
DETERMINAÇÃO DO NÍVEL DE DEFICIÊNCIA NUTRICIONAL DE NITROGÊNIO NO FEJJOEIRO UTILIZANDO REDES NEURAIS ARTIFICIAIS

Murilo Mesquita Baesso¹, Carlos Alberto Alves Varella², Guilherme Augusto Martins³, Alcir Jose Modolo⁴,
Evandro Martin Brandelero⁵

RESUMO

O objetivo desse trabalho foi identificar a deficiência nutricional de nitrogênio no feijoeiro utilizando índices espectrais e técnicas de processamento de imagens digitais. Para isso, foram desenvolvidas redes neurais artificiais com diferentes números de neurônios. Após a aquisição das imagens por uma câmera digital, elas eram cortadas em blocos com tamanho de 20x20 e 40x40 pixels. As redes neurais artificiais conseguiram identificar as diferentes doses de nitrogênio aplicados nas plantas. Os resultados obtidos usando imagens adquiridas com 30 e 40 dias após a emergência não foram diferentes.

Palavras-chave: agricultura de precisão, *Phaseolus vulgaris*, processamento de imagens digitais e sensoriamento remoto

ABSTRACT

DETERMINATION OF NUTRITIONAL DEFICIENCY LEVEL OF NITROGEN IN BEAN USING ARTIFICIAL NEURAL NETWORKS

The objective of this study was to identify nutritional deficiency of nitrogen in bean using spectral indices and techniques of digital image processing. For that it was developed artificial neural networks with different numbers of neurons. Following the acquisition of images by a digital camera, they were cut into blocks with size of 20x20 and 40x40 pixels. Artificial neural networks were able to identify the different levels of nitrogen applied in the plants. The results using images acquired with 30 and 40 days after emergence were not different.

Keywords: precision agriculture, *Phaseolus vulgaris*, digital image processing and remote sensing

Recebido para publicação em 01/09/2011. Aprovado em 19/09/2012.

1- Engº Agrônomo, Prof. Doutor, Departamento de Zootecnia – USP/FZEA, baesso@usp.br

2- Engº Agrônomo, Prof. Doutor, Departamento de Engenharia, UFRRJ, Seropédica-RJ

3- Graduando em Engenharia de Biosistemas, Departamento de Zootecnia – USP/FZEA, Pirassununga – SP.

4- Engº Agrônomo, Prof. Doutor, Universidade Tecnológica Federal do Paraná – UTFPR Via do Conhecimento

5- Engº Agrônomo, Prof. Doutor, Universidade Tecnológica Federal do Paraná – UTFPR Dois Vizinhos.

INTRODUÇÃO

Considerando todos os gêneros e espécies de feijoeiro (FAO, 2009), a produção anual de feijão gira em torno de 25,0 milhões de toneladas, ocupando uma área de 23,2 milhões de hectares divididos em 117 países em todo o mundo.

Na cultura do feijoeiro o nitrogênio é o macronutriente mais absorvido (OLIVEIRA, 2003). Este nutriente estimula o crescimento vegetativo da planta, possibilitando assim que a mesma expresse todo o seu potencial produtivo. O nitrogênio é um nutriente móvel no solo, sendo facilmente perdido por lixiviação. Barbosa Filho (2000), estudando o parcelamento em três aplicações de nitrogênio em cobertura no feijoeiro, obteve aumento de 13% no rendimento de grãos, quando comparado à aplicação não parcelada deste nutriente.

Em aplicações convencionais de fertilizantes a área é considerada como homogênea, ou seja, a deficiência é assumida como igual para toda a área, o que na prática não ocorre. Quando se baseia nas necessidades médias da planta, a aplicação pode ocorrer de forma excessiva em algumas áreas do campo e insuficientes em outras, comprometendo a eficiência no processo de produção. Nestes casos, a agricultura de precisão se torna uma alternativa ao sistema convencional, visto que com aplicação de nutrientes à taxa variada é possível obter adubação sem excesso ou falta de nutrientes, diminuindo assim os custos e o risco de contaminação do solo e das águas subterrâneas.

