

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CAMPUS CACHOEIRA DO SUL
COORDENADORIA ACADÊMICA
CURSO DE ENGENHARIA AGRÍCOLA**

Marisa Menezes Leal

**MONITORAMENTO AMOSTRAL DA TEMPERATURA, UMIDADE
RELATIVA E DIÓXIDO DE CARBONO INTERGRANULAR PARA
ESTIMATIVA E PREDIÇÃO DA PERDA DE MATÉRIA SECA EM
GRÃOS DE TRIGO ARMAZENADOS EM SILOS VERTICAIS**

Cachoeira do Sul, RS
2022

Marisa Menezes Leal

**MONITORAMENTO AMOSTRAL DA TEMPERATURA, UMIDADE RELATIVA E
DIÓXIDO DE CARBONO INTERGRANULAR PARA ESTIMATIVA E PREDIÇÃO
DA PERDA DE MATÉRIA SECA EM GRÃOS DE TRIGO ARMAZENADOS EM
SILOS VERTICAIS**

Trabalho de Conclusão de Curso apresentado ao Curso de Graduação em Engenharia Agrícola da Universidade Federal de Santa Maria Campus Cachoeira do Sul (UFSM-CS, RS), como requisito parcial para obtenção do grau de Bacharel em **Engenharia Agrícola**

Orientadora: Prof. Dr. Paulo Carteri Coradi

Cachoeira do Sul, RS
2022

Marisa Menezes Leal

**MONITORAMENTO AMOSTRAL DA TEMPERATURA, UMIDADE
RELATIVA E DIÓXIDO DE CARBONO INTERGRANULAR PARA
ESTIMATIVA E PREDIÇÃO DA PERDA DE MATÉRIA SECA EM GRÃOS DE
TRIGO ARMAZENADOS EM SILOS VERTICAIS**

Trabalho de Conclusão de Curso
apresentado ao Curso de Graduação em
Engenharia Agrícola da Universidade
Federal de Santa Maria, Campus
Cachoeira do Sul (UFSM-CS), como
requisito parcial para obtenção do grau
de Bacharel em Engenharia Agrícola.



Prof. Dr. Paulo Carteri Coradi
UFSM-Campus Cachoeira do Sul

Prof. Paulo Carteri Coradi, Dr. (UFSM-Campus Cachoeira do Sul)
(Presidente/Orientado)



Lanes Beatriz Acosta Jaques

**Lanes Beatriz Acosta Jaques, Dra. (Profa. Substituta UNIPAMPA-Campus
Alegrete)**
(Membro Externo)



Newton da Silva Timm

**Newton da Silva Timm, Dr. (Eng. Agr. PROCER Agroateligência em Pós-
Colheita)**
(Membro Externo)

Cachoeira do Sul, RS
2022

EPÍGRAFE

Eu tentei 99 vezes e falhei, mas na centésima tentativa eu consegui, nunca desista de seus objetivos mesmo que esses pareçam impossíveis, a próxima tentativa pode ser a vitoriosa.

Albert Einstein

AGRADECIMENTOS

Primeiramente a Deus pela vida, por me guiar, abençoar e me fortalecer todas as vezes que fraquejava.

Agradeço aos meus pais adotivos Araci Conceição Menezes (*in memorian*) e João Nei Felizardo Menezes, pela família na qual eu sou muito grata, pelos ensinamentos e pelo amor recebido.

Agradeço em especial a meu esposo José Gladimir da Silva Felizardo, que esteve sempre ao meu lado durante essa jornada, dando apoio emocional, incentivando em todos os momentos desta caminhada e sendo esse marido compreensivo, amigo, carinhoso que esteve sempre disposto a me ajudar no que fosse necessário.

Ao meu filho Gabriel Leal Felizardo que é razão do meu viver, que esteve sempre junto comigo, sendo esse filho carinhoso, amado, inteligente, educado e responsável.

Aos meus Padrinhos Lúcia Isabel Menezes e Vilmar de Loreto Ferreira, que participaram ativamente durante esta jornada, que me incentivaram e torceram para que eu alcançasse os meus objetivos.

Aos meus irmãos, a minha mãe biológica Alcídia e a minha Avó Odete, por sempre estarem prontos para me ajudar no que estivesse ao seu alcance.

Aos meus amigos Engenheiros Rosana Moraes, Amanda Azevedo, Crístielle Köing, Bianca Dolianitis, Jonatas Steinhaus e Dágila Mello, amigos que sempre estiveram dispostos a me ajudar, ouvir e que sempre colaboraram com o meu desenvolvimento pessoal e profissional.

Ao meu orientador Dr. Paulo Carteri Coradi, por todo apoio prestado ao longo desses anos, pela oportunidade concedida e pelas orientações, para que eu pudesse concluir essa etapa da minha formação.

A professora Viviane Dal-Souto Frescura, pela amizade construída ao longo desta caminhada, pelas oportunidades concedidas, pelos ensinamentos que foram essenciais para atingir meus objetivos.

A Universidade Federal de Santa Maria, Campus Cachoeira do Sul, a qual sinto imenso orgulho em fazer parte do curso de Engenharia Agrícola.

Ao CNPq e FAPERGS pelas bolsas concedidas.

Ao Laboratório de pós-colheita (LAPOS) e aos meus colegas de pesquisa.

Aos professores, colegas e amigos, que de alguma forma contribuíram para que fosse possível a conclusão desta etapa importante da minha vida.

Muito obrigado!

RESUMO

MONITORAMENTO AMOSTRAL DA TEMPERATURA, UMIDADE RELATIVA E DIÓXIDO DE CARBONO INTERGRANULAR PARA ESTIMATIVA E PREDIÇÃO DA PERDA DE MATÉRIA SECA EM GRÃOS DE TRIGO ARMazenADOS EM SILOS VERTICAIS

AUTORA: Marisa Menezes Leal

ORIENTADOR: Prof. Dr. Paulo Carteri Coradi

O armazenamento constitui um ecossistema, os quais podem influenciar na atividade metabólica e na qualidade dos grãos de trigo. Entre as principais variáveis que interferem na respiração da massa de grãos estão a temperatura e umidade relativa intergranular. O aumento da temperatura e da umidade relativa intergranular podem alterar a umidade de equilíbrio higroscópico e conseqüentemente os teores de água dos grãos, provocando perdas. Assim, o presente estudo objetivou avaliar o monitoramento temporal/amostal da temperatura, umidade relativa e dióxido de carbono intergranular para estimativa e predição da perda de matéria seca em grãos de trigo armazenados em silos verticais, utilizando um modelo matemático e algoritmos de aprendizado de máquina. Entre os resultados obtidos, a temperatura do ar intergranular manteve-se próxima da temperatura média ambiente (26,5 a 26,7 °C), porém quando se aproximou das vinte horas de monitoramento teve uma redução para 26,4 °C. Enquanto que, a umidade relativa permaneceu entre 61,3 a 62,5% ao longo do tempo de monitoramento. Nessas condições, os grãos de trigos armazenados permaneceram com uma umidade de equilíbrio higroscópico entre 11,65 à 11,82%. A concentração de dióxido de carbono ao longo do tempo de armazenamento variou de 300 a 550 ppm na massa de grãos. Nessas condições, os grãos de trigo tiveram um leve aumento na atividade metabólica, fazendo com que houvesse uma perda de matéria seca de 0,035 a 0,041%. Os resultados de temperatura, umidade relativa e dióxido de carbono intergranulares foram similares às medições na superfície da massa de grãos. Concluiu-se que o monitoramento da temperatura, umidade relativa e da concentração de dióxido de carbono do ar intergranular determinaram de forma indireta e precocemente as alterações de qualidade dos grãos de trigo durante o armazenamento. Embora, a atividade metabólica dos grãos de trigo tenham sido baixas, em função dos lotes terem permanecido em equilíbrio higroscópico com teores de água próximos a 12% (b.u.), a detecção temporal caracterizou as perdas de matéria seca e a redução do peso dos grãos armazenados. Por fim, o modelo de Redes Neurais Artificiais e Regressão Linear Múltipla previu satisfatoriamente a perda de matéria seca da massa de grãos de trigo armazenados.

Palavras-chave: Conservação de grãos. Dióxido de carbono. Perdas de matéria seca. Temperatura do ar intergranular. Trigo (*Triticum*). Umidade relativa intergranular.

ABSTRACT

MONITORING OF INTERGRANULAR VARIABLES FOR INDIRECT ESTIMATION OF TECHNICAL BREAKDOWN OF WHEAT GRAINS STORED IN VERTICAL SILOS

AUTHOR: Marisa Menezes Leal
ADVISOR: Prof. Dr. Paulo Carteri Coradi

Storage constitutes an ecosystem, which can influence the metabolic activity and quality of wheat grains. Among the main variables that interfere in the respiration of the grain mass are the temperature and intergranular relative humidity. The increase in temperature and intergranular relative humidity can alter the hygroscopic equilibrium humidity and consequently the water content of the grains, causing losses. Thus, the present study aimed to evaluate the temporal/sample monitoring of temperature, relative humidity and intergranular carbon dioxide for estimation and prediction of dry matter loss in wheat grains stored in vertical silos, using a mathematical model and machine learning algorithms. Among the results obtained, the temperature of the intergranular air remained close to the average ambient temperature (26.5 to 26.7 °C), however, when it approached twenty hours of monitoring, it had a reduction to 26.4 °C. While the relative humidity remained between 61.3 to 62.5% throughout the monitoring time. Under these conditions, the stored wheat grains remained with equilibrium moisture content between 11.65 and 11.82%. The concentration of carbon dioxide throughout the storage time ranged from 300 to 550 ppm in the grain mass. Under these conditions, wheat grains had a slight increase in metabolic activity, causing a dry matter loss of 0.035 to 0.041%. The intergranular temperature, relative humidity and carbon dioxide results were similar to the measurements on the surface of the grain mass. It was concluded that the monitoring of temperature, relative humidity and the concentration of carbon dioxide in the intergranular air indirectly and early determined the changes in the quality of wheat grains during storage. Although the metabolic activity of wheat grains was low, as the lots remained in hygroscopic equilibrium with water contents close to 12% (w.b.), the temporal detection characterized the loss of dry matter and the reduction of grain weight. stored. Finally, the Artificial Neural Networks and Multiple Linear Regression model satisfactorily predicted the dry matter loss of stored wheat grain mass.

Keywords: Carbon dioxide. Grain conservation. Intergranular air temperature. Intergranular relative humidity. Loss dry matter. Wheat (*Triticum*).

