



MODELAGEM MATEMÁTICA DA DETERMINAÇÃO DO TEOR DE UMIDADE EM GRÃOS DE MILHO: COMPARAÇÃO ENTRE REGRESSÃO LINEAR E REDES NEURAIIS ARTIFICIAIS¹

MATHEMATICAL MODELING OF MOISTURE CONTENT DETERMINATION OF MAIZE GRAINS: COMPARISON BETWEEN LINEAR REGRESSION AND ARTIFICIAL NEURAL NETWORKS.

Marcelo Carvalho Antunes², Manuel Osório Binelo³, Marcia de Fátima Brondani Binelo⁴

¹ Projeto de pesquisa desenvolvido na UNIJUÍ.

² Estudante do Programa de Pós-Graduação em Modelagem Matemática e Computacional, UNIJUÍ.

³ Professor do Programa de Pós-Graduação em Modelagem Matemática e Computacional, UNIJUÍ.

⁴ Professora do Programa de Pós-Graduação em Modelagem Matemática e Computacional, UNIJUÍ.

RESUMO

A cadeia produtiva de grãos pode ser influenciada por inúmeros fatores, desde a colheita até sua comercialização. A verificação dos teores de umidade constitui uma prática destacada, pois influencia no seu valor de mercado. Os métodos diretos, como dessecação por estufa, têm como princípio mensurar a massa de água que é subtraída após a secagem. Os métodos indiretos, apesar de serem menos precisos, demandam menores quantidades de tempo e são mais práticos que os primeiros. Como parâmetros para a medição do teor de umidade, utilizam algumas propriedades elétricas dos grãos, estabelecendo, dessa maneira, medidas de correlação com o teor de umidade. O presente trabalho tem o objetivo de realizar a modelagem matemática dos teores de umidade em grãos de milho através de medidas elétricas como tensão e frequência e, posteriormente comparar os resultados obtidos por Regressão Linear Múltipla e Redes Neurais Artificiais. Os dados foram fornecidos por uma empresa que coletou amostras e realizou experimentos com grãos de milho à temperatura ambiente. Para a realização da Regressão Linear, foram obtidas ferramentas estatísticas a partir do software MATLAB. A análise dos dados por meio de Redes Neurais Artificiais foi executada utilizando a plataforma de computação *Colaboratory (Colab)*. O estudo concluiu que, dentro da faixa de valores utilizados, existe grande proximidade entre os dados obtidos experimentalmente e calculados através da modelagem, principalmente para o método das Redes Neurais.

Palavras-chave: Umidade. Milho. Regressão linear. Redes Neurais Artificiais.

ABSTRACT

The grain production chain can be influenced by numerous factors, from harvesting to commercialization. The assessment of moisture content is a notable practice as it impacts its market value. Direct methods, such as oven drying, work on the principle of measuring the mass of water subtracted after drying. Indirect methods, while less precise, require less time and are more practical than the former. As parameters for moisture measurement, certain electrical properties of grains are used, establishing correlation measures with moisture content. The present study aims to mathematically model the moisture content in maize grains using electrical measurements such as voltage and frequency, and subsequently compare the results obtained through Multiple Linear Regression and Artificial Neural Networks. The data were provided by a company that collected samples and conducted experiments with maize grains at

room temperature. For the Multiple Linear Regression, statistical tools were obtained using MATLAB software. The analysis of data through Artificial Neural Networks was performed using the Colaboratory computing platform (Colab). The study concluded that, within the range of values used, there is a significant proximity between experimentally obtained data and those calculated through modeling, especially for the Artificial Neural Networks method.

Keywords: Moisture. Maize. Linear Regression. Artificial Neural Networks.

INTRODUÇÃO

O Brasil é um dos principais atores do cenário mundial do mercado agrícola (EMBRAPA, 2020; CONAB, 2022; FAO, 2022), o que contribui para o aumento da balança comercial do país, fomentando o mercado de trabalho e beneficiando as regiões produtoras (MARCONI, 2020). O milho é um dos cereais mais cultivados no mundo e sua importância ganha contornos espessos em função do seu emprego na alimentação humana e animal, bem como pelo elevado potencial produtivo e valor nutritivo dos grãos (MAXIMILIANO, 2017).

