

DESCRITORES DE TEXTURA DE IMAGEM NA DISCRIMINAÇÃO DE DOSES DE NITROGÊNIO EM PLANTAS DE MILHO (*Zea mays* L.) UTILIZANDO ALGORITMOS DE MACHINE LEARNING

THIAGO LIMA DA SILVA¹, MAURÍCIO AMARO DE LIMA², MARCOS SILVA TAVARES³, JAMILE RAQUEL REGAZZO⁴, FERNANDA DE FÁTIMA DA SILVA DEVECHIO⁵, MURILO MESQUITA BAESSO⁶

¹ Doutorando em Engenharia de Sistemas Agrícolas, Escola Superior de Agricultura “Luiz de Queiroz” - ESALQ/USP, e-mail: thiagolim@usp.br

² Graduando Engenharia de Biossistemas, Faculdade de Zootecnia e Engenharia de Alimentos - FZEA/USP

³ Doutorando em Engenharia de Sistemas Agrícolas, Escola Superior de Agricultura “Luiz de Queiroz” - ESALQ/USP

⁴ Doutoranda em engenharia de Sistemas Agrícolas, Escola Superior de Agricultura “Luiz de Queiroz” - ESALQ/USP

⁵ Professora Doutora, Departamento de Agrárias, Faculdade de Zootecnia e Engenharia de Alimentos – FZEA/USP

⁶ Professor Doutor, Departamento de Engenharia de Biossistemas, Faculdade de Zootecnia e Engenharia de Alimentos - FZEA/USP

Apresentado no
LIII Congresso Brasileiro de Engenharia Agrícola - CONBEA 2024
6 a 8 de agosto de 2024 – Natal – RN, Brasil

RESUMO: A cultura do milho (*Zea mays* L.) tem se destacado como um dos principais cereais produzidos no Brasil, utilizado principalmente na alimentação humana e animal. Nesse contexto, a condição nutricional da cultura é indispensável para manter a produtividade, economia de fertilizantes, eficiência dos sistemas operacionais e a sustentabilidade no uso dos recursos naturais. O objetivo principal deste trabalho é discriminar doses distintas de nitrogênio usando descritores texturais de imagens RGB e Machine Learning. O experimento foi implantado em casa de vegetação com um híbrido de milho (*Zea mays* L.) submetido a quatro tratamentos, sendo D1= 5%, D2= 20%, D3= 100% e D4= 200% da dose recomendada de nitrogênio, com quatro repetições. Foi avaliado o estágio V4 e R1, e as imagens foram processadas usando matriz de coocorrência para extração de quatro descritores de textura nas angulações (0°, 45°, 90° e 135°). O algoritmo Bilayered Neural Network (BNN) foi superior ao SVM e KNN, com características robusta e capaz de discriminar doses de nitrogênio em milho com alto performance na classificação.

PALAVRAS-CHAVE: inteligência artificial, nutrição de plantas, agricultura de precisão.

IMAGE TEXTURE DESCRIPTORS IN DISCRIMINATION OF NITROGEN DOSES IN MAIZE PLANTS (*Zea mays* L.) USING MACHINE LEARNING ALGORITHMS.

ABSTRACT: Maize (*Zea mays* L.) has stood out as one of the main cereals produced in Brazil, used mainly for human and animal consumption. In this context, the nutritional condition of the crop is essential to maintain productivity, save on fertilizers, efficiency of operational systems and sustainability in the use of natural resources. The main objective of this work is to discriminate different doses of nitrogen using textural descriptors from RGB images and Machine Learning. The experiment was implemented in a greenhouse with a

maize hybrid (*Zea mays* L.) subjected to four treatments, with D1= 5%, D2= 20%, D3= 100% and D4= 200% of the recommended dose. of nitrogen, with four repetitions. The V4 and R1 stages were evaluated, and the images were processed using a co-occurrence matrix to extract four texture descriptors at angulations (0°, 45°, 90° and 135°). The Bilayered Neural Network (BNN) algorithm was superior to SVM and KNN, with robust characteristics and capable of discriminating nitrogen doses in corn with high classification performance.

KEYWORDS: artificial intelligence, plant nutrition, precision agriculture.

INTRODUÇÃO: Dentro das atividades agrícolas, a produção de milho se destaca no Brasil com expressivas safras, o que demanda cada vez mais pesquisas principalmente sobre técnicas que contribuam no manejo nutricional dessa cultura com exatidão e no momento ideal. A utilização de processamento de imagens digitais apresenta-se como uma poderosa ferramenta em diversas aplicações agrícolas, pois pode ser utilizado para análise de parâmetros importantes como no monitoramento da nutrição de plantas (FARHOOD et al., 2022) usando informações denominadas de texturas amplamente estudada para extração de padrões de interesse em imagens (TENG et al., 2019) e auxílio na aplicação de adubações em taxas variadas. Nesse contexto, o objetivo principal deste trabalho é discriminar doses distintas de nitrogênio usando descritores texturais de imagens RGB como entrada na classificação supervisionada da condição nutricional em um híbrido de milho por meio de algoritmos de Machine Learning.

