da transferência simultânea de calor e massa. Posteriormente, um modelo interno de controlador proporcional integral derivado (PID) (IMPC) baseado no algoritmo de máquina de vetor de suporte (SVM) e no algoritmo genético (GA-SVM-IMPC) foi proposto a partir da visão da perda de energia e da qualidade de o grão seco. A estrutura do controlador GA-SVM-IMPC consiste em um modelo de previsão SVM, um controlador de modelo inverso SVM, um controlador PID e um algoritmo de otimização genética. Dai et al. (2018) concluíram que a eficácia do controlador realizado foi demonstrada por simulações computacionais e o estudo comparativo com os demais controladores previamente projetados confirmou ainda mais a superioridade do controlador de secador proposto.

Uma abordagem tecnológica para controle inteligente foi estudada para armazenamento de grãos. O monitoramento em tempo real baseado no uso de sensoriamento inteligente do ambiente em que a massa de grãos está armazenada, onde os dispositivos comunicam e transmitem os dados ambientais para um servidor web que os interpreta e analisa com base em ferramentas de Machine Learning, verifica enorme potencial de controle qualidade do produto durante o tempo de armazenamento (ABDIPOUR et al., 2018; PATRÍCIO & RIEDER, 2018; LUTZ & CORADI, 2021). Liu et al. (2017) realizaram uma análise de perdas durante o armazenamento de grãos com base em um algoritmo de árvore de decisão. O modelo de algoritmo de árvore de decisão correspondente pode ser usado para lidar com as diferentes condições de armazenamento de grãos e, assim, prever perdas devido ao ataque de insetos ou outros microrganismos associados.

Recentemente Nyabako et al. (2020) estudaram, por meio de uma abordagem de aprendizado de máquina, uma previsão da população de insetos e os danos associados em uma massa de grãos. A inserção dos dados no algoritmo foi realizada por meio da coleta de informações em unidades de armazenamento e correlacionadas com as condições meteorológicas de cada local. A partir desses dados de entrada, foram desenvolvidos modelos para prever a infestação de insetos e os danos que podem ser causados em grãos armazenados usando algoritmos de seleção de parâmetros e algoritmos de aprendizado de decisão de árvore.

Jian et al. (2014) desenvolveram modelos matemáticos para prever as taxas de germinação de canola armazenada sob condições controladas e de campo. A hipótese na base de seus modelos era que a germinação de canola armazenada poderia ser influenciada pela temperatura, teor de umidade e tempo de armazenamento. Seus modelos explicaram mais de 96% da variação nas taxas de germinação observadas em sementes de canola armazenadas com 10% de umidade. A germinação da canola armazenada foi influenciada pelo tempo de armazenamento e pelas interações entre temperatura, umidade e tempo de armazenamento.

Alguns estudos avaliaram diferentes modelos matemáticos que predizem a qualidade de grãos armazenados em silos de sacos. Barreto et al. (2017) descreveram um modelo bidimensional de elementos finitos que prevê a distribuição de temperatura e teor de umidade devido à variação climática sazonal da soja armazenada em silos de sacos. O modelo também incluiu a respiração da massa de grãos e calculou a concentração de dióxido de carbono e oxigênio durante o armazenamento. Os autores encontraram uma diferença de temperatura de (0,5 a 1 °C) entre as camadas inferior e intermediária e uma diferença de 1,5 °C entre as camadas superiores. O grão na camada superior teve um aumento de teor de umidade de

0,4%, enquanto os níveis de água contidos nas camadas intermediária e inferior do saco permaneceram os mesmos. Barreto et al. (2017) recomendaram um valor de referência de concentração de CO₂ de 3% como limite ao armazenar soja com teor de umidade entre 13 e 15%. Enquanto o modelo descrito por Taheri et al. (2021) teve como objetivo prever a perda de soja durante o armazenamento monitorando a concentração de CO₂ ao longo do período de armazenamento, obtendo uma correlação de 73%.

3. CONCLUSÕES E PROPOSTA DE MONITORAMENTO E PREDIÇÃO DE DADOS NA PÓS-COLHEITA

As informações reunidas nesta revisão contribuem positivamente para toda a cadeia produtiva de grãos, desde a aplicação do sensoriamento remoto em campo até as etapas de pós-colheita. O sensoriamento remoto associado às técnicas de monitoramento e previsão de resultados auxilia de forma precisa a gestão das propriedades agrícolas, aumentando as chances de acertos na hora de tomar decisões.

O presente trabalho revisou estratégias de armazenamento de grãos com foco em diferentes fatores ambientais e variáveis mensuráveis, e como sensores atuais e tecnologias computacionais melhoram o monitoramento preditivo indireto da qualidade de grãos. Diversos estudos científicos mostraram como as técnicas de monitoramento preventivo ajudaram a reduzir as perdas nas etapas pós-colheita da produção de grãos. A expansão do paradigma IoT e o crescente uso de técnicas de Inteligência Artificial nas mais variadas áreas da agricultura corroboram estratégias para evitar a deterioração de grãos durante a fase de pós-colheita, criando novas perspectivas para o desenvolvimento tecnológico de monitoramento da qualidade de grãos no transporte e no armazenamento.

REFERÊNCIAS BIBLIOGRÁFICAS

ABDIPOUR, M., RAMAZANI, S. H. R., YOUNESSI-HMAZEKHLANLU, M., & NIAZIAN, M. Modeling oil content of sesame (*Sesamum indicum* L.) using Artificial Neural Network and Multiple Linear Regression Approaches. **Journal American Oil Chemists' Society**, v.95, p.283–297, 2018. <https://doi.org/10.1002/aocs.12027>

ARANGUREN, M., CASTELLÓN, A., & AIZPURUA A. Crop Sensor Based Non-destructive Estimation of Nitrogen Nutritional Status, Yield, and Grain Protein Content in Wheat. **Agriculture**, v.10, n.148, 2020. <https://doi.org/10.3390/agriculture10050148>

ASEFI, M., GILMORE, C., JEFFREY, I., LOVETRI, J., & PALIWAL J. Detection and continuous monitoring of localized high-moisture regions in full-scale grain storage bin using electromagnetic imaging. **Biosystems Engineering**, v.163, p.37-49, 2017. <http://dx.doi.org/10.1016/j.biosystemseng.2017.08.015>

- ASEFI, M., JEFFREY, I., LOVETRI, J., GILMORE, C., CARD, P., & PALIWAL, J. Grain bin monitoring via electromagnetic imaging. **Computers and Electronics in Agriculture**, v.119, p.133-141, 2015. <http://dx.doi.org/10.1016/j.compag.2015.10.016>
- AUBERT, B. A, SCHROEDER, A., & GRIMAUDDO J. IT as enabler of sustainable farming: An empirical analysis of farmers adoption decision of precision agriculture technology. **Decision Support Systems**, v.54, p.510–520, 2012. <https://doi.org/10.1016/j.dss.2012.07.002>
- BARRETO, A. A., ABALONE, R., GASTÓN, A., OCHANDIO, D., CARDOSO, L., & BARTOSIK, R. Validation of a heat, moisture and gas concentration transfer model for soybean (*Glycine max*) grains stored in plastic bags (silo bags). **Biosystems Engineering**, v.158, p.23-37, 2017. <http://dx.doi.org/10.1016/j.biosystemseng.2017.03.009>
- BERRY, J. K., DELGADO, J. A., KHOSLA, R., & PIERCE, F. J. Precision conservation for environmental sustainability. **Journal of Soil and Water Conservation**, v.58, p.332–339, 2003. <https://www.jswnonline.org/content/58/6/332>
- BONGIOVANNI, R., & LOWENBERG-DEBOER J. Precision agriculture and sustainability. **Precision Agriculture**, v.5, p.359–387, 2004. <https://doi:10.1023/B:PRAG.0000040806.39604.aa>
- BRABEC, D., CAMPBELL, J., ARTHUR, F., CASADA, M., TILLEY, D., & BANTAS, S. Evaluation of wireless phosphine sensors for monitoring fumigation gas in wheat stored in farm bins. **Insects**, v.10, n.121, 2019. <https://doi.org/10.3390/insects10050121>
- CORADI, P. C., DUBAL, Í. T. P., BILHALVA, N. D. S., FONTOURA, C. N., & TEODORO, P. E. Correlation using multivariate analysis and control of drying and storage conditions of sunflower grains on the quality of the extracted vegetable oil. **Journal of Food Processing and Preservation**, v.44, n.14961, 2020a. <https://doi.org/10.1111/jfpp.14961>
- CORADI, P. C., OLIVEIRA, M. B., DE OLIVEIRA, L. C., COELHO, G. A. S., ELIAS, M. C., BRACKMANN, A., & TEODORO, P. E. Technological and sustainable strategies for reducing losses and maintaining the quality of soybean grains in real production scale storage units. **Journal of Stored Products Research**, v.87, n.101624, 2020b. <https://doi.org/10.1016/j.jspr.2020.101624>
- CORADI, P. C., LUTZ, E., BILHALVA, N. S., JAQUES, L. B. A., LEAL, M. M., & TEODORO, L. P. R. Wireless sensor network prototype and Internet of Things platform for real-time monitoring of intergranular equilibrium moisture content and quality prediction of maize stored in silo bags. **Expert Systems with Applications**, v.208, n.118242, 2022. <https://doi.org/10.1016/j.eswa.2022.118242>
- CORADI, P. C., LEMES, Â. F. C., MÜLLER, A., JAQUES, L. B. A., DUBAL, Í. T. P., BILHALVA, N. D. S., TEODORO, P. E., STEINHAUS, J. I., & MAIER, D. E. Silo–dryer–aerator in fixed and thick layer conceptualized for high quality of grains applied in different social scales post-harvest: modeling and validation. **Drying Technology**, v.40, p.1369-1394, 2021. <https://doi.org/10.1080/07373937.2020.1870040>
- DAI, A., ZHOU, X., LIU, X., LIU, J., & ZHANG, C. Intelligent control of a grain drying system using a GA-SVM-IMPC controller. **Drying Technology**, v.36, p.1413-1435, 2018. <https://doi.org/10.1080/07373937.2017.1407938>

DANAO, M. G. C., ZANDONADI, R. S., & GATES, R. S. Development of a grain monitoring probe to measure temperature, relative humidity, carbon dioxide levels and logistical information during handling and transportation of soybeans. **Computers and Electronics in Agriculture**, v.119, p.74-82, 2015.
<https://doi.org/10.1016/j.compag.2015.10.008>

DEFOURNY, P., BONTEMPS, S., BELLEMANS, N., CARA, C., DEDIEU, G., GUZZONATO, E., HAGOLLE, O., INGLADA, J., NICOLA, L., RABAUTE, T., SAVINAUD, M., UDROIU, C., VALERO, S., BÉGUÉ, A., DEJOUX, J.-F., HARTI, A. E., EZZAHAR, J., KUSSUL, N., LABBASSI, K., LEBOURGEOIS, V., MIAO, Z., NEWBY, T., NYAMUGAMA, A., SALH, N., SHELESTOV, A., SIMONNEAUX, V., TRAORE, P. S., TRAORE, S. S., & KOETZ, B. Near real-time agriculture monitoring at national scale at parcel resolution: Performance assessment of the Sen2-Agri automated system in various cropping systems around the world. **Remote Sensing of Environment**, v.221, p.551-568, 2019. <https://doi.org/10.1016/j.rse.2018.11.007>

DELGADO, J., SHORT, N. M., ROBERTS, D. P., & VANDENBERG, B. Big data analysis for sustainable agriculture. **Frontiers in Sustainable Food Systems**, v.3, n.54, 2019.
<https://doi.org/10.3389/fsufs.2019.00054>

DONG, T., LIU, J., SHANG, J., QIAN, B., MA, B., KOVACS, J. M., WALTERS, D., JIAO, X., GENG, X., & SHI, Y. Assessment of red-edge vegetation indices for crop leaf area index estimation. **Remote Sensing of Environment**, v.222, p.133-143, 2019.
<https://doi.org/10.1016/j.rse.2018.12.032>

DUYSAK, H., & YIGIT, E. Machine learning based quantity measurement method for grain silos. **Measurement**, v.152, n.107279, 2020.
<https://doi.org/10.1016/j.measurement.2019.107279>

FAO. The Future of Food and Agriculture - Trends and Challenges. Food and Agriculture Organization of the United Nations, Rome, 2019.

GILMORE, C., ASEFI, M., NEMEZ, K., PALIWAL, J., & LOVETRI, J. Three-dimensional radio-frequency electromagnetic imaging of an in-bin grain conditioning process. **Computers and Electronics in Agriculture**, v.167, n.105059, 2019.
<https://doi.org/10.1016/j.compag.2019.105059>

GILMORE, C., ASEFI, M., PALIWAL, J., & LOVETRI, J. Industrial scale electromagnetic grain bin monitoring. **Computers and Electronics in Agriculture**, v.136, p.210-220, 2017.
<http://dx.doi.org/10.1016/j.compag.2017.03.005>

HUANG, Y., CHEN, Z. X., TAO, Y. U., HUANG, X. Z., & GU, X. F. Agricultural remote sensing big data: Management and applications. **Journal of Integrative Agriculture**, v.17, p.1915-1931, 2018. [https://doi.org/10.1016/S2095-3119\(17\)61859-8](https://doi.org/10.1016/S2095-3119(17)61859-8)

HUNT, E. R., & DAUGHTRY, C. S. T. What good are unmanned aircraft systems for agricultural remote sensing and precision agriculture? **International Journal of Remote Sensing**, v.39, p.5345-5376, 2018. <https://doi.org/10.1080/01431161.2017.1410300>

JIAN, F., CHELLADURAI, V., JAYAS, D. S., & DEMIANYK, N. D. G. White, Interstitial concentrations of carbon dioxide and oxygen in stored canola, soybean, and wheat seeds

under various conditions. **Journal of Stored Products Research**, v.57, p.63-72, 2014.
<https://doi.org/10.1016/j.jspr.2013.12.002>

KODALI, R. K., JOHN, J., & BOPPANA, L. IoT Monitoring System for Grain Storage. **IEEE International Conference on Electronics, Computing and Communication Technologies**, v.1, n.19988645, 2020. <https://doi.org/10.1109/conecct50063.2020.9198549>

KUMAR, S., MOHAPATRA, D., KOTWALIWALE, N., & SINGH, K.K. Efficacy of sensor assisted vacuum hermetic storage against chemical fumigated wheat. **Journal of Stored Products Research**, v.88, n.101640, 2020. <https://doi.org/10.1016/j.jspr.2020.101640>

LEWIS, M. A., TRABELSI, S., & NELSON, S. O. Development of an eighth-scale grain drying system with real-time microwave monitoring of moisture content. **Applied Engineering in Agriculture**, v.35, p.767-774, 2019. <https://doi.org/10.13031/aea.13130>

LI, C., LI, B., HUANG, J., & LI, C. Developing an online measurement device based on resistance sensor for measurement of single grain moisture content in drying process. **Sensors**, v.20, n.4102, 2020. <https://doi.org/10.3390/s20154102>

LI, H., & CHEN, S. A neural-network-based model predictive control scheme for grain dryers. **Drying Technology**, v.38, p.1079-1091, 2019.
<https://doi.org/10.1080/07373937.2019.1611598>

LIMA, R. E., CORADI, P. C., NUNES, M. T., BELLOCHIO, S. D. C., TIMM, N. S., NUNES, C. F., TEODORO, P., & CAMPABADAL, C. Mathematical modeling and multivariate analysis applied earliest soybean harvest associated drying and storage conditions and influences on physicochemical grain quality. **Scientific Reports**, v.11, n.23287, 2021.
<https://doi.org/10.1038/s41598-021-02724-y>

LIU, Z., WU, Z., ZHANG, Z., WU, W., & LI, H. Research on online moisture detector in grain drying process based on V/F conversion. **Mathematical Problems in Engineering**, v.1, n.565764, 2015. <https://doi.org/10.1155/2015/565764>

LIU, X., LI, B., & SHEN, D., CAO, J., & MAO, B. Analysis of grain storage loss based on decision tree algorithm. **Procedia Computer Science**, v.122, p.130–137, 2017.
<https://doi.org/10.1016/j.procs.2017.11.351>

LUTZ, E., & 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, 2021. <https://doi.org/10.1016/j.measurement.2021.110609>

NEETHIRAJAN, S., FREUND, M. S., JATAS, D. S., SHAFAI, C., THOMSON, D. J., & WHITE, N. D. G. Development of carbon dioxide (CO₂) sensor for grain quality monitoring. **Biosystems Engineering**, v.106, p.395-404, 2010.
<https://doi.org/10.1016/j.biosystemseng.2010.05.002>

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.
<https://doi.org/10.1016/j.jspr.2020.101592>

- ONIBONOJE, M. O., NWULU, N. I., & BOKORO, P. N. A wireless sensor network system for monitoring environmental factors affecting bulk grains storability. **Journal of Food Process Engineering**, v.42, n.13256, 2019. <https://doi.org/10.1111/jfpe.13256>
- PARVIN, S., GAWANMEH, A., & VENKATRAMAN, S. Optimised Sensor Based Smart System for Efficient Monitoring of Grain Storage. **IEEE International Conference on Communications Workshops**, n.17896512, 2018. <https://doi.org/10.1109/ICCW.2018.8403537>
- PATRÍCIO, D. I., RIEDER, R. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and Electronics in Agriculture**, v.153, p.69-81, 2018. <https://doi.org/10.1016/j.compag.2018.08.001>
- SEGARRA, J., BUCHAILLOT, M.L., ARAUS, J.L., & KEFAUVER, S.C. Sensor remoto para agricultura de precisión: recursos e aplicativos aprimorados do Sentinel-2. **Agronomy Journal**, v.10, n.5, p.641, 2020. <https://doi.org/10.3390/agronomy10050641>
- SINDWANI, A., KUMAR, A., GAUTAM, C., PUROHIT, G., & TANWAR, P. Prediction and Monitoring of stored food grains health using IoT Enable Nodes. **IEEE International Conference on Computing, Power and Communication Technologies**, p.516-522, 2020. doi:10.1109/gucon48875.2020.92311
- TAHERI, S., BRODIE, G., & GUPTA, D. Optimised ANN and SVR models for online prediction of moisture content and temperature of lentil seeds in a microwave fluidized bed dryer. **Computers and Electronics in Agriculture**, v.182, n.106003, 2021. <https://doi.org/10.1016/j.compag.2021.106003>
- UBHI, G. S., & SADAKA, S. Temporal valuation of corn respiration rates using pressure sensors. **Journal of Stored Products Research**, v.61, p.39-47, 2015. <http://dx.doi.org/10.1016/j.jspr.2015.02.004>
- VANINO, S., NINO, P., DE MICHELE, C., FALANGA, S. B., D'URSO, G., DI BENE, C., PENNELLI, B., VUOLO, F., FARINA, R., & PULIGHE, G. Capability of Sentinel-2 data for estimating maximum evapotranspiration and irrigation requirements for tomato crop in Central Italy. **Remote Sensing of Environment**, v.215, p.452-470, 2018. <https://doi.org/10.1016/j.rse.2018.06.035>
- WALLAYS, C., MISSOTTEN, B., BAERDEMAEKER, J., & SAEYS, W. (2009). Hyperspectral waveband selection for on-line measurement of grain cleanness. **Biosystems Engineering**, v.104, p.1-7. <https://doi.org/10.1016/j.biosystemseng.2009.05.011>