No entanto, apesar do reconhecido progresso na produção e comercialização de grãos, deve-se considerar o alto índice de desperdício nos processos de pós-colheita (FAO, 2015); grande parte, implicação direta de procedimentos errôneos ou morosos na determinação do teor de umidade dos grãos. De maneira mais específica, pesquisas consolidadas desde a década de 90 (VALENTINI *et al*, 1998; MELENDEZ, 1992; SILVA, 1997) mostram que a qualidade do cereal é afetada pelo teor de umidade medido nos grãos.

No Brasil, adota-se o método por dessecação em estufa (BRASIL, 2022) como oficial de determinação de umidade em grãos. Este procedimento, assim como os outros métodos diretos, resume-se a retirar a água dos grãos e, após, verificar a diferença de peso das amostras, que define o teor de umidade (PUZZI, 1986). No entanto, a exigência por decisões imediatas tem preterido tais métodos, por alternativas capazes de responder com maior celeridade (TRABELSI; NELSON, 2007).

Desta forma, surgem como alternativa os métodos indiretos, que utilizam como parâmetros algumas propriedades dos grãos, como por exemplo as elétricas. Apesar de apresentarem menor acurácia, necessitam de intervalos menores de tempo (KIN; MONÇALVES; SILVA, 2010); a literatura, infere-se, ainda apresenta um número insuficiente de estudos que considerem mais de uma grandeza elétrica como parâmetros para a determinação do teor de umidade.

O objetivo deste trabalho concentrou-se na obtenção de um modelo para o cálculo de teores de umidade em grãos de milho, através de algumas medidas elétricas. Para tal, foram utilizados e comparados dois métodos: Regressão Linear Múltipla e Redes Neurais Artificiais.

As pesquisas direcionadas à determinação do teor de umidade em grãos podem ser justificadas pelos impactos causados desde o armazenamento até sua comercialização, influenciando, significativamente, o valor de venda da mercadoria (BESSA, 2013). Neste contexto, a modelagem matemática e computacional justifica-se como uma alternativa interessante, enquanto ferramenta científica, para o incremento de ações que possibilitem um controle satisfatório dos teores de umidade em grãos. O texto apresenta uma divisão proposta em 5 seções: Introdução, Metodologia, Resultados e Discussões, Considerações Finais e Referências Bibliográficas.

METODOLOGIA

Esta pesquisa foi desenvolvida a partir de um experimento com grãos de milho utilizando-se um método indireto de determinação de umidade. Como parâmetros para a medição do teor de umidade, foram utilizadas algumas propriedades elétricas dos grãos (tensão e frequência), com o objetivo de registrar possíveis alterações que podem ser associadas aos teores de umidade dos grãos.

A temática deste trabalho, inicialmente, teve seus pressupostos e aproximações teóricas traçadas a partir da literatura encontrada em plataformas de pesquisa, como o portal da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), a biblioteca eletrônica online SciELO e a Biblioteca Digital Brasileira de Teses e Dissertações (BDTD). Os trabalhos foram categorizados a partir da leitura de seus títulos e resumos, produzindo-se 2 categorias: textos que concentravam informações sobre a determinação de umidade a partir de uma grandeza elétrica e textos que descrevessem mais de uma grandeza.

Após a revisão bibliográfica, foi realizado o experimento. Os ensaios foram conduzidos no laboratório de uma empresa no município de Ijuí, no Rio Grande do Sul. O equipamento utilizado foi um medidor de umidade de grãos, com estrutura em metal, medindo 30 cm de largura, 45 cm de altura e 30 cm de profundidade.

Foram utilizados grãos de milho da safra 20/21, adquiridos na Cerealista Seriema, localizada em Ijuí, selecionados de forma aleatória. Inicialmente, os grãos foram

homogeneizados e mantidos à temperatura de 7,5°C, com variação de 1°C, para uniformizar o teor de umidade e evitar a fermentação. Após 5 dias, eles foram retirados do refrigerador e, em algumas horas, atingiram a temperatura ambiente.

Desta forma, os grãos foram acondicionados no equipamento e, pelo intervalo de 5 segundos, foram medidos os valores da temperatura, da frequência, com a ausência e, posteriormente, com a presença de grãos e da tensão. Considerou-se, para efeitos de cálculo, os valores da temperatura com a presença de grãos e a diferença entre os valores obtidas para a frequência.

