

**Evento:** XXXIII Seminário de Iniciação Científica ▾

DETERMINAÇÃO DA UMIDADE DE EQUILÍBRIO HIGROSCÓPICO DE GRÃOS DE SOJA POR MEIO DE REDES NEURAIS ARTIFICIAIS¹

Joana Garcia Câmara², Manuel Osório Binelo ²³, Marcia de Fatima Brondani Binelo⁴¹ Projeto de pesquisa desenvolvido na Unijuí.² Bolsista; estudante do curso Engenharia Elétrica; Bolsista do programa de fomento: Programa Institucional de Bolsas de Iniciação Científica do Conselho Nacional de Desenvolvimento Científico e Tecnológico - PIBIC/CNPq.³ Professor (a) Dr. orientador(a) do projeto Secagem Artificial e Armazenamento de Grãos de Soja: Estudo Experimental e Simulação Numérica.⁴ Professora do PPGMMC, UNIJUÍ.

INTRODUÇÃO

Segundo o último boletim do CONAB (2025), a safra de soja 2024/25 é estimada em 166.013,8 mil toneladas (12,4% maior que a anterior), sendo produzido 3.499 kg/ha em uma área total de 47.450,6 mil ha. Já na safra 2023/24, foram produzidas 147.718,7 mil toneladas e exportadas mais de 204 mil toneladas de soja em grãos.

Perante aos altos índices de produção dos grãos de soja, Cassel et al. (2022) determina que um dos fatores essenciais para a pesquisa de sistemas de secagem, armazenamento e transporte de grãos é o conhecimento sobre o comportamento higroscópico. Carvalho et al. (2024) determina que materiais higroscópicos como o grãos tem a capacidade de ceder ou absorver água do ambiente, pois buscam manter uma relação de equilíbrio dos teores de umidade do grão e do ar ambiente.

A umidade de equilíbrio higroscópico, também referida como teor de umidade de equilíbrio, é o nível de umidade de grãos após serem expostos às condições ambientes por um período elevado (Deshmukh, 2017). Ao serem armazenados, os grãos de soja podem enfrentar diferentes condições o que afeta diretamente a qualidade e durabilidade do produto, Smaniotto et al. (2014) ao realizarem pesquisas avaliando a qualidade da semente de soja em diferentes temperaturas e umidade relativa do ar, constataram que a umidade relativa apresentou influência no estado de conservação e que as melhores condições para armazenamento são a de umidade relativa em torno dos 12% e temperatura igual a 20°C.

Para que não haja tantas perdas na produção por problemas relacionados à umidade, existe uma demanda por modelos e métodos precisos para a estimar a umidade dos grãos em

diferentes condições, isto leva a integração com a inteligência artificial (IA) (PINHEIRO et al., 2021). Como um dos métodos mais comuns de IA desenvolvidos e estudados atualmente, as redes neurais artificiais (RNAs) são algoritmos que constroem modelos matemáticos que simulam a atividade realizada pelas células cerebrais, podem ser divididas entre as de camada única ou multicamadas. As redes neurais de camada simples possuem suas entradas conectadas a apenas uma saída, já uma RNA multicamada tem uma estrutura semelhante a de camada simples, porém com camadas ligadas entre si por sinapses com "pesos" (SILVA, 2019).

Deste modo, serão realizados experimentos com amostras de grãos de soja em diferentes condições de temperatura e umidade relativa do ar em que será determinada a umidade de equilíbrio higroscópico dos grãos e a partir dos dados obtidos será elaborada e treinada uma RNA para a determinação do mesmo parâmetro em diferentes condições.

METODOLOGIA

Os dados utilizados foram colhidos dos experimentos realizados no laboratório de Bromatologia da UNIJUÍ, utilizando diferentes amostras de soja, a determinação da umidade de equilíbrio higroscópico por meio do método de estufa dos grãos de soja, é feita através de diferentes amostras expostas às condições determinadas de temperatura e umidade por um período de tempo na estufa. Sendo o método mais utilizado no Brasil, sua parametrização se dá pelo item 7.17 das Regras para Análise de Sementes, elaborado pelo Ministério da Agricultura, Pecuária e Abastecimento (BRASIL, 2009), em que é possível calcular o teor de umidade em porcentagem (U) de uma amostra exposta por 24 horas a $105 \pm 3^\circ\text{C}$, por meio de:

$$U = \frac{100 (P - p)}{P - t}$$

em que P é o peso inicial; p é o peso final, nos dois casos isto inclui os pesos do recipiente, da tampa e da semente úmida; e t representa a tara, o peso do recipiente com tampa. Para as pesagens necessárias, é utilizada uma balança de precisão com capacidade de pesagem rápida de 0,001g.