LISTA DE FIGURAS

| | |
|---|----|
| FIGURA 1– Capacidade estática de armazenagem no Brasil | 14 |
| FIGURA 2– Capacidade estática dos estados do Brasil..... | 15 |
| FIGURA 3– Vista da unidade armazenadora de grãos da Cooperativa Agrícola Mista de Nova Palma _CAMNPAL (A), Vista da localização do município de Novo Cabrais, RS (B)..... | 19 |
| FIGURA 4– 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), Fixação dos sensores e acondicionamento do conjunto de sensores a sonda de policloreto de vinila (C). | 20 |
| FIGURA 5– Tubo amostrador de grãos para acondicionamento da sonda. A – Vista interna e externa do tubo, B – Peças para vedação, C – Vista superior do tubo amostrador, D – Vista completa do tubo. | 21 |
| FIGURA 6– Aplicação do sistema de monitoramento na massa de grãos de trigo. A- Representação do silo armazenador e da sonda de monitoramento com sensores de temperatura, umidade relativa e dióxido de carbono intergranular, B – Sonda de monitoramento inserida na massa de grãos de trigo, C – Termohigrômetro para medição da temperatura e umidade relativa sobre a massa de grãos de trigo, D – Medidor da concentração de CO ₂ sobre a massa de grãos de trigo. | 22 |
| FIGURA 7– Monitoramento da temperatura da massa de grãos de trigo. | 25 |
| FIGURA 8– Monitoramento da umidade relativa intergranular da massa de grãos de trigo.. | 26 |
| FIGURA 9– Monitoramento da umidade de equilíbrio higroscópico da massa de grãos de trigo. | 26 |
| FIGURA 10–Monitoramento a concentração de dióxido de carbono intergranular da massa de grãos de trigo. | 27 |
| FIGURA 11–Monitoramento da perda de matéria seca da massa de grãos de trigo armazenada. | 28 |
| FIGURA 12–Rede de correlação de Pearson estabelecidas sobre variáveis de perda de massa seca (PMS) na qualidade de grão de trigo durante o armazenamento. Dióxido de carbono (CO ₂), Tempo (TE), Temperatura do ar (T), Umidade de equilíbrio higroscópico (Ue), Umidade Relativa (UR), Perda de matéria seca (PMS)..... | 29 |

FIGURA 13–Boxplot dos valores preditos de perda de matéria seca em grãos de trigo armazenados pelos modelos de Machine Learning. RNA (Redes Neurais Artificiais), M5P (algoritmo M5 de Quinlan), Floresta Aleatória (RA), Árvore de Decisão (REPtrees) e o modelo de Regressão Linear Múltipla (RL). Coeficiente de correlação (r) e o Erro Médio Absoluto (MAE).....31

LISTA DE TABELAS

| | | |
|------------|--|----|
| TABELA 1 – | Perda de matéria seca pela diferença de peso dos grãos de trigo do tempo zero ao tempo final de três meses de armazenamento | 28 |
| TABELA 2 – | Coefficiente de correlação (r), erro médio absoluto (MAE) e coeficiente de determinação (R^2) da predição da perda de matéria seca em grãos trigo armazenados, utilizando algoritmos de Machine Learning (ML)..... | 30 |

SUMÁRIO

| | |
|---|-----------|
| 1. INTRODUÇÃO | 11 |
| 2. REFERENCIAL TEÓRICO | 13 |
| 2.1 ARMAZENAGEM DE GRÃOS NO BRASIL | 13 |
| 2.2 TRIGO | 15 |
| 2.3 MONITORAMENTO DE VARIÁVEIS INTERGRANULARES EM GRÃOS ARMAZENADOS..... | 15 |
| 2.4 APLICAÇÃO DE ALGORITMOS PREDITIVOS NA PÓS-COLHEITA..... | 17 |
| 3. MATERIAL E MÉTODOS..... | 18 |
| 3.1. LOCALIZAÇÃO DOS EXPERIMENTOS E ANÁLISES..... | 18 |
| 3.2 TECNOLOGIA E SOFTWARE APLICADOS PARA MONITORAMENTO DA MASSA DE GRÃOS .. | 19 |
| 3.3 VARIÁVEIS MONITORADAS E CALCULADAS | 21 |
| 3.4 ANÁLISES DE CORRELAÇÃO DE PEARSON | 24 |
| 3.5. MACHINE LEARNING | 24 |
| 4. RESULTADOS..... | 25 |
| 4.1. MONITORAMENTO DA MASSA DE GRÃOS DE TRIGO ARMAZENADA | 25 |
| 4.2. CORRELAÇÃO DE PEARSON..... | 28 |
| 4.3. PREDIÇÃO DE PERDAS DE MATÉRIA SECA UTILIZANDO MACHINE LEARNING | 30 |
| 5. DISCUSSÃO | 32 |
| 6. CONCLUSÃO | 33 |
| REFERÊNCIAS BIBLIOGRÁFICAS | 34 |

1. INTRODUÇÃO

A população mundial até 2050 deverá chegar a 9,6 bilhões de pessoas, conseqüentemente a demanda por cereais pode totalizar 3,3 bilhões de toneladas por ano, ou seja, 30% a mais do que é produzido hoje. O trigo é um dos principais culturas agrícolas produzidas no Brasil e no mundo (CONAB, 2022). O cereal compõe a dieta alimentar humana e animal, sendo rico em proteínas, fibras, lipídios, vitaminas e minerais (FAO, 2016).

A produção do trigo ocorre anualmente, mas em períodos sazonais. Desta forma, é fundamental que os grãos sejam armazenados para atender as demandas do mercado ao longo do tempo. Assim, faz-se necessário a conservação da qualidade dos grãos de trigo durante o armazenamento para o posterior processamento.

O armazenamento constitui um ecossistema formado por fatores abióticos e bióticos, os quais podem influenciar na atividade metabólica e deteriorações dos grãos. Entre as principais variáveis que interferem na atividade respiratória da massa de grãos estão a temperatura e umidade relativa intergranular. O aumento da temperatura e da umidade relativa intergranular podem ocasionar alterações na umidade de equilíbrio higroscópico dos grãos e conseqüentemente nos teores de água. De acordo com Raudiene et al. (2017), a taxa respiratória da massa de grãos de trigo aumenta quando há aumento na temperatura e nos teores de água dos grãos.

Além da temperatura e umidade relativa, estudos têm relatado que o aumento da concentração de dióxido de carbono (CO_2) nos grãos armazenados é um indicador de deterioração. Mesmo após a secagem, os grãos podem permanecer com atividade metabólica e respirando, sendo assim, a massa de grãos ainda estão sujeitos às alterações qualitativas (POHNDORF et al., 2018). O processo de respiração pode provocar o consumo de matéria seca e a oxidação de carboidratos. A decomposição de 1 g de matéria seca durante a respiração aeróbica requer 1,07 g de oxigênio e libera 1,47 g de dióxido de carbono, 0,6 g de água e 15,4 kJ de calor. Assim, modelos matemáticos com CO_2 são usados para prever a perda de matéria seca durante o armazenamento (HUANG et al., 2013), bem como para determinar a difusividade de CO_2 na massa de grãos. De acordo com Huang et al. (2013), o coeficiente efetivo de difusão de CO_2 em grãos de milho a granel aumenta à medida que a temperatura intergranular aumenta. Em conseqüência ao processo respiratório dos grãos podem ocorrer infestações de insetos e infecção por fungos, acelerando a taxa de respiração da massa de grãos, aumentando assim a degradação de carboidratos, proteínas e óleos, aumento na acidez e peróxidos.

Embora, seja recomendado o armazenamento da massa de grãos com os teores de água próximos a 12% (b.u.), ainda assim, essa condição não assegura a conservação dos grãos. Fatores externos e intergranulares, como variações na temperatura e umidade relativa do ar, elevados teores de impurezas e heterogeneidade da massa de grãos, a estrutura e o sistema operacional de armazenamento podem potencializar alterações físicas, físico-química e biológicas na massa de grãos, provocando perdas.

O monitoramento das variáveis intergranulares, como temperatura e umidade relativa do ar intergranular, umidade de equilíbrio higroscópico e a concentração de CO₂ dará uma previsão precoce da intensidade respiratória da massa de grãos, sendo uma alternativa tomar ações para evitar perdas quantitativas e qualitativas nos grãos ao longo do tempo de armazenamento.

Para obter informações mais precisas sobre a perda de matéria seca dos grãos armazenados, podem-se adotar algoritmos computacionais preditivos. O uso de algoritmos de Machine Learning (ML) pode proporcionar uma melhor capacidade de processamento e análise de dados. Quando adequadamente modeladas, as técnicas de ML podem fornecer respostas em um menor tempo, quando comparadas aos modelos de regressão estatística.

Nos últimos anos, os métodos de ML têm sido usados para prever a produtividade das culturas agrícolas (TEODORO et al., 2021), a concentração de nitrogênio nas folhas (SANTANA et al., 2021), na classificação de sementes (ANDRÉ et al., 2022), na redução de fósforo em águas residuais e redução da qualidade de grãos armazenados (LUTZ e CORADI, 2021). O algoritmo Random Forest, por exemplo, é uma técnica de ML usada com sucesso na previsão de safras agrícolas. Comparando aos modelos de regressão linear múltipla, esta técnica é eficaz e mais fácil de usar em análises de previsão da produtividade de milho e soja. Outro exemplo são as Redes Neurais Artificiais (RNAs), que são algoritmos que podem ser treinados para analisar e interpretar dados complexos de segurança alimentar, previsões físicas e químicas (LUTZ et al., 2022).

Para preencher lacunas onde as estatísticas convencionais não podem gerar resultados de previsão satisfatórios, a modelagem de dados usando técnicas de ML pode se tornar uma alternativa viável para avaliar a qualidade de grãos de milho armazenados em vez de realizar testes mais demorados e caros em laboratórios. Nas unidades de processamento e armazenamento de grãos, o uso do ML pode ser uma ferramenta auxiliar para a tomada de decisão dentro do ambiente de armazenamento, contribuindo para a otimização do processo e redução de perdas, impactando socioeconômico no ambiente de produção e colaborando para a formação de um sistema pós-colheita mais sustentável.

A adoção de sistemas de monitoramento para predição da perda de matéria em grãos de trigo armazenados pode ser uma técnica importante para as unidades armazenadoras de grãos, para tomada de decisões sobre o tempo de armazenamento e assim ter mais autonomia para realizar a comercialização dos grãos no momento mais favorável, sem perder a qualidade do produto. Assim, um diagnóstico da qualidade da massa de grãos armazenada em um espaço de tempo reduzido poderia colaborar na tomada de decisão sobre o manejo operacional do sistema de armazenamento e estimar os níveis de deterioração da massa de grãos ao longo do tempo de armazenamento. A partir do monitoramento pode se ter informações para tomada de decisão sobre o tempo ideal de armazenamento dos grãos, sem que haja perda da qualidade. Além disto, possibilitaria as unidades armazenadoras realizar um prognóstico das perdas ao final do tempo de armazenamento.

Em razão disto, o presente estudo objetivou avaliar o monitoramento temporal/amostral da temperatura, umidade relativa e dióxido de carbono intergranular para estimativa e predição da perda de matéria seca em grãos de trigo armazenados em silos verticais, utilizando um modelo matemático e algoritmos de aprendizado de máquina.

2. REFERENCIAL TEÓRICO

2.1 ARMAZENAGEM DE GRÃOS NO BRASIL

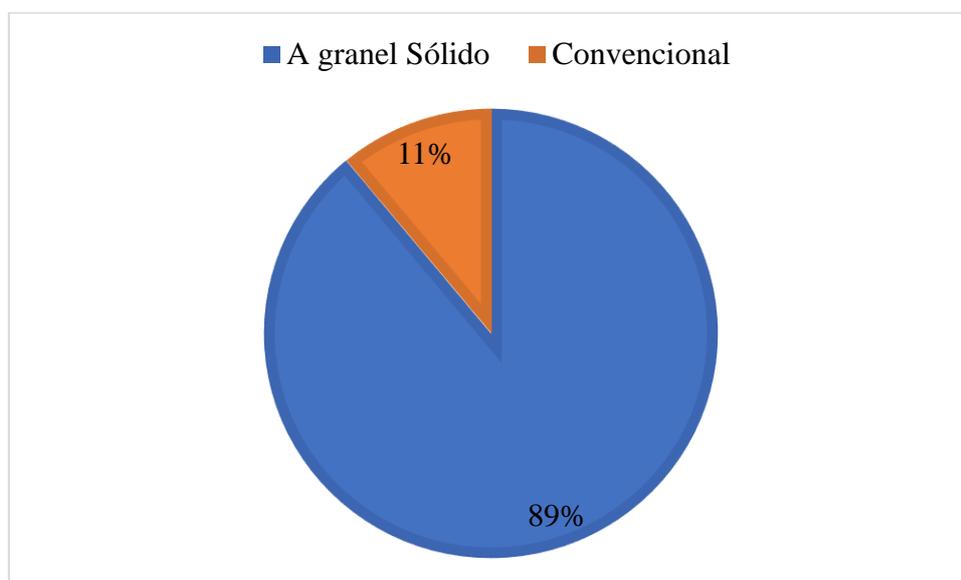
De acordo com a Food and Agriculture Organization (FAO, 2020), a China, a Índia e Bangladesh destacam-se como os maiores produtores de trigo na Ásia durante a safra de 2019/20, com uma produção de 210.737.000 toneladas, 177.975.000 toneladas e 54.746.117.5 toneladas, respectivamente. O Brasil encontra-se na décima posição, com uma produção de 10.729,825 toneladas.