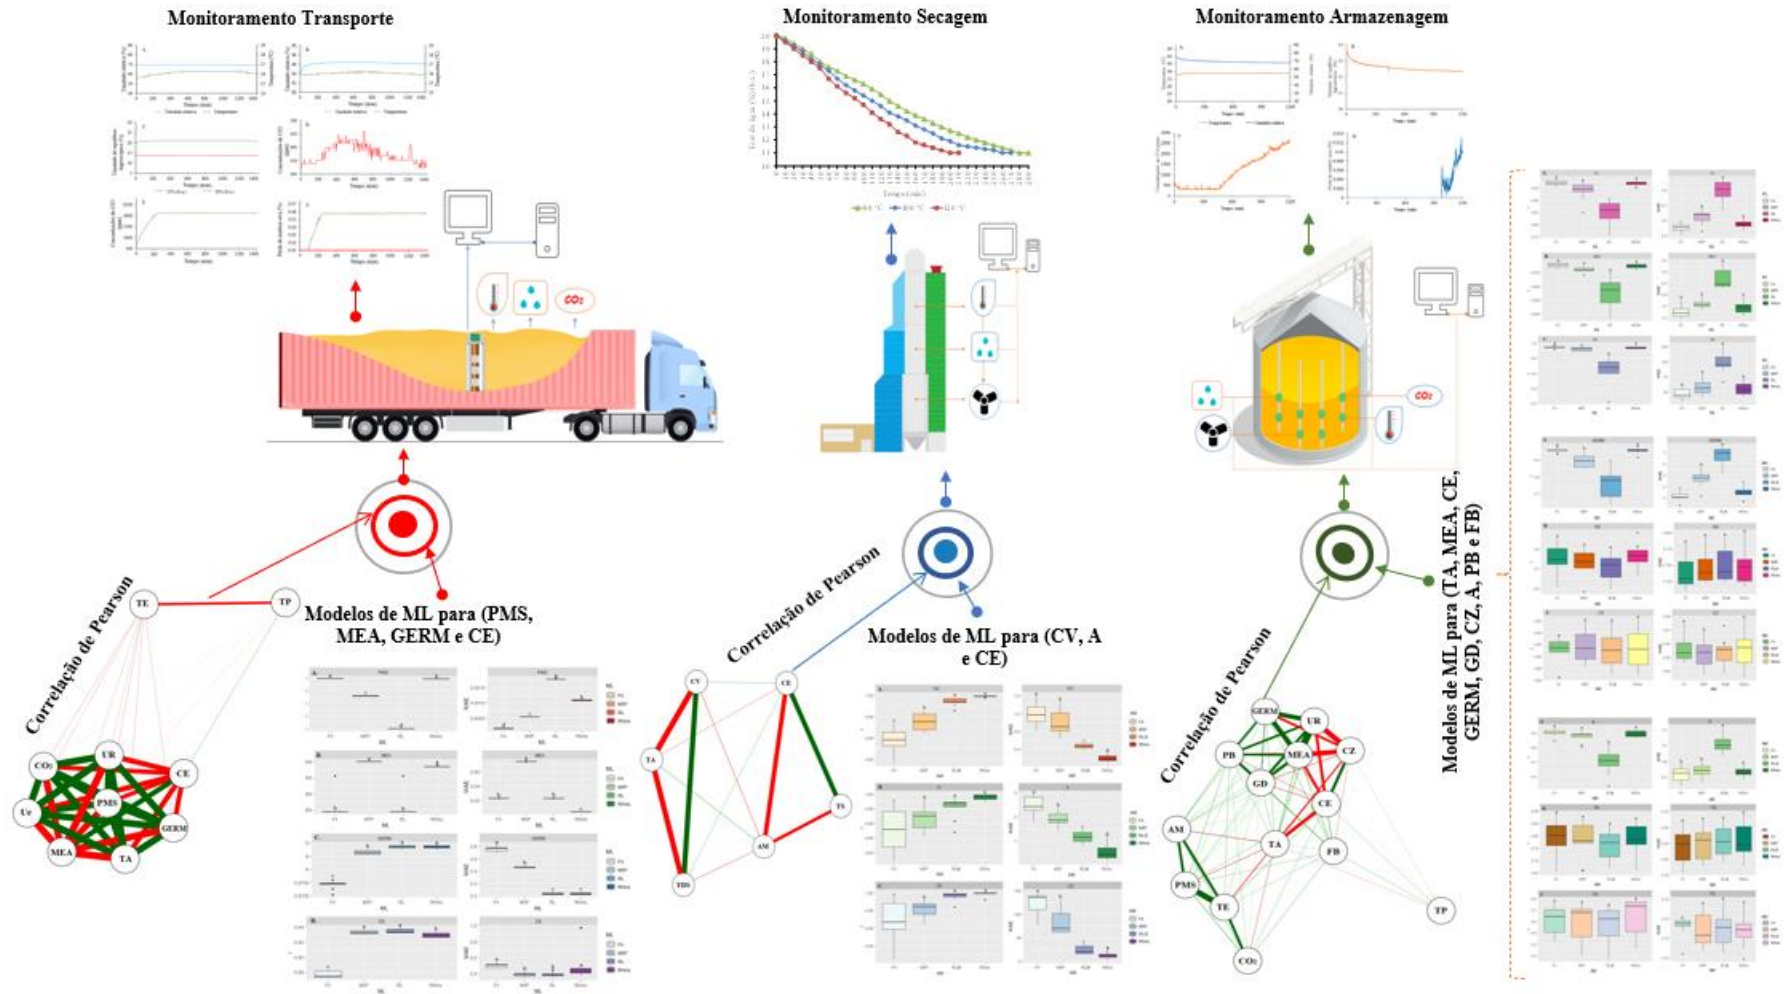
CAPÍTULO III – PREDIÇÃO PRECOCE DA QUALIDADE DE GRÃOS DE MILHO NAS OPERAÇÕES DE TRANSPORTE, SECAGEM E ARMAZENAGEM ATRAVÉS DO MONITORAMENTO DE VARIÁVEIS INTERGRANULARES E APLICAÇÃO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA

RESUMO

Durante as etapas de pós-colheita a variação dos fatores bióticos e abióticos podem contribuir para o aumento da respiração e provocar alterações na qualidade dos grãos. Assim, o objetivo do estudo foi avaliar a predição da qualidade de grãos de milho nas etapas de transporte, secagem e armazenagem, utilizando-se modelos de Aprendizado de Máquina a partir do monitoramento intergranular de temperatura, umidade relativa, umidade de equilíbrio higroscópico e respiração da massa de grãos. Foram utilizados os seguintes modelos para predição: regressão linear múltipla, redes neurais artificiais, árvore de decisão e floresta aleatória. Para verificar a relação entre as variáveis monitoradas e as preditas foi aplicada a correlação de Pearson, utilizando o software Rbio, enquanto que, para determinar o modelo preditivo foi usado o software Weka versão 3.9.5. O monitoramento demonstrou que o teor de água, a umidade relativa intergranular alteram a umidade de equilíbrio higroscópico dos grãos, contribuindo para o aumento da respiração e por consequência perdas de matéria seca ao longo do transporte. Na secagem, a temperatura do ar provocou danos térmicos aos grãos, elevando o índice de condutividade elétrica. No armazenamento, as condições do ambiente alteraram os teores de água provocando redução na massa específica aparente, germinação e nos teores de proteína bruta, fibra bruta e gordura dos grãos de milho. Na etapa de transporte, o modelo de redes neurais artificiais foram os mais indicados para prever a condutividade elétrica, a massa específica aparente e a germinação. Já o modelo de floresta aleatória estimou satisfatoriamente a perda de matéria seca. Na etapa de secagem, o modelo de redes neurais artificiais e floresta aleatória foram os mais indicados para a predição das variáveis. No armazenamento, as redes neurais artificiais e floresta aleatória foram os mais indicados para prever os teores de água e a germinação, no entanto, o modelo de floresta aleatória foi aquele que melhor predisseram os resultados de massa específica aparente, condutividade elétrica e amido.

Palavras chave: Monitoramento. Algoritmos preditivos. Etapas de pós-colheita.

RESUMO GRÁFICO



1. INTRODUÇÃO

O aumento da produção de grãos nas lavouras vem ocorrendo ao longo do tempo em função da aplicação de novos pacotes tecnológicos. Principalmente voltados a agricultura de precisão para otimização da aplicação dos insumos, maquinários e uso dos recursos naturais na expectativa de melhorias dos processos agrícolas, no intuito de obter maiores produtividades de grãos (CAFIERO et al., 2017; KHANAL et al., 2017; CORADI et al., 2018). Assim, é necessário que toda a produtividade de grãos oriundas deste investimento, seja mantido em qualidade nas operações de pós-colheita até a comercialização e processamento do milho.

A pós-colheita é constituída por diferentes etapas e processos que estão ao final da cadeia produtiva de grãos, onde influenciam também sobre a logística do setor através do transporte e a armazenagem dos grãos (ALI, 2020; TOOSI et al., 2022; HIRANO et al., 2022). As perdas nessas etapas podem ocorrer de forma física ou por alterações metabólicas dos grãos influenciadas pelas condições do ambiente, ações dos processos e movimentação do produto.

Portanto, a determinação da umidade de equilíbrio higroscópico da massa de grãos através da medição da temperatura, a umidade relativa do ar intergranular e os teores de água dos grãos nas diferentes condições de processo ou armazenamento, possibilitam controlar a intensidade das possíveis deteriorações dos grãos. Enquanto que, a medição da concentração de dióxido de carbono no ar intergranular ou no ambiente que se encontra a massa de grãos pode fornecer uma resposta dos grãos em função da sua intensidade respiratória. Assim, o monitoramento em tempo real de variáveis intergranulares da massa de grãos, no intuito de preservar a qualidade do produto e reduzir ao máximo as perdas nas diferentes etapas da pós-colheita, possibilita avaliar de forma indireta as possíveis alterações físicas e tecnológicas dos grãos, com a utilização de algoritmos preditivos.

Após a colheita, a massa de grãos com elevados teores de impurezas e água podem ser transportados por longas distâncias, permanecendo armazenados na carroceria dos veículos sem nenhum controle das alterações qualitativas que podem ocorrer em função das variações da temperatura, umidade relativa do ar intergranular. As transferências de calor e umidade entre os grãos, o ar intergranular podem elevar a temperatura da massa de grãos e aumentar a respiração do produto, provocando consumo de matéria seca e alterações físicas e físico-químicas dos grãos. Muitas vezes, os níveis iniciais de deterioração da massa de grãos ao

longo do transporte não são imediatamente perceptíveis, sendo agravados ao longo dos processos de secagem e armazenagem (ZIEGLER et al., 2021).

Na secagem, a alta temperatura e o fluxo da massa de grãos no secador são os principais fatores que podem influenciar na qualidade do produto (TIMM et al. 2020; HASSAN et al. 2021). Assim, o controle da temperatura do ar de secagem e da massa de grãos, bem como do tempo de secagem sobre os teores de água iniciais e finais do produto devem ser monitorados para evitar as perdas (BERLANGA-REYES et al. 2021). Aos danos nos tecidos celulares ocasionados pela secagem somam-se as deteriorações das etapas anteriores, agravando-se ainda mais na etapa subsequente, quando os grãos são armazenados inadequadamente (CORADI et al., 2020; CÓRDOVA-NOBOA et al., 2021). No armazenamento, mesmo em condições seguras em teores de água nos grãos, a forma, as condições e o tempo de armazenagem dos lotes podem causar aquecimento e elevar as taxas respiratórias do produto (NYABAKO et al., 2020).

Entre as tecnologias usadas para coleta de dados estão os sensores de umidade relativa do ar, sensores de temperatura e sensores de dióxido de carbono. Estes por sua vez, darão respaldo para determinar a umidade de equilíbrio higroscópico e perda de matéria seca. Estas variáveis monitoradas são utilizadas como dados de entrada para a predição da qualidade da massa de grãos através de modelos de aprendizagem de máquina (AM) (LUTZ & CORADI, 2022). Neste contexto, a aplicação de modelos AM pode indicar os níveis de acurácia e prever através das variáveis monitoradas às possíveis perdas de qualidade nos grãos (RAMOS et al., 2020; WANG et al., 2021). Assim, o objetivo do estudo foi avaliar a predição da qualidade de grãos de milho nas etapas de transporte, secagem e armazenagem, utilizando-se modelos de Aprendizado de Máquina a partir do monitoramento intergranular de temperatura, umidade relativa, umidade de equilíbrio higroscópico e respiração da massa de grãos.

2. MATERIAL E MÉTODOS

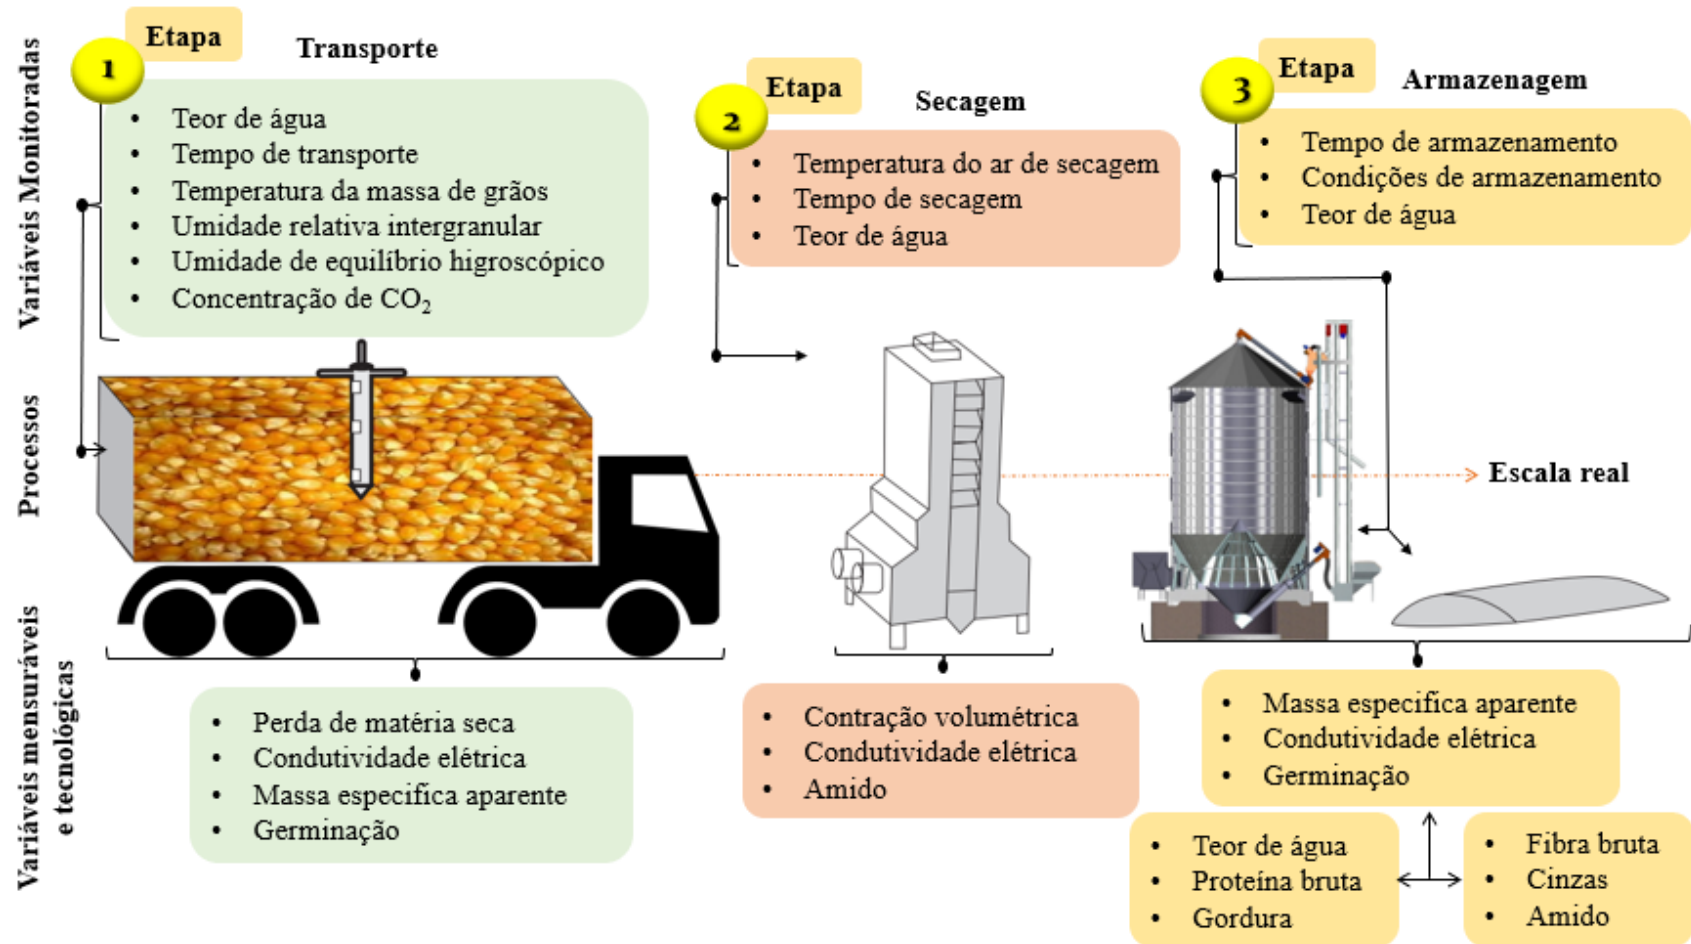
2.1 CARACTERIZAÇÃO EXPERIMENTAL

O experimento foi desenvolvido em escala real em unidades comerciais envolvendo as etapas de transporte, secagem e armazenagem de grãos de milho. A coleta de dados para cada uma das etapas foi realizada através do monitoramento indireto de variáveis de qualidade, por meio de sensores e software, desenvolvidos pelo Laboratório de Pós-Colheita da Universidade Federal de Santa Maria - UFSM, no campus de Cachoeira do Sul. O experimento foi dividido em três etapas, compreendendo o processo de transporte, secagem e armazenagem (Figura 1). Para cada processo, houve um monitoramento e também a obtenção de variáveis mensuráveis e tecnológicas, os quais constituíram o conjunto de dados deste estudo.

A etapa 1 (transporte), foram monitoradas as variáveis: teor de água, tempo de transporte, temperatura da massa de grãos, umidade relativa intergranular, umidade de equilíbrio higroscópico e concentração de CO₂. Na etapa 2 (secagem), monitorou-se as variáveis: temperatura do ar de secagem, tempo de secagem e teor de água. Enquanto que a etapa 3 (armazenagem), foram monitoradas: tempo de armazenamento, condições de armazenamento e teor de água (Figura 1).

Além de cada processo, foram mensuradas e obtidas variáveis tecnológicas que determinaram a qualidade dos grãos de milho. No transporte foram: perda de matéria seca, condutividade elétrica, massa específica aparente e germinação. Já na secagem: contração volumétrica, condutividade elétrica e teor de amido. Enquanto que no armazenamento: massa específica aparente, condutividade elétrica, germinação, teor de água, proteína bruta, gordura, fibra bruta, cinzas e teor de amido (Figura 1).

Figura 1 - Caracterização experimental nas etapas de pós-colheita, transporte, secagem e armazenamento de grãos de milho

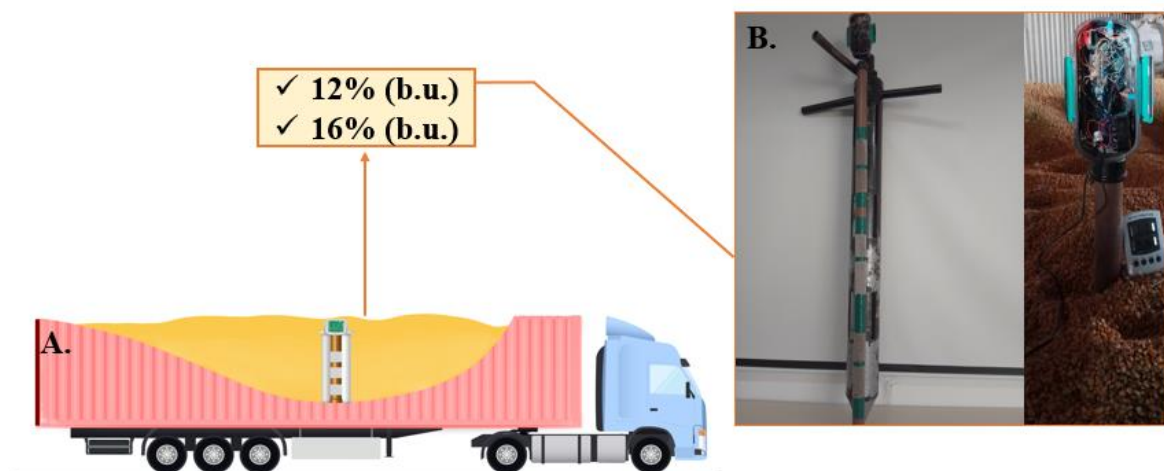


Fonte: Autora (2023).

2.2 TECNOLOGIA E MONITORAMENTO DA MASSA DE GRÃOS DE MILHO NO TRANSPORTE

O monitoramento da massa de grão de milho, ocorreu através de um amostrador metálico e sonda não destrutiva com sensores, os quais foram inseridas em caminhões graneleiros com 12% e 16% (b.u.) de umidade, cada (Figura 2 A-B). A sonda ficou inserido na massa de grão por, aproximadamente, vinte e quatro horas, realizando a leitura da temperatura, umidade relativa e dióxido de carbono no intervalo de 1,87 segundos, cada.

Figura 2 - Caracterização experimental do monitoramento e da coleta de dados na etapa de transporte de grãos de milho. Esquemática do transporte graneleiro com 12% b.u. e 16% b.u. (A.) e Vista do tubo amostrador metálico + Sonda inserida na massa de grãos (B.)



Fonte: Autora (2023).

Foi realizado uma amostragem dos grãos nos tempos 0, 120, 480 e 1440 minutos durante o transporte. A amostragem foi feita a partir da coleta das camadas centrais da massa de grão de milho através do próprio tubo amostrador, usado para o acondicionamento da sonda. Apesar do tubo amostrador e da sonda apresentarem três posições (superior, central e inferior), foram coletadas, apenas as leituras das posições centrais de cada amostragem transportada.

Toda tecnologia utilizada para o monitoramento da temperatura, umidade relativa e concentrações de dióxido de carbono na porosidade intergranular da massa de milho, foi

desenvolvida por Jaques et al. (2022a). Algumas características dos equipamentos são descritas pelos autores na tabela 1.

