

DETERMINAÇÃO DE TEORES DE NITROGÊNIO EM FEIJÃO POR VISÃO COMPUTACIONAL E REDES NEURAIS ARTIFICIAIS

LEONARDO GOMES GUIDOLIN¹, AUGUSTO VAGHETTI LUCHESE², PEDRO LUIZ DE PAULA FILHO³

¹ Acadêmico de Mestrado em Tecnologias Computacionais para o Agronegócio da Universidade Tecnológica Federal do Paraná, Medianeira - PR, Endereço eletrônico: leonardo.gguidolin@gmail.com

² Pós Doutorado, Universidade Federal do Paraná (UFPR), Setor Palotina - PR. Endereço eletrônico: aluchese@gmail.com

³ Doutorado em Informática pela Universidade Federal do Paraná (UFPR), Curitiba - PR. Endereço eletrônico: pedrol@utfpr.edu.br.

Apresentado no
XLVI Congresso Brasileiro de Engenharia Agrícola - CONBEA 2017
30 de julho a 03 de agosto de 2017 - Maceió - AL, Brasil

RESUMO: A nutrição de nitrogênio na cultura do feijão é importante para garantir uma boa produtividade, porém as formas de detecção desses níveis são lentas ou dependem de um profissional experiente, portanto o objetivo deste trabalho consistiu em testar a classificação de níveis de nitrogênio através de Visão Computacional e Redes Neurais Artificiais (RNA). Foram cultivados feijoeiros em uma casa de vegetação contendo 5 doses diferentes de nitrogênio, 50, 100, 150, 200 e 250 mg/L. Coletou-se imagens de folhas destes feijoeiros para extração de características como: energia, entropia, contraste, variância, correlação e homogeneidade utilizando *Gray-Level Co-Occurrence Matrix* (GLCM) para análise de textura dessas imagens. Por fim utilizou-se as características extraídas para o treinamento e teste de uma Rede Neural Artificial (RNA) *Multilayer Perceptron* para classificação dos níveis de nitrogênio utilizando o software Weka. Através dos resultados de testes e análise de matrizes de confusão, notou-se que a melhor porcentagem de acerto obtido na RNA foi de 87,83% utilizando 3 classes: 50, 150 e 250 mg/L. Portanto esse estudo mostra que a utilização de GLCM em conjunto de uma RNA é promissor para a classificação de níveis de nitrogênio na cultura do feijão.

PALAVRAS-CHAVE: GLCM, Nutrição de nitrogênio, Multilayer Perceptron.

DETERMINATION OF NITROGEN LEVELS IN BEANS BY COMPUTATIONAL VISION AND ARTIFICIAL NEURAL NETWORKS.

ABSTRACT: Nitrogen nutrition in the bean crop is important to ensure good productivity, but the ways of detecting these levels are slow or depend on an experienced professional, so the objective of this work was to test the classification of nitrogen levels through Computational Vision And Artificial Neural Networks (ANN). Beans were grown in a greenhouse containing five different doses of nitrogen, 50, 100, 150, 200 and 250 mg/L. Leaf images were collected from these bean plants to extract characteristics such as energy, entropy, contrast, variance, correlation and homogeneity using Gray-Level Co-Occurrence Matrix (GLCM) for texture analysis. Finally, we used the characteristics collected for the training and testing of a Multilayer Perceptron ANN for the classification of nitrogen levels using Weka software. Through the results of tests and analysis of confusion matrices, it was observed that the best percentage of accuracy obtained in ANN was 89.18% using 3 classes: 50, 150 and 250 mg/L. Therefore, this study shows that the use of GLCM together of an ANN is promising for the classification of nitrogen levels in the bean culture.

KEYWORDS: GLCM, Nitrogen nutrition, Multilayer Perceptron.

INTRODUÇÃO: O feijão (*Phaseolus vulgaris* L.) é um dos constituintes mais importantes da dieta do brasileiro, principalmente por ser uma excelente fonte de proteínas, carboidratos e ferro. O feijoeiro