MATERIAL E MÉTODOS: O experimento foi desenvolvido na Universidade de São Paulo, no campus da Faculdade de Zootecnia e Engenharia de Alimentos (FZEA/USP), setor das agrárias em Pirassununga-SP. Foi implementado com a cultura do milho (*Zea mays* L.) em casa de vegetação com doses distintas de nitrogênio (N), sob cultivo hidropônico. Os tratamentos estabelecidos foram quatro doses de nitrogênio com referência na dose recomendada, D1= 5%, D2= 20%, D3= 100% e D4= 200%, com 4 (quatro) repetições. O delineamento experimental foi inteiramente casualizado em esquema fatorial com quatro doses de nutrientes com um híbrido de milho e quatro repetições, em duas épocas de coleta, V4 e R1, num total de 32 parcelas experimentais. As folhas indicativas nas fases V4 e R1 foram retiradas, digitalizadas em scanner e analisadas quimicamente. O pré-processamento das imagens seguiu a metodologia adaptada com base em Lencioni et al (2021). As imagens foram cortadas e agrupadas em quatro classes (doses), sendo armazenado mil blocos de imagens de 224x224 pixels RGB por classe, totalizando quatro mil recortes. As análises e extração dos blocos foram realizadas usando o software Matlab R2022b (Mathworks, EUA), Figura 1.




Figura 1. Exemplo do processo de segmentação de imagem de folha digitalizada.

Para Análise de textura foi gerada uma matriz de coocorrência de nível de cinza (GLCM) de acordo com (Haralick & Dinstein et al., 1973) no software Matlab R2022b (Mathworks, EUA) com o pacote de ferramentas para processamento de imagens e assim extrair quatro

características de textura em quatro angulações distintas 0°, 45°, 90° e 135°. As características extraídas foram, Contraste, Energia, Correlação e Homogeneidade. Uma análise de correlação de Pearson foi realizada, usando o software Origin Pro. No processo de classificação foi utilizado o método de aprendizado de máquina para classificação supervisionada disponibilizado no software MatLab 2022b no aplicativo Classification Learner encontrado no pacote Statistic And Machine Learning Toolbox12.4, usado com os algoritmos SVM, KNN e Bilayered Neural Network (BNN), com o método de validação cruzada k-fold de 10.

RESULTADOS E DISCUSSÃO: A tabela 1 apresenta os resultados das correlações de Pearson para os descritores de textura e o nitrogênio nos dois estádios, através dessa análise foram selecionadas as instâncias significativas para o atributo alvo na classificação supervisionada.

Tabela 1. Análise da correlação de Pearson entre o nitrogênio e os descritores de textura para os estádios V4 e R1 para híbrido de milho.

Descritores	V4				R1			
	0°	45°	90°	135°	0°	45°	90°	135°
Contraste	0,70*	0,66*	0,65*	0,66*	-0,11 ^{ns}	0,22 ^{ns}	0,08 ^{ns}	0,19 ^{ns}
Correlação	-0,55*	-0,55*	-0,53*	-0,55*	0,05 ^{ns}	0,09 ^{ns}	0,01 ^{ns}	-0,08 ^{ns}
Energia	-0,10 ^{ns}	0,06 ^{ns}	0,06 ^{ns}	0,07 ^{ns}	0,01 ^{ns}	0,07 ^{ns}	-0,03 ^{ns}	-0,07 ^{ns}
Homogeneidade	-0,71*	-0,66*	-0,66*	-0,66*	0,10 ^{ns}	-0,23 ^{ns}	-0,09 ^{ns}	-0,20 ^{ns}

* Coeficiente de correlação de Pearson significativo ao nível de 5% de probabilidade;

^{ns} Coeficiente de correlação de Pearson não significativo.

Observa-se as instâncias no estádio V4 com o atributo de energia em todas as direções com correlações não significativas, sendo assim retirada para modelagem do algoritmo de machine learning. O atributo energia conhecido também como segundo momento pode variar entre 0 e 1, sendo que é atribuído valor 1 para imagem com tonalidades constantes, mesmo tom de cinza em toda extensão, e em materiais vegetais como a folha é relacionada com o brilho ou a cerosidade. Os blocos amostrais das imagens com tamanho de 224x224 pixels apresentam regiões paralelinéreas características em monocotiledôneas, esse fator pode ter influenciado nos valores não significativos de energia na análise de correlação com o nitrogênio. Já o estádio R1 todas as instâncias apresentaram baixa correlação com o nitrogênio, sendo integralmente preservada para construção do modelo de machine learning. Na tabela 2 estão apresentadas as métricas de desempenho de cada classificador nos estádios v4 e R1.