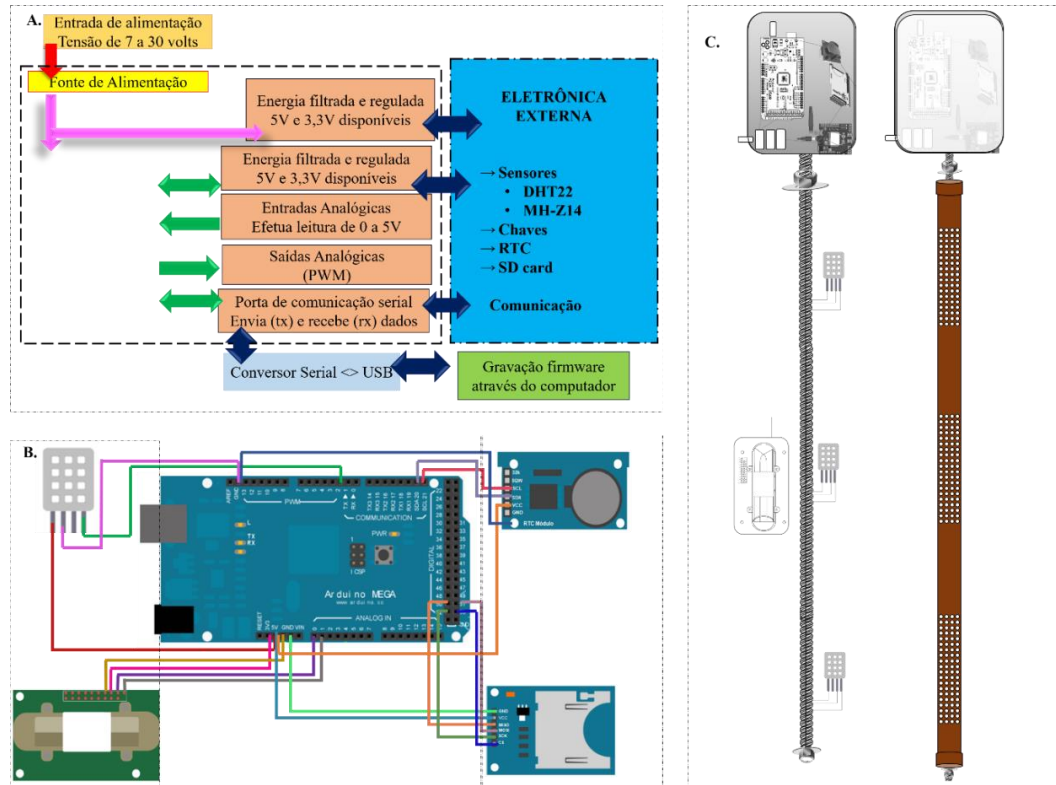
Tabela 1 - Caracterização tecnológica do equipamento para monitoramento da temperatura, umidade relativa e concentrações de dióxido de carbono na porosidade intergranular de milho durante o transporte

Caracterização Tecnológica do equipamento para monitoramento	
a)	Denominado de microcontrolador Arduino Mega (modelo 2560, Arduino LLC, Itália) como núcleo de controle.
b)	O hardware do sistema inclui três sensores digitais para detectar a temperatura e umidade relativa do ar (modelo DHT22, Aosong Electronics, Guangzhou, China). Os sensores foram fixados em três extremidades de uma barra roscada.
c)	Além disso, também é constituído de um sensor infravermelho não destrutivo para detectar a concentração de CO ₂ (modelo MHZ-14, Winsen, China). E este, foi fixado apenas na parte central da barra roscada.
d)	Possui módulos de relógio em tempo real (modelo DS3231, flip-flop, China). Estando armazenado em uma caixa conectada a sonda.
e)	No equipamento, também está incluído um cartão micro-SD (modelo Greatzt cartão micro SD, importação, China). O qual, também, foi armazenado na caixa.
f)	Neste equipamento, os dados de saída do sensor digital, sensor infravermelho e módulos são conectados aos terminais de comunicação I/O do microcontrolador responsável pela comunicação física, integração de componentes e cálculo de dados.
g)	A conexão de cada componente via cabos jumper.
h)	Este equipamento, possui alimentação própria com três baterias dispostas em série com potência total é de 27 V.
i)	O software utilizado na placa Arduino foi programado com base na linguagem de programação C++, sendo a maioria das bibliotecas fornecida pela plataforma (LUTZ & CORADI, 2022).
j)	O IDE (Integrated Development Environment) do Arduino foi usado para desenvolver o firmware embarcados para os microcontroladores Atmega 2560.
k)	O tubo amostrador de grãos metálicos desenvolvido para acoplar a sonda, é constituído de dois tubos sobrepostos, com ponta na extremidade inferior e um braço giratório na extremidade.

Fonte: Jaques et al. (2022a).

Toda estrutura tecnológica do sensor é esquematizada por Jaques et al. (2022a) na figura 3 e figura 4. Em primeiro momento, é mostrado o diagrama de blocos do sistema de controle (A), conexão dos componentes ao micro controlador por meio de cabos jumper (B) e fixação dos sensores e acondicionamento do conjunto de sensores a sonda de policloreto de vinila (C).


Figura 3 - Representação esquemática do diagrama de blocos das partes constituintes do sistema de controle do equipamento (A.), conexão dos componentes ao micro controlador por meio de cabos jumper (B.) e Fixação dos sensores e acondicionamento do conjunto de sensores a sonda de policloreto de vinila (C.)



Fonte: Jaques et al. (2022a).

Além disso, Jaques et al. (2022a) exemplificam na figura 4 o mostrador de grãos desenvolvido que serviu de suporte para a sonda ser acondicionada. Pois durante o transporte, a movimentação é intensa, logo a sonda, além de não resistir ao percurso, compromete a leitura da temperatura, umidade relativa e o CO_2 na porosidade intergranular do milho. Além disso, o tubo amostrador foi um mecanismo desenvolvido pelos autores para coletar as amostragens nas camadas internas da massa de grão (Figura 4). A partir destas amostragens, foram analisados os teores de água, a germinação, a condutividade elétrica, e determinado a umidade de equilíbrio higroscópico (Equação 1 e 2), a perda de matéria seca (Equação 3) e a massa específica aparente, pelo método direto (laboratório).

Figura 4 - Representação esquemática do tubo amostrador de grãos para acondicionamento da sonda. Vista interna e externa do tubo (A.), Peças para vedação (B.), Vista superior do tubo amostrador (C.), Vista completa do tubo (D.), Aplicação do sistema de monitoramento na massa de grãos de milho (E.)



Fonte: Jaques et al. (2022).

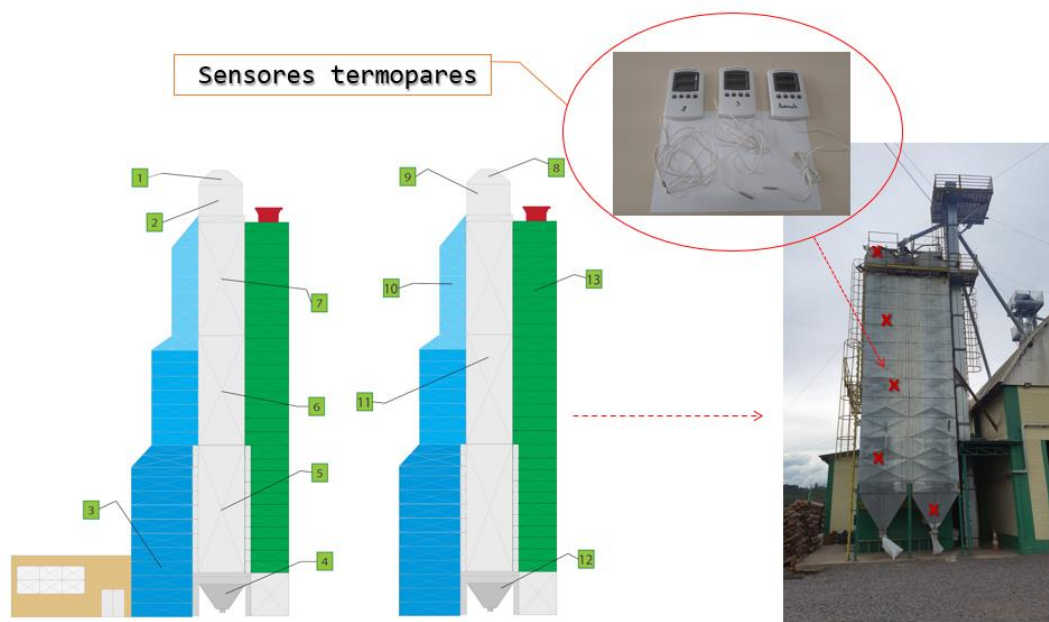
2.3 TECNOLOGIA E MONITORAMENTO DA MASSA DE GRÃOS DE MILHO NA SECAGEM

Inicialmente o grão de milho chegou na unidade de beneficiamento com teor de água de 18% (b.u.). Em seguida os grãos foram submetidos ao processo limpeza para retirada das impurezas e matérias estranhas em uma máquina de ar e peneira. Posteriormente, os grãos foram submetidos à secagem em um secador intermitente, com capacidade de 80 ton.

Com o auxílio de sensores termopares instalados no próprio secador, o monitoramento consistiu a partir da coleta de três temperatura de secagem 80, 100 e 120 °C, da medição do teor de água e do tempo de secagem no período de vinte e quatro horas, cada. Neste estudo, os grãos ficaram submetidos ao processo de secagem até atingirem um teor de água de 13% (b.u.). O monitoramento da massa de grão de milho, ocorreu no secador intermitente (Figura 5). Durante os três testes de secagem, foram coletadas amostras para determinação dos teores

de água, medição da contração volumétrica (CV) conforme (Equação 4), condutividade elétrica (CE) e teor de amido (A).

Figura 5 - Caracterização experimental do monitoramento e coleta de dados através de sensores termopares instalados no secador intermitente. 1 - Sensor de nível máximo, 2 - Sensor nível mínimo, 3 - Sensor de entrada ar quente, 4 - Sensor de parada, 5 - Sensor de massa, 6 - Sensor de massa, 7 - Sensor de massa, 8 - Produto de entrada, 9 - Caixa de carga, 10 - Câmara de secagem, 11 - Torre de secagem, 12 - Mesa de descarga




Fonte: Autora (2023).

2.4 TECNOLOGIA E MONITORAMENTO DA MASSA DE GRÃOS NO ARMAZENAMENTO

O monitoramento da massa de grãos de milho ocorreu em dois momentos. A primeira coleta de dados, ocorreu em unidade de beneficiamento (UB) comercial de milho, localizada nas proximidades de Cachoeira do Sul, RS. O grão de milho estava armazenado no silo horizontal (graneleiro) com teor de umidade de 12% (b.u.) (Figura 6A e B). Para este monitoramento, foi utilizado o microcontrolador Arduino Mega (modelo 2560, Arduino LLC, Itália), conforme descrito na tabela 1 e exemplificado na figura 3 por Jaques et al. (2022a). A sonda ficou inserida na massa de milho por, aproximadamente, vinte e quatro horas e foram coletadas a temperatura, umidade relativa do ar intergranular e concentrações de dióxido de carbono.

Figura 6 - Caracterização experimental do monitoramento e coleta de dados na etapa de armazenagem em silo horizontal (graneleiro) de grãos de milho. Esquemática do silo graneleiro (A.) e Vista da sonda inserida na massa de grãos (B.)




Fonte: Autora (2023).

O monitoramento, também, ocorreu em um silo protótipo metálico com capacidade de 45 litros, estando preenchido com aproximadamente 20 kg de grãos de milho. Este equipamento foi desenvolvido pelo Laboratório de Pós-colheita da Universidade Federal de Santa Maria, Campus de Cachoeira do Sul, RS. Nele a massa de grãos de milho com 12% (b.u.) foi armazenada por seis meses (Figura 7). Foi verificado a temperatura, umidade relativa do ar intergranular e concentrações de dióxido de carbono na massa de grãos. Para o monitoramento da temperatura e da umidade relativa do ar intergranular, foi utilizado um termohigrômetro (marca-TLX) e (modelo DTH-16). E para as concentrações de CO₂, foi utilizado o sensor modelo MZ-19 com infravermelho não dispersivo do tipo NIR.

Em ambos os monitoramentos foram estimadas a umidade de equilíbrio higroscópico e a perda de matéria seca ao longo do armazenamento, conforme descrito pela Equação 1, Equação 2 e Equação 3. Foi aplicado testes fisiológicos, entre eles a condutividade elétrica e germinação, também bioquímicos como amido, proteína bruta, fibra bruta, gordura e cinzas.

Figura 7 - Caracterização experimental do monitoramento e coleta de dados na etapa de armazenagem em silos protótipos metálicos de grãos de milho



Fonte: Autora (2023).

2.5 AVALIAÇÕES DA QUALIDADE DOS GRÃOS DE MILHO

Os cálculos da umidade de equilíbrio higroscópico da massa de grãos foram realizados pelas Equações 1 ($0 < UR \leq 55\%$) e 2 ($55 < UR < 100\%$):

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

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

em que,

U_e : Umidade de equilíbrio higroscópico (% , b.u.)

UR: Umidade relativa (%)

T: Temperatura (F)

A perda de matéria seca foi calculada pela concentração de CO_2 monitorada na massa de grãos de milho, por meio da Equação 3:

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

em que,

PMS: Perda de matéria seca (%)

C_{CO_2} : concentração de C_{CO_2} (v/v) medida no interior dos silos metálicos

ΔC_{O_2} : variação da concentração de O_2 ao longo do armazenamento considerando a concentração inicial de 21%

ε : porosidade da massa granular (40%)

P: pressão atmosférica local (96 kPa)

W_g : massa molar da glicose (180 kg kmol^{-1})

P_g : massa específica aparente dos grãos (kg m^{-3}) (750 kg m^{-3})

U: Teor de água dos grãos (decimal, b.u.)

R: constante dos gases perfeitos ($8,314 \text{ kJ Kmol}^{-1} \text{ K}^{-1}$)

T: Temperatura (K)

O teor de água dos grãos em (% b.u.) foi determinado pelo método gravimétrico (balança analítica 0,0001, modelo AUY-220-I) (Brasil, 2009). A contração volumétrica dos grãos foi determinada pela Equação 4 (Mohsenin, 1986), em que se mediu os eixos principais, médios e menores de cem grãos para cada amostra, com auxílio de um paquímetro digital.

$$V_g = \frac{\pi a b c}{6} \quad (4)$$

em que,

a: eixo principal do grão (mm)

b: eixo médio do grão (mm)

c: eixo menor do grão (mm)

O teste de condutividade elétrica foi realizado de acordo com a metodologia descrita por Krzyzanowski (1999). Cinquenta grãos foram utilizados para três subamostras de cada tratamento e pesados com precisão de duas casas decimais (0,01 g). As amostras foram colocadas para embeber em copos plásticos com 75 mL de água deionizada e mantidas em câmara refrigerada com temperatura controlada a $25 \pm 2 \text{ }^\circ\text{C}$ por 24 horas. As soluções contendo os grãos foram levemente agitadas para a homogeneização dos lixiviados e imediatamente lidas em um medidor de condutividade portátil CD-850 “Instrutherm”, sendo os resultados divididos pela massa dos 25 grãos e expressos em $\mu\text{S cm}^{-1} \text{ g}^{-1}$ de grãos.

Para o teste de germinação foram utilizadas quatro subamostras de 50 sementes de cada unidade experimental, distribuídas em rolos de papel toalha (Germitest), e umedecidas com água destilada em quantidade 2,5 vezes a massa de papel seco. Em seguida, os rolos com as sementes foram colocados em germinador (Mangesdorf), regulado a temperatura de $25 \text{ }^\circ\text{C} \pm 2 \text{ }^\circ\text{C}$. As avaliações foram realizadas no oitavo dia após a instalação do teste, contando-se

plântulas normais e anormais e sementes mortas, conforme os critérios estabelecidos nas Regras para Análise de Sementes (Brasil, 2009).

Para determinar o amido (A), proteína bruta (PB), fibra bruta (FB), gordura (GD) e cinzas (CZ) em grãos de milho, utilizou-se a espectroscopia de infravermelho próximo (NIRS) (Metrohm, DS2500 espectrômetro, Herisau, Suíça) com alta precisão óptica. As amostras foram homogeneizadas e colocadas na cápsula de amostragem. A análise foi baseada em iluminar uma amostra com radiação de um comprimento de onda específico do infravermelho próximo e, em seguida, medir a diferença entre a energia emitida pelo espectroscópio e refletida pela amostra para o detector. Essa diferença foi medida em várias bandas, criando um espectro para cada amostra. O resultado obtido foi comparado a um conjunto de calibração (AOAC, 2000).

2.6 ANÁLISES DE CORRELAÇÃO DE PEARSON

Foi construído uma rede de correlação de Pearson entre as variáveis monitoradas e previstas. Essas análises foram realizadas com o auxílio do Software Rbio, seguindo os procedimentos recomendados por Bhering et al. (2017).

2.7 APRENDIZADO DE MÁQUINA

Os dados foram analisados no software Weka versão 3.9.5. utilizando os seguintes modelos: regressão linear múltipla (RLM), redes neurais artificiais (RNAs), algoritmo M5 de Quinlan (M5P) e floresta aleatória (FA) (Figura 8). O modelo RLM foi utilizado como modelo controle. A RNAs testada consiste em uma camada oculta única formada por um número de neurônios que é igual ao número de atributos, mais o número de classes, todos divididos por 2 (EGMONT-PETERSEN et al., 2002). O modelo M5P testado é uma reconstrução do algoritmo M5 de Quinlan que se baseia na árvore de decisão convencional com a adição de uma função de regressão linear aos nós das folhas (BLAIFI et al., 2018). O modelo FA é capaz de produzir várias árvores de predição para o mesmo conjunto de dados e usar um esquema de votação entre todas essas árvores aprendidas para prever novos valores (BELGIU & DRĂGU, 2016). As análises foram realizadas utilizando a configuração padrão do software para todos os modelos testados (BOUCKAERT et al., 2010) em uma CPU Intel® Core™ i5-3317U com 4 Gb de RAM.

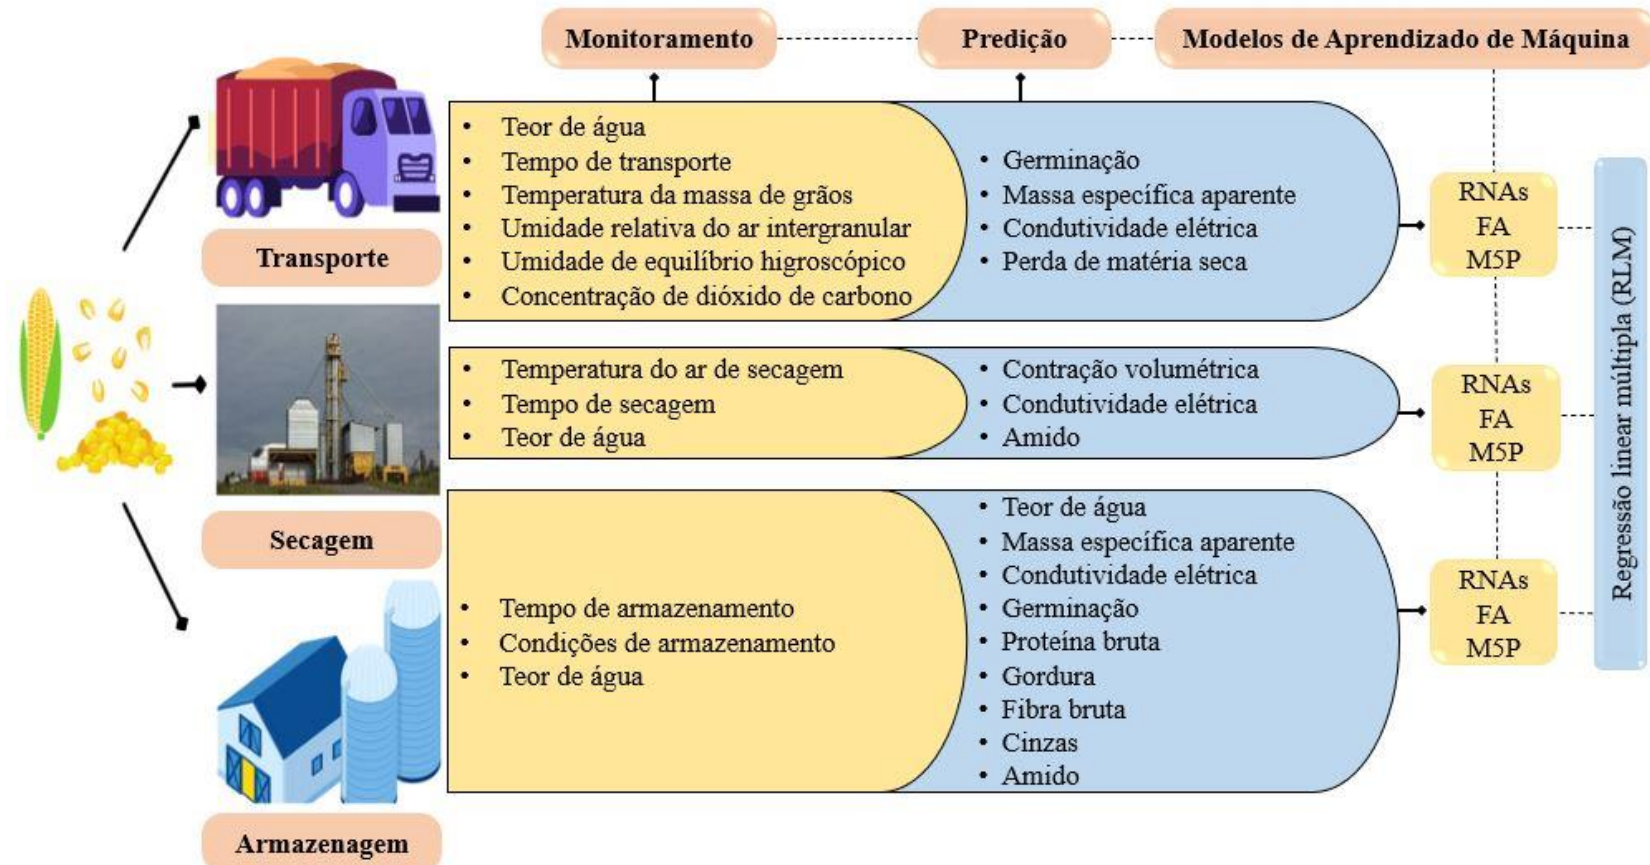
Para a aplicabilidade dos modelos de Aprendizado de Máquina (AM), foi padronizado critérios conforme descritos na figura 8, para as três etapas de pós-colheita de grãos. Neste

caso estabeleceu as variáveis que representaram os dados de entrada, e as variáveis que representaram os dados de saída.

No transporte, o teor de água, tempo, temperatura da massa de grãos, umidade relativa do ar intergranular, umidade de equilíbrio higroscópico e concentração de dióxido de carbono, determinaram os dados de entrada. Variáveis como germinação, massa específica aparente, condutividade elétrica e perda de matéria seca foram os dados de saída. Na secagem, a temperatura do ar de secagem, tempo de secagem e teor de água, representaram os dados de entrada e, como dados de saída a contação volumétrica, condutividade elétrica e amido. No armazenamento, para os dados de entrada, estabeleceu o tempo de armazenamento, as condições de armazenamento e o teor de água dos grãos. Enquanto que para os dados de saída, para esta mesma etapa, foi usado o teor de água, a massa específica aparente, condutividade elétrica, germinação, proteína bruta, gordura, fibra bruta, cinzas e amido.

Para treinamento dos diferentes algoritmos de (AM) utilizou-se o método de validação cruzada aleatória estratificada de dobras com 10 repetições para cada etapa (transporte, secagem e armazenagem) em cada modelo aplicado (RLM, RNAs, M5P e FA) seguindo os parâmetros descritos (Tabela 2, 3 e 4). Com esta análise, obteve-se o coeficiente de correlação (r) e o erro aparente médio (MAE) na predição dos resultados de qualidade dos grãos.