Durante o experimento, foram consideradas 10 amostras numa faixa de umidade compreendida entre 11% e 20,4%, em temperatura ambiente, de 18°C e 19,5°C. Os valores obtidos (tensão e frequência) com a variação da umidade foram todos armazenados (figura 1) em uma planilha eletrônica e, em seguida, gerados modelos com resposta de teores de umidade através de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA), permitindo-se medir a magnitude do erro de cada ferramenta. Verificou-se que cada amostra apresentou o mesmo valor de umidade para os grãos de milho. A figura 1 apresenta os valores da umidade observada e os valores (média aritmética) das grandezas das variáveis independentes em cada amostra.

Figura 1 – Dados do experimento.

	umidade observada [%]	média da temperatura [°C]	média da diferença de frequência [Hz]	média da tensão [V]
amostra 1	11,0	19,6	129940,0	1,3
amostra 2	12,7	18,7	142518,0	87,7
amostra 3	13,7	18,6	144197,7	106,3
amostra 4	14,4	18,5	151491,0	173,7
amostra 5	15,1	18,5	160692,7	238,0
amostra 6	16,3	18,4	165740,3	290,0
amostra 7	16,9	18,4	176666,3	359,3
amostra 8	18,3	18,4	185948,7	388,3
amostra 9	19,5	18,3	192253,3	419,3
amostra 10	20,4	18,5	203196,3	440,7

Fonte: própria dos autores.

O modelo de RLM possui o objetivo de estimar uma função que descreve a relação entre as variáveis (mais do que duas), dependendo de suas médias aritméticas, desvios-padrões e da correlação entre elas (COHEN *et al.*, 2003). A função de regressão (amostral) com i



observações e k variáveis independentes, a equação (COHEN *et al.*, 2003) pode ser representada por:

$$y_i = \beta_0 + \beta_1 x_{i1} + \beta_2 x_{i2} + \dots + \beta_k x_{ik} + e_i, \quad \text{com } i = 1, \dots, n. \quad (1)$$

O coeficiente β_0 é o intercepto e os parâmetros $\beta_1, \beta_2, \dots, \beta_k$ representem as inclinações nas i retas de um sistema. O método busca a aproximação do conjunto de pontos (x_i, y_i) , fazendo com que os valores do erro $e_i (|y_i - \hat{y}_i|)$, as diferenças entre os valores conhecidos e os calculados (ordenadas) seja a menor possível (CHEIN, 2019). Em termos matemáticos, isto é realizado através do Método dos Mínimo Quadrados (STOCK; WATSON, 2009).

Nesta pesquisa, foi utilizada uma abordagem matricial, capaz de simplificar o trabalho computacional. Deste modo, pode-se reescrever (1) da seguinte forma:

$$Y = X\beta + \epsilon, \quad \text{ou, equivalentemente} \quad (2)$$

$$\begin{bmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{bmatrix} = \begin{bmatrix} 1 & x_{11} & \dots & x_{1k} \\ 1 & x_{21} & \dots & x_{2k} \\ \vdots & \vdots & \ddots & \vdots \\ 1 & x_{n1} & \dots & x_{nk} \end{bmatrix} \begin{bmatrix} \beta_1 \\ \beta_2 \\ \vdots \\ \beta_n \end{bmatrix} + \begin{bmatrix} \epsilon_1 \\ \epsilon_2 \\ \vdots \\ \epsilon_n \end{bmatrix}. \quad (3)$$

Este método foi aplicado, a partir da seguinte rotina: (a) coleta e tabulação dos dados; (b) definição das variáveis – a escolha das variáveis foi realizada com base em estudos anteriores; outras medidas elétricas poderiam ter sido selecionadas. Destas escolhas, dependem uma série de fatores, como por exemplo os valores do coeficiente de determinação (R^2) que mede a correlação entre as variáveis (FIELD, 2009). Foram escolhidas como variável dependente a umidade (u), enquanto temperatura (x_1), frequência (x_2) e tensão (x_3) representaram as variáveis explicativas. (c) Executar a RLM no software MATLAB. O objetivo, nesta etapa, é obter as medidas estatísticas e os coeficientes que formam as equações (modelo de RLM) para a determinação dos teores de umidade dos grãos de milho. Além disso, são obtidas as medidas de estatística de regressão: erro padrão, coeficiente de regressão, coeficiente de regressão ajustado, o valor de F de significação e o valor- p .