Nutrientes como fósforo e potássio são recomendados em função da análise do solo, considerando as tabelas de recomendação de adubação. Já para o nitrogênio a análise de solo não proporciona dados precisos de necessidade de adubação. Normalmente a recomendação de nitrogênio é baseada na produtividade esperada e no potencial de resposta da cultura associado ao histórico de uso da área, o que dificulta o processo de adubação deste macronutriente. Com isso, a cada dia surgem novas pesquisas para estimar o nível de deficiência nutricional de nitrogênio (N) das culturas utilizando as características espectrais das mesmas.

Com o uso de um sistema de visão artificial, pode-se reconhecer e extrair informações úteis de

uma cena para sistemas automáticos (MARQUES FILHO & VIEIRA NETO, 1999). Sérélé *et al.* (2000), citado por Orlando (2003), usaram índices espectrais, índices texturais e parâmetros topográficos para verificar a deficiência de nitrogênio, e concluíram que estas características possuem grande potencial na identificação da deficiência desse nutriente.

Com a finalidade de se explorar o potencial dessa tecnologia na agricultura, o objetivo do presente trabalho foi desenvolver um sistema de visão artificial capaz de caracterizar a deficiência de nitrogênio no feijoeiro, extraído da cena as propriedades espectrais da cultura, além de se determinar a melhor arquitetura de camadas ocultas e o melhor tamanho de sub-bloco.

MATERIAL E MÉTODOS

O trabalho foi conduzido em casa de vegetação localizada no campus da Universidade Federal de Viçosa, com 5 tratamentos (0, 50, 100, 150 e 200 kg ha⁻¹ de N) e 10 repetições, totalizando 50 vasos contendo 8 dm³ de solo. Devido o nitrogênio ser um nutriente de mobilidade no solo, a dose foi aplicada em duas etapas: uma no ato do plantio correspondendo a um terço do total e o restante foi aplicado 20 dias após a emergência. Os demais nutrientes foram aplicados de maneira uniforme em todos os vasos de acordo com o resultado da análise de solos, ficando apenas o nitrogênio como limitante na produção do feijão.

Os vasos foram dispostos em um delineamento inteiramente casualizado em esquema de parcela subdividida no tempo, em que as doses foram alocadas na parcela e a época da coleta dos dados na subparcela.

Foi feita uma irrigação diária até se atingir a capacidade de campo do solo para que não houvesse nenhuma influência do déficit hídrico nas plantas.

O feijoeiro é uma planta de ciclo curto, exigente em nutrientes. Por isso, é fundamental que os nutrientes sejam colocados à disposição da planta em quantidades, tempo e locais adequados. Os compostos e teores de nutrientes e pH antes e depois da adubação e correção são apresentados no Quadro 1.

Quadro 1. Compostos e teores de nutrientes e pH antes e depois da adubação e correção

Adubo	Compostos	Solo normal	Solo adubado
Calcário	Mistura 4:1 de Cloreto de Cálcio e Cloreto de Magnésio	pH 5,0	pH 6,0
Potássio	Cloreto de Potássio	18 mg dm ⁻³	150 mg dm ⁻³
Enxofre	Super Fosfato Simples	0,5 mg dm ⁻³	40 mg dm ⁻³
Fósforo	Super Fosfato Simples e Super Fosfato Triplo	0,5 mg dm ⁻³	200 mg dm ⁻³
Nitrogênio	Uréia	-	0; 50; 100; 150 e 200 kg ha ⁻¹

O primeiro adubo a ser adicionado foi o calcário na dose de 5,44 g por vaso, após isso, os vasos foram irrigados por 10 dias. Em uma segunda etapa foi adicionado uma mistura de 2,19-g de cloreto de potássio, 3,20 g de super fosfato simples e 6,90 g de super fosfato triplo por vaso. Foram semeadas cinco sementes por vaso, sendo que após 25 dias após a emergência DAE procedeu-se um desbaste deixando apenas três plantas por vaso.

Os tratamentos foram T0 (testemunha), T1 (50 kg ha⁻¹ de N), T2 (100 kg ha⁻¹ de N), T3 (150 kg ha⁻¹ de N) e T4 (200 kg ha⁻¹ de N). Em cada tratamento foi adicionado respectivamente 0, 0,45, 0,9, 1,35, e 1,8 g de uréia por vaso. Sendo 1/3 do total de uréia adicionado no plantio e o restante aos 20 dias após a emergência.