comum possui grande importância econômica e social pois é cultivado por pequenos e grandes produtores, em diversificados sistemas de produção e em todas as regiões brasileiras (PENA, 2015). O baixo nível técnico empregado pelos produtores e o cultivo em solos de baixa fertilidade, principalmente pobres em Nitrogênio (N), resultam em baixa produtividade da cultura do feijoeiro no Brasil. As principais fontes de N para a cultura do feijoeiro são o solo, por meio da decomposição da matéria orgânica, a aplicação de adubos nitrogenados e a fixação biológica de N_2 atmosférico, pela associação do feijoeiro com bactérias do grupo dos rizóbios. Porém, além do alto custo econômico, o uso de adubos nitrogenados em solos tropicais tem ainda um custo ecológico, através das perdas de adubos nitrogenados ocasionadas principalmente por lixiviação, na forma de nitrato e escoamento superficial, provocado pela água das chuvas ou irrigação. Assim o N perdido nesse processo é altamente poluente e, uma vez carregado para o lençol freático, provoca a contaminação dos aquíferos subterrâneos, rios e lagos. Nesse contexto, o manejo adequado da adubação nitrogenada representa uma das principais dificuldades da cultura do feijoeiro, visto que a aplicação de doses excessivas de N, além de aumentar o custo econômico, pode promover sérios riscos ao ambiente, e a sua utilização em quantidade insuficiente pode limitar o seu potencial produtivo (PELEGRIN et al., 2009). Uma maneira prática e rápida de determinar a existência da deficiência de nitrogênio na planta é por meio do diagnóstico visual que consiste em se comparar visualmente o aspecto da amostra com o padrão, ou seja, comparar a coloração, tamanho e forma com o formato padrão da planta. Na maioria das vezes o órgão de comparação é a folha, pois é o que melhor reflete o estado nutricional da planta. Porém, a sua precisão está limitada à experiência do técnico e, também, exige bastante trabalho para gerar um mapa de prescrição para ser utilizado no manejo localizado (BEASSO et al., 2007; FANQUIN, 2002). Uma forma de automatizar esse processo é utilizando técnicas de processamento digital de imagens, pois apresentam grande potencial para a obtenção de índices que expressem a cor verde da planta (Karcher & Richardson, 2003).

MATERIAL E MÉTODOS: Ocorreram duas coletas de dados e imagens para realizar este estudo sobre formas de detecção automática de teores de nitrogênio (N) em feijoeiros. Para isso um experimento foi conduzido em uma casa de vegetação na UFPR, localizada na cidade de Palotina – PR. Neste experimento foram cultivados feijoeiros em vasos com areia e receberam tratamentos de soluções nutritivas com diferentes doses de N. O experimento foi feito em casas de vegetação por necessitar de um ambiente controlado onde a cultura fica protegida de pragas e do clima externo. Foram cultivados 160 feijoeiros no total, possuindo 5 doses diferentes de N com 4 repetições cada e cada repetição, com 8 plantas. As doses utilizadas foram 50, 100, 150, 200 e 250 mg/L, sendo que os demais nutrientes não apresentaram variações. Ocorreram duas coletas de dados e imagens do experimento, a primeira coletando 50% dos dados e imagens e a segunda coletando o restante. A aquisição das imagens foi feita utilizando a câmera fotográfica digital da marca Nikon cujo modelo é Coolpix L820. As fotos foram tiradas em um ambiente controlado com o intuito de reduzir ruídos e padronizar as imagens. O ambiente controlado consistiu em uma caixa com iluminação artificial feita de pranchas de madeira e painéis de LED nas laterais. As folhas foram posicionadas no fundo da caixa onde uma escala de cores é posicionada ao lado para análise futura, conforme a FIGURA 1 e FIGURA 2.



FIGURA 1. Caixa utilizada para padronizar a coleta de imagens.




FIGURA 2. Fotos coletadas das 5 doses de N, sendo (a) 50, (b) 100, (c) 150, (d) 200 e (e) 250 mg/L

Foi utilizado o *Gray-Level Co-Occurrence Matrix* (GLCM) para extração de características das fotos das folhas do feijoeiro. Este método consiste de uma maneira de extrair características estatísticas da textura de uma imagem. No GLCM é construído uma matriz com o número de linhas e colunas igual ao número de níveis de cinza de uma imagem, ou seja, normalmente é construído uma matriz de 256x256. Os elementos da matriz são calculados através da frequência relativa entre dois pontos separados por uma distância de pixels d . Para evitar dependência de direção na classificação é possível calcular a matriz de coocorrência em 4 diferentes ângulos: $0^\circ, 45^\circ, 90^\circ$ e 135° . Originalmente foi proposto por Haralick em 1973, a extração de 14 descritores texturais desta matriz, porém neste trabalho foram utilizados apenas 6 destes: energia, entropia, contraste, variância, correlação e homogeneidade. Foram calculados esses descritores para cada um dos 4 ângulos possíveis, todos com distância d de 1 pixel. Por fim foram calculados esses descritores para o sistema RGB, ou seja, para vermelho, verde e azul, totalizando 72 descritores. Esses descritores foram retirados de 308 fotos e utilizados como atributos para treinamento e teste de uma Rede Neural Artificial *Multilayer Perceptron* utilizando o software Weka. Para treinamento da RNA foram utilizados 247 exemplos com validação cruzada, já para teste foram utilizados os 61 exemplos restantes.