Tabela 2. Resultados de Acurária (%), Custo total (%), F1-score (%), Precisão(%), Sensibilidade (%), Velocidade de predição (Obs/sec) e tempo de treinamento (Sec) usados como métricas de avaliação de desempenho de classificadores de ML para estádios V4 e R1 em híbrido de milho na discriminação de doses de N.

	Acurácia (%)	Custo total (%)	F1-score (%)	Precisão (%)	Sensibilidade (%)	Velocidade de predição (Obs/sec)	Tempo de treinamento (Sec)
V4							
KNN	99,0	41	98,9	98,9	98,9	26.000	1,358
SVM	99,7	13	99,6	99,6	99,6	40.000	3,552
BNN	100	Não aplicável	99,9	99,9	99,9	30.000	5,462
R1							

KNN	97,8	87	97,8	97,8	97,8	19.000	1,404
SVM	99,6	15	99,6	99,6	99,6	30.000	3,455
BNN	100	Não	99,9	99,9	99,9	95.000	2,434

aplicável

Os valores de acurácia para os todos os classificadores utilizados foram satisfatórios, alcançando 100% com a Neural Network. A acurácia pode apresentar erros na avaliação de classificadores principalmente quando as classes não são equilibradas, fato que não ocorreu neste trabalho, pois todas as classes foram estabelecidas criteriosamente com 1.000 imagens. Wen et al. 2023, também encontraram acurácia de 100% usando a BPNN nos testes para reconhecimento comportamentos térmicos de reações em reatores semi-batelada isoperibólicos, ainda segundo os autores a BPNN é ideal devido à baixa complexidade de tempo e eficácia, sendo comparada neste trabalho com Naive Bayes (NB), SVM (Support vector machines) e o KNN (k-Nearest neighbor), algoritmos comparados também nesse estudo. O SVM foi aplicado kernel gaussian e kernel scale automático, e na Neural network a função de ativação Relu e standardize data que podem ter contribuído na diminuição de erros e overffiting, além disso no estádio R1 foi utilizado como entrada todos os atributos de textura e suas angulações (0°, 45°, 90° e 135°) devido ao teste de Pearson não ter apontado correlações significativas com o nitrogênio, o que pode ter aumentado o custo de classificação no KNN e SVM.

CONCLUSÕES: Os descritores de textura extraídos por meio da matriz de coocorrência se apresentam como banco de dados de entrada satisfatório para discriminação de doses de nitrogênio usando algoritmos de Machine Learning. No estádio V4 em milho, o descritor de textura “energia” nas angulações 0°, 45°, 90° e 135° mostrou-se não ser uma instância indicada como entrada de dados para classificação usando algoritmo de Machine Learning. A Bilayered Neural Network mostrou-se um algoritmo de Machine Learning robusto capaz de discriminar doses de nitrogênio em milho com alto desempenho na classificação.

AGRADECIMENTOS: Ao Instituto Federal de Sergipe pela concessão do afastamento para capacitação e ao técnico de processamento de dados José Edson de Souza Sardinha - FZEA/USP.

REFERÊNCIAS:

- FARHOOD, H.; BAKHSHAYESHI, I.; POOSHIDEH, M.; REZVANI, N.; BEHESHTI, A. Chapter 7 - **Recent advances of image processing techniques in agriculture**. In: Cognitive Data Science in Sustainable Computing, Artificial Intelligence and Data Science in Environmental Sensing. Academic Press. p. 129-153, 2022.
- HARALICK, K. S. R. M.; DINSTEN, I. Textural features for image classification. **IEEE Transactions on Systems, Man and Cybernetics**. v. 3, n. 6, p. 610–621, 1973.
- LENCIONI, G. C.; SOUSA, R. V.; SARDINHA, E. J. S.; CORRÊA, R. R.; ZANELLA, A. J. Pain assessment in horses using automatic facial expression recognition through deep learning-based modeling. **Plos One**. p. 1-12. 2021.
- MATLAB (R2022b). Natick, Massachusetts: **The MathWorks Inc.**, 2022.
- TENG, J.; ZHANG, D.; LEE, D.-J.; CHOU, Y. Recognition of Chinese food using convolutional neural network. **Multimedia Tools and Applications**, n.78, v. 9, p. 11155-11172, 2019.T
- WEN, X.; ZHONG, S.; SUN, W.; XUE, W.; BAI, W. Development of an optimal bilayered back propagation neural network (BPNN) to identify termal behaviors of reactions in isoperibolic semi-batch reactors. **Process Safety and Environmental Protection**, Volume 173, 2023.