Estima-se que a produção mundial de trigo em 2022 situa-se em 782 milhões de toneladas. Já no Brasil a estimativa para 2022 é que seja cultivado 2.821,9 mil hectares do grão de trigo, resultando uma produção de 8.130,6 mil toneladas do grão (CONAB, 2022).

De acordo com a Companhia Nacional de Abastecimento (CONAB, 2022), a armazenagem é uma área estratégica na logística do abastecimento, que vai além de guardar e conservar o produto agrícola estocado. O armazenamento de grãos de trigo é realizado de duas formas: convencional ou a granel. A armazenagem convencional é relativamente simples, ou seja, utilizam-se estruturas como armazéns ou depósitos de alvenaria, assim acondicionando os grãos em sacarias. Já a armazenagem de grãos a granel é utilizada para a estocagem dos grãos em estruturas como silos, armazéns graneleiros, metálicos ou de concreto (FILHO et al., 2012).

No Brasil a evolução da Armazenagem tem uma taxa média crescimento de 2,312% referente à capacidade estática entre 2010 a 2022, totalizando uma capacidade de 177.079.442,00 (t), sendo que 157.570.925,00 (t) é armazenado do tipo a granel sólido e 19.508.517,00 convencional (Figura 1).

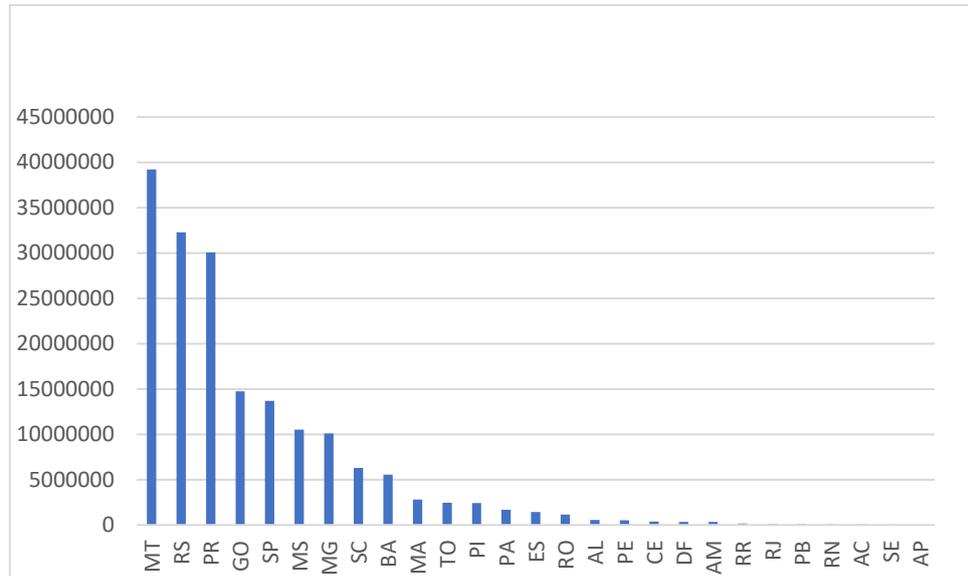
FIGURA 1 – Capacidade estática de armazenagem no Brasil



Fonte: Conab. Adaptado pelo autor

O estado de Mato Grosso, Rio Grande do Sul e Paraná se destacam com a maior capacidade estática de armazenagem de grãos no Brasil, como apresentado na Figura 2 (CONAB, 2022).

FIGURA 2 – Capacidade estática dos estados do Brasil



Fonte: Conab, adaptado pelo autor

2.2 TRIGO

O trigo é uma das principais fontes de energia para a alimentação humana e animal, sendo rico em proteínas, calorias, carboidratos e carboidratos líquidos. Por conter baixos conteúdos de macronutrientes, o trigo não é consumido in natura e então é destinado na produção de farinhas, a qual é composta de amido (75%), proteínas (16%), água (14%) e amiláceos (3%) lipídeos (2%) e cinzas (1%), apresentando diferenças nas composições devido as cultivares, métodos de cultivo e outros (MORITA et al., 2002). O farelo de trigo é um alimento energético o qual pode ser incluído na dieta de animais. Com essa gama de produtos derivados do trigo, justifica a importância comercial dessa cultura. Para isso, manter as propriedades do grão preservadas nas etapas pré-processamento e armazenamento torna-se importante para a qualidade e valorização comercial do produto.

2.3 MONITORAMENTO DE VARIÁVEIS INTERGRANULARES EM GRÃOS ARMAZENADOS

O armazenamento de grãos é uma das etapas do processo produtivo, onde o uso de novas tecnologias contribui para melhorar a conservação da qualidade dos grãos. Quando monitorados, obtém-se um maior controle de temperatura e umidade, assim possibilitando que o grão seja armazenado por um período maior (FERRASA, 2010).

Desta forma, as operações de pós-colheita, como momento de colheita, processamento e armazenamento do produto, devem ser bem executadas preservando a qualidade do grão. Em

condições inadequadas nas etapas de pós-colheita, os grãos podem sofrer alterações químicas, física perdendo seu valor comercial (NOURBAKHS et al., 2016).

A combinação de temperatura e o teor de água influenciam a qualidade do produto durante o armazenamento (BAZONI et al., 2017). Para conservar a qualidade dos grãos, a faixa ideal para o teor de água está entre 12% a 13% (b.u), assim é possível manter um armazenamento seguro, teores de água acima de 14% causam o aumento da respiração, ocasionando sua deterioração (SMANIOTTO et al., 2014; HARTMANN FILHO et al., 2016).

O teor de água na massa de grão é o fator mais relevante na prevenção da deterioração do grão durante o armazenamento. Ao manter o teor de água e temperatura baixa, o ataque dos microrganismos e a respiração dos grãos são minimizados (Berbert et al., 2008). Porém quando a temperatura e teor de água estão elevada a evolução da população de insetos e microrganismos é grande, o que causa a deterioração dos grãos, afetando diretamente na qualidade do produto (ELIAS et al., 2009). A temperatura é outro fator que interfere na qualidade de armazenamento de grãos (REHMAN et al., 2002; PARK et al., 2012). Quando armazenados são expostos a alterações da temperatura e do teor de água na massa de grãos, sendo assim, o grão de trigo pode sofrer alterações em suas propriedades físicas químicas e biológicas (ALENCAR et al. 2009).

Ao serem armazenados em sistemas convencionais ou a granel, o produto é exposto a uma atmosfera descontrolada, que pode leva-lo a mudanças dramáticas, assim, causando a deterioração por aquecimento e introdução de umidade na massa de grão, ocasionando um desequilíbrio higroscópico com adsorção e dessorção de água entre o grão e o ar intergranular.

Lutz e Coradi (2021), diz que o grão e a estrutura de armazenamento formam um ecossistema, e a qualidade do produto depende de fatores bióticos e abióticos. A relação do produto armazenado com o ar intergranular, a condição de armazenamento e a estrutura de armazenamento criam variações no teor de água, temperatura da massa e umidade relativa intergranular. A correlação desses fatores determina um ambiente de armazenamento com variações no teor de umidade de equilíbrio dos grãos.

O teor de umidade de equilíbrio, também é conhecido como higroscópico ou equilíbrio higroscópico, que é quando o teor de água do grão tem a mesma tensão de vapor de água que a do ar ambiente, ou seja, o teor de água do grão está em equilíbrio com a umidade relativa do ar em uma determinada temperatura (CORADI et al., 2014). Sendo então que a umidade de equilíbrio dos grãos acontece quando os grãos não ganham, nem perdem umidade para o meio onde estão acondicionados (LISBOA et al., 2019).

A massa de grãos são materiais biológicos vivos que respiram, por essa razão, consomem o oxigênio e liberam dióxido de carbono e água (BARRETO et al., 2017). A produção de CO₂ é resultado da respiração dos grãos armazenados e dos fatores bióticos na massa de grão, como microorganismos e insetos (RAMACHANDRAN, 2022). O monitoramento de CO₂ na massa de grãos possibilita correlacionar estes valores com estado de conservação, visto que há uma relação direta entre a atividade biológica e a concentração de CO₂ (RUDIENE et al., 2017).

Abalone (2011), ao realizar um trabalho com armazenamento nas estações fria e quente, observou que grãos com diferentes teores de água 10, 11, 12, 13%, apresentaram baixo valores de CO₂ independente das estações. Já grãos com umidade acima de 14%, nas estações quente, obtiveram diferença de sete pontos percentuais no valor da concentração de CO₂ em comparação com a estação fria.

De acordo com (NEETHIRAJAN, 2010) concentrações de CO₂, entre 380 a 500 ppm é considerável a concentração atmosfera sem deterioração, de 500 a 1100 ppm início de deterioração, de 1100 a 3500 ppm há uma leve infestação de insetos e microorganismos, de 3500 a 5000 ppm é considerável uma alta infestação de insetos e ou infecção de microorganismos, de 5000 a 9000 ppm a deterioração é severa, considerando condições perigosas para o armazenamento e acima de 10000 ppm as condições de armazenamentos é altamente inadequadas. Portanto, níveis de CO₂ elevados indicam a presença de insetos, mofo ou respiração excessiva.

2.4 APLICAÇÃO DE ALGORITMOS PREDITIVOS NA PÓS-COLHEITA

A modelagem primitiva é uma técnica estatística que vem mostrando resultados notáveis no contexto do manejo de pós-colheita de grãos como forma inovadora de análise de dados (LIAKOS, 2018). Ou seja, o modelo primitivo consiste em uma ou mais funções matemáticas aplicadas a um conjunto de dado observados que, através da ajuda de inferência estatística, é possível gerar dados que preveem o que pode acontecer com as variáveis de respostas de interesse à medida que as entradas mudam (ZEYMER, 2021).

O rápido desenvolvimento da tecnologia de controle computacional e da inteligência artificial, tem sido amplamente utilizado na área de secagem, proporcionando diferentes formas de controle de secagem de grãos (DAIA et al., 2018). Liakos et al. (2018) exploraram as técnicas de Machine Learning (ML) na agricultura e concluíram que a inteligência artificial, possibilita que programas computacionais gerem informações e percepções aos agricultores, a fim de que os mesmos tomem melhores decisões.

O Machine Learning (ML) pode ser aplicado na agricultura sustentável, de acordo com o artigo realizado por Sharma et al. (2020), os autores concluem que na fase pré-produção, o ML é aplicado para a previsão do rendimento da cultura, informações sobre a propriedade do solo e irrigação. Já fase de produção, o ML é utilizado para previsão do tempo, detecção de daninhas e doenças, nutrição do solo. Na fase etapa de processamento, o ML é usado para estimar a demanda e planejamento da produção. No estágio de distribuição, o uso do ML é para o gerenciamento e análise do consumidor.

WU et al. (2021), realizaram um estudo que teve como objetivo desenvolver e validar um algoritmo para usar os dados de temperaturas rotineiras grãos armazenados em grande escala para monitorar as condições dos grãos armazenados. O estudo buscou um novo caminho de análise para um volume grande de dados de temperatura coletados rotineiramente para monitorar digitalmente e remotamente a quantidade de grãos e detectar possíveis problemas de qualidade em grandes instalações de armazenamento de grãos.

Ao mesmo tempo que a ciência avança, a tecnologia tem chegado cada vez mais perto do meio rural, promovendo um maior controle do produtor sobre o seu produto, sendo assim o produtor tem mais autonomia para tomada de decisão.

3. MATERIAL E MÉTODOS

3.1. LOCALIZAÇÃO DOS EXPERIMENTOS E ANÁLISES

O experimento foi realizado no Laboratório de Pós-colheita (LAPOS) da Universidade Federal de Santa Maria (UFSM), Campus Cachoeira do Sul (CS), em parceria com a Cooperativa Agrícola Mista de Nova Palma – CAMNPAL (figura 3 – A), unidade armazenadora localizada em Novo Cabrais, RS (Figura 3 – B).

FIGURA 3 – Vista da unidade armazenadora de grãos da Cooperativa Agrícola Mista de Nova Palma – CAMNPAL (A). Vista da localização do município de Novo Cabrais, RS (B).