Após os resultados obtidos com a RLM, foi utilizado um outro método de modelagem. As Redes Neurais Artificiais, conhecidas como “um modelo matemático que procura simular a estrutura e a funcionalidade de uma rede neural biológica” (KRENKER; BEŠTER; KOS, 2011, p. 3), possuem uma estrutura baseada em unidades fundamentais de processamento que realizam inúmeras conexões, denominadas neurônios.

Em linhas gerais, a estrutura da rede é configurada com base na determinação do número de camadas (entrada, ocultas e saída) e na quantidade de neurônios em cada camada (ERTEL, 2018). A característica fundamental das redes neurais reside na capacidade de aprender a partir de modelos, ou seja, por meio da experiência adquirida durante o treinamento da rede. Esse processo ocorre através de ajustes ponderados realizados a cada iteração matemática. O objetivo é permitir que a rede neural compreenda as interconexões existentes nos dados, até que um conjunto de regras definidas (algoritmo de aprendizagem) seja identificado para resolver uma classe específica de problemas (aprendizado) (KRENKER; BEŠTER; KOS, 2011).

A estrutura de uma rede neural pode variar, dependendo do seu propósito, sendo frequentemente empregada em modelagem, aplicações e implementações. No contexto de modelagem, uma divisão da rede pode ser feita em três níveis: neurônios, arquitetura (que define a estrutura das conexões) e o algoritmo de aprendizado, que descreve um método para alterar o estado de cada neurônio e suas conexões, a fim de modificar o comportamento da rede como um todo (KRENKER; BEŠTER; KOS, 2011). De maneira abrangente, a topologia da rede é configurada a partir da especificação do número de camadas (entrada, ocultas e saída) e da quantidade de neurônios em cada camada (ERTEL, 2018). De maneira geral, a topologia da rede é organizada com base na determinação do número de camadas (entrada, ocultas e saída) e do número de neurônios em cada camada (ERTEL, 2018). A característica fundamental das redes neurais é a capacidade de aprender a partir de modelos – pela experiência –, ou seja, do treinamento da rede. Este evento ocorre por meio de ajustes ponderados que são realizados a cada iteração matemática, pois pretende-se que a rede neural aprenda as relações existentes entre os dados, até que se encontre um conjunto de regras definidas (algoritmo de aprendizagem) para a solução de uma classe de problemas (aprendizado) (KRENKER; BEŠTER; KOS, 2011).

A análise dos dados, utilizando Redes Neurais Artificiais (RNA), foi realizada por meio de um serviço de nuvem gratuito oferecido pelo Google, chamado *Colaboratory* (Colab). Criado com o propósito de promover a pesquisa em Aprendizado de Máquina e Inteligência Artificial, o *Colab* utiliza uma interface semelhante ao *Jupyter Notebook*, onde textos e códigos são intercalados, normalmente em linguagem *Python* (LEE; PERRET, 2022). Os notebooks são executados em máquinas virtuais baseadas em Linux, projetadas para uso interativo e colaborativo; portanto, desconectam-se após um período de inatividade (NELSON; AMY, 2020).