Figura 8 - Caracterização experimental da aplicabilidade dos modelos de Aprendizado de Máquina nas variáveis monitoradas e previstas nas etapas de transporte, secagem e armazenagem de grãos de milho



Fonte: Autora (2023).

Tabela 2 - Parâmetros utilizados para prever as variáveis de qualidade na etapa de transporte de grãos de milho

Modelos	Parâmetros	
	Condutividade elétrica (CE)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4 (Cross-validation folds 10)	
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.01 -M 0.01 -N 3500 -V 0 -S 1 -E 20 -H "20, 20" -output-debug-info (Cross-validation folds 10)	
M5P	weka.classifiers.trees.M5P-M 4.0 -num-decimal-places 4 (Cross-validation folds 10)	
FA	weka.classifiers.trees.RandomForest -P 100 -I 400 -num-slots 1 -K 1 -M 1.0 -V 0.001 -S 2 -output-debug-info (Cross-validation folds 10)	
Massa específica aparente (MEA)		
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4 (Cross-validation- folds 10)	
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H "2, 2" -output-debug-info (Cross-validation-folds 10)	
M5P	weka.classifiers.trees.M5P -R -M 4.0 -output-debug-info -num-decimal-places 4 (Cross-validation-folds 10)	
FA	weka.classifiers.trees.RandomForest -P 100 -I 500 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -output-debug-info (Cross-validation-folds 10)	
Perda de matéria seca (PMS)		
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4 (Cross-validation-folds 10)	
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H "2, 4" (Cross-validation-folds 10)	
M5P	weka.classifiers.trees.M5P -N -M 4.0 -output-debug-info -num-decimal-places 4 (Cross-validation-folds 10)	
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 500 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 (Cross-validation-folds 10)	
Germinação (GERM)		
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4 (Cross-validation-folds 10)	
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.1 -M 0.01 -N 500 -V 0 -S 0 -E 20 -H "1, 1" -G -R -output-debug-info (Cross-validation-folds 10)	
M5P	weka.classifiers.trees.M5P -R -M 4.0 -output-debug-info -num-decimal-places 4 (Cross-validation-folds 10)	
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -output-debug-info (Cross-validation-folds 10)	

Fonte: Autora (2023).

Tabela 3 - Parâmetros utilizados para prever as variáveis de qualidade na etapa de secagem de grãos de milho

(Continua)

Modelos	Parâmetros	
	Condutividade elétrica (CE)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4- cross-validation-fold 10	
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H a-cross-validation-fold 10	
M5P	weka.classifiers.trees.M5P -R -M 4.0 -output-debug-info -num-decimal-places 4- cross-validation-fold 10	
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -depth 1 -output-debug-info- cross-validation-fold 10	

Contração volumétrica (CV)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4- cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H "2, 2" -output-debug-info-cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -R -M 4.0 -output-debug-info -num-decimal-places 4- cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -depth 1 -output-debug-info- cross-validation-fold 10
Amido (A)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4- cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.2 -N 500 -V 0 -S 0 -E 20 -H "2, 2" -output-debug-info- cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -R -M 4.0 -output-debug-info -num-decimal-places 4- cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -depth 1 -B -output-debug-info- cross-validation-fold 10

Fonte: Autora (2023).

Tabela 4 - Parâmetros utilizados para prever as variáveis de qualidade na etapa de armazenagem de grãos de milho

(Continua)

Modelos	Parâmetros
	Massa específica aparente (MEA)
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4-Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.1 -M 0.2 -N 2500 -V 0 -S 0 -E 20 -H "10, 10" -output-debug-info Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -M 4.0 -output-debug-info -num-decimal-places 4 Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 0 -output-debug-info-Cross-validation-fold 10
Germinação (GERM)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.2 -N 1000 -V 0 -S 1 -E 20 -H "10, 10" -output-debug-info- Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -M 4.0 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -output-debug-info- Cross-validation-fold 10
Condutividade elétrica (CE)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.2 -N 3500 -V 0 -S 0 -E 20 -H "10, 10" -output-debug-info- Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -M 4.0 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -output-debug-info- Cross-validation-fold 10
Proteína bruta (PB)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-

	decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.1 -M 0.2 -N 500 -V 0 -S 1 -E 20 -H "8, 8" -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -M 4.0 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -I 500 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 0 -depth 4 -output-debug-info -num-decimal-places 6- Cross-validation-fold 10
Teor de água (TA)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.3 -M 0.1 -N 4500 -V 0 -S 1 -E 20 -H "10, 10" -output-debug-info -num-decimal-places 6- Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -M 4.0 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 100 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
Gordura (GD)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.1 -M 0.2 -N 2500 -V 0 -S 1 -E 20 -H "2, 2" -output-debug-info -Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -N -R -M 4.0 -output-debug-info -num-decimal-places 6- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 500 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -depth 3 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
Fibra bruta (FB)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.2 -M 0.1 -N 500 -V 0 -S 1 -E 20 -H "25, 25" -output-debug-info -Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -N -R -M 5.0 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 200 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 1 -Cross-validation-fold 10
Cinzas (CZ)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -num-decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.1 -M 0.2 -N 2000 -V 0 -S 0 -E 20 -H "4, 4" -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -N -M 2.0 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -I 400 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 4 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
Amido (A)	
RLM	weka.classifiers.functions.LinearRegression -S 0 -R 1.0E-8 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
RNAs	weka.classifiers.functions.MultilayerPerceptron -L 0.1 -M 0.2 -N 1000 -V 0 -S 0 -E 20 -H "8, 8" -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
M5P	weka.classifiers.trees.M5P -M 6.0 -output-debug-info -num-decimal-places 4- Cross-validation-fold 10
FA	weka.classifiers.trees.RandomForest -P 100 -attribute-importance -I 300 -num-slots 1 -K 0 -M 1.0 -V 0.001 -S 2 -output-debug-info -num-decimal-places 6- Cross-validation-fold 10

Fonte: Autora (2023).

2.8 ANÁLISES ESTATÍSTICAS

Após a obtenção do coeficiente de correlação (r) e o erro aparente médio (MAE) na análise de Aprendizado de Máquina, nas três etapas (transporte, secagem e armazenagem), foi estabelecida uma análise de variância. A partir desta análise, observou-se o nível de significância entre os modelos testados para cada variável. O delineamento utilizado foi o inteiramente ao acaso (DIC). Para o DIC foram considerados os três modelos de Aprendizado de Máquina (RNAs, M5P e FA) mais a regressão linear múltipla (RLM) para comparação.

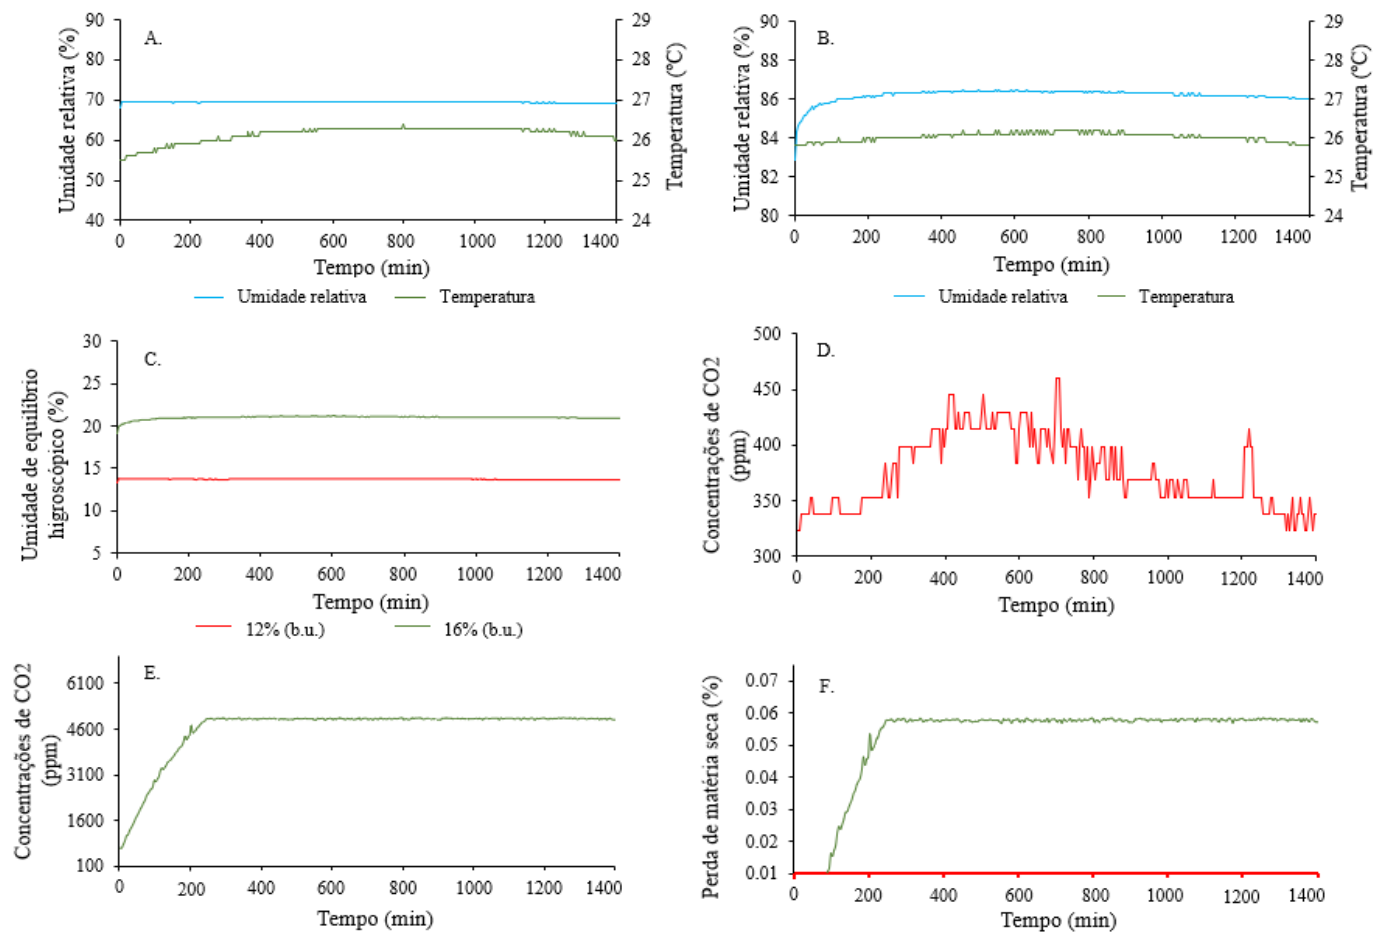
Para o conhecimento da maior variabilidade dos resultados, o coeficiente de correlação (r) variaram de 0 e 1. Quando o valor da correlação se aproxima de 1, o modelo conseguiu explicar com melhor acurácia as variáveis. Para o agrupamento das médias foi adotado o teste de Scott-knott a 5% de probabilidade e teste de normalidade dos dados (Shapiro-Wilk). A partir das médias foram gerados gráficos Boxplot para cada variável (r e MAE). Foram utilizados o software Rbio, recomendados por Bhering et al. (2017) e o software R (R Core Team, 2018) utilizando os pacotes ExpDes.pt e ggplot2.

3. RESULTADOS E DISCUSSÃO

3.1 MONITORAMENTO E PREDIÇÃO DA QUALIDADE DOS GRÃOS DE MILHO NO TRANSPORTE

No monitoramento dos grãos com 12% de teores de água (Figuras 9A), 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% (Figura 9B), a temperatura intergranular mantiveram-se próximas das condições de 12% de teor de água, enquanto, a umidade relativa intergranular aumentou acima de 86%. Além disto, verificou-se que a umidade de equilíbrio higroscópico se elevou para próximos a 20%, mantendo-se constante (Figura 9C).

Figura 9 - 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



Fonte: Autora (2023).

As variáveis intergranulares indicaram uma possível respiração celular naquele microclima. Estas por sua vez desencadearam picos de dióxido de carbono (CO_2) na massa de grãos ao longo do 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). Salienta-se, que a massa de grãos entrando em equilíbrio higroscópico com teores de água acima de 12% há riscos de deterioração, se o tempo de percurso dos grãos no transporte for prolongado, haveria possibilidades de perdas da qualidade dos grãos de milho (CORRÊA et al., 2010; ATUNGULU & OLATUNDE, 2018; LIN et al., 2019).

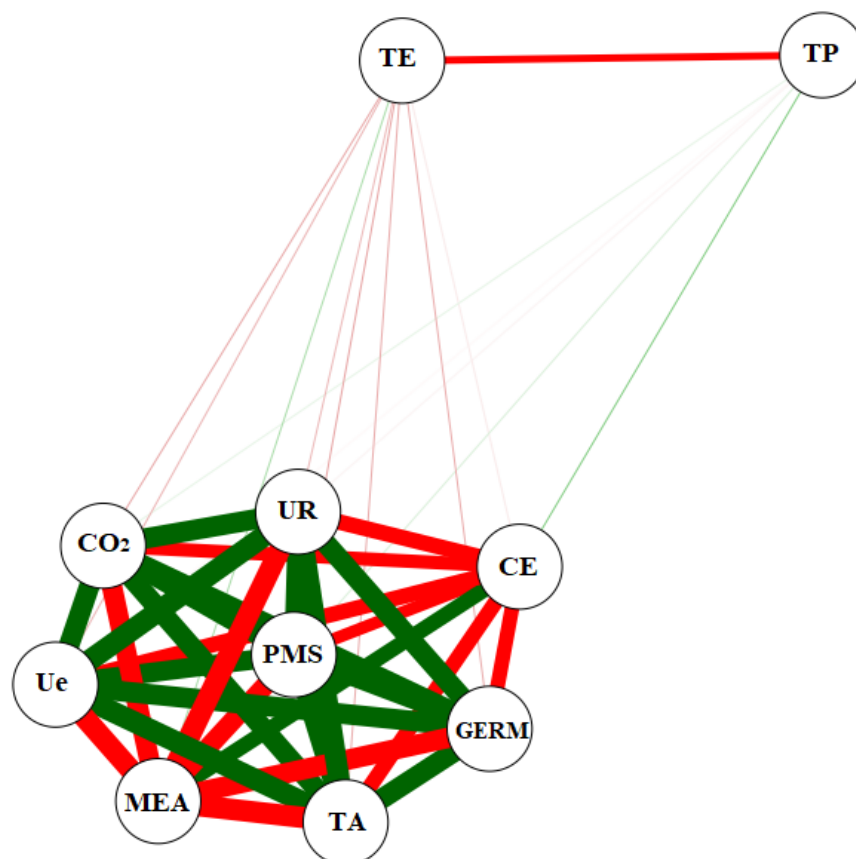
Nas condições de 12% de teor de água (Figura 9D) a massa de grãos não teve respiração acentuada, mantendo-se abaixo e próxima dos níveis aceitáveis do ambiente natural de 420 ppm (MAIER et al., 2010). Porém, com 16% de teor de água (Figura 8E), os níveis de dióxido de carbono (CO_2) foram elevados, chegando a 4960 ppm, indicando uma alta intensidade respiratória dos grãos com riscos elevados de deterioração (NEETHIRAJAN et al., 2010; JAQUES et al., 2022a). 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. Com o aquecimento da massa de grãos aumentaram-se as transferências de massa e calor e a respiração celular (GOLDSMITH et al., 2015; KUMAR & KALITA, 2017).

Na Figura 9F observou-se que os grãos com teores de água à 12% não alterou o consumo de matéria seca dos grãos, concordando com os resultados monitorados nas Figuras 9A e 9D. Porém, nos grãos com teores de água de 16% houve perdas de matéria seca próximos a 0,06% ao longo do período de monitoramento de vinte horas. Essa combinação resultou em atividades enzimáticas e biológicas, favorecendo o desenvolvimento de insetos e infecção por fungos e bactérias, desencadeando em reações de degradação da qualidade dos grãos (CORADI et al., 2016; CORADI et al., 2017).

A rede de correlação de Pearson (Figura 10) indicou uma relação das variáveis monitoradas com a qualidade dos grãos em função dos teores de água de 12 e 16%. Existiu uma correlação positiva e forte da perda de matéria seca (PMS) com a umidade relativa do ar (UR), teor de água (TA), umidade de equilíbrio higroscópico (Ue) e dióxido de carbono (CO_2) e fortemente negativa com a massa específica aparente (MEA). Estes resultados são coerentes com resultados das Figuras (9A-E) para os teores de 12% e 16% de água na massa de grão de milho. A germinação (GERM) obteve uma correlação positiva e forte com o teor de água (TA), a umidade relativa intergranular (UR) e a perda de matéria seca (PMS). Porém, existe uma correlação negativa entre estas variáveis com a massa específica aparente (MEA) e com a condutividade elétrica (CE). A GERM é diretamente dependente das condições da umidade

relativa intergranular, assim como, dos níveis de água com a atividade metabólica dos grãos. A correlação das variáveis TA e UR podem afetar as propriedades bioquímicas e reduzir a matéria seca, inibindo os componentes que confere a germinação dos grãos. Quando avaliamos a variável CE, foi observado também uma correlação medianamente positiva com a MEA e negativa com a UR, Ue e PMS. A correlação do tempo (TP) foi medianamente negativa em relação à temperatura (TE) e, este, por sua vez, exerceu uma correlação fraca e negativa com o CO₂, Ue, UR, PMS, TA e GERM. Porém, o (TP) correlacionou-se positivamente fraca com a CE, indicando que com o aumento do tempo de transporte houve maiores alterações sobre a qualidade dos grãos.

Figura 10 - Rede de correlação de Pearson estabelecidas sobre variáveis de massa específica aparente (MEA), condutividade elétrica (CE), germinação (GERM) e perda de matéria seca (PMS) na qualidade de grão de milho nas etapas de transporte. Teor água (TA), tempo (TP), temperatura (TE), umidade relativa intergranular (UR), umidade de equilíbrio higroscópico (Ue) e concentrações de dióxido de carbono (CO₂)



Fonte: Autora (2023).

Na Tabela 5 e Figura 11A estão os resultados dos coeficientes de correlação (r), coeficientes de determinação (R^2) e o erro absoluto médio (MAE) da predição da qualidade

dos grãos milho durante o transporte: perda de matéria seca (PMS), massa específica aparente (MEA), germinação (GERM) e condutividade elétrica (CE). Considerando os diferentes modelos de Aprendizado de Máquina e variáveis de entrada nos modelos (teor de água, tempo, temperatura, umidade relativa, umidade de equilíbrio higroscópico e concentrações de dióxido de carbono), foi observada significância a $p < 0,05$ pelo teste de Scott Knott (SK) dos modelos para as variáveis de qualidade.

Tabela 5 - Médias para coeficiente de correlação (r), erro absoluto médio (MAE), coeficiente de determinação (R^2) entre os valores observados e estimados das variáveis de qualidade dos grãos de milho no transporte, para os diferentes modelos de Aprendizado de Máquina

Modelos	r	PMS		r	MEA	
		MAE	R^2		MAE	R^2
RLM	0,99d	0,00a	98,01	1,00b	0,00b	100,0
RNAs	1,00b	0,00b	100,0	1,00a	0,00c	100,0
M5P	0,99c	0,00c	98,01	1,00a	0,07a	100,0
FA	0,99a	0,00d	98,01	1,00b	0,00b	100,0
Modelos	r	GERM		r	CE	
		MAE	R^2		MAE	R^2
RLM	0,98a	2,45c	96,33	0,92a	0,39b	84,64
RNAs	0,98a	2,49c	96,19	0,92b	0,39a	84,64
M5P	0,98b	2,98b	96,33	0,93a	0,38b	86,49
FA	0,97c	2,72a	94,88	0,88c	0,50a	77,44

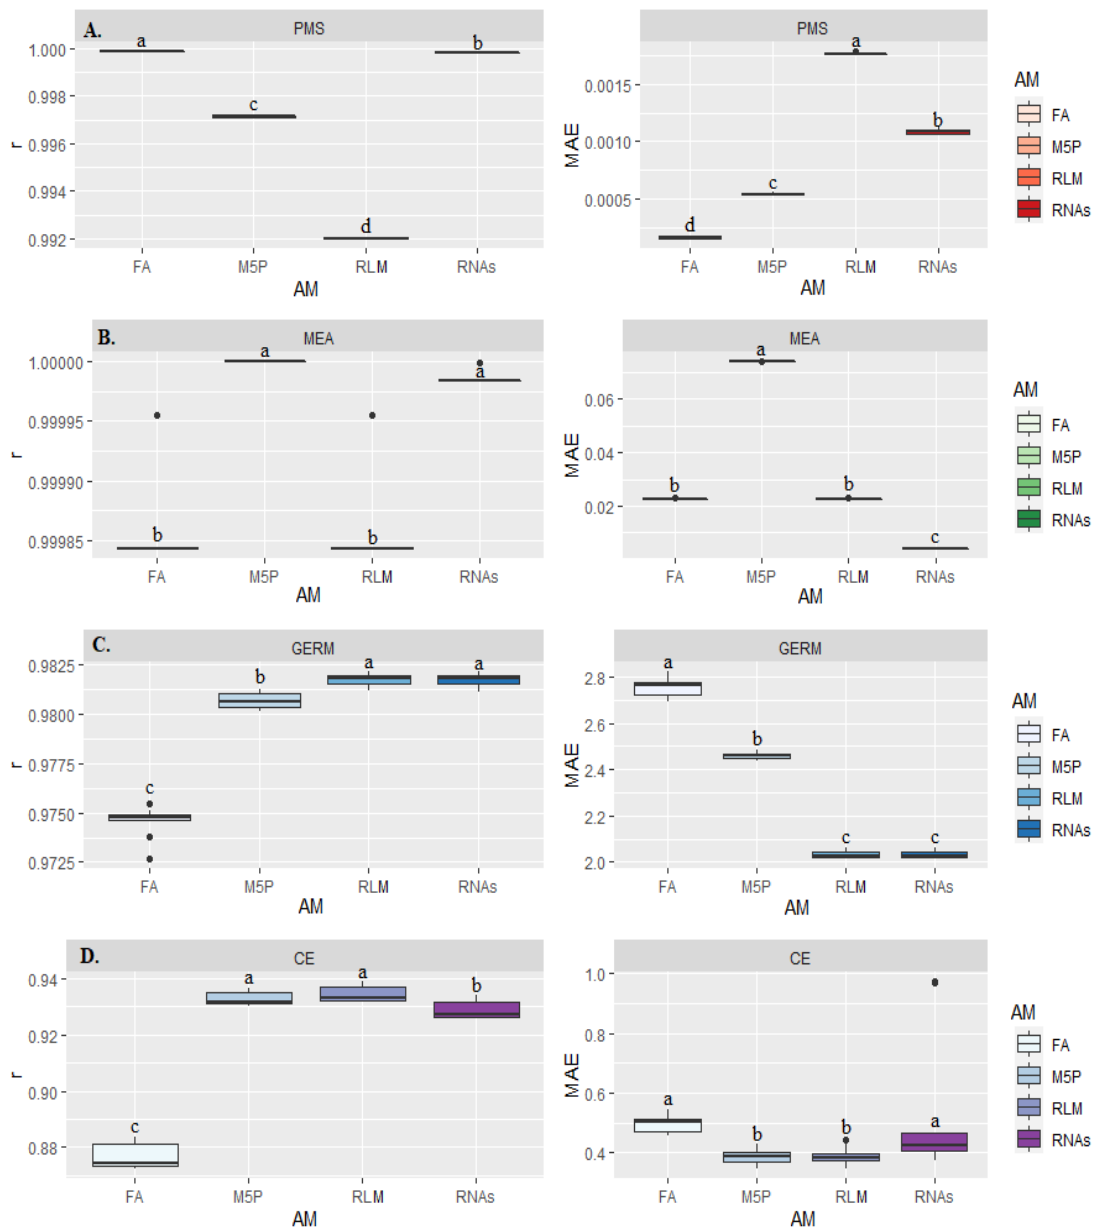
*Letras iguais na coluna não diferem a $p < 0,05$ pelo teste Scott knott. Perda de matéria seca (PMS), Massa específica aparente (MEA), Germinação (GERM) e Condutividade elétrica (CE). Regressão Linear Múltipla (RLM), Redes Neurais Artificiais (RNAs), Algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (FA).