Fonte: Autor

3.2. TECNOLOGIA E SOFTWARE APLICADOS PARA MONITORAMENTO DA MASSA DE GRÃOS

Para o monitoramento da massa de grãos de trigo no armazenamento foi aplicado um equipamento portátil (Jaques et al., 2022). O equipamento constitui-se de um microcontrolador Arduino Mega 2560 (modelo Mega 2560, Arduino LLC, Itália) como núcleo de controle. O hardware do sistema inclui três sensores digitais para detectar a temperatura e umidade relativa do ar (modelo DHT22, Aosong Electronics, Guangzhou, China), um sensor infravermelho não destrutivo para detectar a concentração de CO₂ (modelo MHZ-14, Winsen, China), módulos de relógio em tempo real (modelo DS3231, flip-flop, China) e um cartão micro-SD (modelo Greatz cartão micro SD, importação, China).

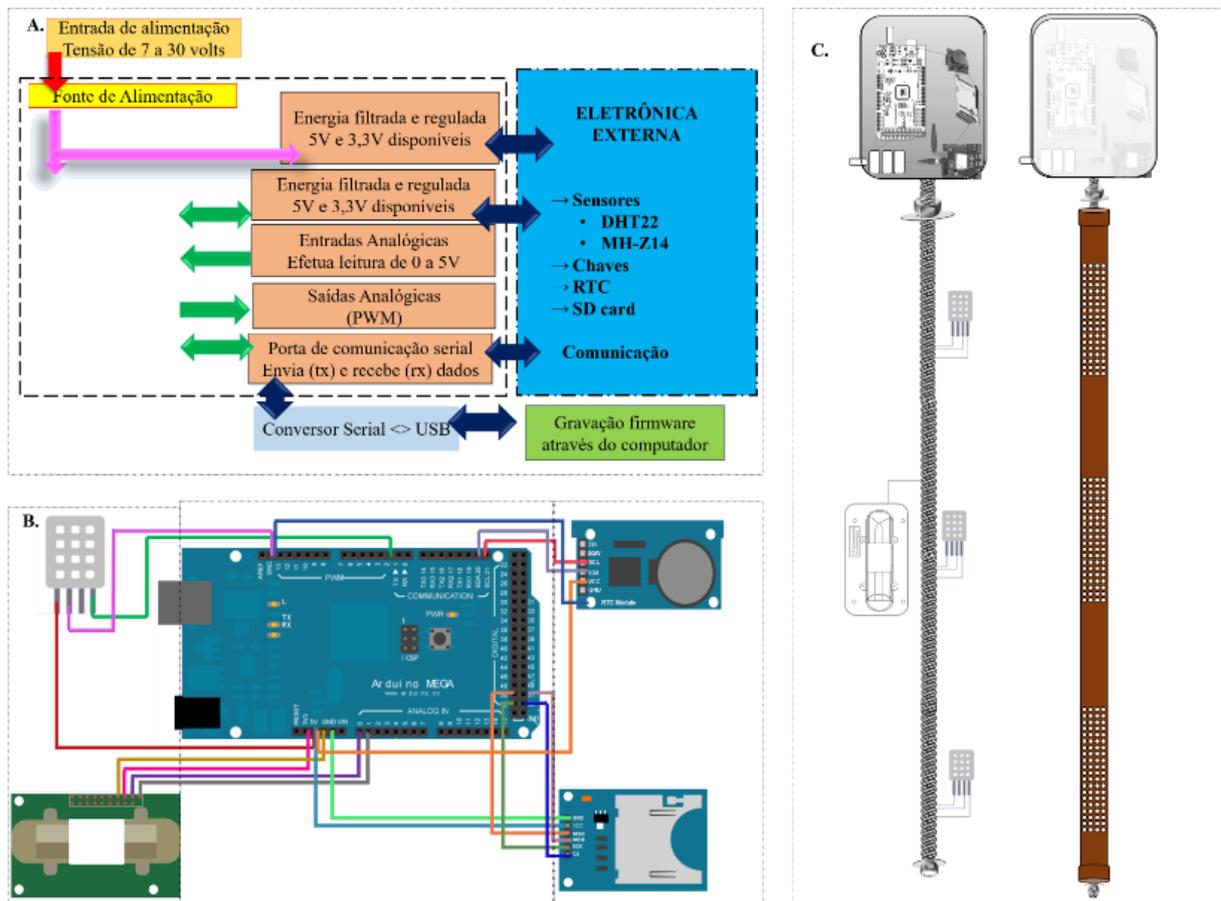
O diagrama de blocos do sistema de controle é mostrado na Figura 4A. Os dados de saída do sensor digital, sensor infravermelho e módulos são conectados aos terminais de comunicação de I/O do microcontrolador que são responsáveis pela comunicação física, integração de componentes e cálculo de dados. A esquematização de conexão de cada componente via cabos jumper é mostrado na Figura 4B (Coradi e Jaques, 2022).

Os sensores de temperatura e umidade relativa (modelo DHT22, Aosong Electronics, Guangzhou, China) foram fixados em três extremidades de uma barra roscada e o sensor de CO₂ (modelo MHZ-14, Winsen, China) foi fixado na parte central. O módulo de relógio em tempo real (modelo DS3231, flip-flop, China) e o cartão micro-SD (modelo Greatz cartão micro-SD, Import, China) foram armazenados em uma caixa. A Figura 4C mostra a estrutura do equipamento com os sensores dispostos ao longo da barra roscada e protegidos por uma

sonda de policloreto de vinila. O equipamento possui alimentação própria com três baterias dispostas em série e a potência total é de 27 V.

O software SmartStorage (CORADI e LUTZ, 2022a) e o software CO₂ Reader (CORADI e LUTZ, 2022b) foram utilizados na placa Arduino e programados com base na linguagem de programação C++, sendo a maioria das bibliotecas fornecida pela plataforma. O IDE (Integrated Development Environment) do Arduino foi usado para desenvolver o firmware embarcados para os microcontroladores Atmega 2560.

FIGURA 4 – 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), Fixação dos sensores e acondicionamento do conjunto de sensores a sonda de policloreto de vinila (C).

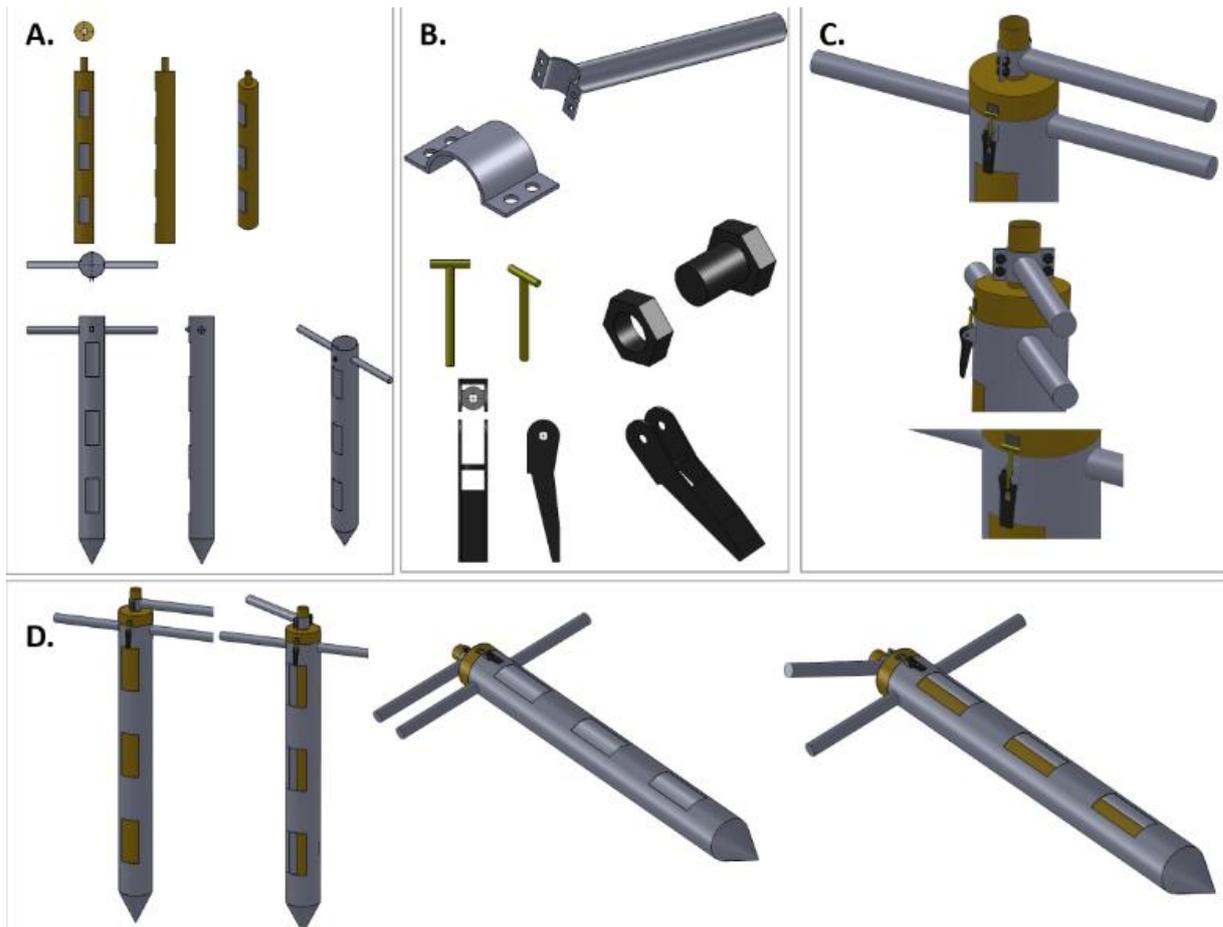


Fonte: Jaques (2021).

Um tubo amostrador de grãos metálicos foi desenvolvido para acoplar a sonda. O tubo consistiu em dois tubos sobrepostos, com uma ponta na extremidade inferior e um braço giratório na extremidade superior. Isso possibilitou a proteção da sonda e aumentou a precisão

da leitura intergranular dos grãos. O tubo continha aberturas / células na parte superior, central e inferior ao longo de seu comprimento, como mostrado na Figura 5.

FIGURA 5 – 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).



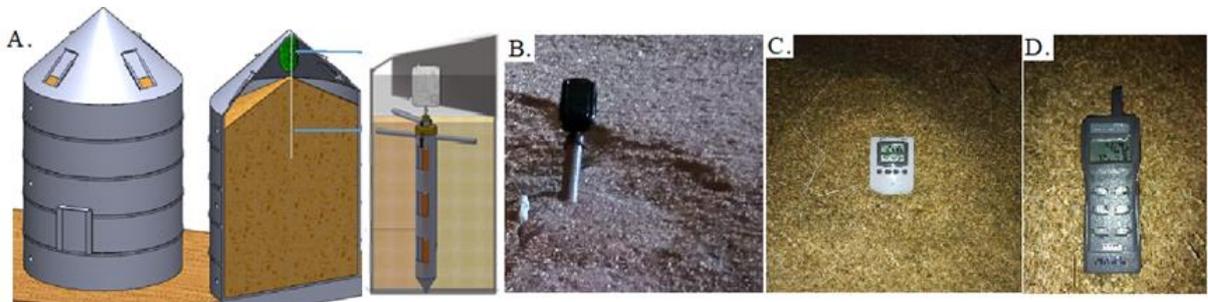
Fonte: Jaques (2021).

3.3. VARIÁVEIS MONITORADAS E CALCULADAS

Monitorou-se a temperatura, a umidade relativa e concentração de dióxido de carbono no ar intergranular na massa de grãos de trigo armazenados em silo vertical metálico, com 11,5% (b.u.) de teores de água, ao longo de 20 horas (Figura 6). Ao mesmo tempo, realizou-se medições de 1 em 1 hora da temperatura, umidade relativa e a concentração de dióxido de carbono do ambiente de armazenamento através de um termohigrômetro marca TLX, modelo

DTH-16 (Shenzhen Tonglixing Technology, Guangdong, China) e um medidor de CO₂, modelo 77525 (AKSON, São Leopoldo, Brasil).

