

CLASSIFICAÇÃO DA CONDIÇÃO NUTRICIONAL DO FEIJOEIRO (*Phaseolus Vulgaris*) UTILIZANDO REDES NEURAS CONVOLUCIONAIS E ANÁLISE DE IMAGENS

JULIA LUNA COUTO ¹, JAMILE RAQUEL REGAZZO ², MURILO MESQUITA BAESSO ³, ADRIANO ROGÉRIO BRUNO TECH ⁴, THIAGO LIMA DA SILVA ⁵

1 Graduada de Eng. de Biosistemas, Depto. Eng. de Biosistemas, FZEA/USP, Pirassununga - SP, julialuna@usp.br

2 Doutoranda em Eng. de Sistemas Agrícolas, Depto. Eng. de Biosistemas, ESALQ/USP, Piracicaba – SP

3 Prof. Doutor Associado, Depto. Eng. de Biosistemas, FZEA/USP, Pirassununga – SP

4 Prof. Doutor Associado, Depto. Ciências Básicas, FZEA/USP, Pirassununga - SP

5 Doutorando em Eng. de Sistemas Agrícolas, Depto. Eng. de Biosistemas, ESALQ/USP, Piracicaba – SP

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

RESUMO: O cultivo de feijão, antes de pequena escala e para subsistência, agora é feito com agricultura tecnificada. A deficiência de nitrogênio (N) é um problema significativo, interferindo no florescimento e formação dos grãos, a qual é detectável pela clorose das folhas após o 30º dia após emergência (DAE), mas métodos convencionais são caros, destrutivos e demorados. Há interesse em métodos de detecção não destrutivos, como técnicas de aprendizado profundo utilizando redes neurais convolucionais (CNN). Esta pesquisa, executada na FZEA-USP, desenvolveu um sistema de visão computacional baseado em CNN para estimar o status de nitrogênio em feijoeiros a partir da aplicação de diferentes doses. O objetivo é identificar a combinação ideal de arquitetura e período para um desempenho otimizado. Utilizando uma câmera Fujifilm, imagens foram capturadas em diferentes períodos e resoluções de pixels. Os resultados foram avaliados usando Acurácia, Erro e índice Kappa, demonstrando a eficácia das CNNs na identificação do estado de nitrogênio. Todos os tamanhos de blocos testados são eficazes, mas podem apresentar limitações de rapidez e demanda computacional em análises de campo em tempo real.

PALAVRAS-CHAVE: deep learning; nitrogênio; agricultura de precisão.

CLASSIFICATION OF THE NUTRITIONAL CONDITION OF COMMON BEAN (*Phaseolus Vulgaris*) USING CONVOLUTIONAL NEURAL NETWORKS AND IMAGE ANALYSIS

ABSTRACT: Bean cultivation, previously small-scale and for subsistence, is now carried out using technical agriculture. Nitrogen (N) deficiency is a significant problem, interfering with flowering and grain formation, which is detectable by leaf chlorosis after the 30th day after emergence (DAE), but conventional methods are expensive, destructive and time-consuming. There is interest in non-destructive detection methods, such as deep learning techniques using convolutional neural networks (CNN). This research, carried out at FZEA-USP, developed a

computer vision system based on CNN to estimate the nitrogen status in bean plants based on the application of different doses. The goal is to identify the optimal combination of architecture and period for optimal performance. Using a Fujifilm camera, images were captured at different time periods and pixel resolutions. The results were evaluated using Accuracy, Error and Kappa index, demonstrating the effectiveness of CNNs in identifying the nitrogen state. All tested block sizes are effective, but may present limitations in speed and computational demand in real-time field analysis.

KEYWORDS: deep learning; nitrogen; precision agriculture.