Fonte: Autora (2023).

Para a variável 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) expressou maior desempenho (Tabela 5 e Figura 11A). A massa de grãos durante transporte pode sofrer ações de diversas variantes, as quais são condicionantes para os 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 parte de sua matéria seca preditos pela resposta dos modelos de Aprendizado de máquina (AM), principalmente pela floresta aleatória (FA.) O algoritmo FA possui várias alternativas para predição, onde escolhem aleatoriamente as condicionantes, elegendo uma única, sendo aquela que mais pode interferir na qualidade. Quando comparado a outros modelos de AM, este algoritmo de inteligência computacional faz previsão rápida, com grande conjunto de dados, como vistos em estudos de Ramos et al. (2020) para determinar rendimento de milho a partir do NDVI e de André et al. (2022) para determinação da qualidade de sementes de soja

armazenadas em diferentes embalagens. Alguns estudos verificaram que a técnica FA teve maior desempenho para prever a perda de massa seca em sementes de soja em ambientes com diferentes umidades relativas e temperatura de armazenamento (ZEYMER et al., 2021).

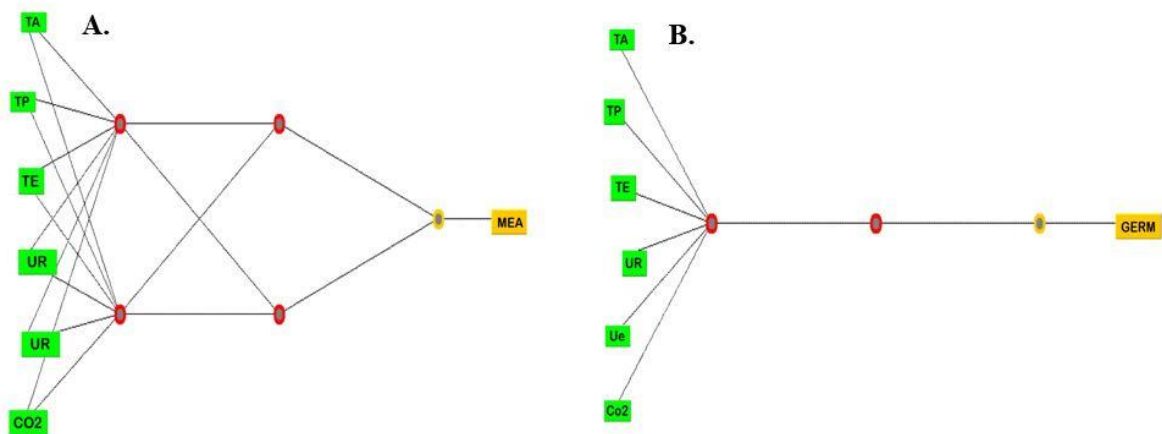
Figura 11 - Boxplot para comparação de média entre o modelo de regressão linear múltipla (RLM) e modelos de Aprendizado de Máquina: Redes Neurais Artificiais (RNAs), Algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (FA) na predição da perda de matéria seca-PMS (A.), massa específica aparente-MEA (B.), germinação-GERM (C.) e condutividade elétrica-CE (D.) do coeficiente de correlação (r) e do erro absoluto médio (MAE) em grãos de milho no transporte



Fonte: Autora (2023).

Para a variável massa específica aparente (MEA), os modelos de Aprendizado de Máquina (AM) testados apresentaram níveis elevados no coeficiente de correlação, com exceção do modelo M5P (Tabela 5 e Figura 11B). Quando aplicado o teste SK a $p < 0,05$ os modelos RNAs e M5P tiveram um melhor ajuste e predizem satisfatoriamente a massa específica aparente (Figura 11B). Durante o tempo, a MEA sofreu alterações, influenciadas pelas variáveis teores de água e temperaturas elevadas que agiram simultaneamente no processo de respiração. A MEA é definida como variável física que relaciona a massa do grão seco com seu volume total (BOTELHO et al., 2018; LORINI et al., 2018). A alteração da MEA pode reduzir o peso dos grãos (quebra técnica) e influenciar na matéria seca total, já que estão correlacionadas. Este evento pode ser reduzido a partir do uso do AM, com os modelos preditivos de M5P e principalmente pela RNAs, pois resultaram nos melhores (r) e (MAE). A taxa de aprendizagem do modelo de RNAs sobre a variável MEA foi reduzida, o que permitiu fazer uma leitura do banco de dados mais eficiente e menos complexa da estrutura da rede neural, tornando-se o modelo mais indicado na predição desta variável (Figura 12A).

Figura 12 - Arquitetura do modelo de redes neurais artificiais (RNAs) na predição da massa específica aparente-MEA (A.) e germinação-GERM (B.), em grãos de milho no transporte



Fonte: Autora (2023).

As RNAs são algoritmos com vasta capacidade de previsão de conjunto de dados complexos e de longa ocorrência (SHIEL & West, 2016). Diferentemente dos modelos de regressão lineares tradicionais, as RNAs processam o grande conjunto de dados e ainda possibilita uma eventual previsão através de um único sinal de saída ou neurônio (LIMA et al., 2010). Este neurônio representa, neste caso, uma variável de fácil medição monitorada

durante o tempo estabelecido de transporte de grãos. Com este modelo preditivo é possível realizar a tomada de decisão com mais assertividade sobre a MAE (OLIVEIRA & SÁ, 2018).

Na avaliação da germinação (GERM) verificou-se que os algoritmos de RLM e RNAs e M5P tiveram os coeficientes de correlação (r) mais elevados e menores erros absolutos médios (MAE) (Tabela 5 e Figura 11C). Todavia, aplicando o teste SK a $p < 0,05$ os modelos que mais previu os resultados de germinação foram os algoritmos de RNAs e RLM (Figura 11C). A germinação (GERM) por ser uma análise susceptível aos efeitos da temperatura e umidade relativa intergranular determinou as alterações de qualidade dos grãos. A combinação da elevação dos teores de água e da temperatura desencadeiam reações bioquímicas, modificando a estrutura celular do grão. Essa reação em série, prejudica o potencial de vigor, que por consequência reduz a germinação dos grãos (RANI et al., 2013; KATTA et al., 2019). Porém, a partir do monitoramento em tempo real das variáveis de fácil medição, podem-se ser aplicadas técnicas preditivas para controlar esses eventos que interferiram na germinação. O que pode ser comparado a estudos de Wang et al. (2021) sobre o monitoramento do manejo da adubação na produção e qualidade de grãos de milho. Os resultados de (r) e (MAE) indicam que o modelo de RNAs é o mais indicado para prever a GERM, isso se deve a leitura satisfatória do banco de dados para esta variável, sendo demonstrada através da arquitetura de sua rede (Figura 12B).


Na avaliação da condutividade elétrica (CE), o algoritmo de M5P obteve destaque entre os demais modelos de AM. Para este modelo, houve uma correlação de r (0,93), MAE (0,38), com 85,89% de acurácia da técnica para a predição (Tabela 5 e Figura 11D). Porém, quando aplicado o teste SK $p < 0,05$ as médias (0,93) dos modelos M5P e RLM foram semelhantes, assim como o MAE (0,38) para ambas as técnicas. Os grãos transportados com elevado teor água estão sujeitos às alterações a níveis celulares pela intensificação do processo respiratório dos grãos (CARVALHO et al., 2009). Os resultados elevados da condutividade elétrica (CE) ocorreram em função do rompimento da membrana e da parede celular dos grãos onde os exsudatos foram liberados e lixiviados (COIMBRA et al., 2009). Danos nos tecidos celulares podem alterar também a composição físico-química dos grãos, principalmente nos carboidratos. O algoritmo M5P alcançou os melhores resultados de (r) e (MAE) para predição do teste de condutividade elétrica nos grãos de milho. Alguns estudos que compararam o uso de algoritmos para prever as alterações da condutividade elétrica em grãos ainda são escassos na literatura. Por essa razão, M5P quando modelado adequadamente poderá fornecer respostas em tempo reduzido, quando comparados ao modelo de regressão comum (ANDRÉ et al., 2022).

3.2 MONITORAMENTO E PREDIÇÃO DA QUALIDADE DOS GRÃOS DE MILHO NA SECAGEM

Na Figura 13 estão as curvas de secagem dos grãos de milho para diferentes temperaturas do ar de secagem. Observou-se que na temperatura de secagem de 80 °C o tempo de secagem prolongou-se até 4,83 horas. Já na secagem com temperatura de 100 °C o tempo reduziu para 4,5, enquanto, a 120 °C a secagem foi de apenas 3,5 horas. Para todas as condições de secagem, os grãos reduziram os teores de água até 13,2% (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 à secagem, e também o/sob os efeitos na qualidade física, físico-química e morfológica dos grãos, quando o aumento da temperatura do ar de secagem de 80 °C para 120 °C pode ter afetado a estrutura morfológica dos grãos e alterados os tecidos celulares, causando mudanças no amido, proteínas e lipídeos. Estes resultados foram monitorados e preditos para determinação do melhor modelo de Aprendizado de Máquina no controle da operação de secagem, com base na temperatura do ar e tempo de secagem (CORADI et al., 2014; MALUMBA et al., 2014; MARTINEZ-FERIA et al., 2019; WEI et al., 2020; TIMM et al., 2022).


Figura 13 - Curvas de secagem dos grãos de milho para diferentes temperaturas do ar de secagem



Fonte: Autora (2023).

Na Figura 14 estão às correlações das variáveis monitoradas e previstas. A temperatura de secagem (TS) teve correlação forte e positiva com a condutividade elétrica (CE). Enquanto, a CE esteve correlacionada positivamente e fraca com a contração volumétrica (CV) e com a (TDS). Foi observado que a CE influenciou no teor de amido (A) dos grãos de milho com uma correlação forte e negativa, enquanto que o (A) teve uma correlação negativa e moderada com a TS. A TDS se correlacionou negativamente e forte com os teores de água (TA) e positivamente e forte com a contração volumétrica, enquanto, a contração volumétrica teve uma correlação forte e negativa com a TA. Houve uma correlação negativa e fraca entre TDS x A, CV x A, TA x CE e fraca e positiva entre TDS x CE e TA x A.

Figura 14 - Rede de correlação de Pearson estabelecidas entre as variáveis: contração volumétrica (CV), amido (A), condutividade elétrica (CE), temperatura do ar de secagem (TS), teor de água (TA) e tempo de secagem (TDS)



Fonte: Autora (2023)

Na Tabela 6 estão os resultados dos coeficientes de correlação (r), coeficientes de determinação (R^2) e o erro absoluto médio (MAE) para predição das variáveis de qualidade dos grãos milho na secagem: contração volumétrica (CV), amido (A) e condutividade elétrica

(CE). Considerando os diferentes modelos de Aprendizado de Máquina e as variáveis monitoradas de temperatura do ar de secagem (TS), teor de água (TA) e tempo de secagem (TDS) foi observado que houve diferença significativa a $p < 0,05$ pelo teste SK. Os modelos de redes neurais artificiais (RNAs) obtiveram os melhores resultados de (r) e (MAE) e por isto foi o modelo mais indicado para prever as variáveis CV, A e CE (Tabela 6).

Tabela 6 - Médias para os coeficientes de correlação (r), erro absoluto médio (MAE), coeficiente de determinação (R^2) entre os valores observados e estimados das variáveis de qualidade dos grãos de milho na secagem, para os diferentes modelos de Aprendizado de Máquina

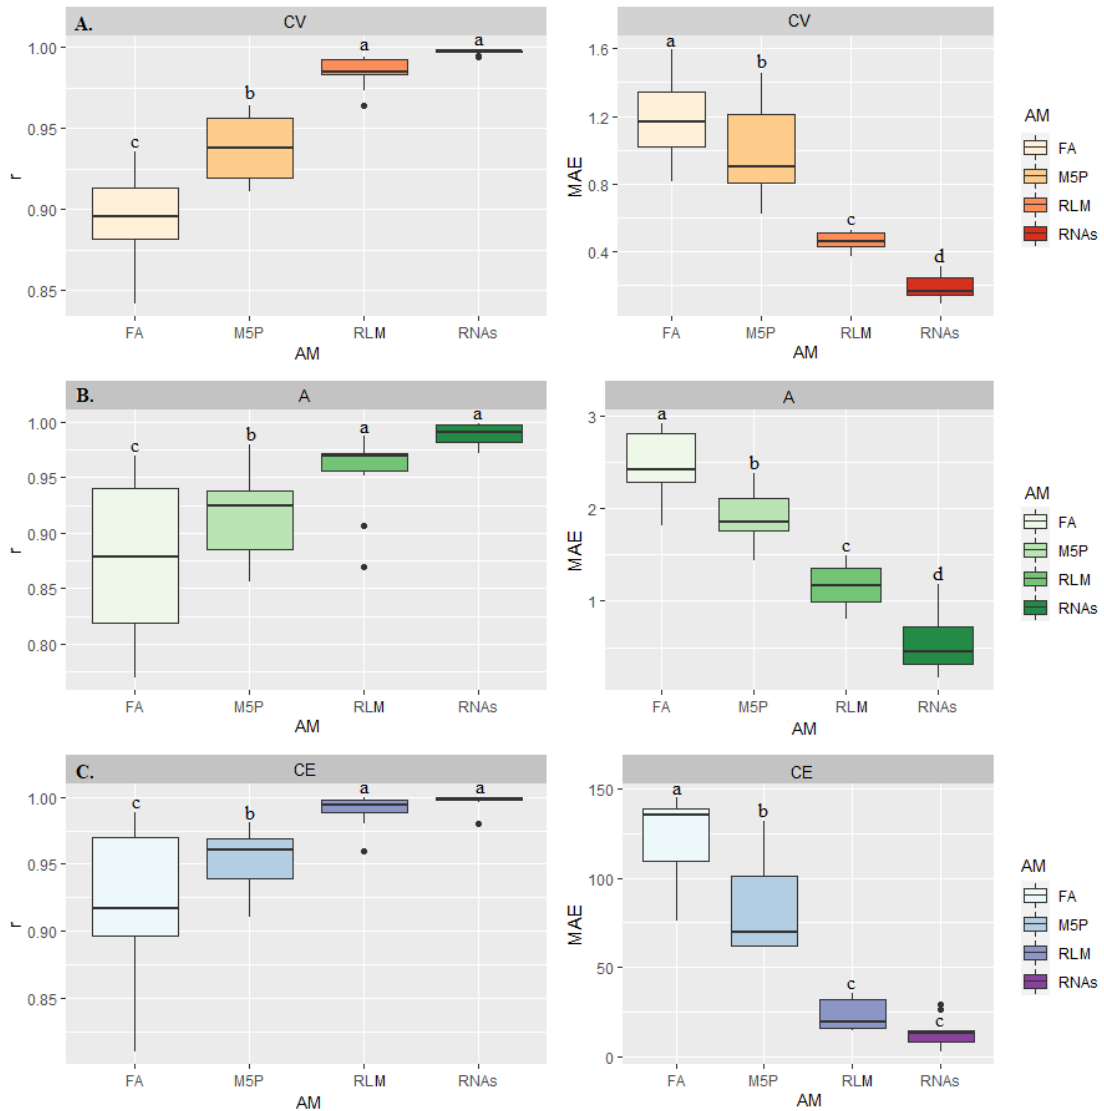
Modelo	CV			A			CE		
	r	MAE	R^2	r	MAE	R^2	r	MAE	R^2
RLM	0,98a	0,46c	96,04	0,94a	1,14c	88,36	0,98a	21,98c	96,04
RNAs	0,99a	0,20d	98,01	0,98a	0,52d	96,04	0,99a	13,21c	98,01
M5P	0,93b	0,97b	86,49	0,91b	1,84b	82,81	0,93b	81,68b	87,89
FA	0,88c	1,88a	77,44	0,86c	2,32a	73,96	0,89c	117,9a	80,96

*Letras iguais na coluna não diferem a $p < 0,05$ pelo teste Scott knott. Contração volumétrica (CV), Amido (A), Condutividade elétrica (CE). Regressão Linear Múltipla (RLM), Redes Neurais Artificiais (RNAs), Algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (FA).

Fonte: Autora (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 $p < 0,05$ (Figura 15A). Entre as médias de MAE (0,20 e 0,46, respectivamente) verificou-se que o modelo de RNAs por apresentar um menor distanciamento entre as variáveis analisadas e preditas foi a que melhor previu o CV na massa de grão de milho, com acurácia de R^2 (98,01%) (Tabela 6). As alterações da contração volumétrica é consequência do aumento da temperatura do ar de secagem que pode ter provocado alterações no endosperma dos grãos, a partir da redução dos teores de água. Assim, durante o processo de secagem, as propriedades proteicas e os carboidratos totais podem ter sofrido alterações. As moléculas de carboidratos quando submetidos a temperaturas elevadas podem ter quebrado e transformados em moléculas menos complexas, multiplicadas no espaço intercelular. Essas mudanças físico-químicas comprometeram a qualidade dos grãos (MARTINEZ-FERIA et al., 2019; WEI et al., 2020).

Figura 15 - 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



Fonte: Autora (2023)

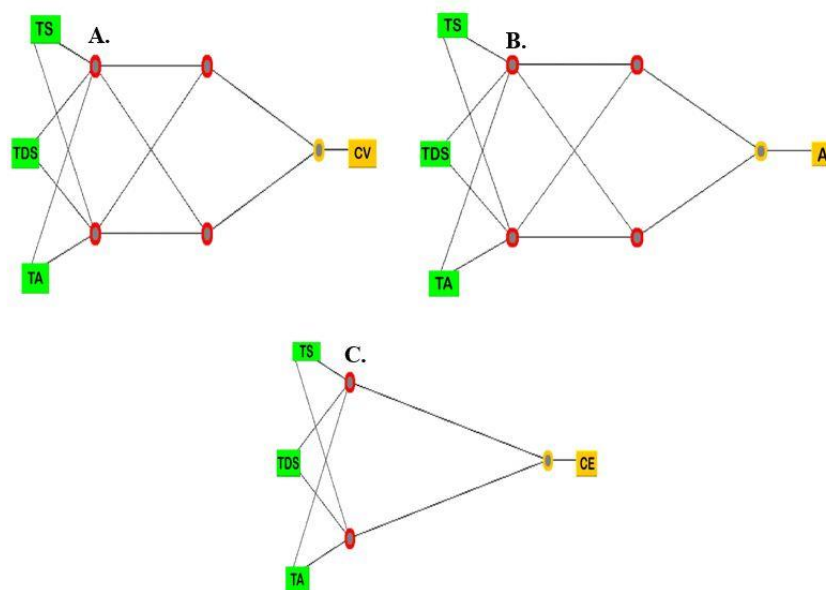
Na predição do rendimento de amido (A) os modelos RNAs e RLM apresentaram os maiores coeficientes de correlação r (0,98 e 0,94, respectivamente) não diferindo entre si pelo teste SK $p < 0,05$ (Figura 15B). Os valores do erro absoluto médio para cada modelo foram de MAE (0,52 e 1,14, respectivamente), indicando os modelos de RNAs com acurácia de R^2 (96,04%) (Tabela 6). O amido é um carboidrato biomolecular que compreendem a maioria da estrutura do grão de milho e necessita que seus bicomponentes estejam em arranjos perfeitos (H, O_2 e C). Associados aos outros bicomponentes, quando o grão passa por

temperaturas elevadas de secagem, estruturas moleculares são afetadas. A secagem a temperaturas acima de 80 °C pode afetar a estrutura do amido e seus constituintes (HUART et al., 2018). Em estudos com secagem de milho, Timm et al. (2022) verificaram que a temperatura de secagem do ar abaixo de 80 °C ampliou consideravelmente o tempo de secagem, porém a constituição físico-química e especialmente o amido é preservado.