FIGURA 6 – Aplicação do sistema de monitoramento na massa de grãos de trigo. A- Representação do silo armazenador e da sonda de monitoramento com sensores de temperatura, umidade relativa e dióxido de carbono intergranular, B – Sonda de monitoramento inserida na massa de grãos de trigo, C – Termohigrômetro para medição da temperatura e umidade relativa sobre a massa de grãos de trigo, D – Medidor da concentração de CO₂ sobre a massa de grãos de trigo.



Fonte: Autor

Com os resultados da temperatura e umidade relativa do ar intergranular calculou-se a umidade de equilíbrio higroscópico da massa de grãos armazenada (Equações 1 e 2).

Equação 1: Umidade relativa do ar entre $0 < UR \leq 55\%$:

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

Equação 2: Umidade relativa do ar entre $55 < UR < 100\%$:

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

em que,

U_e : Umidade de equilíbrio higroscópico

UR : Umidade relativa (%)

T : Temperatura (F)

A perda de matéria seca foi calculada pela concentração de CO₂ monitorada no período do armazenamento dos grãos através da Equação 3:

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

em que,

PMS: Perda de matéria seca (%)

C_{CO₂}: concentração de C_{CO₂}(v/v) medida no interior dos silos metálicos

ΔC_{O₂}: variação da concentração de O₂ 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 kJ Kmol⁻¹ K⁻¹)

T: Temperatura (K)

A determinação da matéria seca de grãos de trigo armazenada foi realizada pelas Equações 4 e 5 (Santos et al., 2012).

$$MS = \left[1 - \left(\frac{U}{100} \right) \right] P_i \quad (4)$$

em que,

MS: matéria seca (g)

U: teor de água (%)

P_i: massa inicial de grãos (g)

$$PMS_{calculada} = \left(\frac{MS_{inicial} - MS_{final}}{MS_{inicial}} \right) * 100 \quad (5)$$

em que,

PMS_{calculada}: perda de matéria seca (%)

MS_{inicial}: matéria seca inicial (g)

MS_{final}: matéria seca final (g)

3.4 ANÁLISES DE CORRELAÇÃO DE PEARSON

Foi realizada a análise de rede de correlação de Pearson, onde a proximidade entre os nós foi determinada pela proporcionalidade ao valor absoluto da correlação entre os nós. A espessura das arestas foi controlada aplicando um valor de corte de 0,60, o que significava que apenas $|r_{XY}| \geq 0,60$ tiveram suas bordas destacadas. Essas análises foram realizadas com o auxílio do pacote “ggfortify” do aplicativo gratuito R e seguiram os procedimentos recomendados por Naldi et al. (2011). As correlações positivas destacadas em verde e as correlações negativas representadas em escala em vermelho.

3.5. MACHINE LEARNING

Os dados foram analisados no *software* Weka versão 3.9.5. utilizando os seguintes modelos: Regressão Linear Múltipla (RL), Redes Neurais Artificiais (RNA), Árvore de Decisão (REPtree), algoritmo M5 de Quinlan (M5P) e Floresta Aleatória (RA). O modelo RL foi utilizado como modelo controle. A RNA 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 múltipla aos nós das folhas (BLAIFI et al., 2018). O modelo RL 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 & DRĂGĂU, 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.

A predição da perda de matéria seca de grãos de trigo foi realizada através dos modelos RL, RNA, REPtree, M5P e RA, com validação cruzada aleatória estratificada de dobras com 10 repetições, utilizando um conjunto de dados com as seguintes variáveis de entrada: temperatura (T), umidade relativa (UR), umidade de equilíbrio higroscópico (Ue) e dióxido de carbono intergranular (CO₂).

O coeficiente de correlação de Pearson (r) e o erro médio absoluto (MAE) foram as estatísticas utilizadas para avaliar a qualidade do ajuste dos dados preditos pelos modelos. Os resultados do coeficiente de correlação e do erro médio absoluto foram submetidos a uma análise de variância (ANOVA) com dez repetições realizada no software R. Subsequentemente, as médias de r e MAE obtidas para cada técnica foram agrupadas pelo teste de Scott-Knott a 5% de probabilidade. Para expressar esses resultados para cada variável de saída, boxplots

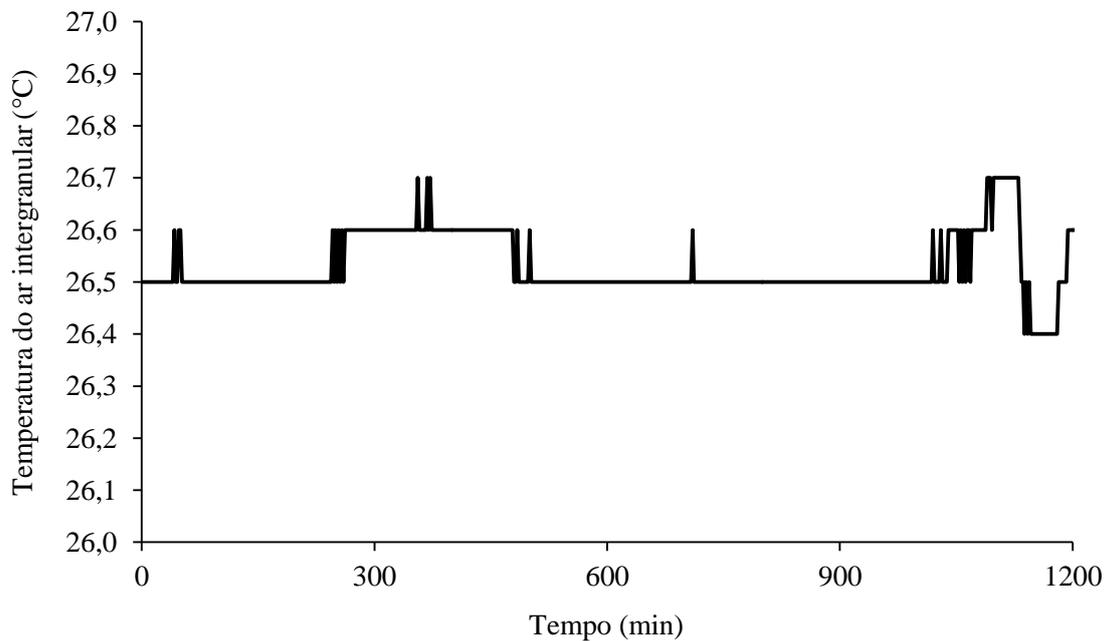
foram construídos no software R (R CORE TEAM, 2018) utilizando os pacotes ExpDes.pt e ggplot2.

4. RESULTADOS

4.1. MONITORAMENTO DA MASSA DE GRÃOS DE TRIGO ARMAZENADA

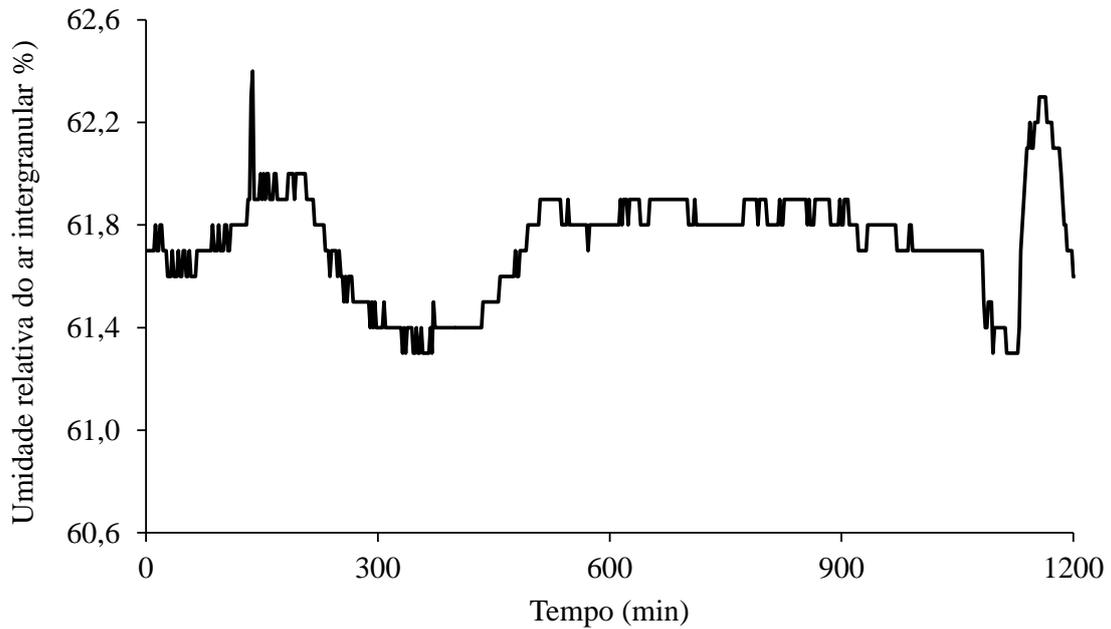
A temperatura do ar intergranular (°C) manteve-se próxima da temperatura média ambiente (Figura 7). Durante o monitoramento a temperatura do ar intergranular variou entre 26,5 a 26,7 °C, porém quando se aproximou das vinte horas de monitoramento teve redução para 26,4 °C. A umidade relativa variou entre 61,3 a 62,5% em relação ao tempo de monitoramento. (Figura 8). Nessas condições, os grãos de trigos armazenados permaneceram com uma de umidade de equilíbrio higroscópico entre 11,65 à 11,82% (Figura 9).

FIGURA 7 – Monitoramento da temperatura da massa de grãos de trigo.



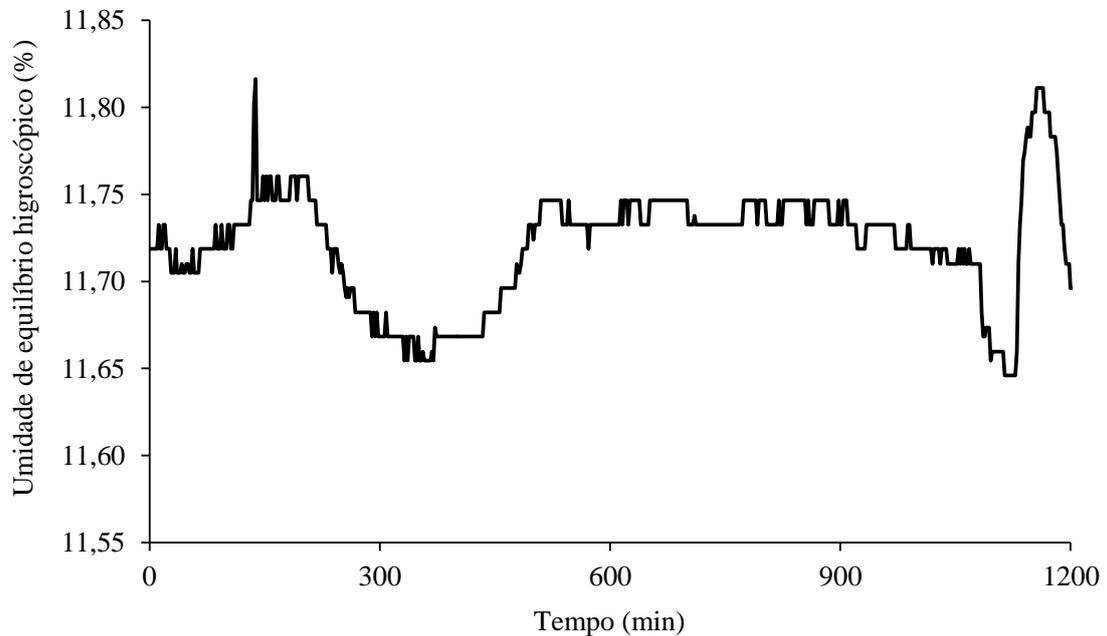
Fonte: Autor

FIGURA 8 – Monitoramento da umidade relativa intergranular da massa de grãos de trigo.