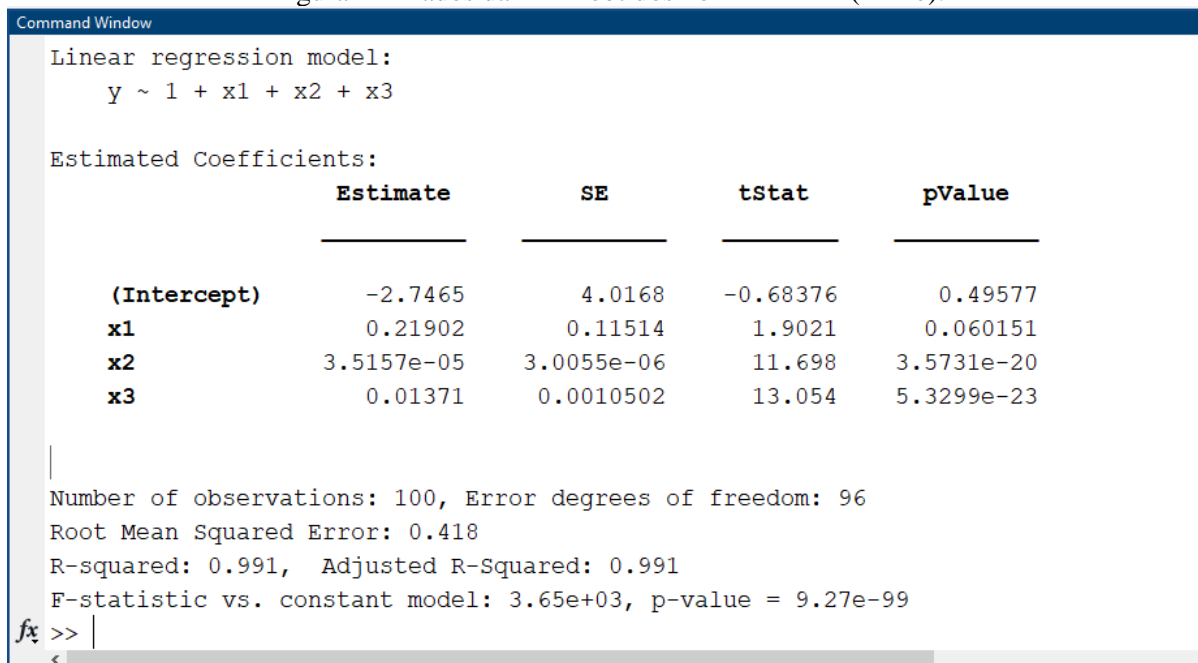
No código de programação, foram empregadas as bibliotecas *Numpy* (para processamento de matrizes e vetores), *NeuroLab* (para criação da rede neural), *Pandas* (para análise de dados) e *Matplotlib* (para geração de gráficos). Inicialmente, após a incorporação da planilha de dados, para realizar o treinamento desta RNA, foi necessário processar as informações agrupando os valores de entrada e saída em matrizes. Para isso, os dados foram normalizados; assim, os valores das colunas no conjunto de informações foram ajustados para uma escala comum, sem distorcer as diferenças nos intervalos de valores.

Para construir esta RNA, o código de programação foi estruturado com 3 entradas (temperatura, frequência e tensão) e uma saída (umidade), e os dados foram divididos da seguinte maneira: 80% para treinamento e 20% para teste. Além das camadas de entrada e saída, cada uma com 1 neurônio, a rede foi configurada com uma camada oculta contendo 6 neurônios. Posteriormente, com base nos valores experimentais medidos para a umidade, foi necessário especificar os parâmetros a serem alcançados. Foram definidos o número de épocas (10000) e o objetivo (0,000001), que normaliza o erro. A validação dos resultados foi realizada por meio do cálculo do Erro Médio Absoluto (diferença entre os valores medidos e observados) e do Erro Relativo (variação em relação ao valor exato).

RESULTADOS E DISCUSSÃO

No MATLAB, foram inseridos, sob a forma de matrizes, os dados referentes às variáveis independentes: temperatura (x_1), frequência (x_2) e tensão (x_3). Desta forma, após o processamento, foram obtidos os dados que produziram o modelo para a determinação de umidade. A figura 2 mostra os dados obtidos por RLM a partir do ensaio com grãos de milho.

Figura 2 – Dados da RLM obtidos no MATLAB (milho).



Fonte: própria dos autores.