A aquisição das imagens foi feita por uma câmera colorida digital da marca JAI modelo (CV-M7+CL) com um CCD de 2/3". As imagens foram salvas no formato TIFF ("tagged image file format") com uma resolução de 1380 (h) x 1030 (v) pixels. Foi usada também uma lente manual da marca Tamron modelo 23FM25L, com distância focal de 25 mm.

Para a aquisição das imagens em condições de iluminação controlada, foi construída uma estrutura metálica com dimensão de 1,5 x 1,5 m e 2,0 m de altura recoberta com tecido do tipo "blackout". O sistema de iluminação era composto por oito refletores com lâmpadas halógenas de 150 watts direcionadas para cima, evitando a incidência de luz direta sobre as plantas. Todos os 50 vasos foram levados individualmente à estrutura na ocasião da obtenção das imagens.

As imagens foram processadas no Laboratório de Projeto de Máquinas e Visão Artificial

(PROVISAGRO) do Departamento de Engenharia Agrícola da Universidade Federal de Viçosa. Foi utilizado o sistema computacional Matlab® com o pacote de ferramentas para processamento de imagens.

Foram processados sub-blocos de imagens adquiridas aos 30 e 40 dias após a emergência (DAE), com dimensões de 20x20 e 40x40 pixels, com o objetivo de se retirar descritores (características) das imagens, condensando a informação contida nas mesmas. Dessa maneira, em vez de se utilizar imagem original, se utilizou um vetor com características que representasse a informação desejada. Este trabalho partiu da hipótese que três índices espectrais levam a informação desejada para classificar o nível de deficiência de nitrogênio na planta.

As seguintes características foram calculadas:

$$EVd = \frac{2 \cdot Vd - Vm - Az}{Vm + Vd + Az} \quad (1)$$

$$Vern = \frac{Vm}{Vm + Vd + Az} \quad (2)$$

$$Rvv = \frac{Vd}{Vm} \quad (3)$$

em que

- Ev d = excesso de verde;
- Vd = média dos pixels na banda do verde;
- Az = média dos pixels na banda do azul;
- Vm = média dos pixels na banda do vermelho;
- Ven = vermelho normalizado; e
- Rvv = razão verde-vermelho.

O programa usado para desenvolvimento do classificador com base em redes neurais artificiais também foi o Matlab® com um pacote de ferramentas específico. Foram testadas redes neurais artificiais acíclicas completamente conectadas (BRAGA *et al.*, 2000). A rede neural foi constituída por quatro camadas: a primeira foi formada pelo vetor de características previamente selecionado; seguido de duas camadas intermediárias, nas quais foram testadas dez combinações de números de neurônios (2-2, 2-5, 5-5, 5-10, 10-10, 12-12, 12-15, 15-15, 15-20, 20-20); por fim a camada de saída que foi constituída por cinco neurônios, cada um representando um dos níveis de nitrogênio.

Nas camadas intermediárias foi usada a função de transferência tangente hiperbólica sigmóide (função “tansig” do Matlab®). Na camada de saída foi usada a função de transferência logarítmica sigmóide (função “logsig” do Matlab®). Dessa maneira, ao apresentar um vetor desconhecido na rede, este foi considerado da classe cujo neurônio de saída mais se aproximou do valor um. A regra de aprendizado usada foi a Trainlm do Matlab®.

O erro de classificação foi avaliado utilizando o método de validação cruzada deixando um de fora (KHATTREE; NAIK, 2000), após isso foi criada uma matriz de erros para que a avaliação do classificador fosse feita por meio do coeficiente kappa (HUDSON & RAMM, 1987).

O coeficiente kappa foi estimado pela seguinte equação:

$$\hat{K} = \frac{n \sum_{i=1}^c x_i - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}}{n^2 - \sum_{i=1}^c x_{i\oplus} x_{\oplus i}} \quad (4)$$

em que

- \hat{K} = Estimativa do coeficiente kappa;
- x_i = Valor na linha *i* e coluna *i* (diagonal) da matriz de erros;
- $x_{i\oplus}$ = Total da linha *i*;
- $x_{\oplus i}$ = Total da coluna *i*;
- n* = Número total de amostras; e
- c* = Número total de classes.