INTRODUÇÃO: As práticas agrícolas são fundamentais para o progresso econômico e social do país, impactando diretamente o Produto Interno Bruto (PIB) e diversas entidades produtivas. É crucial abordar essas atividades de maneira responsável, otimizar o uso dos recursos naturais e com foco na sustentabilidade, considerando a variabilidade dos sistemas para compreender e dimensionar seus limites de suporte. O feijão é um alimento de extrema importância para a segurança alimentar e financeira do Brasil, que de acordo com a Organização das Nações Unidas para Alimentação e Agricultura (FAO, 2019), o Brasil se posiciona em terceiro lugar na produção global desse alimento, onde a relevância desse grão ultrapassa suas implicações econômicas, destacando-se como um pilar fundamental da segurança alimentar e nutricional. Para manter a produção de feijoeiro em níveis elevados, é fundamental um manejo nutricional preciso, atendendo às necessidades específicas da cultura e garantindo que os nutrientes sejam aplicados em dosagem ideais para evitar impactos negativos e perdas na produtividade. O nitrogênio é essencial para seu cultivo, sendo essencial em grande quantidade durante todas as fases do seu desenvolvimento, influenciando o crescimento e desenvolvimento da planta, além da qualidade e produtividade dos grãos. A falta ou o excesso desse nutriente pode levar ao insucesso no cultivo, evidenciando a importância de uma adubação nitrogenada adequada (Kraeski *et al.*, 2021). A sua deficiência na lavoura pode ser notada pelo retardo no desenvolvimento geral e amarelecimento das folhas, pois o N participa da formação da molécula de clorofila - que fornece a tonalidade verde as folhas -, e este sintoma se expressa nas folhas mais antigas, devido a alta mobilidade dentro das plantas, o que implica uma redistribuição desses nutrientes das folhas mais antigas para as mais jovens, sendo isto um atributo dos macronutrientes - por exemplo o fósforo, potássio e nitrogênio (Malavolta *et al.*, 2006; Motta, 2016). Métodos convencionais para avaliar o estado nutricional, como análise foliar, são caros, demorados e limitados. Dada a importância e a urgência de respostas mais eficientes e econômicas, há um interesse crescente em métodos não destrutivos e eficazes de detecção, como as redes neurais convolucionais (CNN), uma das ferramentas mais relevantes do *deep learning*. As CNNs - estruturas multicamadas que se aprimoram com a exposição a grandes quantidades de dados, aperfeiçoando sua capacidade de reconhecimento e análise de padrões - são eficientes na extração de características de imagens de folhas durante o processamento e análises destas, como a medição indireta do teor de pigmentação das folhas, relevante para uma compreensão mais profunda do estado nutricional, de forma eficiente e econômica (Liu; Pu; Sun, 2021). Esta pesquisa propôs e avaliou um modelo de CNN para processar imagens RGB, onde além de ter analisado a eficácia em prever com precisão o conteúdo de nitrogênio nas folhas com base em imagens capturadas a partir dos 30 dias após a emergência (DAE), período em que os sintomas de amarelecimento já estão presentes de forma visual, em diferentes momentos e tamanhos de pixels, buscou-se identificar a combinação ideal de arquitetura e período que

apresenta o desempenho mais destacado para essa finalidade. Essa pesquisa contribui para o avanço de abordagens mais eficientes na prática da agricultura de precisão.

MATERIAL E MÉTODOS: Projeto realizado no Laboratório de Máquinas e Agricultura de Precisão (LAMAP) da Faculdade de Zootecnia e Engenharia de Alimentos (FZEA) da Universidade de São Paulo (USP) em Pirassununga/SP. O local tem coordenadas geográficas de 21°59' de latitude sul, 47°26' de longitude oeste e altitude média de 635 metros. Na casa de vegetação do LAMAP, foram cultivados feijoeiros, com cinco tratamentos diferentes de nitrogênio (0, 50, 100, 150 e 200% da dose recomendada) e 6 repetições, totalizando em 30 vasos com 15 dm³ de solo cada. Foi feita uma irrigação diária para que não houvesse nenhuma influência do déficit hídrico nas plantas. O cultivo das mudas de feijoeiro *Phaseolus vulgaris* L., do cultivar BRSMG Madrepérola, em vasos para permitir um controle mais preciso das quantidades aplicadas de nutrientes. Considerando a alta mobilidade do nitrogênio no solo, a aplicação da dose foi dividida em duas etapas: um terço foi aplicado durante o plantio, e o restante administrado 20 dias após a germinação. Para capturar as imagens das folhas, foi utilizada uma câmera Fujifilm Finepix S4500 com zoom óptico 30x, montada em um tripé, à 80 cm de distância dos vasos na estufa e sem iluminação artificial para simular o ambiente em que seria aplicado em Campo. Sendo fotografado cada vaso para obtenção de um banco de dados abrangente, e adquiridas a partir dos 30 dias após emergência, período em que a deficiência de nitrogênio começa a ser expressa nas folhas. Repetindo-se o procedimento uma vez por semana, durante quatro semanas (30 DAE, 37 DAE, 44 DAE e 51 DAE), no período da manhã entre 10 e 12 horas do dia. As imagens foram processadas no LAMAP com auxílio do Laboratório de Robótica e Automação da Engenharia de Biosistemas (RAEB) da Universidade de São Paulo (USP). Utilizando um script no software MATLAB® R2021a para recortar automaticamente as imagens em dimensões de 10x10, 40x40, 60x20 e 80x80 pixels (Figura 01).