Fonte: Autor

FIGURA 9 – Monitoramento da umidade de equilíbrio higroscópico da massa de grãos de trigo.

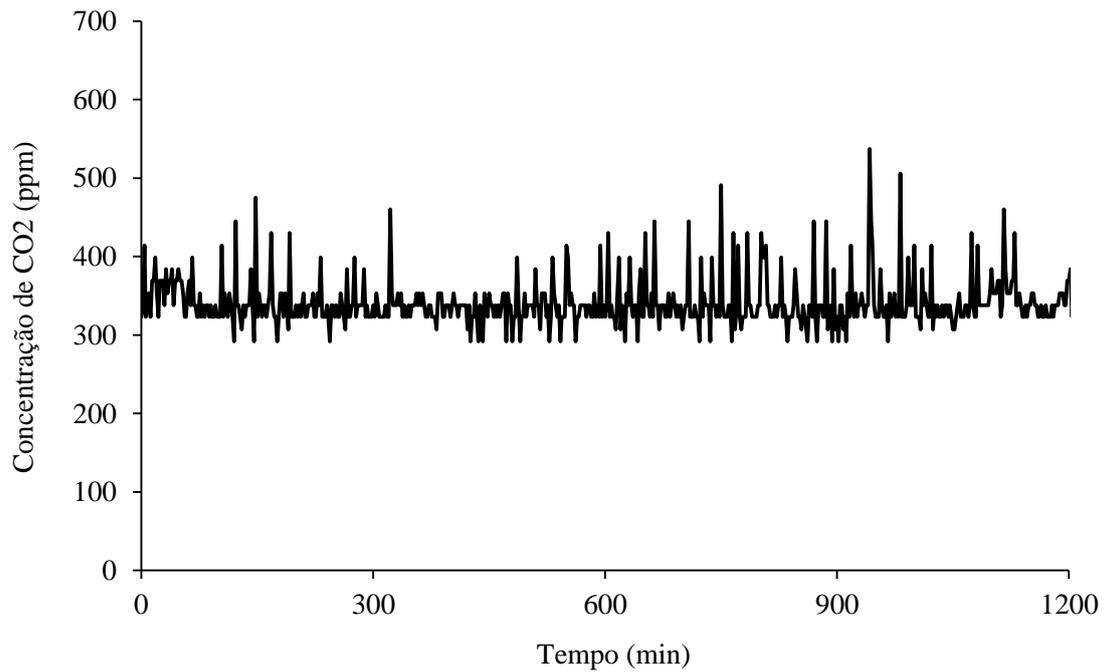


Fonte: Autor

A concentração de dióxido de carbono ao longo do tempo de armazenamento variou de 300 a 550 ppm na massa de grãos (Figura 10). Nessas condições, os grãos de trigo tiveram um leve aumento na atividade metabólica (TAHER et al., 2019; VILLAGÓMES et al., 2020),

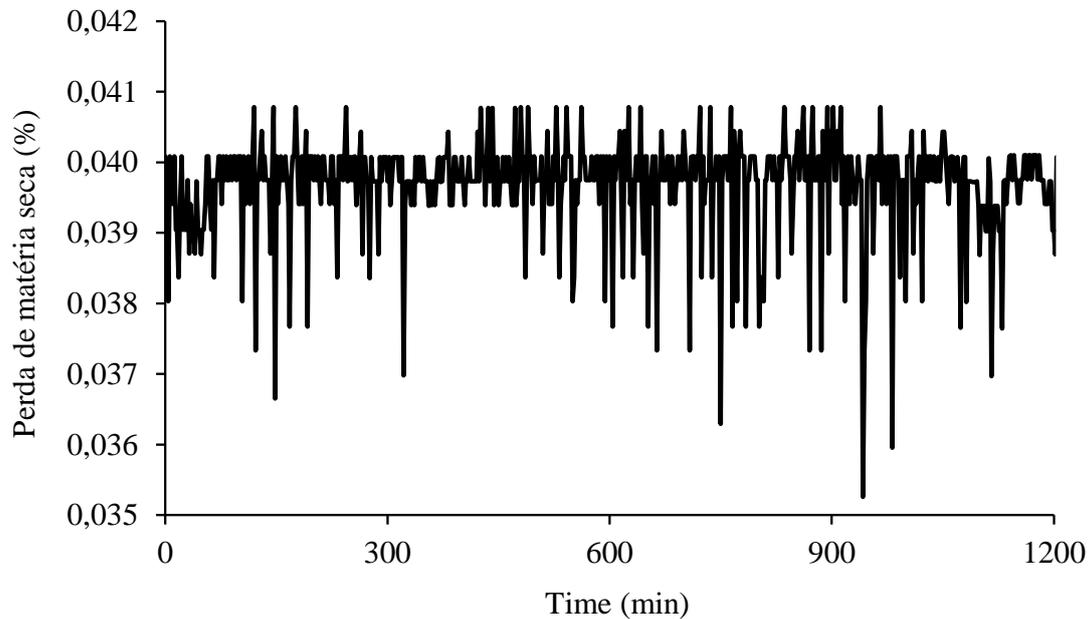
fazendo com que houvesse perda de matéria seca em 0,035 a 0,041% (Figura 11). Os resultados obtidos de temperatura, umidade relativa e dióxido de carbono intergranulares foram similares às medições dessas variáveis realizadas no ar, sobre a superfície da massa de grãos de trigo armazenada.

FIGURA 10 – Monitoramento a concentração de dióxido de carbono intergranular da massa de grãos de trigo.



Fonte: Autor

FIGURA 11 – Monitoramento da perda de matéria seca da massa de grãos de trigo armazenada.



Fonte: Autor

Os resultados obtidos do monitoramento precoce e amostral de vinte de horas (Figuras 7-10) condizesse com a diferença de peso inicial e final da massa de grãos de trigo armazenada ao longo de três meses (Tabela 1).

TABELA 1 – Perda de matéria seca pela diferença de peso dos grãos de trigo do tempo zero ao tempo final de três meses de armazenamento

| Avaliações | Quantidades |
|---------------------------------------|-------------|
| $MS_{inicial}$ | 353.220 kg |
| MS_{final} | 353.100 kg |
| $PMS_{calculada}$ | 0,0033% |
| $PMS_{calculada} \times MS_{inicial}$ | 120 kg |

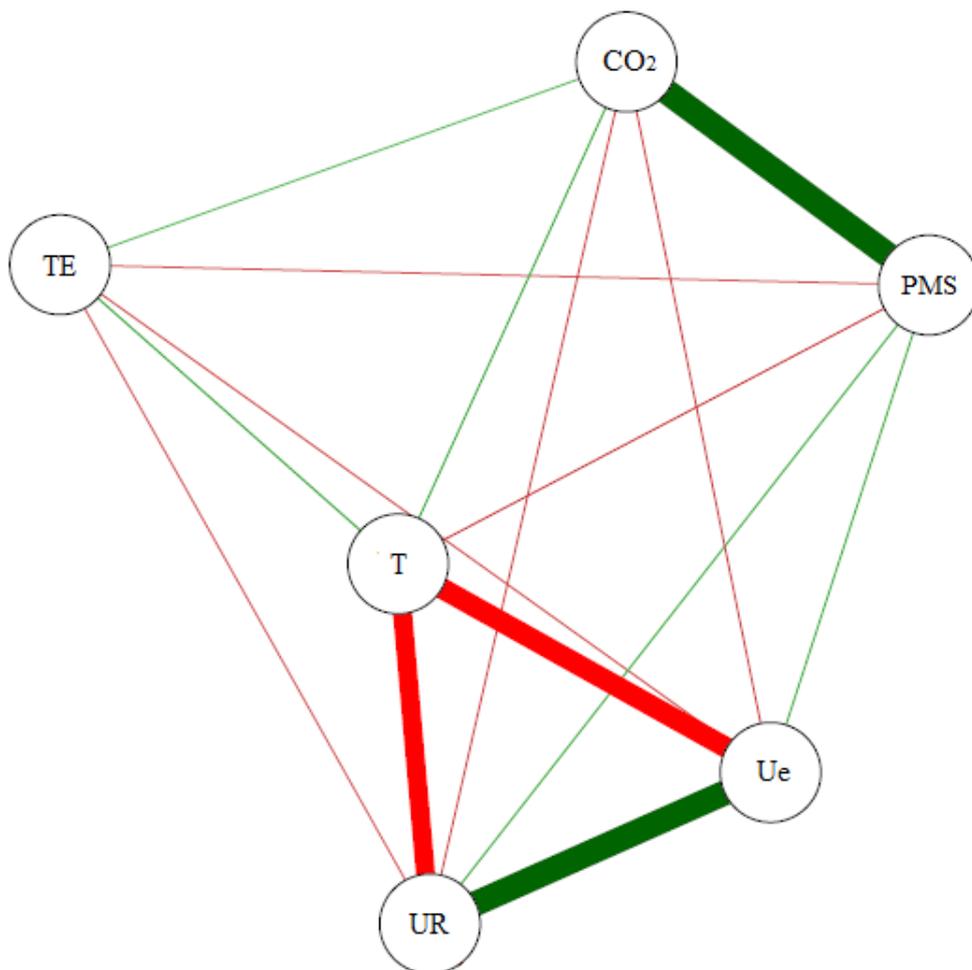
$MS_{inicial}$ – Massa seca inicial; MS_{final} – Massa seca final; $PMS_{calculada}$ – Perda de matéria seca calculada.

4.2. CORRELAÇÃO DE PEARSON

As variáveis intergranulares monitoradas na massa de grãos de trigo tiveram correlações (Figura 12) coerentes com os resultados obtidos nas Figuras 7-11. As variáveis de dióxido de carbono (CO_2) e a perda de matéria seca (PMS) estão fortemente e positivamente

correlacionadas entre si, ou seja, quando o CO_2 aumentou a PMS também teve aumento, demonstrando uma correlação com alta magnitude. O mesmo ocorreu entre a correlação da umidade relativa (UR) e umidade de equilíbrio higroscópico (Ue). Já a temperatura do ar intergranular (T) teve uma forte correlação negativa UR e a Ue, o que era esperado, pois à medida que a T aumenta, a UR e Ue tendem a diminuir, ou vice-versa. O tempo (TE) de monitoramento esteve correlacionado com todas as variáveis, porém de forma positiva com a T e CO_2 e de forma negativa com UR e Ue, entretanto, com baixa magnitude. O CO_2 teve correlação fraca e positiva com a T e fraca e negativa com a UR e Ue.

FIGURA 12 – Rede de correlação de Pearson estabelecidas sobre variáveis de perda de massa seca (PMS) na qualidade de grão de trigo durante o armazenamento. Dióxido de carbono (CO_2), Tempo (TE), Temperatura do ar (T), Umidade de equilíbrio higroscópico (Ue), Umidade Relativa (UR), Perda de matéria seca (PMS).



Fonte: Autor

4.3. PREDIÇÃO DE PERDAS DE MATÉRIA SECA UTILIZANDO MACHINE LEARNING

Na Tabela 2 foram apresentados os coeficientes de correlação (r), coeficiente de determinação (R^2) e o erro absoluto médio (MAE) dos modelos de aprendizado de máquina para predição precoce e temporal da variável de perda de matéria seca em grãos de trigo durante o armazenamento.