Por fim, para definir se os valores kappa das

arquitecturas de redes neurais artificiais diferiam estatisticamente utilizou-se o teste Z a 5% (CONGALTON & MEAD, 1983).

O valor do Z calculado foi determinado pela seguinte equação:

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (5)$$

em que

Z = Valor de Z calculado;

\hat{K}_1 = Coeficiente kappa 1;

\hat{K}_2 = Coeficiente kappa 2;

$\text{var}(\hat{K}_1)$ = Variância do coeficiente kappa 1; e

$\text{var}(\hat{K}_2)$ = Variância do coeficiente kappa 2.

A variância do coeficiente kappa foi determinada pela equação 6 (BISHOP *et al.*, 1975, citados por HUDSON & RAMM, 1987).

$$\text{var}(\hat{K}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (6)$$

em que

$$\theta_1 = \frac{1}{n} \sum_{i=1}^c x_i \quad (7)$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^c x_{i\oplus} x_{\oplus i} \quad (8)$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^c x_i (x_{i\oplus} + x_{\oplus i}) \quad (9)$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c x_j (x_{j\oplus} + x_{\oplus j})^2 \quad (10)$$

RESULTADOS E DISCUSSÃO

Observa-se no Quadro 2, que as redes neurais artificiais foram capazes de identificar o nível de deficiência nutricional de nitrogênio no feijoeiro ainda em tempo hábil para que se possa realizar uma adubação por cobertura. Aos 30 DAE, a planta está em pleno crescimento vegetativo, e quando

adubada adequadamente com nitrogênio nesta fase, o feijoeiro irá mostrar todo o seu potencial produtivo. Vale ressaltar que quatro arquiteturas foram estatisticamente iguais a 5%, neste caso deveremos optar pela menor arquitetura (5-10), já que o tempo computacional será menor.

Aos 40 DAE, as arquiteturas de camadas ocultas testadas, que obtiveram os melhores índices Kappa tiveram comportamento estatisticamente igual às melhores redes obtidas aos 30DAE (teste Z 5%) (Quadro 3). Porém, vale ressaltar que ao nível que o ciclo do feijoeiro evolui para próximo da fase da floração, a resposta da adubação nitrogenada diminui, sendo viável tal prática apenas quando se deseja um aumento de matéria seca ou uma melhoria no teor de proteína da semente do feijoeiro. Da mesma forma dos blocos retirados das imagens adquiridas aos 30 DAE aos 40 DAE também se escolheu a arquitetura de camadas ocultas com menos neurônios nas camadas ocultas 5-5.

Como um sub-bloco maior irá proporcionar processamento mais rápido de imagem, no presente trabalho também foram testados sub-blocos com dimensão de 40x40pixels, os resultados obtidos

estão apresentados no Quadro 4.

O Quadro 4 demonstra que a arquitetura de camada oculta que obteve o melhor resultado foi a 15-15, acertando 35 amostras, porém quatro arquiteturas são estatisticamente iguais (teste Z a 5%), sendo assim foi escolhida a menor arquitetura 10-10 neurônios.

Os resultados obtidos pelos blocos 40x40 pixels retirados das imagens adquiridas aos 40 DAE, apresentaram tendência de acertar mais amostras (Quadro 5), porém os melhores resultados não foram estatisticamente diferentes da análise dos blocos 20x20 pixels, neste caso devemos optar pela arquitetura 5-10 neurônios, que é a menor arquitetura de camada oculta.

Observa-se no Quadro 6 que, independentemente da época e do tamanho dos sub-blocos, todas as arquiteturas de camadas ocultas que obtiveram os melhores resultados são estatisticamente iguais (teste Z 5%), sendo assim, baseado nos resultados apresentados, escolheu-se os sub-blocos de 40x40 pixels pois quanto maior o tamanho dos sub-blocos menor será o tempo gasto no processamento da imagem.