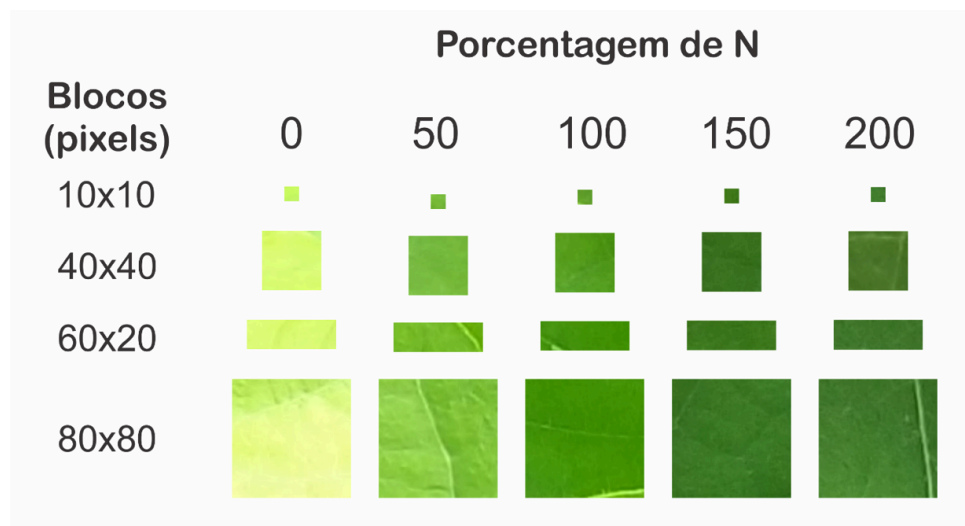


FIGURA 1. Tamanho dos recortes com cada status de N.

Para introduzir não linearidade na rede e melhorar sua capacidade de compreender padrões complexos, foi utilizada a função de ativação ReLu (Unidade Linear Rectificada). Esta função é amplamente adotada em modelos de aprendizado profundo devido à sua simplicidade e eficácia na mitigação do problema do gradiente que desaparece (Lima, Agostinho, 2022). Do total de blocos, 60% serão para treinamento, 20% para validação e 20% para teste. Realizados 10 treinamentos com 20 épocas (etapas de aprendizagem da rede), para cada semana e

tamanho de bloco, visando selecionar o melhor classificador com base na Acurácia de teste dentre os treinamentos. A partir de cada um dos modelos finais de rede, as respectivas matrizes de confusão para cada semana e tamanho de bloco foram desenvolvidas, totalizando 16 matrizes. Vários ciclos da arquitetura CNN foram executados para determinar a melhor configuração dos parâmetros que produziram o melhor desempenho do classificador. Ao final de cada ciclo, o desempenho foi avaliado usando métricas de matriz de confusão (exatidão, precisão, recall e f1-score), além do Índice Kappa, Acurácia e Erro calculados pelas equações a seguir (Tabela 1).

TABELA 1. Fórmulas das métricas envolvidas na matriz de confusão.

Métrica	Fórmula	Descrição
Exatidão	$(VP + VN) / \text{Total}$	Analisa a eficácia geral do modelo
Precisão	$VP / (VP + FP)$	Proporção de positivos reais em todos os positivos previstos
Recall	$VP / (VP + FN)$	Eficiência de um modelo de amostras positivas
F1-Score	$(2 \times \text{precisão} \times \text{recall}) / (\text{precisão} + \text{recall})$	Média harmônica entre precisão e sensibilidade
Índice Kappa	$\hat{K} = \frac{n_i \sum_{i=1}^c x_{ii} - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n_i^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}$	Avalia a concordância entre as classificações observadas e as esperadas de um classificador
Acurácia	$(\text{Corretos} / \text{Total}) \times 100$	Proporção de predições corretas em relação ao total de predições
Erro	$1 - \text{Acurácia}$	Proporção de predições incorretas em relação ao total de predições

VP: verdadeiro positivo; VN: verdadeiro negativo; FP: falso positivo; FN: falso negativo