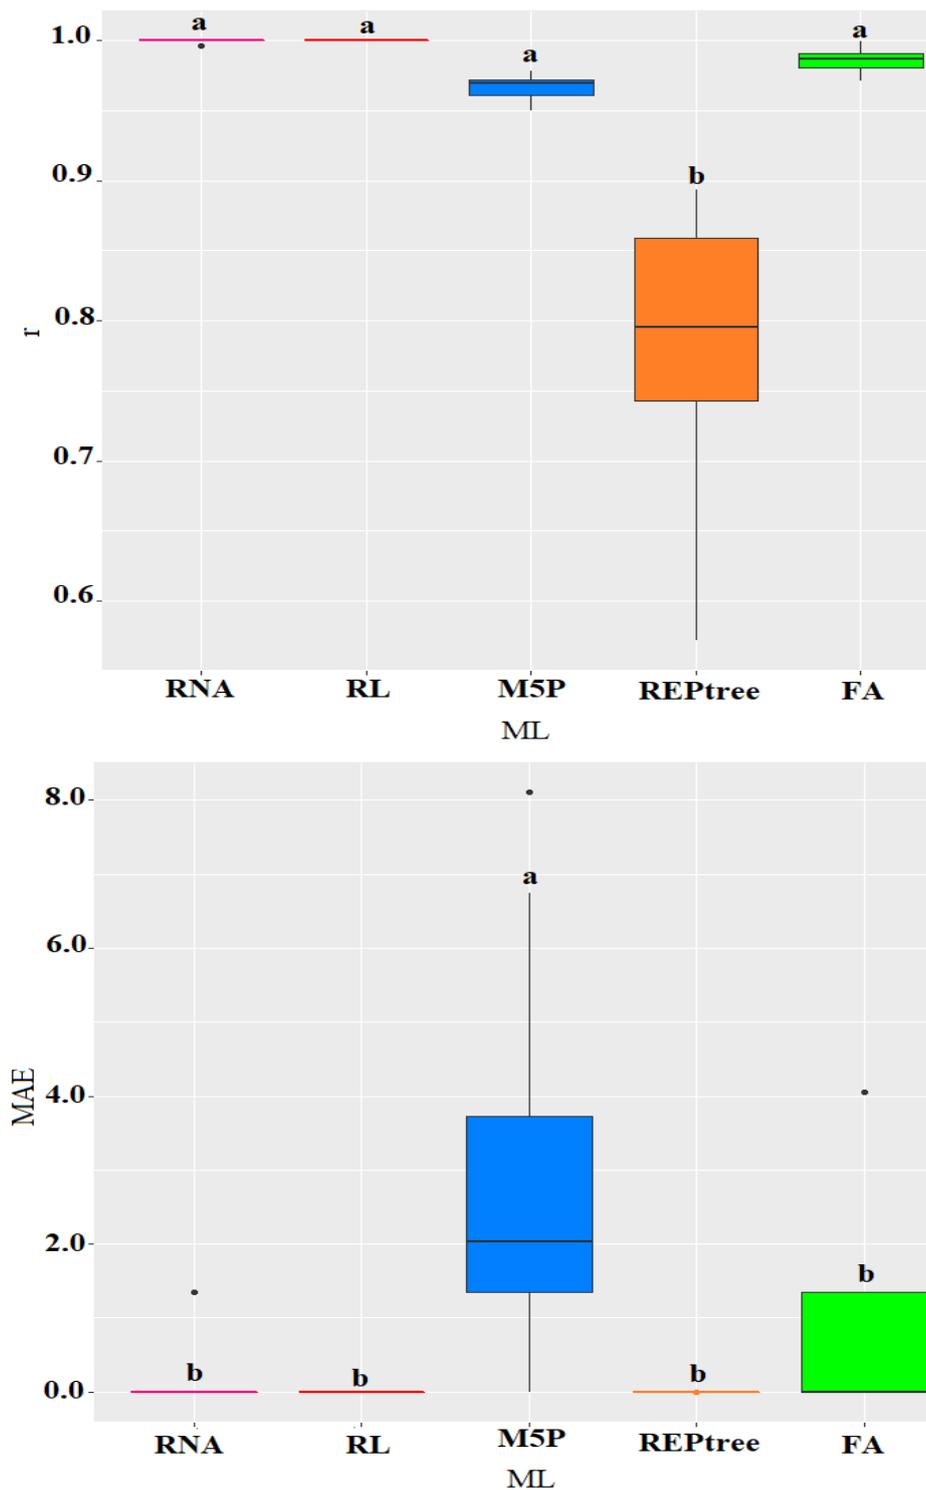
TABELA 2 – Coeficiente de correlação (r), erro médio absoluto (MAE) e coeficiente de determinação (R^2) da predição da perda de matéria seca em grãos trigo armazenados, utilizando algoritmos de Machine Learning (ML)

| Modelos | r | MAE | R² (%) |
|----------------|----------|------------|--------------------------|
| RLm | 1,00 | 0,0000 | 100,00 |
| RNAs | 0,99 | 0,0000 | 98,01 |
| M5P | 0,97 | 0,0001 | 94,09 |
| FA | 0,99 | 0,0000 | 98,01 |
| REPtree | 0,80 | 0,0004 | 64,00 |

(RLm – Regressão Linear Múltipla; RNAs – Redes Neurais Artificiais; M5P – Algoritmos M5 de Quinlan; FA – Floresta Aleatória; REPtree – Árvore de Decisão)

Neste estudo, foram analisados diferentes algoritmos preditivos de Machine Learning (ML), sendo os dados de entrada o tempo de monitoramento, teor de água dos grãos, temperatura (T), umidade relativa (UR), dióxido de carbono (CO₂) e umidade de equilíbrio higroscópico (Ue) para predizer a variável de saída de perda de matéria seca dos grãos de trigo armazenados. Entre as técnicas utilizadas, os algoritmos de Redes Neurais Artificiais (RNA), Floresta Aleatória (FA) e Regressão Linear Múltipla (RL) apresentaram os maiores desempenhos (Tabela 2). Porém, quando os modelos foram avaliados a 5% de probabilidade pelo teste de Scott-Knott (SK), os modelos de RNA, M5P e FA, juntamente com o modelo padrão de RL, foram, os que apresentaram as maiores médias, não diferindo entre si, apenas do modelo REPTree (Figura 12).

FIGURA 13 – Boxplot dos valores preditos de perda de matéria seca em grãos de trigo armazenados pelos modelos de Machine Learning. RNA (Redes Neurais Artificiais), M5P (algoritmo M5 de Quinlan), Floresta Aleatória (RA), Árvore de Decisão (REPtree) e o modelo de Regressão Linear Múltipla (RL). Coeficiente de correlação (r) e o Erro Médio Absoluto (MAE).



Fonte: Autor

5. DISCUSSÃO

Os resultados de temperatura, umidade relativa e dióxido de carbono intergranulares foram similares às medições realizadas no ar, acima da superfície da massa de grãos de trigo armazenada. A difusão de CO₂ nas camadas da massa de grãos pode ser diferente em função das pressões estáticas exercidas pela presença de materiais finos e/ou impurezas, tornando o material poroso heterogêneo (BAKHTAVAR et al., 2019). Neste estudo, verificou-se que os níveis de concentração de CO₂ detectáveis foram similares nos diferentes pontos da massa de grãos, equiparando-se com os níveis medidos no ar do ambiente de armazenamento.

A correlação das variáveis monitoradas foi coerente com a perda de matéria seca (Figura 12). As variações da temperatura e da umidade relativa do ar intergranular (Figuras 7 e 8) influenciaram sobre a conservação da qualidade dos grãos armazenados, visto que, o aumento dessas variáveis intensificou a atividade respiratória e a deterioração dos grãos, gerando perdas de matéria seca. Já a umidade de equilíbrio higroscópico próximos a 11,7% (b.u.) (Figura 9), amenizou a atividade metabólica dos grãos e os níveis de respiração ficaram 300 a 550 ppm de CO₂. A perda de matéria seca está relacionada à respiração dos grãos (KALETA & GÓRNICK, 2013), conforme detectado nos resultados acima (Figuras 7-11). Estes resultados indicaram um processo inicial de deterioração (Figura 10 e 11), embora, somente acima de 1000 ppm poderia se constatar níveis mais avançados (MAIER et al., 2010; RAUDIENĖ et al., 2017).

Considera-se que os grãos com teores de água abaixo de 13,5% apresentam condições seguras de armazenamento (VILLAGÓMES et al. 2020). Entretanto, a variação da temperatura e umidade relativa do ar intergranular (TIECKER JUNIOR et al., 2014, CORADI et al., 2022) causou variações dos teores de água dos grãos, alterando a umidade de equilíbrio higroscópico entre os grãos e o ar intergranular, que mesmo em condições baixas indicou uma redução da qualidade dos grãos. Bakhtavar et al. (2019) avaliou a absorção de água em grãos de trigo, milho, algodão e quinoa em ambientes controlados com umidades relativas de 60, 70, 80 e 90%. Os autores verificaram que os teores de água dos grãos aumentaram com o aumento da umidade relativa do ar, proporcionando aquecimento da massa de grãos e uma respiração mais intensa.

Assim, com o monitoramento das variáveis intergranulares os níveis de perdas podem ser determinados de forma indireta, a fim de estabelecer um tempo máximo aceitável para o armazenamento dos grãos de trigo (LOPES & SÍMILE NETO, 2020). A medição de CO₂ pode ser utilizada para a detecção precoce da deterioração dos grãos (RUDIENĖ et al., 2020), sendo um indicador de estágio inicial de deterioração dos grãos armazenados.

A predição da perda de matéria seca foi realizada pelos modelos de Machine Learning, em que RNA (Redes Neurais Artificiais), M5P (algoritmo M5 de Quinlan), Floresta Aleatória (RA) e o modelo de Regressão Linear Múltipla (RL) alcançaram os melhores resultados (Figura 12). Zeymer et al. (2021), realizou um estudo em que testou diferentes estruturas de modelos para estimar a perda de matéria seca de grãos de soja utilizando dados adquiridos de um sistema de respiração dinâmica de grãos com diferentes teores de água (12, 14, 18, 22%) e temperaturas (25, 30, 35 °C). Os cinco diferentes modelos foram testados, entre eles o Cubista, Floresta Aleatória, Redes Neurais Artificiais, Máquina de Vetor de Suporte com Kernel Polinomial, Máquina de Vetor de Suporte com Kernel Radial. A partir das simulações os autores concluíram que o modelo Floresta Aleatória foi determinado como o modelo que melhor simulou os dados experimentais, sendo recomendado o algoritmo de escolha para prever a perda de matéria seca do grão em função da temperatura e do teor de umidade durante o armazenamento.

6. CONCLUSÃO

O monitoramento da variável temperatura, umidade relativa e a concentração de dióxido de carbono do ar intergranular determinaram de forma indireta e precocemente as alterações de qualidade dos grãos de trigo durante o armazenamento, para tomada de decisão.

A detecção amostral das variáveis intergranulares conseguiu caracterizar as perdas de matéria seca e a redução de 0,035% peso dos grãos armazenados.

O modelo de Redes Neurais Artificiais previu satisfatoriamente a perda de matéria seca da massa de grãos de trigo armazenados.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABALONE, R.; GASTÓN, A.; BAARTOSIK, R.; CARDOSO, L.; RODRIGUEZ, J. Gas concentration in the interstitial atmosphere of a wheat silo-bag. Part I: Model development and validation. **Journal of Stored Products Research**. v.47, p.268-275, 2011.
- ALENCAR, E, R.; FARONI, L, R, D.; FILHO, A, F, L.; PERTERNELLI, L, A.; COSTA, A, R. Qualidade dos grãos de soja armazenados em diferentes condições. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n.5, p. 606-613, 2009.
- ANDRÉ, G, S.; CORADI, P, C.; TEODORO, L, P, R.; TEODORO, P, E. Predicting the quality of soybean seeds stored in different environments and packaging using machine learning. **Scientific Reports**, v.12, p.1-13. 2022
- BAKHTAVAR, M, A.; AFZAL, I.; BASRA, S, M, A. Moisture adsorption isotherms and quality of seeds stored in conventional packaging materials and hermetic Super Bag. **Plos One**, v. 14, n. 2, p. e0207569, 2019.
- 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.
- BAZONI, B, H, V.; IDA, E, I.; BARBIN, D, F.; KUROZAWA, L, E. Near-infrared spectroscopy as a rapid method for evaluation physicochemical changes of stored soybeans. **Journal of Stored Products Research**, v.73, p.1-6, 2017.
- BELGIU, M.; DRĂGUȚ, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24– 31, 2016.
- BLAIFI, S. A.; MOULAHOU, S.; BENKERCHA, R.; TAGHEZOUIT, B.; SAIM, A.; M5P model tree based fast fuzzy maximum power point tracker. **Solar Energy**, v. 163, p. 405-424, 2018.
- BOUCKAERT R. et al. **WEKA manual for version 3-7-1**, 2010.
- CONAB. Companhia Nacional de Abastecimento. **Acompanhamento da Safra brasileira**. Documento online. Disponível em: <<https://www.conab.gov.br/info-agro/safras/graos/boletim-da-safra-de-graos>> Acesso em: maio de 2022.
- CONAB. Companhia Nacional de Abastecimento. **Armazenagem**. Documento online. Disponível em: <<https://www.conab.gov.br/armazenagem>> Acesso em: maio de 2022.
- CORADI, P, C.; CHAVES, J, B, P.; FILHO, A, F, L.; MOTA, T, O. Quality of stored grain of corn in different conditions. **Científica**, Jaboticabal, v. 42, n.2, p. 118-133, 2014.
- CORADI, P. C., JAQUES, L. B. A. **Dispositivo e processo não destrutivo para monitoramento e controle de qualidade de grãos em transporte, em tempo real**. 2022,

Brasil. Patente: Privilégio de Inovação. Número do registro: BR10202201072, Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial. Depósito: 01 de jun.2022, Instituição(ões) financiadora(s): CNPq; CAPES; FAPERGS.