Enquanto, para variável condutividade elétrica (CE), os modelos RNAs e RLM apresentaram os maiores valores de correlação r (0,98 e 0,99, respectivamente) e MAE (21,98 e 13,21, respectivamente) não diferindo entre si pelo teste SK $p < 0,05$ (Figura 15C), com uma melhor acurácia de R^2 (98,04%) para a RNAs (Tabela 6). A elevação da CE esteve ligada ao aumento da temperatura do ar de secagem. Com a movimentação mais intensa da umidade do interior dos grãos para a superfície nas camadas internas dos grãos, as paredes celulares da estrutura do grão foram afetadas, causando ruptura de suas membranas. Quando isto ocorre, como consequência, os exsudatos são liberados, elevando a condutividade elétrica dos grãos.

As RNAs exerceram leituras satisfatórias sobre as variáveis CV, A e CE. A taxa de aprendizagem reduzida do modelo (RNAs), permitiram rapidez na leitura dos dados monitorados sobre os preditos (Figura 16A, B e C). Neste caso, houve um impacto positivo nos valores de r e baixo (MAE), indicando que as RNAs são, portanto, os modelos com fácil predição na qualidade do grão de milho na secagem.

Figura 16 - Arquitetura do modelo de redes neurais artificiais (RNAs) na predição da contração volumétrica-CV (A.), amido-A (B.) e condutividade elétrica-CE (C.), em grãos de milho na secagem

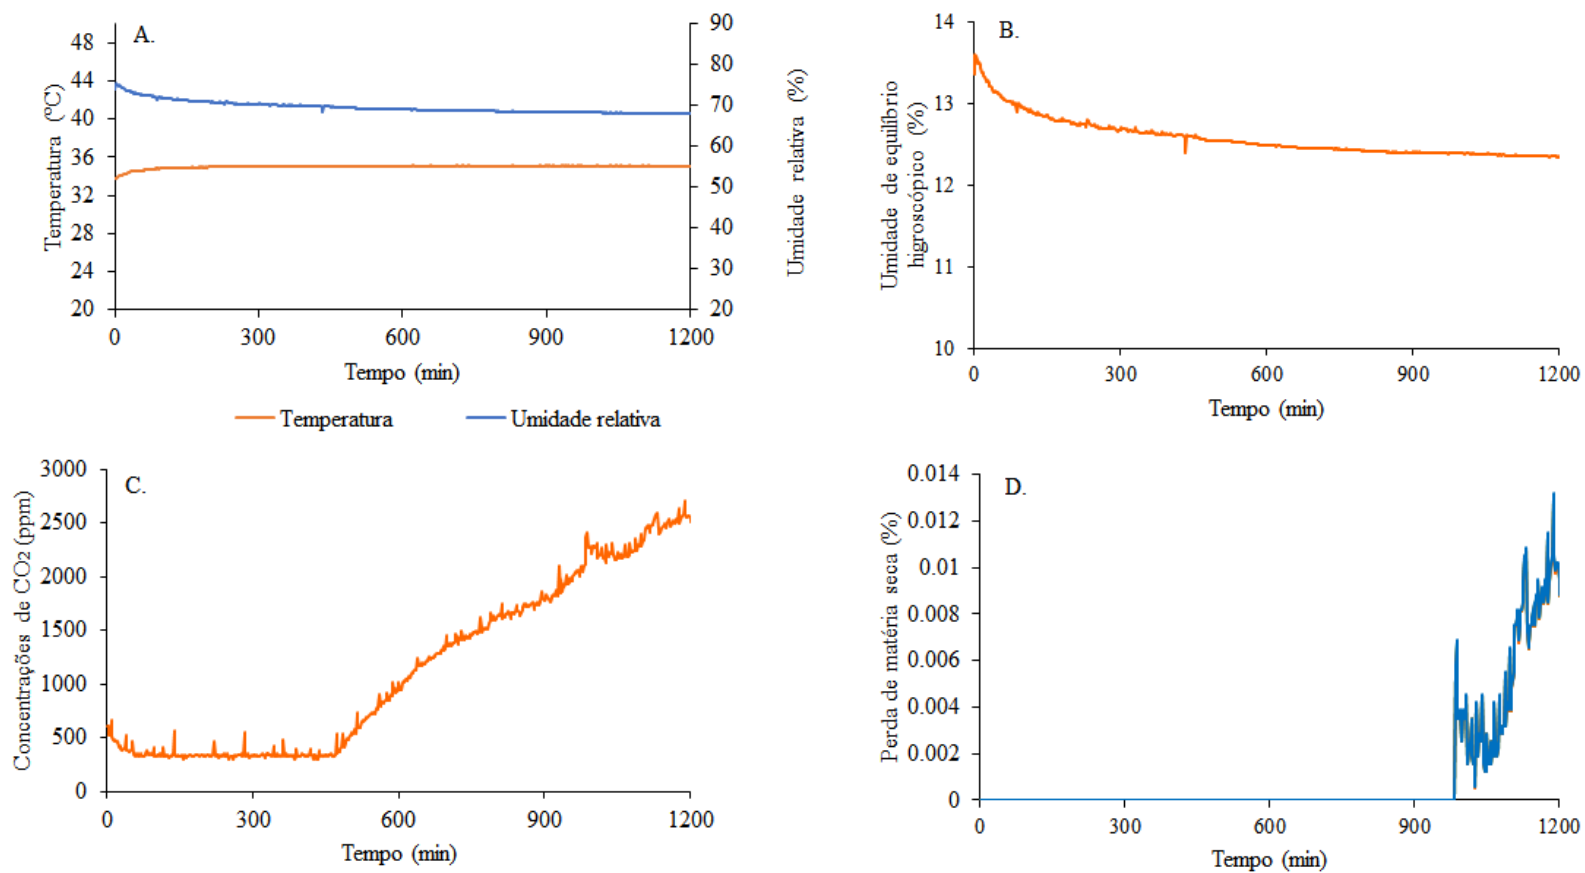


3.3 MONITORAMENTO E PREDIÇÃO DA QUALIDADE DOS GRÃOS DE MILHO ARMAZENADOS

Nas (Figuras 17A e B) estão os resultados de temperatura (TE), umidade relativa do ar intergranular (UR) para cálculo da umidade de equilíbrio higroscópico (Ue) da massa de grãos de milho armazenados. Durante as vinte horas de monitoramento a (TE) manteve-se constante, porém elevada, entre 30 a 36 °C, enquanto a (UR) permaneceu próxima a 70%, alcançando 13% de (Ue). A partir das 7,5 horas de monitoramento houve um aumento dos níveis de dióxido de carbono (CO₂) (Figura 17C) e conseqüentemente maior consumo de matéria seca (Figura 17D) ao final do tempo de monitorando (a partir das 15 horas), acompanhando os picos de respiração dos grãos.

As temperaturas elevadas associada a alta umidade relativa pode desencadear reações metabólicas no grão (CORADI et al., 2014; CORADI et al., 2020; LUTZ & CORADI., 2022). Durante a liberação desses componentes, enzimas, carboidratos são degradados, reduzindo a qualidade do grão de milho. Por essa razão, é importante conhecer essas relações em tempo real para prever e controlar as variáveis de fácil mensuração e poder determinar o tempo ideal de armazenamento dos grãos (LUTZ & CORADI, 2022), sem que haja perdas (NYABAKO et al., 2020).


Figura 17 - Monitoramento precoce da umidade relativa e da temperatura intergranular (A.), umidade de equilíbrio higroscópico (B.), concentrações de CO₂ (C.), e perda de matéria seca (D.), em grãos de milho no armazenamento



Fonte: Autora (2023).

Na Figura 18 estão os resultados de correlação entre as variáveis monitoradas e preditas. As variáveis UR x GERM tiveram uma alta correlação positiva com a MEA e média correlação positiva com a PB, bem como uma média correlação positiva entre GD x MEA, GERM x PB, PB x MEA, PB x GD, GD x MEA, CE x CZ. Foi observado, também, uma alta correlação entre a variável PMS x TE, bem como média correlação entre PMS x A, A x TE e TE x CO₂. Houve uma alta correlação negativa entre as variáveis MEA x CZ, UR x CZ, média correlação negativa entre as variáveis GERM x CZ, MEA x CE, UR x CE, TA x CE. Além disto, houve uma correlação fraca, porém positiva entre GD x FB, PB x FB, FB x TE, TE x CE, TE x CZ, PB x A, PB x TP, GERM x TP, GERM x TA, GERM x TE, FB x A, PMS x CO₂, PMS x PB, PMS x GD, PMS x UR, PMS x MEA, PMS x CE, CO₂ x A, CO₂ x PB, CO₂ x GD e CO₂ x FB. Assim como correlações fracas e negativas nas variáveis TP x TA, A x TA, TE x TA, PB x CE, GERM x CE, FB x CZ, GD x CZ, PB x CZ e A x CZ.

Figura 18 - Rede de correlação de Pearson estabelecidas entre as variáveis: tempo de armazenamento (TP), temperatura intergranular (TE), umidade relativa do ar intergranular (UR), teor de água (TA), massa específica aparente (MEA), germinação (GERM), condutividade elétrica (CE), proteína bruta (PB), fibra bruta (FB), gorduras (GD), cinzas (CZ) e amido (A), concentrações de dióxido de carbono (CO₂) e perda de matéria seca (PMS)



Fonte: Autora (2023).

Destaca-se que entre as variáveis monitoradas, a UR foi aquela que teve maior influência sobre a qualidade dos grãos (CHOTIKASATIAN et al., 2017; FLEURAT-

LESSARD, 2017). Enquanto entre as variáveis determinadas, a MEA e GERM indicaram os níveis positivos e negativos de qualidade (YILDIRIM et al., 2018; CORADI et al., 2020).

Na Tabela 7 estão os resultados dos coeficientes de correlação (r), coeficiente de determinação (R^2) e o erro absoluto médio (MAE) dos modelos de aprendizado de máquina (AM) para predição das variáveis de qualidade dos grãos milho armazenado: massa específica aparente (MEA), germinação (GERM), condutividade elétrica (CE), proteína bruta (PB), teor de água (TA), gorduras (GD), fibra bruta (FB), cinzas (CZ) e amido (A). As variáveis de entrada de fácil mensuração (TE, UR e TP) para os diferentes modelos de AM, foram significativos a $p < 0,05$ pelo teste Scott Knott (SK). Os modelos de redes neurais artificiais (RNAs) e floresta aleatória (FA) foram os modelos mais indicados para prever as variáveis TA, GERM, PB, FB, CZ e GD, enquanto que, o modelo M5P predissesse satisfatoriamente a MEA, CE e A.

Tabela 7 - Médias para os coeficientes de correlação (r), erro absoluto médio (MAE), coeficiente de determinação (R^2) entre os valores observados e estimados das variáveis de qualidade dos grãos de milho no armazenamento, para os diferentes modelos de Aprendizado de Máquina

Modelo	r	MAE	R ²	r	MAE	R ²	r	MAE	R ²
		TA	MEA		CE				
RLM	0,84c	0,89a	70,56	0,93b	2,69a	86,49	0,65b	96,93a	42,25
RNAs	0,96a	0,45c	92,16	0,98a	1,43b	96,04	0,92a	54,75b	84,64
M5P	0,93b	0,53b	86,49	0,97a	1,59b	94,09	0,91a	57,33b	82,81
FA	0,97a	0,39c	94,09	0,98a	1,24b	96,04	0,94a	46,41b	88,36
Modelo	r	MAE	R ²	r	MAE	R ²	r	MAE	R ²
		GERM	GD		CZ				
RLM	0,75c	6,74a	56,25	0,69a	0,15a	47,61	0,90a	0,05a	81,00
RNAs	0,94a	3,45b	88,36	0,73a	0,14a	53,29	0,90a	0,05a	81,00
M5P	0,89b	4,67c	79,21	0,71a	0,14a	50,41	0,91a	0,05a	82,81
FA	0,95a	3,13c	90,25	0,73a	0,14a	53,29	0,90a	0,05a	81,00
Modelo	r	MAE	R ²	r	MAE	R ²	r	MAE	R ²
		A	PB		FB				
RLM	0,68b	1,01a	46,24	0,75a	0,24a	56,25	0,56a	0,13a	31,36
RNAs	0,88a	0,66b	77,44	0,76a	0,24a	57,76	0,62a	0,13a	38,44
M5P	0,87a	0,67b	75,69	0,77a	0,23a	59,29	0,59a	0,12a	34,81
FA	0,89a	0,63b	79,21	0,78a	0,23a	60,84	0,61a	0,13a	37,21

*Letras iguais na coluna não diferem a $p < 0,05$ pelo teste Scott Knott. Teor de água (TA), Perda de matéria seca (PMS), Massa específica aparente (MEA), Germinação (GERM), Condutividade elétrica (CE), Gordura (GD), Cinzas (CZ), Amido (A), Proteína bruta (PB), Fibra bruta (FB). Regressão Linear Múltipla (RLM), Redes Neurais Artificiais (RNAs), Algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (FA).

Para melhor prever a variável TA, os modelos de RNAs e FA se destacaram apresentando uma correlação de r (0,96 e 0,97, respectivamente), porém não diferindo entre si pelo teste SK $p < 0,05$ (Tabela 7 e Figura 19A). As menores médias de MAE (0,45 e 0,39) permitiu melhor ajuste 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 aparente médio (MAE) foi de (0,89 e 0,53, respectivamente). Com estes resultados pode-se indicar que os modelos de RNAs e FA, são melhores modelos, devido ao nível de acurácia de R^2 (92,16% e 94,09%, respectivamente).

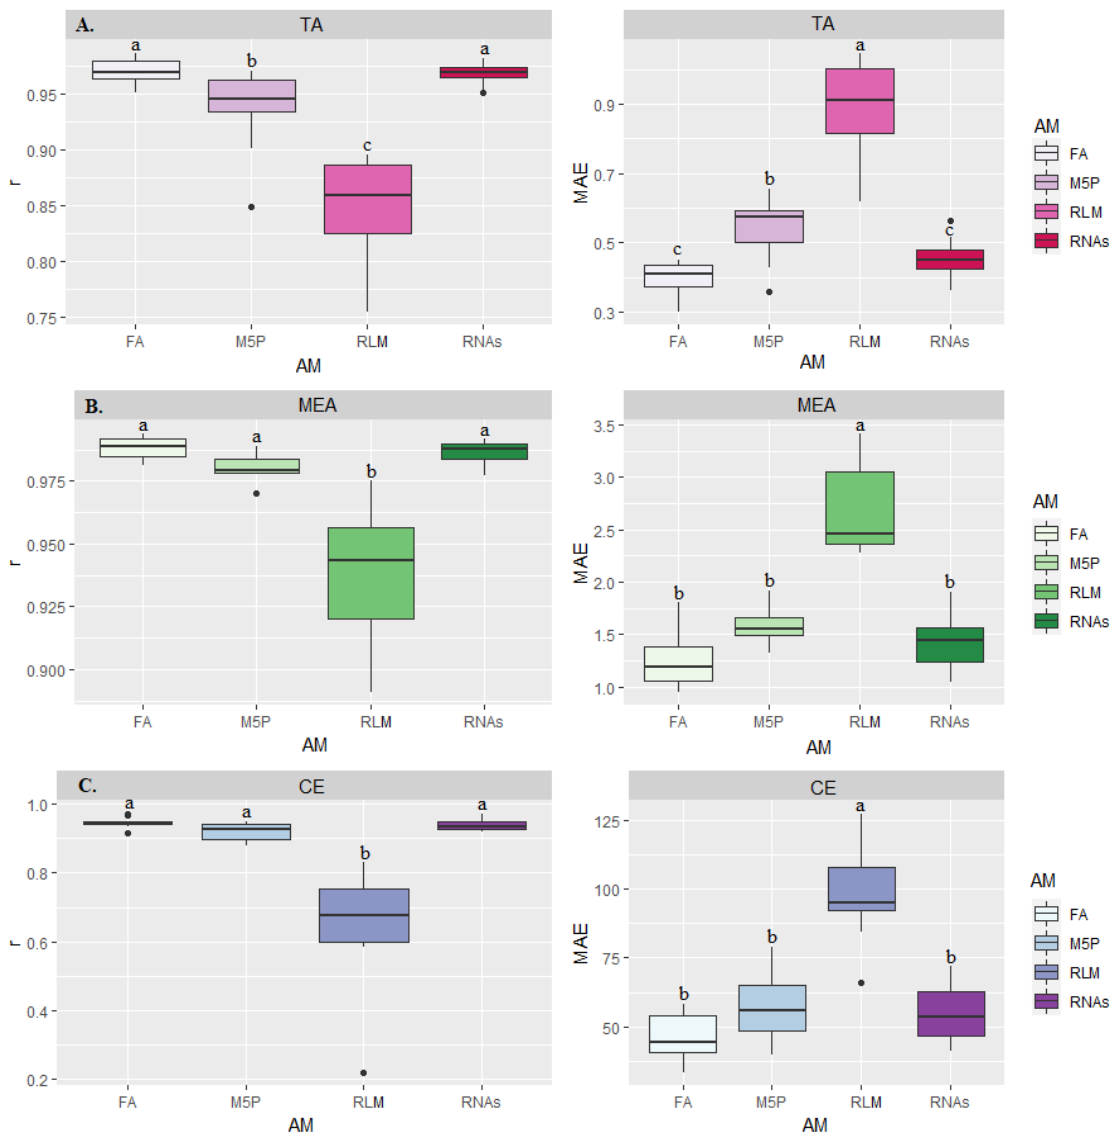
Mesmo o grão de milho sendo armazenado com teor de água entre 12% a 13% estão suscetíveis a variar em função das condições estabelecidas na massa de grão. A forma de armazenamento associadas às condições de umidade e temperatura, corroboram com a reabsorção dos teores de água no grão. Com o teor de água elevado, a atividade biológica da massa de grãos é mais intensa. Para estes casos, tem-se um aumento da respiração celular, além da possibilidade de patógenos e micotoxinas se desenvolverem no milho (VALLE et al., 2011; FREURAT-LESSARD, 2017; GARCÍA-DÍAZ et al., 2020). Além disto, a quantidade de água na massa de grãos pode vir de etapas anteriores ao armazenamento, tais como na secagem de baixa eficiência, permitindo que o grão entre em equilíbrio higroscópico com teores de água elevados, sem estar em condições ideais de armazenamento (BERNARDI et al., 2017; WEI et al., 2020; MULLER et al., 2022).

Entre os problemas está na estabilidade do teor de água no grão induzindo ao equilíbrio higroscópico (MAINA et al., 2016). Por essa razão é importante fazer associações de tecnologias herméticas ou semi-herméticas e aplicação de modelos preditivos de Aprendizado de Máquina. Entre as vantagens estão a redução de trocas gasosas e a absorção de água para a massa de grão durante o armazenamento. Os modelos de RNAs e FA foram os mais indicados para prever esse controle. Quando treinada as redes neurais artificiais foram eficientes para prever a qualidade física e química dos grãos de milho durante o armazenamento (LUTZ et al., 2022). Estudos de Córdova-Noboa et al. (2020) reforça essa temática, onde os grãos de milho armazenados, secos a 35 °C, obtiveram maiores teores de água (14,45%) em detrimento dos secos a 120 °C (11,20%).

Os modelos de Aprendizado de máquina RNAs, M5P e FA foram melhores para a variável MEA, as quais 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 19B). As menores médias de r (0,93) foram observadas para o modelo padrão de regressão linear múltipla (RLM), que

por consequência, seu MAE (2,69) foi superior em detrimento dos modelos RNAs, M5P e FA com MAE (1,43, 1,59 e 1,24, respectivamente) (Tabela 7).

Figura 19 - 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



Fonte: Autora (2023).

Os resultados indicaram que MEA dos grãos de milho sofreram influência da umidade relativa e da temperatura no armazenamento. Além disso, o tempo foi um fator que interferiu na massa específica do grão armazenado. Esses fatos podem ser observados em estudos

científicos, onde a massa específica aparente dos grãos foram alterados pelo tempo e a temperatura de armazenamento (ALENCAR et al., 2009; ANDRÉ et al., 2022).