RESULTADOS E DISCUSSÃO: A partir da Tabela 2 e Tabela 3, pode-se analisar a influência que a riqueza banco de dados tem sobre a precisão e resultados da CNN que está sendo treinada. Ao associarmos a quantidade de imagens usadas (Tabela 2) e os níveis de precisão (Tabela 3) correspondentes em tarefas de classificação baseadas em CNN, surge uma tendência clara em que um aumento no número de imagens leva a melhores taxas de precisão em diferentes tamanhos de blocos (10x10, 40x40, 60x20 e 80x80 pixels) e estágios de crescimento (30 DAE, 37 DAE, 44 DAE e 51 DAE). A título de ilustração, aos 30 DAE, a precisão aumentou de 78,3% com 2995 imagens para 81,4% com 2937 imagens para o tamanho do bloco 60x20, indicando uma correlação positiva entre a quantidade da imagem e a precisão da classificação. Da mesma forma, aos 37 DAE, a precisão melhorou de 78,2% com 2457 imagens para 82,8% com 4252 imagens para o tamanho do bloco 10x10, destacando ainda mais a importância de um maior número de imagens no aprimoramento do desempenho da classificação. Essa associação ressalta a importância do tamanho do conjunto de dados no treinamento eficaz de modelos CNN, enfatizando a necessidade de amplos dados de imagem para atingir níveis ideais de precisão em tarefas de análise de imagens agrícolas.

TABELA 2. Número de imagens aplicados na CNN para cada combinação.

DAE	Imagens			
	10x10	40x40	60x20	80x80
30	2995	1042	2937	2195
37	4252	3372	2748	2457
44	2638	3009	3218	1687
51	2818	3250	2708	1457

TABELA 3. Resultados de Acurácia e Índice Kappa para cada combinação.

DAE	Acurácia (%)				Índice Kappa			
	10x10	40x40	60x20	80x80	10x10	40x40	60x20	80x80
30	78,3	70,3	81,4	80,4	0,7569 ^{Aa}	0,6252 ^{Aa}	0,7664 ^{Aa}	0,7517 ^{Aa}
37	82,8	78,8	79,4	78,2	0,7530 ^{Aa}	0,7298 ^{Aa}	0,7409 ^{Aa}	0,7235 ^{Aa}
44	71,0	73,3	78,9	69,4	0,6376 ^{Aa}	0,6619 ^{Aa}	0,7301 ^{Aa}	0,6122 ^{Aa}
51	73,0	80,4	70,7	66,3	0,6612 ^{Aa}	0,7521 ^{Aa}	0,6327 ^{Aa}	0,6618 ^{Aa}

Legenda: Os coeficientes Kappa seguidos de uma mesma letra maiúscula não diferem na coluna pelo teste Z a 5% de probabilidade; Os coeficientes Kappa seguidos de uma mesma letra minúscula não diferem na linha pelo teste Z a 5% de probabilidade.

Na Tabela 3, apresenta-se os resultados da Acurácia, obtidos a partir das matrizes de confusão, e Índice Kappa da pesquisa para os diferentes combinações de tamanhos de blocos e DAE. A partir da análise dos resultados obtidos é possível afirmar que com relação ao período de desenvolvimento dos feijoeiros (30 DAE, 37 DAE, 44 DAE e 51 DAE), os resultados revelaram que não foi um fator determinante na escolha ou desempenho do classificador. Todos os classificadores demonstraram uma classificação substancial, conforme avaliado pelo Índice Kappa, indicando consistência e confiabilidade ao longo do ciclo de crescimento da planta. Em relação aos tamanhos de blocos utilizados na análise (10x10, 40x40, 60x20 e 80x80 pixels), todos foram considerados adequados para a elaboração de um classificador eficiente. Contudo, ao se analisar as acurácias, destacou-se que os blocos de 10x10 pixels com 37 DAE apresentaram os melhores resultados, seguidos pelos blocos de 60x20 pixels com 30 DAE e, por fim, os blocos de 40x40 pixels com 51 DAE. Notavelmente, o tamanho de bloco 60x20 pixels se destacou duas vezes entre os melhores resultados, sendo a quarta matriz de confusão com melhor acurácia aos 44 DAE. Embora o modelo construído com 37 DAE ter apresentado a maior precisão em global, ao analisar de forma mais profunda, sua performance não foi uniforme. A inconsistência na previsão das classes revelou dificuldades do modelo em diferenciar os diferentes níveis de status de nitrogênio nas safras de feijão. Essa variabilidade pode resultar em um desempenho desigual entre as classes, indicando que o modelo teve mais dificuldades com algumas classes do que com outras. Apesar da precisão superior do modelo treinado com dados de 37 DAE, uma avaliação abrangente indica que o modelo gerado com dados de 30 DAE é considerado o mais adequado. Isso se deve aos valores consistentemente altos de precisão para o nível de 100% de nitrogênio em diferentes dias após a emergência (DAE) no estudo. Considerando o tempo de treinamento de rede e a demanda computacional exigida para a elaboração do classificador, os blocos de 10x10 e 60x20 pixels foram identificados como os mais ideais. Ambos possuem uma fácil aquisição da imagem por serem relativamente pequenos, além de apresentarem um banco de dados mais extenso em comparação com os blocos de 80x80 pixels. Além disso, o tamanho de bloco com melhor Índice Kappa foi o de 60x20 pixels com 30 DAE, seguido pelo