CORADI, P, C.; LUTZ, É. **CO2 Reader - Sistema de monitoramento da concentração de dióxido de carbono em grãos armazenados. 2022b.** Patente: Programa de Computador. Número do registro: BR512022000960-9, data de registro: 10/05/2022, Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial.

CORADI, P, C.; LUTZ, É. **SmartStorage - Sistema inteligente de monitoramento da qualidade de grãos armazenados. 2022a.** Patente: Programa de Computador. Número do registro: BR512022000638-3, data de registro: 29/03/2022, Instituição de registro: INPI - Instituto Nacional da Propriedade Industrial.

CORADI, P, C.; LUTZ, E.; BILHALVA, N, S.; JAQUES, L, B, A.; LEAL, M, M.; TEODORO, L, P, R. Prototype wireless sensor network and Internet of Things platform for real-time monitoring of intergranular equilibrium moisture content and predict the quality corn stored in silos bags. *Expert Systems with Applications*, v. 1, p. 118242, 2022.

DAIA, 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.1-23, 2018.

ELIAS, M, C.; LOPES, V.; GUTKOSKI, L, C.; OLIVEIRA, M.; MAZZUTTI, S.; DIAS, A, R, G. Umidade de colheita, métodos de secagem e tempo de armazenamento na qualidade tecnológica de grãos de trigo (cv.'Embrapa 16'). *Ciência Rural*, v. 39, n. 1, p. 25-30, 2009.

EGMONT-PETERSEN, M.; DE RIDDER, D.; HANDELS, H. Image processing with neural networks—a review. *Pattern recognition*, v. 35, n. 10, p. 2279-2301, 2002.

FAO- Food and Agriculture Organization of the Unites Nations. **Save and Grow in practice: A guide to sustainable cereal production.** 2016. Documento online. Disponível em: <<http://www.fao.org/3/a-i4009e.pdf>> Acesso: maio de 2022

FAO- Food and Agriculture Organization of the Unites Nations. **Crops and livestock products.** 2020. Documento online. Disponível em <<https://www.fao.org/faostat/en/#data/QCL/>> Acesso: maio de 2022

FAO- Food and Agriculture Organization of the Unites Nations. **World Food Situation** Documento online. Disponível em <<https://www.fao.org/worldfoodsituation/csdb/en/>> Acesso: maio de 2022

FILHO, E. F.; ANTUNES, L, E, G.; GOTARDI, R.; DIONELLO, R. G.; PETRY, P. A, R.; BARRETO, G. P. Qualidade de grãos de trigo submetidos a diferentes condições de armazenamento. *Pesquisa Agropecuária Gaúcha*, v. 18, n. 1, p. 25-35, 2012.

FERRASA, M.; BIAGGIONI, M. A. M.; DIAS, A. H. Sistema de monitoramento da temperatura e umidade em silos grane-leiros via radiofrequência (RF). *Revista Energia na Agricultura*, v.25, n.2, p. 139-156, 2010.

HARTMANN FILHO, C. P.; GONELI, A. L. D.; MASETTO, T. E.; MARTINS, E. A. S.; OBA, G. C.; SIQUEIRA, V. C. Quality of second season soybean submitted to drying and storage. **Pesquisa agropecuária tropical**, v.46, n.3, p.267-275, 2016.

HUANG, H.; DANAIO, M. G. C.; RAUSCH, K. D.; SINGH, V. Diffusion and production of carbon dioxide in bulk corn at various temperatures and moisture contents. **Journal Stored Products Research**, v. 55, p. 21-26, 2013.

JAQUES, Lanes Beatriz Acosta. **Desenvolvimento e Validação de um dispositivo para monitoramento da qualidade da massa de grãos de soja no transporte rodoviário**. 2021. Tese (doutorado) – Centro de Ciências Rurais, Universidade Federal de Santa Maria, Santa Maria, RS, 2021. Disponível em: https://repositorio.ufsm.br/bitstream/handle/1/23719/TES_PPGEA_2021_JAQUES_LANES.pdf?sequence=1&isAllowed=y. Acesso em: 01 jun. 2022.

KALETA, A.; GÓRNICKI, K. Criteria of Determination of safe grain storage time- A review. **Advances in Agrophysical Research**, v.12, p.300-3017, 2013.

LIAKOS K. G.; BUSATO P.; MOSHOU D.; PEARSON, S.; BOCHTIS D. Machine Learning in Agriculture: A Review. **Sensors**, v.18, n.8: 2674, 2018.

LISBOA, L. M.; ARAÚJO, H.; PAIVA, G.; ORIENTE, S.; PASQUALI, M.; DUARTE, M. E.; MATA, M. E. C. Determination of characteristic properties of mulatto beans (*Phaseolus vulgaris* L.) during convective drying. **Journal of Agriculture and Food Research**, v.1, p.1-6, 2019.

LOPES, D. C.; STEIDLE, N. J. Modelling the dry matter loss of coffee beans under different storage conditions. **Journal of Stored Products Research**, v.88, n.1, p.1-7, 2020.

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, p.110609, 2021.

LUTZ, É., CORADI, P. C.; JAQUES, L. B. A.; CARNEIRO, L. O.; TEODORO, L. P. R.; TEODORO, P. E.; MENEGHETTI, V. L.; SOUZA, G. A. C. Real-time equilibrium moisture content monitoring to predict grain quality of corn stored in silo and raffia bags. **Journal of Food Process Engineering**, e14076, 2022.

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.

MORITA, N.; MAEDA, T.; MIYAZAKI, M.; YAMAMORI, M.; MIURA, H.; OHTSUKA, I. Dough and baking properties of high-amylose and waxy wheat flours. **Cereal Chemistry**, v.79, n.4, p.491-495, 2002.

NEETHIRAJAN, S.; FREUND, M. S.; JAYAS, D. S.; SHAFI, C.; THOMSON, D. J.; WHITE, N. D. G. Development of carbon dioxide (CO₂) sensor for grain quality monitoring. **Biosystems Engineering**, v.30, n.4, p.395-404, 2010.

- NOURBAKSH, S, M.; BAI, Y.; MAIA, G, D, N.; OUYANG, Y.; RODRIGUEZ, L. Grain supply chain network design and logistics planning for reducing post- harvest loss. **Biosystems Engineering**, v.153, p.105-115, 2016.
- PARK, C, E.; KIM, Y, S.; PARK, K, J.; KIM, B, K. Changes in physicochemical characteristics of rice during storage at different temperatures. **Journal of Stored Products Research**, v.48, p.25-29, 2012.
- RAMACHANDRAN, R. P. Integrated Approach on Stored Grain Quality Management with CO.sub.2 Monitoring-A Review. **Journal of Stored Products Research**, v.96, p.101950, 2022.
- REHMAN, Z, U.; HABIB, F.; ZAFAR, S, I. Nutritional changes in maize (*Zea mays*) during storage at three temperatures. **Food Chemistry**, v.77, p.197-201, 2002.
- RAUDIENE, E.; RUSINSKAS, D.; BALCIUNAS, G.; JUODEIKIENE, G.; GAILIUS, D. Carbon Dioxide Respiration Rates in Wheat at Various Temperatures and Moisture Contents. **Journal of Metrology Society of India**, v.21, n.1, 2017.
- RAUDIENE, E.; GAOLIUS, D.; DOBILENE, J.; GINTAUTAS, BALCIUNAS, G.; MESKUOTIEN, A. Assessment of Qualitative Characteristics of Carbon Dioxide Respiration Rates Evaluation in Wheat Measurements. **Journal of Metrology Society of India**, p.1-7, 2020.
- SANTANA, D, C.; COTRIM, M, F.; FLORES, M, S.; BAIIO, F, H, R.; SHIRATSUCHI, L, S.; DA SILVA JUNIOR, C, A.; TEODORO, P. E. UAV-based multispectral sensor to measure variations in corn as a function of nitrogen topdressing. **Remote Sensing Applications: Society and Environment**, v.23, p.100534, 2021
- SANTOS, S, B.; MARTINS, M, A.; FARONI, L, R, A.; JUNIOR, V, R, B. Perda de matéria seca em grãos de milho armazenados em bolsas herméticas. **Revista Ciência Agronômica**, v. 43, n. 4, p. 674- 682, dez. 2012.
- SHARMA R.; KAMBLE S.S.; GUNASEKARAN A.; KUMAR V.; KUMAR A. A systematic literature review on machine learning applications for sustainable agriculture supply chain performance. **Computers and Operations Research**, v.119, p.104926, 2020
- SMNIOTTO, T, A, S.; RESENDE, O.; MARÇAL, L, A, F.; OLIVEIRA, D, E, C.; SIMON, G, A. Qualidade fisiológica das sementes de soja armazenadas em diferentes condições. **Revista Brasileira de Engenharia Agrícola e Ambiental**. v.18, n.4, p.446-453, 2014.
- TAHER, H, I.; URCOLA, H, S.; CENDOYA, M, G.; BARTOSIK, R, E. Predicting soybean losses using carbon dioxide monitoring during storage in silo bags. **Journal of Stored Products Research**, v.82, p.1-8, 2019.
- TIECKER J. A.; GUIMARÃES, L.E.; FILHO, E. F.; CASTRO, B.; PONTE, E. M. D.; DIONELLO, R. F. Qualidade físico-química de grãos de milho armazenados com diferentes umidades em ambientes hermético e não hermético. **Revista Brasileira de Milho e Sorgo**, v.13, n.2, p. 174-186, 2014.

TEODORO, P, E.; TEODORO, L, P, R.; BAIO, F, H, R.; JUNIOR, C, A, S.; SANTOS, R, G.; RAMOS, A, P, M.; PINHEIRO, M, M, F.; OSCO, L, P.; GONÇALVES, W, N.; CARNEIRO, A, M.; JUNIOR, J, M.; PISTORI, H.; SHIRATSUCHI, L, S. Predicting days to maturity, plant height, and grain yield in soybean: A machine and deep learning approach using multispectral data. **Remote sensing**, v.13, ed. 22, 2021.

VILLAGÓMEZ, L, I, Q.; HERRARA, F, I, M.; RODRIGUEZ, M, C.; RAMIREZ, M, C.; GONZÁLES, G, M.; BOLAÑOS, J, L, N.; ISLAS, H, J. Numerical Study to Predict Temperature and Moisture Profiles in Unventilated Grain Silos at Prolonged Time Periods. **International Journal of Thermophysics**, v.41, n.52, p.1-28, 2020.

WU W.; CUI H.; HAN F.; LIU Z.; WU X., WU Z.; ZHANG Q. Digital monitoring of grain conditions in large-scale bulk storage facilities based on spatiotemporal distributions of grain temperature. **Biosystems Engineering**, v.210, p.247-260, 2021.

ZEYMER, J, S.; GUZZO, F.; ARAÚJO, 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 (*Glycine max L.*). **Journal of Food Process Engineering**, v.44, n.10, p.1-29, 2021.