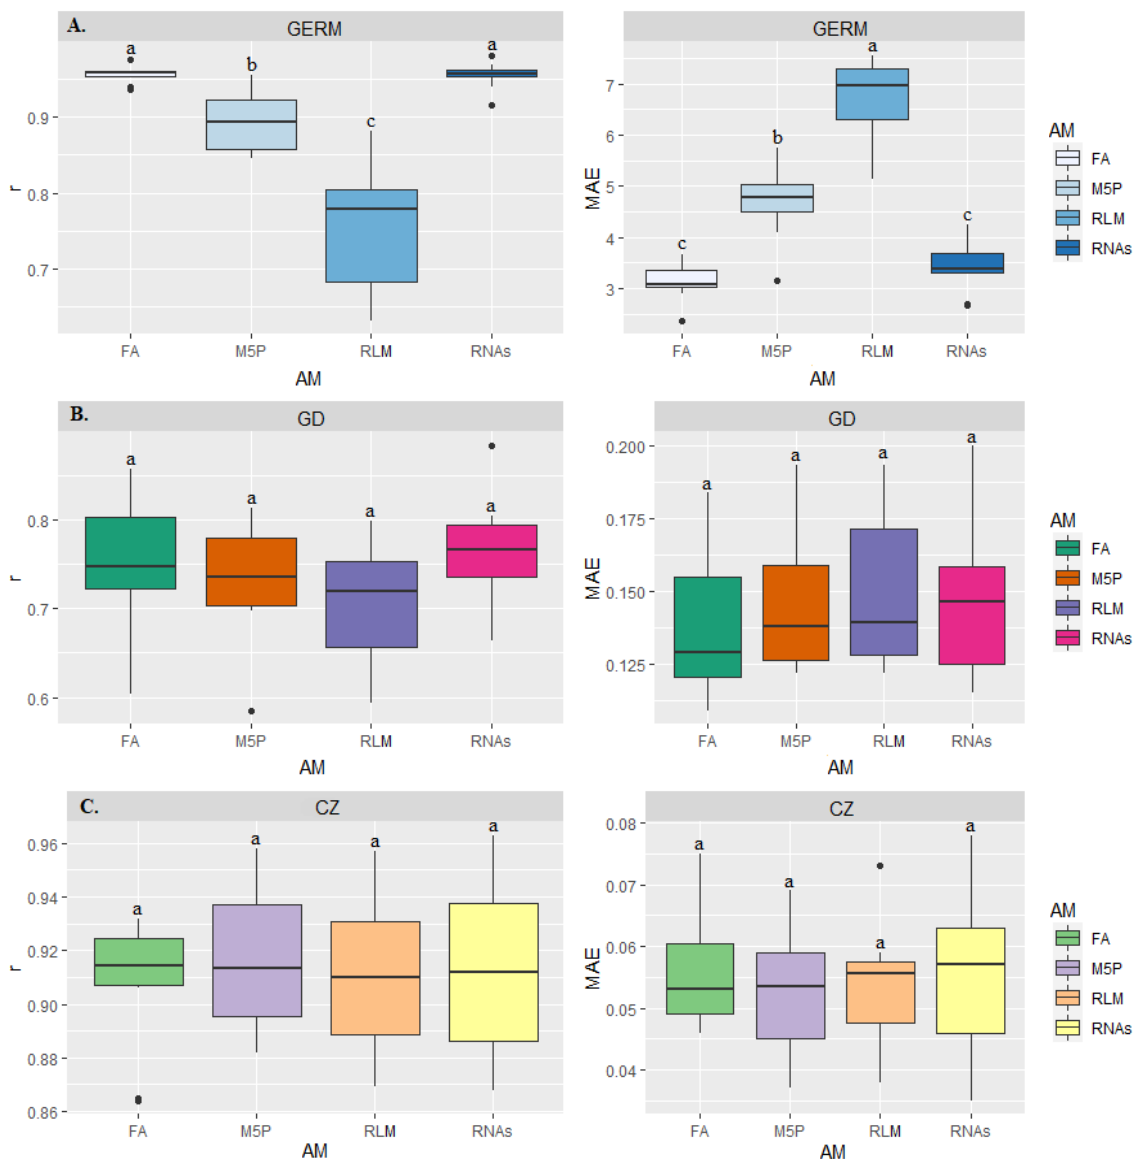
Entre as explicações para esse fato, está na atividade bioquímica, onde as células entram em atividade respiratória consumindo propriedades da massa do grão, principalmente quando a temperatura e os teores de água estão elevados, impulsionando o processo. Alguns autores relatam que durante as reações em série na massa de grão ocorrem oxidação dos grãos, por consequência perda de carboidratos totais, amido, proteínas e óleos (LIMA et al., 2021; MYLONA & MAGAN, 2011). No entanto, o uso tecnologias de armazenamento, como as de monitoramento de variáveis de fácil mensuração em modelos de armazenamento somadas ao uso de modelos preditivos foram alternativas para melhor controle da qualidade dos grãos. Em pesquisas com grãos armazenados em diferentes embalagens, André et al. (2022) verificaram que os modelos RNAs, M5P e FA podem ser usados para prever a massa específica aparente, concordando com os resultados obtidos neste estudo.

Mesmo não apresentando diferença significativa entre si, pelo teste SK $p < 0,05$ (Figura 19C), os modelos RNAs, M5P e FA obtiveram os maiores valores de r (0,92, 0,91 e 0,94, respectivamente) para a variável CE. Esta alta correlação foi definida pelos seguintes valores de MAE (54,75, 57,33 e 46,41, respectivamente), enquanto que, o modelo de floresta aleatória (FA) obteve um maior R^2 (88,36%). No armazenamento dos grãos de milho, a temperatura, o tempo e os teores de água, influenciaram no aumento de condutividade elétrica. Esta variável é recorrente de danos causados pela respiração dos grãos (ALENCAR et al., 2009; CARVALHO et al., 2016; CORADI et al., 2020; ANDRÉ et al., 2022). A contribuição destes fatores favorece as reações adversas da massa de grãos, causando danos na membrana da parede celular (COIMBRA et al., 2009; CARVALHO et al., 2009), as quais foram melhor preditos pelos modelos de FA, RNAs e M5P.

Na variável germinação (GERM), os modelos RNAs e FA obtiveram as maiores correlações de r (0,94 e 0,95, respectivamente), não diferindo entre si pelo teste SK $p < 0,05$ (Figura 20A). Com valores de MAE (3,45 e 3,13, respectivamente) inferior aos demais modelos, verificou-se uma maior acurácia entre as variáveis monitoradas e preditas para o modelo de FA com R^2 (90,25%) (Tabela 7). As técnicas de RLM e M5P por apresentarem valores maiores de MAE (6,74 e 4,47, respectivamente) e correlação de r (0,75 e 0,89) tiveram um menor nível de predição da GERM. O tempo de armazenamento e condições de armazenamento aceleraram as reações bioquímicas nos grãos, degradando reservas proteicas, carboidratos e impactando negativamente na germinação (BELLALLOUI et al., 2017; HUSSAIN et al., 2019). Observou-se que os altos teores de água, umidade relativa,

temperatura e tempo de armazenamento aumentaram as oxidações e deteriorações no embrião, reduzindo a germinação (FOEL et al., 2003). Os modelos FA e RNAs conseguiram prever com mais assertividade os resultados de germinação, concordando com os resultados obtidos por Zeymer et al. (2021).

Figura 20 - 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 germinação-GERM (A.), gordura-GD (B.) e cinzas-CZ (C.) do coeficiente de correlação (r) e do erro absoluto médio (MAE) em grãos de milho armazenados



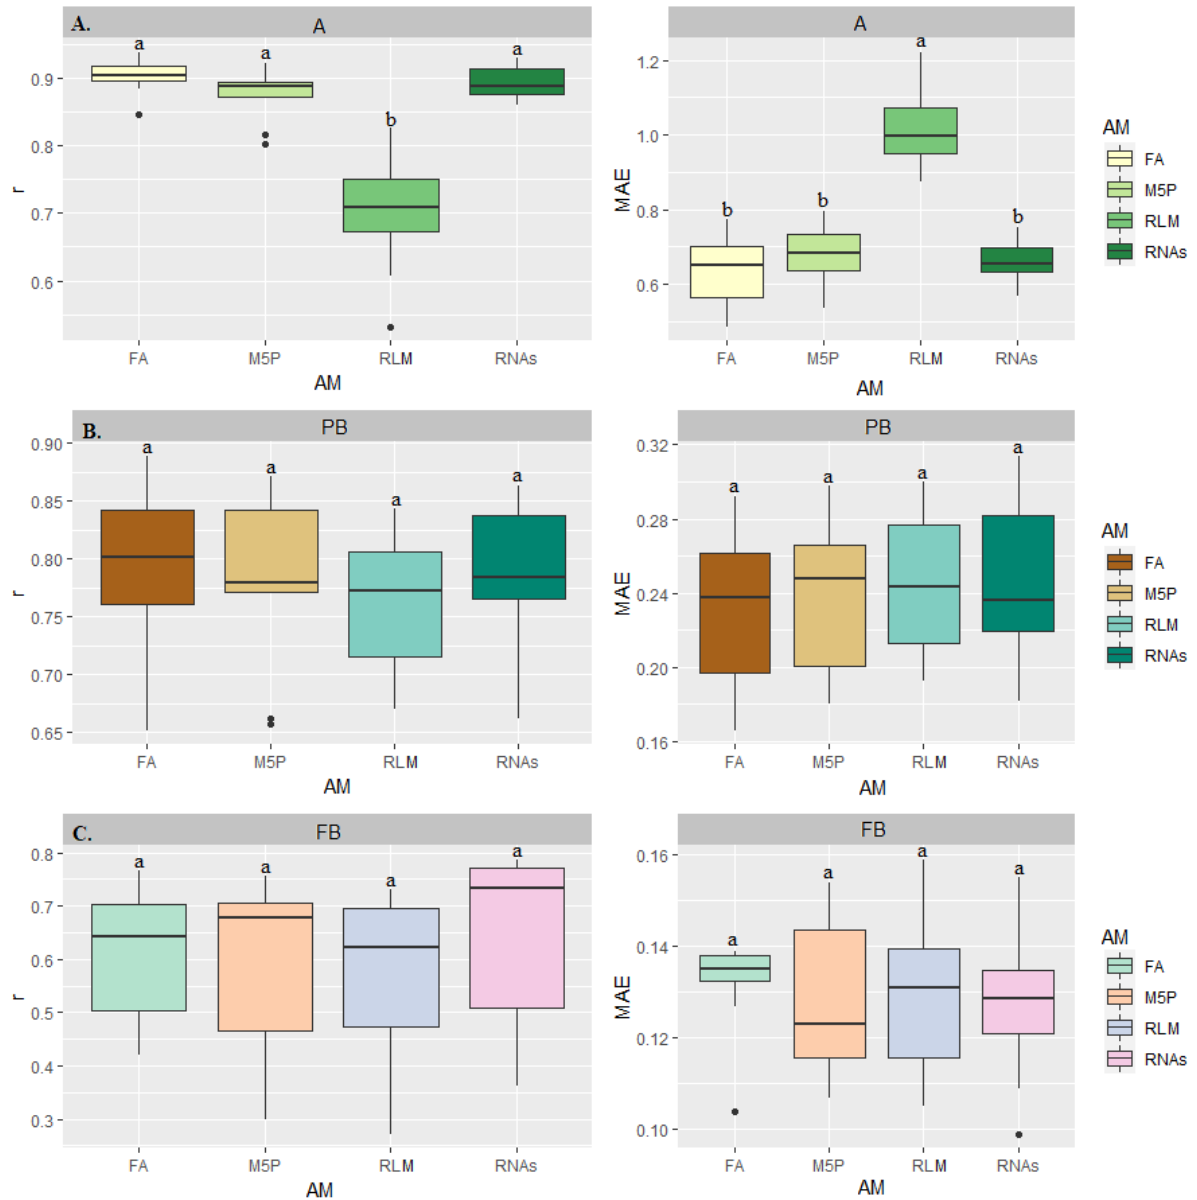
Fonte: Autora (2023).

Para a variável GD, quando submetidos ao teste SK $p < 0,05$, verificou-se que não houve diferença estatística entre os modelos avaliados. Porém, analisando cada modelo de AM de forma isolada observou-se que os modelos de RNAs e FA apresentaram as melhores correlações de r (0,73 e 0,73, respectivamente) e MAE (0,14) (Figura 20B). Da mesma forma a variável CZ, as quais também não houve diferença estatística pelo teste SK $p < 0,05$ entre os modelos de AM (Figura 20C). Porém, levando em consideração a maior correlação de r (0,91), o M5P obteve uma previsão mais acurada com R^2 (82,81%), em relação aos demais modelos (Tabela 7).

Na predição do amido (A), os modelos RNAs, M5P e FA foram os mais indicados mesmo não diferindo entre si pelo teste SK $p < 0,05$ (Figura 21A). Suas correlações de r (0,88, 0,87 e 0,89, respectivamente) e MAE (0,66, 0,67 e 0,63, respectivamente) (Tabela 7) dos modelos RNAs, M5P e FA mostraram-se relativamente menores, quando comparados ao modelo RLM. Ressalta-se ainda que o modelo com maior nível de acurácia foi FA, com R^2 (79,21%).

Por ser um carboidrato, o amido apresenta função sinalizadora, regulando processos metabólicos além e estabilizar o potencial osmótico celular (ZHAO et al., 2015; AGUIRRE et al., 2018; YANG et al., 2019;). O amido é uma propriedade bioquímica vulnerável aos efeitos das condições de armazenamento, principalmente da temperatura da massa de grãos (TIMM et al., 2022). Estudos observaram que o milho armazenado por três meses com temperatura abaixo de 20 °C mantiveram as propriedades do amido (CALVO-BRENES & O'HARE, 2020). Porém, quando verificados temperaturas elevadas, já em um tempo de 60 dias observou redução dos teores e degradação do amido do milho (FERNANDES et al., 2021). Além disso, a tecnologia de armazenagem do milho também pode contribuir para a redução do amido. Estudos mostram redução nos conteúdos de açúcares totais no grão de milho em função da redução dos teores de amido quando armazenados em embalagens de papel durante 90 dias (KUMAR et al., 2020). Para estimar as perdas de qualidade do amido e ajudar na tomada de decisão, verificou-se que os modelos de RNAs, M5P e FA obtiveram os resultados satisfatórios, principalmente o FA, devido sua acurácia (Tabela 7 e Figura 21A).

Figura 21 - 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 de amido-A (A.), proteína bruta-PB (B.) e fibra bruta-FB (C.) do coeficiente de correlação (r) e do erro absoluto médio (MAE) em grãos de milho armazenados



Fonte: Autora (2023).


Para a variável proteína bruta (PB), quando submetidos ao teste SK $p < 0,05$, não houve diferença estatística entre os modelos avaliados (Figura 21B). Porém o modelo floresta aleatória (FA) apresentou maior correção r (0,78), com erro aparente médio MAE (0,23), conferido uma acurácia de R^2 (60,84%) (Tabela 7). Não houve diferença estatística entre todos os modelos avaliados a $p < 0,05$ pelo teste SK, para variável fibra bruta (FB) (Figura 21C). Nesta variável não foi possível observar uma correlação satisfatória entre os dados

monitorados e preditos (Tabela 7). As variáveis PB, GD, FB e CZ tiveram um bom aprendizado da máquina em especial FA e M5P, RNAs, porém sem diferença estatística entre os modelos. Em estudos realizados por Alvarez et al. (2019) verificaram que as condições de armazenamento influenciaram sobre os teores de proteína bruta na massa dos grãos de milho, reduzindo para (10,6%) no período de (60 dias) de armazenamento em temperaturas de (16 °C).

A elevação dos teores de água da massa de grãos de milho afeta a qualidade dos grãos armazenados (CHOTIKASATIAN et al., 2017). Analisando algumas dessas propriedades bioquímicas em grãos de milho armazenados a 0 e 180 dias verificou-se que teores de cinzas e fibra bruta aumentaram de (1,27% para 1,45%) e reduziu de (11,1 a 9,5%), respectivamente, sem alterações nos lipídios (4,7%) (QUEIROZ et al., 2010).

Apesar de algumas variáveis de qualidade dos grãos de milho armazenados serem preditas pelos modelos de RNAs, tais como, TA, MEA, CE, GERM e A, foi exercida uma maior taxa de aprendizagem sobre estas variáveis. Esse fato tornou a obtenção dos dados mais complexos, como mostrados na arquitetura de cada rede entre os dados de entrada e de saída (Figura 22A, B, C, D e E). Por esse motivo, é importante que durante a escolha do melhor modelo de predição, dar-se ênfase a floresta aleatória (FA).

Figura 22 - Arquitetura do modelo de redes neurais artificiais (RNAs) na predição do teor de água-TA (A.), massa específica aparente-MEA (B.), condutividade elétrica-CE (C.), germinação-GERM (D.) e amido-A (E.), em grãos de milho armazenados



Fonte: Autora (2023).

4. CONCLUSÕES

- a) A qualidade dos grãos de milho nas diferentes etapas de pós-colheita foi predita pelos modelos de Aprendizado de Máquina.
- b) Na etapa de transporte de grãos, os modelos RNAs, M5P e FA obtiveram os melhores resultados de predição da perda de matéria seca, massa específica aparente, condutividade elétrica e germinação.
- c) Na secagem, o modelo de RNAs foi o mais indicado para prever a contração volumétrica, o amido e a condutividade elétrica.
- d) No armazenamento, os modelos de RNAs e FA foram os mais indicados para prever as variáveis teor de água, massa específica aparente, condutividade elétrica, germinação e amido. A qualidade química (proteína bruta, fibra bruta, gorduras e cinzas) independeu do tipo de modelo, pois todos alcançaram bons resultados.
- e) O modelo de Aprendizado de Máquina de floresta aleatória e de redes neurais artificiais são o mais indicado para prever a qualidade dos grãos de milho nas diferentes etapas de pós-colheita.

5. CONSIDERAÇÕES GERAIS

Esta pesquisa reforça que o uso da Inteligência Artificial (IA) através da aplicação dos algoritmos de Aprendizado de Máquina (AM), também é eficiente na automação de tarefas dentro das etapas da pós-colheita. Observou-se que existe um comportamento diversificado entre os modelos aplicados para cada variável de qualidade. Os modelos de floresta aleatória (FA) e de redes neurais artificiais (RNAs) exerceram leituras satisfatórias sobre os diferentes bancos de dados das três etapas analisadas.

Cada variável é influenciada pela taxa de aprendizagem do modelo dentro de cada banco de dados. Por exemplo, para as RNAs, os atributos aprendidos (lidos), distinguirão a sua arquitetura, como observado nas variáveis GERM e MEA para o transporte, nas variáveis CV, A e CE para a secagem, nas variáveis TA, MEA, CE, GERM e A no armazenamento. Ou seja, quanto menor for a taxa de aprendizado, menos complexa é a rede neural, indicando que a leitura do banco de dados, tendem a ser mais rápida. Por esse motivo, este estudo evidencia que as RNAs são as mais indicadas para prever as variáveis de qualidade nas etapas de transporte e de secagem.

Por outro lado, verificou-se que o banco de dados durante o armazenamento do milho, por ser mais complexo, o modelo de floresta aleatória, conseguiu eleger com maior rapidez,

do conjunto de dados, as variáveis. Sua eficiência deu-se através do esquema de votação da variável que mais interferem na qualidade da massa de grão de milho, independentemente do tempo de armazenamento. Neste caso, o modelo FA é, portanto, o mais indicado para fazer a predição no armazenamento.

REFERÊNCIAS BIBLIOGRÁFICAS

- AGUIRRE, M., KIEGLE, E., LEO, G., & EZQUER, I. Carbohydrate reserves and seed development: an overview. **Plant Reproduction**, v.31, n.3, p.263–290, 2018. <https://doi.org/10.1007/s00497-018-0336-3>
- ALENCAR, E. R., FARONI, L. R. D., LACERDA FILHO, A. F., PETERNELLI, L. A. & COSTA, A. R. Quality of soy bean grains stored under diferent conditions. **Rev. Bras. Eng. Agric. Ambient.** v.13, n.5, p.606–613, 2009. <https://doi.org/10.1590/S1415-43662009000500014>
- 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. <https://doi.org/10.1016/j.scienta.2020.109326>
- ALVAREZ, E., CARDOSO, M., DEPETRIS, G., CASTELLARI, C., CRISTOS, D., MONTIEL, M. D., & BARTOSIK, R. Storage of WDGS under hermetic and non-hermetic conditions: Effect on sensory properties, microorganisms, mycotoxins and nutritional value. **Journal of Stored Products Research**, v.80, p.65–70, 2019. <https://doi.org/10.1016/j.jspr.2018.11.011>
- ANDRÉ, G., CORADI, P. C., TEODORO, L. P. R., & TEODORO, P. E. Predicting the quality of soybean seeds stored in diferent environments and packaging using machine learning. **Scientific Reports**, v.12, n.8793, 2022. <https://doi.org/10.1038/s41598-022-12863-5>
- ATUNGULU, G. G., & OLATUNDE, G. A. Assessment of new in-bin drying and storage technology for soybean seed. **Drying Technology**, v.36, n.4, p.383–399, 2018. <https://doi.org/10.1080/07373937.2017.1335751>
- BELGIU, M., & DRAGU T. L. Random forest in remote sensing: A review of applications and future directions. **ISPRS J. Photogramm. Remote Sens.** v.114, p.24–31, 2016. <https://doi.org/10.1016/j.isprsjprs.2016.01.011>.
- BELLALOU, N., SMITH, J. R., & MENGISTU, A. Seed Nutrition and Quality, Seed Coat Boron and Lignin Are Influenced by Delayed Harvest in Exotically-Derived Soybean Breeding Lines under High Heat. **Frontiers in Plant Science**, v.8, n.1563, 2017. <https://doi.org/10.3389/fpls.2017.01563>
- BERLANGA-REYES, C., GUERRERO-ELIAS, H. Y., IGNACIO-PACHECO, M., CONTRERAS-JÁCQUEZ, V., CAMACHO-RUIZ, R., MATEOS-DÍAZ, J. C., NEVÁREZ-MOORILLÓN, V., & ASAFF-TORRES, A. Effect of drying method and process conditions on physicochemical and rheological properties of arabinoxylans extracted from corn-lime-

cooking-liquor on a pilot plant scale. **Food Hydrocolloids**, v.119, n.106819, 2021.
<https://doi.org/10.1016/j.foodhyd.2021.106819>

BHERING, L.L. Rbio: A tool for biometric and statistical analysis using the R platform (2017). **Crop Breed. Appl. Biotechnol**, v.17, n.2, 2017. <https://doi.org/10.1590/1984-70332017v17n2s29>

BLAIFI, S. A., MOULAHOU, S., BENKERCHA, R., TAGHEZOUIT, B., & SAIM, A. M5P model tree based fast fuzzy maximum power point tracker. **Sol. Energy**, v.163, p.405-424, 2018. <https://doi.org/10.1016/j.solener.2018.01.071>

BOTELHO, F. M., FARIA, B. M. E. M., BOTELHO, S. C. C., RUFFATO, S., MARTINS, R. N. Methods for grains density determination. **Revista Agrarian**, v.41, p.251-259, 2018.
<http://ojs.ufgd.edu.br/.../4687>

BOUCKAERT, R., FRANK, E., HALL, M., KIRKBY, R., REUTEMRNA, P., & SEEWALD A. **WEKA manual for version**, v.3, p.7-1, 2010
https://statweb.stanford.edu/~lpekelis/13_datafest_cart/WekaManual-3-7-8.pdf

BRASIL. Ministério da Agricultura, Pecuária e Abastecimento. Secretaria de Defesa Agropecuária. **Regras para análise de sementes**. Brasília, DF: Mapa/ACS, p.395, 2009.

LORINI, I., MIIKE, L. H., SCUSSEL, V. M., FARONI, L. R. D. **Armazenagem de grãos**. Jundiaí, SP, v.1, cap.3, p.150-164, 2018.