Com os dados de temperatura, umidade relativa e o teor de umidade presente na amostra, iniciou-se a elaboração da RNA, que se deu por meio da ferramenta Google Colaboratory e a linguagem de programação Python. São importadas as bibliotecas para a


modelagem da RNA, manipulação de dados, plotagem de gráficos e importação dos dados, para então randomizar os dados, determinar que a temperatura e umidade relativa são as entradas e o teor de umidade em porcentagem dos grãos é a saída; são normalizados os dados, ou seja, os dados são transformados em valores entre 0 a 1 e determinado que 80% serão utilizados para treino e 20% para teste.

A RNA é definida, com o número de neurônios, dimensão da entrada, função de ativação, camada de saída e função de ativação de saída; ocorre o treinamento da rede com 1000 épocas e a predição, são calculados os erros médios absoluto e os erros médios relativos de treino e teste, desnormalizados os dados e gerado o gráfico, que contém os dados originais, de teste e treinamento e a linha que representa o comportamento da RNA. Neste estudo, foram realizados quatro testes, iniciando com 2 neurônios e aumentando o valor até chegar a 5 neurônios no teste final.

RESULTADOS E DISCUSSÃO

A partir dos treinamentos e testes da RNA com diferentes números de neurônios, foi obtido um gráfico da umidade dos grãos pela umidade relativa do ar contendo os dados originais, treinamento, teste e comportamento.

Figura 1: Resultados da RNA com 4 neurônios.



Fonte: Autores, 2025.

Para análise dos resultados, os erros absoluto e relativo calculados, expressos na tabela 1, foram divididos em treinamento e teste. Observando os valores de erro absoluto é possível constatar que nos treinamentos, com o aumento do número de neurônios, o valor foi se aproximando cada vez mais, já nos testes, o comportamento foi contrário. Quando analisado o erro relativo associado aos treinamentos, o comportamento se repete, o valor diminui conforme o aumento de neurônios, já nos testes, os valores variam.

Tabela 1: Resultados de Erro Absoluto e Relativo.

Número de Neurônios	Erro Absoluto		Erro Relativo	
	Treinamento	Teste	Treinamento	Teste
2	0,0901	0,0387	29,7215	10,3382
3	0,0796	0,0548	25,6403	25,0676
4	0,0721	0,0552	25,9325	13,7020
5	0,0735	0,0761	20,4078	69,7630

Fonte: Autores, 2025.

As variações podem ser explicadas pela dificuldade da rede de aprender tendo uma de suas entradas, a temperatura, constante além da variação aleatória dos dados e o tamanho do conjunto utilizado, que tinha tamanho reduzido.

CONSIDERAÇÕES FINAIS

Por fim, é possível determinar que os resultados, perante ao conjunto de dados, foram satisfatórios, a RNA apresentou comportamento adequado e pode ser validada. Para demais trabalhos, a perspectiva é mudar a faixa de temperatura dos experimentos e obter um conjunto de dados variado e de maior volume.

Palavras-chave: Umidade Relativa. Temperatura. Inteligência Artificial.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio de bolsa PIBIC/CNPq.



REFERÊNCIAS BIBLIOGRÁFICAS

BRASIL. Ministério da Agricultura e Reforma Agrária. **Regra para análise de sementes**. 2009.

CARVALHO, Danieli de et al. ANÁLISE E DETERMINAÇÃO DA UMIDADE DE EQUILÍBRIO HIGROSCÓPICO DE GRÃOS E DA FARINHA DE TRIGO NA TEMPERATURA DE 50 °C. *Revista Foco*, v. 17, n. 7, p. e5548, 2024.

CASSEL, Júlia Letícia et al. PSICOMETRIA E UMIDADE DE EQUILÍBRIO HIGROSCÓPICO: DAS CONDIÇÕES DO AR À QUALIDADE DE SEMENTES E GRÃOS. Em: *Agricultural sciences: Knowledge and diffusion of technology*. [s.l.] Atena Editora, 2022. p. 106–116.

CONAB - COMPANHIA NACIONAL DE ABASTECIMENTO. **Acompanhamento da Safra Brasileira de Grãos**, Brasília, DF, v. 12, safra 2024/25, n. 5 quinto levantamento, fevereiro 2025.

DESHMUKH, Gajanan et al. **Sorption isotherms of traditional indian dairy products: a review**. *J Food Nutr Popul Health*, v. 1, n. 3, p. 25, 2017.

PINHEIRO, Romário de Mesquita et al. **Inteligência artificial na agricultura com aplicabilidade no setor sementeiro**. *Diversitas Journal*, v. 6, n. 3, p. 2996–3012, 2021.

SILVA, Fabrício Machado da. **Inteligência artificial**. Porto Alegre: SAGAH, 2019. Recurso eletrônico. ISBN 978-85-9502-939-2.

SMANIOTTO, Thaís A. de S. et al. **Qualidade fisiológica das sementes de soja armazenadas em diferentes condições**. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 18, p. 446–453, 2014