

Determinação do nível de deficiência nutricional de nitrogênio no feijoeiro (*Phaseolus vulgaris*) utilizando redes neurais artificiais

Murilo Mesquita Baesso¹
Francisco de Assis de Carvalho Pinto¹
Daniel Marçal de Queiroz¹
Darly Geraldo de Sena Junior¹
Joseph Kalil Khoury Junior¹

¹ Universidade Federal de Viçosa - UFV/DEA
36570-000 - Viçosa - MG, Brasil
murilo@vicosa.ufv.br
facpinto@ufv.br
queiroz@ufv.br
sena@vicosa.ufv.br
khouryjr@vicosa.ufv.br

Abstract. The objective of this work was to identify the nutritional deficiency of nitrogen in bean plants using spectral indexes and digital image processing techniques. To this aim were developed artificial neural networks with different numbers of neurons. After the acquisition of the images with a digital camera they were cut in blocks with the size of 20x20 and 40x40 pixels. The artificial neural networks worked well to determine the different doses of nitrogen applied in the bean plants. The results using the images acquired at 30 and 40 days after emergency were not different.

Palavras-chave: remote sensing, digital image processing, precision farming, sensoriamento remoto, processamento de imagens digitais, agricultura de precisão.

1. Introdução

Considerando todos os gêneros e espécies de feijoeiro englobados nas estatísticas da FAO (2001), a produção mundial de feijão em 2001 foi de, aproximadamente, 16,8 milhões de toneladas, ocupando uma área de 23,2 milhões de hectares. Cerca de 65,1% da produção foram oriundos de apenas sete países, sendo a Índia responsável por 15,3% e o Brasil 14,6%.

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 muito móvel no solo, sendo facilmente perdido por lixiviação. BARBOSA FILHO (2000), estudando o parcelamento da aplicação de nitrogênio em cobertura no feijoeiro, obteve um aumento de 13% no rendimento de grãos quando comparado a 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 nos baseamos 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, já que com uma aplicação de nutrientes a taxa variada iremos obter uma adubação sem excesso ou falta de nutrientes, diminuindo assim os custos e o risco de contaminação do solo e das águas subterrâneas.

Nutrientes como o fósforo e o 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 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 um grande potencial.

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

2. Material e Métodos

O trabalho foi conduzido em casa de vegetação localizada no campus da UFV, com 5 tratamentos (0, 50, 100, 150 e 200 kg de N/ha), com 10 repetições, totalizando 50 vasos contendo 8dm³ de solo. Cada vaso teve três plantas de feijão (*Phaseolus vulgaris*). Devido o nitrogênio ser um nutriente de alta 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 germinação. 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, onde as doses foram alocados na parcela e a época na subparcela. Foi feita uma irrigação diária 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. As fontes e as doses de adubos colocado em cada vaso são apresentados na Tabela 1.

Tabela 1. Fonte e quantidade de adubo por vaso

Adubo	Fonte	Solo original	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

O primeiro adubo a ser adicionado foi o calcário na dose de 5,44g por vaso, após isso os vasos foram irrigados por 10 dias, em uma segunda etapa foi adicionado uma mistura de 2,19g de cloreto de potássio, 3,2g de super fosfato simples e 6,9g de super fosfato triplo por

vaso. Foram plantadas cinco sementes por vaso sendo que após 25 DAE procedeu-se um desbaste deixando apenas três plantas por vaso.

Os tratamentos foram T0 (testemunha), T1 (50Kg de N/ha), T2 (100kg de N/ha), T3 (150kg de N/ha) e T4 (200Kg de N/ha). Em cada tratamento foi adicionado respectivamente 0, 0,45, 0,9, 1,35, e 1,8g de uréia por vaso. Sendo que 1/3 do total de uréia foi adicionado no plantio e o restante com 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 25mm.

Para que as imagens fossem adquiridas em condições de iluminação controlada, foi construída uma estrutura metálica com dimensão de 1,5 x 1,5m e 2,0m de altura recoberta com tecido do tipo "blackout". O sistema de iluminação era composto por oito refletores com lâmpadas halógenas de 150 watts que estavam direcionadas para cima, para que as plantas não recebessem luz direta. 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,

- Evd - 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;
- 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 intermediarias, 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 intermediarias 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 através do coeficiente kappa (HUDSON & RAMM, 1987).