de 10x10 pixels com 37 DAE, o de 40x40 pixels com 51 DAE e, novamente, o de 60x20 pixels com 44 DAE. Esses resultados indicam que os blocos de 60x20 pixels são mais adequados, pois oferecem um compromisso razoável, fornecendo informações contextuais suficientes para uma classificação precisa e, ao mesmo tempo, minimizando o tempo de treinamento e os recursos computacionais. A consistência e confiabilidade dos resultados foram evidenciadas pelo desempenho substancial de todos os classificadores em diferentes períodos de desenvolvimento dos feijoeiros (30 DAE, 37 DAE, 44 DAE e 51 DAE), conforme avaliado pelo Índice Kappa. Isso indica que o método é robusto e confiável ao longo do ciclo de crescimento da planta. Quanto aos tamanhos de blocos utilizados na análise (10x10, 40x40, 60x20 e 80x80 pixels), todos se mostraram adequados para a criação de um classificador eficiente. Contudo, é importante ressaltar que a rapidez e a demanda computacional podem se tornar fatores limitantes para a análise em tempo real em futuras aplicações práticas no campo. Portanto, ao analisar os resultados e o objetivo proposto a esse trabalho, os blocos de 10x10 e 60x20 pixels são os mais adequados, sendo o de 60x20 pixels preferíveis devido ao maior detalhamento das folhas, tamanho menor para treinamento rápido e menor exigência computacional.

CONCLUSÕES: É possível identificar o estado de nitrogênio em folhas de feijoeiro utilizando imagens RGB. Classificadores de visão computacional baseados em redes neurais convolucionais (deep learning) podem determinar o estado nutricional de nitrogênio no feijoeiro. O período de desenvolvimento dos feijoeiros (30 DAE, 37 DAE, 44 DAE e 51 DAE) não foi determinante na escolha do classificador, pois todos apresentaram classificação substancial segundo o Índice Kappa. Todos os tamanhos de blocos testados (10x10, 40x40, 60x20 e 80x80 pixels) são adequados para a elaboração de um classificador eficiente, com a única ressalva relacionada à rapidez e demanda computacional, que podem limitar a análise em tempo real em futuras aplicações a campo.

AGRADECIMENTOS: Ao apoio da Fundação de Estudos Agrários Luiz de Queiroz (FEALQ).

REFERÊNCIAS:

FAOSTAT. **Croops and livestock products.** Disponível em: <http://www.fao.org/faostat/en/#data/QC>. Acesso em: 23 nov. 2019.

LIMA, A. S.; AGOSTINHO, W. R. U. **Sistema de processamento de big data aplicado à monitoração de automóveis em tempo real.** 2022. Trabalho de Conclusão de Curso - Universidade Tecnológica Federal do Paraná, Curitiba, 2022.

LIU, Y.; PU, H.; SUN, D. Efficient extraction of deep image features using convolutional neural network (CNN) for applications in detecting and analysing complex food matrices. **Trends in Food Science and Technology**, [S. l.], v. 113, p. 193-204, 2021.

MALAVOLTA, E. *et al.* Repartição de nutrientes nas flores, folhas e ramos da laranjeira cultivar Natal. **Revista Brasileira de fruticultura**, [s. l.], v. 28, p. 506-511, 2006.

MOTTA, T. P. **Índices espectrais de imagens coloridas na avaliação do estado nutricional de fósforo, enxofre e magnésio no capim-marandu.** 2016. 80 f. Tese (Doutorado) –

Faculdade de Zootecnia e Engenharia de Alimentos, Universidade de São Paulo, Pirassununga, 2016.

KRAESKI, M. J. *et al.* Manejo da irrigação, inoculação e nitrogênio no feijoeiro de inverno. **Research, Society and Development**, [s. l.], v. 10, n. 8, art. e56910817437, 2021.