

GISLAINE PACHECO TORMEN

**CARACTERIZAÇÃO DO TEOR DE NITROGÊNIO FOLIAR E
PRODUTIVIDADE DO FEIJOEIRO COM TÉCNICAS DE VISÃO
ARTIFICIAL**

Dissertação apresentada à
Universidade Federal de Viçosa,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia Agrícola, para obtenção
do título de *Magister Scientiae*.

VIÇOSA
MINAS GERAIS - BRASIL
2008

GISLAINE PACHECO TORMEN

**CARACTERIZAÇÃO DO TEOR DE NITROGÊNIO FOLIAR E
PRODUTIVIDADE DO FEIJOEIRO COM TÉCNICAS DE VISÃO
ARTIFICIAL**

Dissertação apresentada à
Universidade Federal de Viçosa,
como parte das exigências do
Programa de Pós-Graduação em
Engenharia Agrícola, para obtenção
do título de *Magister Scientiae*.

APROVADA: 29 de maio de 2008

Prof. Daniel Marçal de Queiroz
(Co-Orientador)

Prof. Elpídio Inácio Fernandes
Filho

Prof. Ricardo Capúcio de Resende

Dr. Trazilbo José de Paula Júnior

Prof. Francisco de Assis de Carvalho Pinto
(orientador)

À minha querida e inesquecível mamãe Maria Pacheco de Medeiros Tormen
(*in memorium*)

Dedico

À Deus pela benção e saúde para concluir este trabalho.

Ao meu pai Pedro, pelo amor incondicional.

Aos meus irmãos Gilvan e Giselle, pelo amor, amizade e apoio.

Ao meu marido Diogo e minha filhinha Giovana pelo amor e carinho.

AGRADEÇO

AGRADECIMENTOS

À Universidade Federal de Viçosa e ao Departamento de Engenharia Agrícola, pela oportunidade de realização do curso.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), pela concessão da bolsa de estudos.

Ao Professor Francisco de Assis de Carvalho Pinto pela orientação, amizade e confiança.

Ao Professor Daniel Marçal de Queiroz e Professor Nerilson Terra Santos pela amizade e colaboração nas atividades de pesquisa.

Ao Departamento de Fitotecnia da Universidade Federal de Viçosa, em especial ao Professor José Eustáquio de Souza Carneiro, pela concessão da área experimental, pela orientação e apoio nas atividades de campo.

Ao amigo Antônio, pela paciência, amizade e ajuda no desenvolvimento dos algoritmos.

Aos colegas e amigos da mecanização agrícola Alisson, Danilo, Douglas, Elder, Enrique, Fábio, Francelino, Geice, Gérson, João Cleber, Leonardo, Marcos, Mário, Murilo, Paula, Ronaldo, Selma, Sérgio, Wagner, Walter e Willian.

Aos professores Haroldo Fernandes, Luciano Baião, Mauri Teixeira, Pedro Hurtado e Ricardo Capúcio pelo auxílio e conhecimento.

Aos funcionários do Departamento de Engenharia Agrícola, pela amizade e convívio do dia a dia.

À meu pai Pedro, aos meus irmãos Giselle e Gilvan, à D. Iara e ao Sr. Aloísio pela amizade, incentivo e apoio na realização deste trabalho.

Ao meu marido Diogo, pela bravura no desenvolvimento do experimento, pelos conselhos e principalmente pelo carinho, estímulo, compreensão e apoio nas horas difíceis enfrentadas durante o curso.

E por último, à minha filhinha Giovana, pelo carinho e compreensão, mesmo ainda sem entender o que isso significa, nas horas que a mãe não pode estar ao seu lado.

BIOGRAFIA

GISLAINE PACHECO TORMEN, filha de Maria Pacheco de Medeiros Tormen (*in memoriam*) e Pedro Lúcio Tormen, nasceu em Visconde do Rio Branco, MG, no dia 16 de janeiro de 1983.

Em abril de 2001 iniciou o curso de Engenharia de Agrimensura na Universidade Federal de Viçosa, o qual concluiu em maio de 2006.

Em maio de 2006 iniciou o curso de mestrado em Engenharia Agrícola, área de concentração em Mecanização Agrícola, na Universidade Federal de Viçosa, e submeteu-se à defesa de dissertação em maio de 2008.