O coeficiente kappa foi estimado pela seguinte equação:

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

Em que,

\hat{K}	=	Estimativa do coeficiente kappa;
x_{ii}	=	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 arquiteturas 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;
$\text{var}(\hat{K}_2)$	=	Variância do coeficiente kappa 2.

A variância do coeficiente kappa foi determinada pela equação 6 (Bishop et al., 1975, citados por HUDSON e 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,

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

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

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

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

3. Resultados e Discussão

Como podemos observar na Tabela 2, 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.

Tabela 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

Aos 40DAE as arquiteturas de camadas ocultas testadas, que obtiveram os melhores índices Kappa tiveram comportamento estatisticamente igual as melhores redes obtidas aos 30DAE (teste Z 5%) (Tabela 3), porem vale ressaltar que ao nível que o ciclo do feijoeiro evolui para próximo da fase da floração, a resposta da adubação nitrogênada diminui, sendo viável tal pratica 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 30DAE aos 40DAE também se escolheu a arquitetura de camadas ocultas com menos neurônios nas camadas ocultas 5-5.

Tabela 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

Como um sub-bloco maior ira proporcionar um processamento mais rápido de imagem, no presente trabalho também foram testados sub-blocos com dimensão de 40x40pixels, os resultados obtidos estão apresentados na Tabela 4.

Tabela 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

A Tabela 4 demonstra que a arquitetura de camada oculta que obteve o melhor resultado foi a 15-15, acertando 35 amostras, porem 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, tiveram uma tendência de acertar mais amostras (Tabela 5), porem os melhores resultados não foram estatisticamente diferentes da análise dos blocos 20x20 pixels, porem neste caso devemos optar pela arquitetura 5-10 neurônios, que é a menor arquitetura de camada oculta.

Tabela 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

Podemos observar na Tabela 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 40x40pixels pois quanto maior o tamanho dos sub-blocos menor será o tempo gasto no processamento da imagem.

Tabela 5 – 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

4. Conclusões

Neste trabalho, foram testadas técnicas de processamento de imagens digitais e sensoriamento remoto para identificação do nível de deficiência de nitrogênio no feijoeiro utilizando redes neurais artificiais .

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

- As redes neurais artificiais conseguiram 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.
- As redes neurais obtiveram resultados estatisticamente iguais nas duas épocas estudadas (30 e 40 DAE).
- As melhores arquiteturas de neurônios artificiais para os blocos 40x40 pixels foram 5-5 aos 30 DAE e 5-10 aos 40 DAE.

5. Referências Bibliográficas

- Barbosa Filho, M.P. & Silva, O. F. da. **Adubação e calagem para feijoeiro em solo de cerrado**. Pesq. agropec. bras., 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**. LTC – livros técnicos e Científicos Editora S.A. Rio de Janeiro, RJ. 262p. 2000.
- Congalton, R.G.; Mead, R.A. **A quantitative method to test for consistency and correctness in photointerpretation**. Photogrammetric Engineering & Remote Sensing, v.49 n.1 p.69-74, 1983.
- Hudson, W.D.; Ramm, C.W. **Correct formulation of the kappa coefficient of agreement**. Photogrammetric Engineering & Remote Sensing, v.53 n.4 p.421-422, 1987.
- Khattree, R. E Maik, D.N. **Multivariate data reduction and Discrimination with SAS software**. Cary, NC: SAS Institute Inc., 2000.
- Marques Filho, O.; Vieira Neto, H. **Processamento digital de imagens**. Rio de Janeiro: Editora Brasport, 1999, 406 p.
- Oliveira, I.P. de; Fageria, N.K. IV. Calagem e Adubação. In: Moreira, J.A.A.; Stone, L.f.; Biava, M. **Feijão: o produtor pergunta a Embrapa responde**. P. 39-53, 2003.
- Orlando, R.C. **Sistema de visão artificial para discriminação entre plantas daninhas e milho**. Viçosa, MG: UFV, 2003. 85p. (dissertação doutorado).