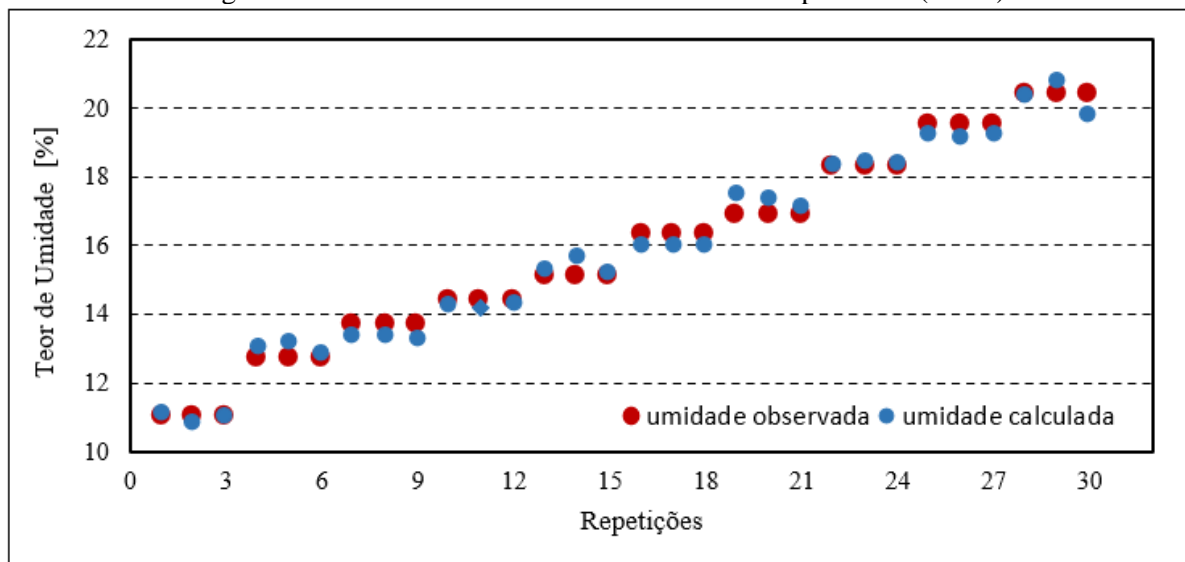
Os coeficientes β_0 , β_1 e β_2 são os números pelos quais as variáveis x_1 , x_2 e x_3 serão multiplicadas. A figura 4 mostra os valores de 9,1506 para β_0 , - 0,65059 para β_1 , 0,00011209 para β_2 e 0,00099584 para β_3 . Esses valores representam a alteração imposta à variável dependente quando a respectiva variável independente variar 1 unidade.

O valor de R^2 ajustado, encontrado neste modelo, foi de 0,987, ou seja, as variáveis independentes explicam juntas 98,7% da variável dependente. Ainda, o diminuto valor do erro-padrão (0,338) indica que as variáveis independentes escolhidas explicam suficientemente o modelo proposto, ou seja, os valores residuais podem ser considerados insignificantes.

O teste F aponta que o modelo proposto é útil para explicar a variável dependente (umidade), visto que o valor obtido para o F de significação ficou extremamente abaixo do valor 0,05. A informação obtida para o “valor – P” informa que somente a variável frequência é significativamente relacionada com a umidade, pois, é a única que apresenta valor menor do que 0,05, em um intervalo de 95% de confiança.

Assim, de acordo com o modelo proposto por Regressão Linear Múltipla, a umidade dos grãos pode ser estimada por: $y(x_1, x_2, x_3) = 9,1506 - 0,6506 x_1 + 0,0001 x_2 + 0,001x_3$. A figura 3 apresenta uma comparação entre os valores observados e os valores calculados para umidade dos grãos.

Figura 3: Umidade observada x umidade calculada por RLM (milho).



Fonte: própria dos autores.

O modelo obtido por RLM mostra resposta bastante próxima aos valores observados, nesta faixa de umidade. O gráfico, ainda, confirma parcialmente as indicações dadas pelas medidas estatísticas, de que as variáveis temperatura, frequência e tensão, quando consideradas concomitantemente, explicam satisfatoriamente o modelo produzido.