Quadro 2. Resumo dos resultados dos classificadores para os blocos 20x20 pixels das fotos adquiridas, aos 30 DAE, começando pelas melhores arquiteturas

Arquitetura	Acertos	Kappa
12-12	37/50	0,67 ^a
5-10	36/50	0,65 ^a
10-10	35/50	0,62 ^a
20-20	33/50	0,57 ^a

Quadro 3. Resumo dos resultados dos classificadores para os blocos 20x20 pixels das fotos adquiridas aos 40 DAE, começando pelas melhores arquiteturas

Arquitetura	Acertos	Kappa
12-12	39/50	0,72 ^a
5-10	37/50	0,67 ^a
10-15	37/50	0,67 ^a
5-5	35/50	0,62 ^a

Quadro 4. Resumo dos resultados dos classificadores para os blocos 40x40 pixels das fotos adquiridas, aos 30 DAE, começando pelas melhores arquiteturas

Arquitetura	Acertos	Kappa
15-15	35/50	0,62 ^a
12-12	33/50	0,57 ^a
10-10	32/50	0,55 ^a
10-15	32/50	0,55 ^a

Quadro 5. Resumo dos resultados dos classificadores para os blocos 40x40 pixels das fotos adquiridas aos 40 DAE, começando pelas melhores arquiteturas

Arquitetura	Acertos	Kappa
10-10	37/50	0,67 ^a
15-20	36/50	0,65 ^a
5-10	34/50	0,60 ^a
12-12	34/50	0,60 ^a
15-15	34/50	0,60 ^a

Quadro 6. Resumo dos resultados dos melhores classificadores para os blocos 20x20 e 40x40 pixels das fotos adquiridas aos 30 e 40 DAE

30 DAE			
Bloco	Arquitetura	Acertos	Kappa
20x20	5-10	36/50	0,65 ^a
40x40	5-5	35/50	0,62 ^a
40 DAE			
Bloco	Arquitetura	Acertos	Kappa
20x20	10-10	32/50	0,55 ^a
40x40	5-10	34/50	0,60 ^a

CONCLUSÕES

Nas condições em que o trabalho foi realizado concluiu-se que:

- As redes neurais artificiais possibilitaram identificar, satisfatoriamente, o nível de deficiência nutricional de nitrogênio no feijoeiro;
- O tamanho de sub-bloco escolhido foi o de 40x40 pixels, já que o mesmo apresenta menor esforço computacional na fase de processamento da imagem;
- O uso das redes neurais proporcionou resultados estatisticamente iguais nas duas épocas estudadas (30 e 40 DAE); e
- As melhores arquiteturas de neurônios artificiais, para os blocos 40x40 pixels, foram 5-5 aos 30 DAE e 5-10 aos 40 DAE.

REFERÊNCIAS BIBLIOGRÁFICAS

BARBOSA FILHO, M.P.; SILVA, O.F. da. Adubação e calagem para feijoeiro em solo de cerrado. **Pesquisa agropecuária brasileira**,

Brasília, v.35, n.7, p.1317-1324, jul. 2000.

BRAGA, A.P.; CARVALHO, A.C.P.L.F.; LUDEMIR, T.B. **Redes neurais artificiais teoria e aplicações**. Rio de Janeiro: LTC – livros técnicos e Científicos Editora S.A., 2000, 262p.

CONGALTON, R.G.; Mead, R.A. A quantitative method to test for consistency and correctness in photointerpretation. **Photogrammetric Engineering & Remote Sensing**, Bethesda, v.49, n.1, p.69-74, ago. 1983.

FAO. FAOSTAT. <http://faostat.fao.org/> acesso em: 15 de maio de 2009.

HUDSON, W.D.; RAMM, C.W. Correct formulation of the kappa coefficient of agreement. **Photogrammetric Engineering & Remote Sensing**, Bethesda v.53, n.4p.421-422, jun. 1987.

KHATTREE, R. E; MAIK, D.N. **Multivariate data reduction and Discrimination with SAS software**. Cary: SAS Institute Inc., 2000. 558p.

MARQUES FILHO, O.; VIEIRA NETO, H.

Processamento digital de imagens. Rio de Janeiro: Editora Brasport, 1999, 406p.

OLIVEIRA, I.P. de; FAGERIA, N.K.I.V. Calagem e Adubação. In: MOREIRA, J.A.A.; STONE, L.F.; BIAVA, M. (eds.). **Feijão: o produtor pergunta**

a Embrapa responde. Brasília, 2003, p.39-53.

ORLANDO, R.C. **Sistema de visão artificial para discriminação entre plantas daninhas e milho.** 2003. 85f. Dissertação (doutorado em Engenharia Agrícola). Universidade Federal de Viçosa, 2003.