RESULTADOS E DISCUSSÃO: A RNA treinada para classificar as 5 classes propostas inicialmente obteve uma porcentagem de acerto de 53,44 %. Matriz de confusão consiste em uma forma de visualizar a performance de um algoritmo, onde cada coluna da matriz representa as instancias preditas em uma classe, enquanto as linhas representam as instancias com a sua classe real. A TABELA 1 apresenta a matriz de confusão obtida deste modelo:

TABELA 1 – Matriz de confusão da RNA classificando 5 classes

	Classificado como				
	50 mg/L	100 mg/L	150 mg/L	200 mg/L	250 mg/L
50 mg/L	29	8	6	1	2
100 mg/L	6	19	13	7	3
150 mg/L	2	10	23	16	0
200 mg/L	4	5	14	20	8
250 mg/L	3	2	0	5	41

Nota-se que a RNA confunde-se na classificação das classes que possuem mg/L próximo, portanto foi testado a classificação sem as classes 100 mg/L e 200 mg/L. Assim a RNA com apenas 3 classes obteve acerto de 87,83%. A TABELA 2 apresenta a matriz de confusão para este modelo:

TABELA 2 – Matriz de confusão da RNA classificando 3 classes

	Classificado como		
	50 mg/L	150 mg/L	250 mg/L
50 mg/L	36	6	4
150 mg/L	5	46	0
250 mg/L	3	0	48

Utilizando apenas 3 classes na classificação, a RNA confundiu menos do que com as 5 classes originais, pois a diferença entre as imagens é maior, facilitando a classificação.

CONCLUSÕES: Este estudo demonstrou que a utilização do GLCM em conjunto com o classificador *Multilayer Perceptron* para classificação de níveis de N no feijoeiro é promissora, chegando a 87,83% de acerto. Já utilizando as 5 classes propostas originalmente ocorre bastante confusão na classificação. Porém neste estudo não foi testado a variação da distância de pixel na construção da matriz de coocorrência no GLCM, sendo utilizando distância fixa de 1 pixel. Haralick (1973) propôs 14 descritores texturais originalmente, porém neste trabalho utilizou-se apenas 6, portanto em estudos futuros seria interessante explorar os outros descritores em conjunto com diferentes variações de distâncias de pixels com o objetivo de melhorar ainda mais a porcentagem de classificação tanto para 3 quanto para as 5 classes originais.

REFERÊNCIAS

PENA, C. **Cultura do feijão**. 2015. Disponível em:

<<https://plantarcrescercolher.blogspot.com.br/2015/09/cultura-do-feijao-resumo.html>>. Acesso em: 16 abr. 2017.

PELEGRIN, R.; MERCANTE, F.M.; OTSUBO, I.M.N. & OTSUBO, A.A. **Resposta da cultura do feijoeiro à adubação nitrogenada e à inoculação com rizóbio**. R Bras Ci Solo, 33:219-226, 2009.

BEASSO, Murilo et al. **Determinação do "status" nutricional de nitrogênio no feijoeiro utilizando imagens digitais coloridas**. Engenharia Agrícola, Jaboticabal, v. 8, n. 2, p.520-528, 1 maio 2007.

KARCHER, D.E.; RICHARDSON, M.D. **Quantifying turfgrass color using digital image analysis**. Crop Science, v.43, p.943-951, 2003.

FANQUIN, V. **Diagnose do Estado Nutricional das Plantas**. Universidade Federal de Lavras – UFLA, 2002, Disponível em:

<Fonte:http://www.dcs.ufla.br/site/_adm/upload/file/pdf/Prof_Faquin/Diagnose%20do%20Estado%20Nutricional%20das%20Plantas.pdf> . Acesso em: 16 abr. 2017.

HARALICK, R.M., K. SHANMUGAN, I. DINSTEN, **Textural Features for Image Classification**. *IEEE Transactions on Systems, Man and Cybernetics*, 1973. SMC-3(6): p. 610-621.