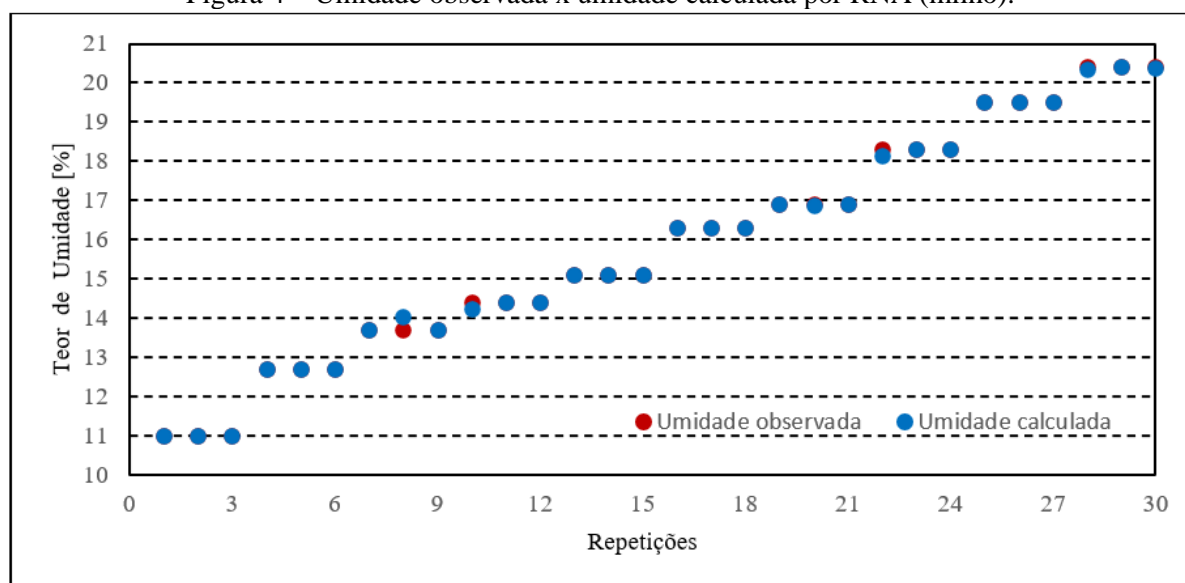
As Redes Neurais Artificiais constituem uma importante ferramenta para auxiliar na busca de modelos preditivos. Desta forma, ao ser percorrido um roteiro de processamento, anteriormente expresso, foi produzido um modelo que buscasse aproximação dos valores medidos da umidade nos grãos. Os resultados obtidos foram plotados em uma planilha eletrônica, produzindo os gráficos, a exemplo do que foi feito por RLM.

Os valores absolutos no treinamento e teste para grãos de milho foram de 0,002 e 0,1026 pontos percentuais. Sublinha-se que o erro de treinamento corresponde às amostras selecionadas para o processo de treinamento (80% escolhidas aleatoriamente) e o erro de teste corresponde às amostras que não fizeram parte do treinamento (20% escolhidas aleatoriamente).

O gráfico da figura 4 (umidade calculada por RNA), se comparado ao gráfico da figura 3, em termos visuais, mostra menores amplitudes de discordância entre os valores observados e calculados dos teores de umidade, mesmo que, a inspeção deste gráfico, ainda indique valores

com menor conformidade entre os dados reais e o modelo, como por exemplo, nas amostras com umidade na faixa de 13 a 15%.

Figura 4 – Umidade observada x umidade calculada por RNA (milho).



Fonte: própria dos autores.

A tabela 1 mostra a comparação entre os erros produzidos pelos modelos de RLM e RNA.

Tabela 1 – comparação do erro absoluto.

Grão	e_{RLM}	$e_{RN\ treino}$	$e_{RN\ teste}$
milho	0,2734	0,002	0,1026

Fonte: própria dos autores.

Com base nos dados fornecidos, fica evidente o desempenho superior do modelo proposto pela Rede Neural Artificial. Essa conclusão é substantiada pelos valores centrais dos erros de treinamento ($e_{RN\ treino}$) e teste ($e_{RN\ teste}$) obtidos com a RNA, em contraste com os valores dos erros absolutos encontrados com o Modelo de Regressão Linear (e_{RLM}).

CONSIDERAÇÕES FINAIS

Neste estudo, foi realizada a modelagem matemática e computacional para determinar o teor de umidade em grãos de milho. Para alcançar este objetivo, foram utilizadas as técnicas de Regressão Linear Múltipla e Redes Neurais Artificiais, a fim de desenvolver modelos

preditivos eficazes que pudessem inferir a umidade nos grãos, a partir de medidas elétricas de frequência e tensão. Os resultados mostraram que o método RNA é superior para modelar a inferência da umidade pois apresentou erros mais baixos que a RLM tanto de treinamento quanto de teste.