CAFIERO, C., VIVIANI, S., & NORD, M. Food security measurement in a global context: The food insecurity experience scale. **Measurement**, v.116, p.146–152, 2018.
<https://doi:10.1016/j.measurement.2017.10.065>

CALVO-BRENES, P., & O'HARE, T. Effect of freezing and cool storage on carotenoid content and quality of zeaxanthin-biofortified and standard yellow sweet-corn (*Zea mays* L.). **Journal of Food Composition and Analysis**, v.86, n.103353, 2020.
<https://doi.org/10.1016/j.jfca.2019.103353>

CARVALHO, E. R.; OLIVEIRA, J. A.; MAVAIEIE, D. P. R.; SILVA, H. W.; LOPES, C. G. M. Pre-packing cooling and types of packages in maintaining physiological quality of soybean seeds during storage. **Journal of Seed Science**, Londrina, v.38, n.2, p.129-139, 2016
<https://doi.org/10.1590/2317-1545v38n2158956>

CARVALHO, L. F., SEGUEYUKI, C. S., REIS, M. R., DIAS, D. C. F. S. MOREIRA, M. A. Influence of soaking temperature of soybean seeds in the electric conductivity test to evaluate physiological quality. **Revista Brasileira de Sementes**, v.31, n.1, p.9-17, 2009.
<https://doi.org/10.1590/S0101-31222009000100001>

CHOTIKASATIAN, C., CHAYAPRASERT, W., & PATHAVEERAT, S. A study on the feasibility of quantifying the population density of stored product insects in air-tight grain storage using CO2 concentration measurements. **Journal of Stored Products Research**, v.73, p.21–29, 2017. <https://doi.org/10.1016/j.jspr.2017.05.005>

COIMBRA, R. A., MARTINS, C. C., TOMAZ, J. N., NAKAGAWA, J. Vigor tests for

selection of sweet corn (sh2) seeds lot. **Ciência Rural**, v.39, n.9, p.2402-2408, 2009.
<https://doi.org/10.1590/S0103-84782009000900004>

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.
<https://doi.org/10.15361/1984-5529.2014v42n2p118-133>

CORADI, P. C., DE OLIVEIRA, M. B., DE OLIVEIRA CARNEIRO, L., COELHO DE SOUZA, G. A., ELIAS, M. C., BRACKMANN, A., & TEODORO, P. E. Technological and sustainable strategies for reducing losses and maintaining the quality of soybean grains in real production scale storage units. **Journal of Stored Products Research**, v.87, n.101624, 2020.
<https://doi:10.1016/j.jspr.2020.101624>

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**, v.20, n.4, p.385–392, 2016.
<https://doi.org/10.1590/1807-1929/agriambi.v20n4p385-392>

CORADI, P. C., LIMA, R. E., PADIA, C. L., ALVES, C. Z., TEODORO, P. E., & CARINA DA SILVA CÂNDIDO, A. Soybean seed storage: Packaging technologies and conditions of storage environments. **Journal of Stored Products Research**, v.89, n.101709, 2020.
<https://doi.org/10.1016/j.jspr.2020.101709>

CORADI, P. C., LIMA, R.E., ALVES, C.Z., TEODORO, P.E & CÂNDIDO, A.C.D.S. Evaluation of coatings for application in raffia big bags in conditioned storage of soybean cultivars in seed processing units. **PLoS ONE**, v.15, n.0242522, 2020.
<https://doi.org/10.1371/journal.pone.0242522>

CORADI, P. C., MAIER, D. E., CHANNAIAH, L. H., & CAMPABADAL, C. (2016). Effects of the processing on the distribution of aflatoxin and fumonisin levels in corn fractions and feeds. **Journal of Food Process Engineering**, v.39, n.3, p.215– 225, 2016.
<https://doi.org/10.1111/jfpe.12212>

CORADI, P. C., MALDANER, V., LUTZ, É., DA SILVA DAÍ, P. V., & TEODORO, P. E. Influences of drying temperature and storage conditions for preserving the quality of maize postharvest on laboratory and field scales. **Scientific Reports**, v.10, n.1, p.1–15, 2020.
<https://doi.org/10.1038/s41598-020-78914-x>

CORADI, P. C., MÜLLER, A., SOUZA, G. A. C., STEINHAUS, J. I., & WAGNER, R. Quality of soybean cultivars in the drying and storage processes in real scale and experimental. **Journal of Food Process Engineering**, v.43, n.13418, 2020.
<https://doi.org/10.1111/jfpe.13418>

CORADI, P. C., SOUZA, A. E. M., & BORGES, M. C. R. Z. Yield and acidity indices of sunflower and soybean oils in function of grain drying and storage. **Acta Scientiarum Agronomy**, v.39, n.2, p.255, 2017. <https://doi.org/10.4025/actasciagron.v39i2.31121>

CORADI, P. C., MALDANER, V., LUTZ, É., DA SILVA DAÍ, P.V., TEODORO, P.E. Influences of drying temperature and storage conditions for preserving the quality of maize postharvest on laboratory and field scales, **Scientific Reports**, v.10, p.1-15, 2020.

<https://doi.org/10.1038/s41598-020-78914-x>

CÓRDOVA-NOBOA, H. A., OVIEDO-RONDÓN, E. O., ORTIZ, A., MATTA, Y., HOYOS, S., BUITRAGO, G. D., MARTINEZ, J. D., YANQUEN, J., PEÑUELA, L., SORBARA, J. O. B., & COWIESON, A. J. Corn drying temperature, particle size, and amylase supplementation influence growth performance, digestive tract development, and nutrient utilization of broilers. **Poultry Science**, v.99, n.11, p.5681–5696, 2020.

<https://doi.org/10.1016/j.psj.2020.07.010>

CÓRDOVA-NOBOA, H.A., OVIEDO-RONDÓN, E.O., ORTIZ, A., MATTA, Y., HOYOS, J.S., BUITRAGO, G. D., MARTINEZ, J.D., YANQUEN, J.J., CHICO, M., MARTIN, V.E.S., FAHRENHOLZ, A., OSPINA-ROJAS, I.C., & PEÑUELA, L. Effects of corn kernel hardness and grain drying temperature on particle size and pellet durability when grinding using a roller mill or hammermill. **Animal Feed Science and Technology**, v.271, n.114715, 2021. <https://doi.org/10.1016/j.anifeedsci.2020.114715>

CORRÊA, P. C., GONELI, A. L. D., JÚNIOR, P. C. A., DE OLIVEIRA, G. H. H., & VALENTE, D. S. M. Moisture sorption isotherms and isosteric heat of sorption of coffee in different processing levels. **International Journal of Food Science and Technology**, v.45, n.10, p. 2016–2022, 2010. <https://doi:10.1111/j.1365-2621.2010.02373.x>

EGMONT-PETERSEN, M., RIDDER, D., & HANDELS, H. Image processing with neural networks a review. **Pattern Recognit**, v.35, p.2279–2301, 2002.

[https://doi.org/10.1016/S0031-3203\(01\)00178-9](https://doi.org/10.1016/S0031-3203(01)00178-9)

FERNANDES, J., DA SILVA, É. B., CARVALHO-ESTRADA, P. DE A., DANIEL, J. L. P., & NUSSIO, L. G. Influence of hybrid, moisture, and length of storage on the fermentation profile and starch digestibility of corn grain silages. **Animal Feed Science and Technology**, v.271, n.114707, 2021. <https://doi.org/10.1016/j.anifeedsci.2020.114707>

FLEURAT-LESSARD, F. Integrated management of the risks of stored grain spoilage by seedborne fungi and contamination by storage mould mycotoxins – An update. **Journal of Stored Products Research**, v.71, p.22–40, 2017. <https://doi.org/10.1016/j.jspr.2016.10.002>

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.

<https://doi.org/10.3390/microorganisms8010141>

GOEL, A., GOEL, A. K., & SHEORAN, I. S. Changes in oxidative stress enzymes during artificial ageing in cotton (*Gossypium hirsutum* L.) seeds. **Journal of Plant Physiology**, v.160, n.9, p.1093–1100, 2003. <https://doi:10.1078/0176-1617-00881>

GOLDSMITH, P. D., MARTINS, A. G., & DE MOURA, A. D. The economics of post-harvest loss: a case study of the new large soybean - maize producers in tropical Brazil. **Food Security**, v.7, n.4, p.875–888, 2015. <https://doi.org/10.1007/s12571-015-0483-4>

BERNARDI, A., LIMA, J.D., OLIVEIRA, G. A., TRENTIN, M. G. Análise de investimento em segregação de milho: estudo de caso em agroindústria produtora de rações para frangos de corte. **Custos e @gronegocio**, v.13, n.4, 2017. ISSN 1808-2882

www.custoseagronegocioonline.com.br.

HASSAN, A. B., PAWELZIK, E., & VON HOERSTEN, D. Effect of microwave heating on the physiochemical characteristics, colour and pasting properties of corn (*Zea mays* L.) grain. **LWT- Food Science and Technology**, v.138, n.110703, 2021.

<https://doi.org/10.1016/j.lwt.2020.110703>

HIRANO, M., & KOBAYASHI, R. Machine Learning Based Ransomware Detection Using Storage Access Patterns Obtained From Live-forensic Hypervisor. Sixth International Conference on Internet of Things: Systems, Management and Security (IOTSMS). **Institute of Electrical and Electronics Engineers**, 2019.

<https://doi:10.1109/IOTSMS48152.2019.8939214>

HIRANO, M., HODOTA, R., KOBAYASHI, R. RanSAP: An open dataset of ransomware storage access patterns for training machine learning models. **Forensic Science International: Digital Investigation**, v.40, n.30131, 2022. <https://doi>

[10.30612/agrarian.v11i41.7922](https://doi.org/10.30612/agrarian.v11i41.7922)

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

<https://doi.org/10.1080/00071668.2018.1477253>

HUSSAIN, S., N. IQBAL, AND T. RAHMAN. Shade effect on carbohydrates dynamics and stem strength of soybean genotypes. **Environmental and Experimental Botany**, v.162, p.374–382, 2019. ISSN 0103-8478

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**, v.23, n.3, p.3028-3040, 2022a. <https://doi: 10.1109/JSEN.2022.3226168>

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**, v.71, n.2517412, p.1-12, 2022b. <https://doi: 10.1109/TIM.2022.3204078>.

KATTA, Y, M.; KAMARA, M, M.; ATY, M, S.; ELGAMAL, W, H.; SOLEIMAN, R, M.; MOUSA, K, M.; UENO, T. Effect of Storage Temperature on Storage Efficacy, Germination and Physical Characters of Some Paddy Rice Cultivars during Different Storage Periods. **Journal Faculty of Agriculture**, v.64, n.10, p.61-69, 2019. <https://doi.org/10.5109/2232279>

KHANAL, S., FULTON, J., & SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture. **Computers and Electronics in Agriculture**, v.139, p.22-32, 2017. <https://doi.org/10.1016/j.compag.2017.05.001>

KRZYŻANOWSKI, F. C. et al. **Vigor de sementes: conceitos e testes**. Londrina: ABRATES, cap.2, p.2-24, 1999.

KUMAR, D., & KALITA, P. Reducing postharvest losses during storage of grain crops to strengthen food security in developing countries. **Foods**, v.6, n.1, 2017. <https://doi.org/10.3390/foods6010008>

KUMAR, N., KACHHADIYA, S., & NAYI, P. Storage stability and characterization of biochemical, rehydration and colour characteristics of dehydrated sweet corn kernels. **Journal of Stored Products Research**, v.87, n.101619, 2020. <https://doi.org/10.1016/j.jspr.2020.101619>

LIMA, F. G., KIMURA, H., NETO, A. A., PERERA, L. C. J. Previsão de preços de commodities com modelos ARIMA-GARCH e redes neurais com ondaletas: velhas tecnologias-novos resultados. *Revista Administração*, v.45, n.2, p.188-202, 2010. <https://doi.org/10.1590/S0080-21072010000200008>

LIMA, R. E., CORADI, P. C., NUNES, M. T., BELLOCHIO, S. D. C., TIMM, N. S., NUNES, C. F., CARNEIRO, L. O., TEODORO, P. E., & CAMPABADAL. Mathematical modeling and multivariate analysis applied earliest soybean harvest associated drying and storage conditions and influences on physicochemical grain quality. **Scientific Reports**, v.11, p.1–20, 2021. <https://doi.org/10.1038/s41598-021-02724-y>

LIN, P., XIAOLI, L., LI, D., JIANG, S., ZOU, Z., LU, Q., & CHEN, Y. Rapidly and exactly determining postharvest dry soybean seed quality based on machine vision technology. **Scientific Reports**, v.9, n.1, p.1–11, 2019. <https://doi.org/10.1038/s41598-019-53796-w>

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. <https://doi.org/10.1016/j.measurement.2021.110609>

MAIER, D. E., CHANNAIAH, L. H., MARTINEZ-KAWAS, A., LAWRENCE, J. S., CHAVES, E. V., CORADI, P. C.; FROMME, G. Monitoring carbon dioxide concentration for early detection of spoilage in stored grain. **Proceedings of the 6th International Working Conference on Stored-Product Protection**, p.505-509, 2010. <https://doi:10.5073/jka.2010.425.332>

MAINA, A. W., WAGACHA, J. M., MWAURA, F. B., MUTHOMI, J. W., & WOLOSHUK, C. P. Postharvest Practices of Maize Farmers in Kaiti District, Kenya and the Impact of Hermetic Storage on Populations of *Aspergillus* Spp. and Aflatoxin Contamination. **Journal of Food Research**, v.5, n.6, p.53, 2016. <https://doi:10.5539/jfr.v5n6p53>

MALUMBA, P.; ODJO, S.; BOUDRY, C.; DANTHINE, S.; BINDELLE, J.; BECKERS, Y.; BÉRA, F. Physicochemical characterization and in vitro assessment of the nutritive value of starch yield from corn dried at different temperatures. **Starch-Stärke**, v.66, p.738-748, 2014. <https://doi.org/10.1002/star.201400012>

MARTINEZ-FERIA, RAFAEL A., LICHT, MARK A., ORDÓÑEZ, RAZIEL A., HATFIELD, JERRY L., COULTER, JEFFREY A., ARCHONTOULIS, SOTIRIOS V. Evaluating maize and soybean grain dry-down in the field with predictive algorithms and genotype-by-environment analysis. **Scientific Reports**, v.9, p.1-13, 2019. <https://doi:10.1038/s41598-019-43653-1>

MÜLLER, A., NUNES, M. T., MALDANER, V., CORADI, P. C., MORAES, R. S., MARTENS, S., LEAL, A. F., PEREIRA, V. F., & MARIN, C. K. Rice drying, storage and processing: effects of post-harvest operations on grain quality. **Rice Science**, v.29, n.1, p.16–30, 2022. <https://doi.org/10.1016/j.rsci.2021.12.002>

MYLONA, K. & MAGAN, N. Fusarium langsethiae: Storage environment influences dry matter losses and T2 and HT-2 toxin contamination of oats. **Journal of Stored Products Research**, v.47, p.321–327, 2011. <https://doi.org/10.1016/j.jspr.2011.05.002>

NEETHIRAJAN, S., FREUND, M.S., JATAS, D.S., SHAFAI, C., THOMSON, D.J., & WHITE, N.D.G. Development of carbon dioxide (CO₂) sensor for grain quality monitoring. **Biosystems Engineering**, v.106, p.395-404, 2010. <https://doi.org/10.1016/j.biosystemseng.2010.05.002>

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. <https://doi.org/10.1016/j.jspr.2020.101592>

OLIVEIRA, D. J., & SÁ, A. A. R. Redes Neurais Aplicadas à Classificação de Tráfego de Redes de Computadores Utilizando os Protocolos TCP e UDP. **Revista de Sistemas e Computação**, v.8, n.1, p.135-152, 2018. ISSN 2237-2903. Disponível em: jan./jun. <https://core.ac.uk/download/pdf/234559717.pdf>.

POMMERENIG, B., LUDEWIG, F., CVETKOVIC, J., TRENTMANN, O., KLEMENS, P. A. W., & NEUHAUS, H. E. In Concert: Orchestrated Changes in Carbohydrate Homeostasis Are Critical for Plant Abiotic Stress Tolerance. **Plant and Cell Physiology**, v.59, p.1290-1299, 2018. <https://doi.org/10.1093/pcp/pcy037>.

QUEIROZ, V. A. V., PEREIRA, F. M., CARVALHO, A. C. R., ALVES, G. O., MENDES, S. M & SIMEONI, M. L. F. Alterações na Composição Nutricional de Milho Durante o Armazenamento em Paióis. **XXVIII Congresso Nacional de Milho e Sorgo**, 2010, Goiânia: Associação Brasileira de Milho e Sorgo. Disponível em: <https://www.alice.cnptia.embrapa.br/bitstream/doc/865334/1/0025.pdf>.

RAMOS, A. P., PRADO OSCO, L., ELIS GARCIA FURUYA, D., NUNES GONÇALVES, W., CORDEIRO SANTANA, D., PEREIRA RIBEIRO TEODORO, L., PISTORI, H. A random forest ranking approach to predict yield in maize with uav-based vegetation spectral indices. **Computers and Electronics in Agriculture**, v.178, n.105791, 2020. <https://doi.org/10.1016/j.compag.2020.105791>

RANI, P. R.; CHELLADURAI, V.; JAYAS, D. S.; WHITE, N. D. G.; ABIRAMI, C. V. K. Storage studies on pinto beans under different moisture contents and temperature regimes. **Journal of Stored Products Research**, v.52, p.78-85, 2013. <https://doi.org/10.1016/j.jspr.2012.11.003>

SHIEL, P., WEST, R. Effects of building energy optimisation on the predictive accuracy of external temperature in forecasting models. **Journal of Building Engineering**, v.7, p.281–291, 2016. <https://doi.org/10.1016/j.jobbe.2016.07.001>

SNOUSY, M. B. A., EL-DEEB, H. M., BADRAN, K., & KHLIL, I. A. A. Suite of decision tree-based classification algorithms on cancer gene expression data. **Egyptian Informatics Journal**, v.12, p.73–82, 2011. <https://doi.org/10.1016/j.eij.2011.04.003>

TEODORO, P. E.; TEODORO, L.P. R; BAIIO, F. H. R; SILVA JUNIOR, C. A; SANTOS, R. S; RAMOS, A. P. M. S; PINHEIRO, M. F; OSCO, L. P; GONÇALVES, W. N; CARNEIRO, A. M; MARCATO JUNIOR; PISTORI, H. Predicting Days to Maturity, Plant Height, and Grain Yield in Soybean: A Machine and Deep Learning Approach Using Multispectral. **Remote Sensing**, v.13, n.4632, 2021. <https://doi.org/10.3390/rs13224632>

TIMM, N. DA S., RAMOS, A. H., FERREIRA, C. D., BIDUSKI, B., EICHOLZ, E. D., & OLIVEIRA, M. DE. Effects of drying temperature and genotype on morphology and technological, thermal, and pasting properties of corn starch. **International Journal of Biological Macromolecules**, v.165, p.354–364, 2020. <https://doi.org/10.1016/j.ijbiomac.2020.09.197>

TIMM, N. S, CORADI, P.C., DOS SANTOS BILHALVA, N. NUNES, C. F., CANIZARES, L. C. Efeitos das condições de secagem e armazenamento de milho na produção de farinha, amido, ração e etanol: uma revisão. **J Food Sci Technol**, 2022. <https://doi.org/10.1007/s13197-022-05549-3>

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. <https://doi.org/10.1016/j.buildenv.2021.108656>

VALLE, F. J., CASTELLARI, C., YOMMI, A., PEREYRA, M. A., & BARTOSIK, R. Evolution of grain microbiota during hermetic storage of corn (*Zea mays* L.). **Journal of Stored Products Research**, v.92, n.101788, 2021. <https://doi.org/10.1016/j.jspr.2021.101788>

WANG, X., MIAO, Y., DONG, R., ZHA, H., XIA, T., CHEN, Z., LI, M. Machine learning-based in-season nitrogen status diagnosis and side-dress nitrogen recommendation for corn. **European Journal of Agronomy**, v.123, n.126193, 2021. <https://doi.org/10.1016/j.eja.2020.126193>

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. <https://doi.org/10.1016/j.compag.2020.105335>

YANG, J., C. ZHANG, Z. WANG, S. SUN, R. ZHAN, Y. ZHAO, B. MA, F. MA, AND M. LI. Melatonin-mediated sugar accumulation and growth inhibition in apple plants involves down-regulation of fructokinase 2 expression and activity. **Frontiers Plant Science**, v.10, 2019. <https://doi.org/10.3389/fpls.2019.00150>

YILDIRIM, S., RÖCKER, B., PETTERSEN, M. K., NILSEN-NYGAARD, J., AYHAN, Z., RUTKAITE, R., COMA, V. Active Packaging Applications for Food. **Comprehensive Reviews in Food Science and Food Safety**, v.17, n.1, p.165–199, 2018. <https://doi.org/10.1111/1541-4337.12322>

ZEYMER, J. S., GUZZO, F., ARAUJO, M. E. V., GATES, R. S., CORRÊA, P. C., VIDIGAL, M. C. T. R., & NEISSE, A. C. Machine learning algorithms to predict the dry matter loss of stored soybean grains (*Glycine max* L.). **Journal of Food Process Engineering**, v.44, n.10, 2021. <http://doi:10.1111/jfpe.13820>

ZHAO, H., T. SU, L. HUO, H. WEI, Y. JIANG, L. XU, FENGWANG, M. Unveiling the mechanism of melatonin impacts on maize seedling growth: sugar metabolism as a case. **Journal Pineal Research**, v.59, p.255–266, 2015. <http://doi:10.1111/jpi.12258>

ZIEGLER, V., PARAGINSKI, R.T., FERREIRA, C. D. Sistemas de armazenamento de grãos e efeitos da umidade, temperatura e tempo na qualidade dos grãos - uma revisão. **Journal of Stored Products Research**, v.91, n.101770, 2021. <https://doi:10.1016/j.j.jspr.2021.10177>