REFERÊNCIAS BIBLIOGRÁFICAS

- BESSA, W. K. S. **Avaliação do método capacitivo de placas coplanares para determinação da umidade dos grãos de soja em movimento**. 2013. 104 p. Dissertação (Mestrado em Sistemas Eletrônicos) – Faculdade de Engenharia Elétrica, Universidade Federal do Paraná, Curitiba, 2013.
- BRASIL. Ministérios da Agricultura, Pecuária e Abastecimento. Online. Acessado em 15/03/2022, <https://www.gov.br/agricultura/pt-br/>.
- CONAB. Companhia Nacional de Abastecimento. Acompanhamento da safra brasileira – grãos: Oitavo levantamento, maio 2022 – safra 2021/2022. Brasília/DF. 2022. Disponível em: <https://www.onab.gov.br/info-agro/safra/graos>
- CHEIN, F. **Introdução aos modelos de regressão linear: um passo inicial para compreensão da econometria como uma ferramenta de avaliação de políticas públicas**. Brasília: ENAP, 2019.
- COHEN, J., COHEN, P., WEST, S.G.; AIKEN, L.S. **Applied Multiple Regression. Correlation Analysis for the Behavioral Sciences**. New jersey: 1983.
- ERTEL, W. Introduction to artificial intelligence. [S.l.]: Springer, 2018.
- EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **VII Plano Diretor da Embrapa: 2020 – 2030**. Brasília/DF, 2020. Disponível em: <https://www.embrapa.br/vii-plano-diretor/a-agricultura-brasileira>. Acesso em: maio. 2022.
- FAO. Food and Agriculture Organization of the United Nations. Disponível em: <https://www.fao.org/faostat/en/#data>. Acesso em: jun. 2022.
- KRENKER, A.; BEŠTER, J.; KOS, A. Introduction to the Artificial Neural Networks. Artificial Neural Networks: Methodological Advances and Biomedical Applications. InTech, p. 1–18, 2011.
- LEE, I. ; PERRET, B. Preparing High School Teachers to Integrate AI Methods into STEM Classrooms. In: **Proceedings of the AAAI Conference on Artificial Intelligence**. 2022. p. 12783-12791.
- MARCONI, N. O mercado de trabalho ajudará a economia brasileira a se recuperar? Revista Conjuntura Econômica, v. 74, n. 2, p. 17–21, 2020.
- MAXIMIANO, C. V. Pré-condicionamento de sementes de milho em água com diferentes concentrações de ozônio no desenvolvimento inicial de plântulas e no controle de *fusarium spp*. 2017.
- MELLENDEZ, J.; GRENOVERO, S.; CAPELLACCI, H. Anticipated maize harvest in Entre Rios province. In: Congresso argentino de ingeniería rural, 2, 1992, Villa Maria, Argentina.

NELSON, S.O., GUO, W.C., TRABELSI, S.; KAYS, S.J., Dielectric spectroscopy of watermelons for quality sensing. **Measurement Science and Technology**, IOP Publishing, v. 18, n. 7, p. 1887, 2007.

NELSON, M. J.; HOOVER, A. K. Notes on using Google Colaboratory in AI education. In: **Proceedings of the 2020 ACM conference on innovation and Technology in Computer Science Education**. 2020. p. 533-534

PUZZI, D. *Abastecimento e Armazenagem de Grãos, Campinas, SP: Instituto Campineiro de Ensino Agrícola, 1986.*

R. A. KIN; V. A. MONÇALVES; L. H. DA SILVA. “Comparação entre métodos de determinação de umidade para arroz em casca (*Oryza sativa L*)”. Em: Anais do Salão Internacional de Ensino, Pesquisa e Extensão 2.1 (2010).

SILVA, J.S.; CARVALHO, G.R. **Amostragem e determinação de umidade de grãos**. Viçosa, Centreinar, 1980. 26 p.

STOCK, J. H.; WATSON, M. W. Introduction to econometrics, 2/e. Instructor, Addison-Wesley, v. 10, 2009.

VALENTINI, Sílvia Regina de T.; CASTRO, Maria FP; ALMEIDA, Fernanda H. de. Determinação do teor de umidade de milho utilizando aparelho de micro-ondas. **Food Science and Technology**, v. 18, p. 237-240, 1998.