ÍNDICE

RESUMO	vii
ABSTRACT.....	ix
1. INTRODUÇÃO.....	1
2. REVISÃO BIBLIOGRÁFICA.....	4
2.1. Cenário da cultura do feijão no Brasil.....	4
2.2. Nitrogênio e produtividade do feijoeiro	5
2.3. Avaliação do estado nutricional do feijoeiro.....	6
2.3.1. Clorofilômetro portátil.....	6
2.3.2. Técnicas de sensoriamento remoto	7
2.4. Agricultura de precisão e Visão artificial.....	9
2.5. Classificadores estatísticos	10
2.6. Avaliação dos classificadores	11
3. MATERIAL E MÉTODOS.....	13
3.1. Implantação do experimento.....	13
3.2. Obtenção das imagens	14
3.3. Estimativas do teor de clorofila foliar	17
3.4. Determinação do teor de nitrogênio foliar	18
3.5. Determinação da Produtividade	18
3.6. Processamento das imagens	20
3.7. Análise de Regressão	21
3.8. Análise de Correlação	21
3.9. Desenvolvimento dos Classificadores	22

3.10. Avaliação dos classificadores	24
4. RESULTADO E DISCUSSÃO.....	28
4.1. Análise das imagens adquiridas ao longo dos dias após a emergência ...	28
4.2. Análise de regressão das variáveis SPAD e N foliar em relação às doses de N aplicadas na semeadura	32
4.2.1. Relação entre valores de N foliar e doses de N aplicadas na semeadura	32
4.3.2. Relação entre valores SPAD e doses de N aplicados na semeadura .	38
4.3. Análise de correlação	44
4.3.1. Correlação entre os valores de N foliar e valores SPAD.....	44
4.3.2. Correlação entre os índices de vegetação e os valores de N foliar	46
4.3.3. Correlação entre índice de vegetação e produtividade	51
4.4. Discriminação de classes de N foliar utilizando índices de vegetação.....	54
4.5. Discriminação das classes de N foliar utilizando o medidor de clorofila SPAD 502.....	56
4.6. Comparação entre os índices de vegetação e o clorofilômetro portátil na discriminação de classes de N foliar.....	57
4.7. Desenvolvimento e avaliação dos classificadores na discriminação de classes de produtividade	58
4.8. Avaliação da combinação dos índices de vegetação	62
5. CONCLUSÕES.....	70
6. REFERÊNCIAS BIBLIOGRÁFICAS.....	72
7. APÊNDICES	78
Apêndice A	78
Apêndice B	80
Apêndice C.....	84
Apêndice D.....	87
Apêndice E	88

RESUMO

TORMEN, Gislaine Pacheco, M.Sc., Universidade Federal de Viçosa, maio de 2008. **Caracterização do teor de nitrogênio foliar e produtividade do feijoeiro com técnicas de visão artificial.** Orientador: Francisco de Assis de Carvalho Pinto. Co-Orientadores: Daniel Marçal de Queiroz e Nerilson Terra Santos.

O feijão é um dos componentes básicos da dieta alimentar da população brasileira e importante fonte de proteína. O Brasil é o maior produtor e maior consumidor mundial, porém com um rendimento médio inferior aos dos Estados Unidos e China. Com a necessidade de aumentar a produtividade da lavoura de maneira eficiente e a preocupação com a questão ambiental, nos últimos anos aumentou o interesse dos produtores no uso de novas tecnologias como a utilização das técnicas de agricultura de precisão. Portanto, visando os conceitos de agricultura de precisão o objetivo deste trabalho foi avaliar a discriminação de classes de nitrogênio (N) foliar, a partir de índices de vegetação e clorofilômetro portátil, e classes de produtividade do feijoeiro, a partir de índices de vegetação. O experimento constou de duas safras (“seca” e “inverno” de 2007). O delineamento experimental utilizado foi o de blocos casualizados, com tratamentos distribuídos em esquema fatorial 5 x 6, com três repetições, totalizando 90 parcelas. Os tratamentos foram constituídos por cinco doses de N (0, 20, 30, 40 e 50 kg ha⁻¹) aplicadas na semeadura e seis doses de N (0, 20, 30, 40, 60 e 80 kg ha⁻¹) aplicadas em cobertura na forma de uréia, totalizando 30 tratamentos. Os índices de vegetação foram extraídos de imagens digitais, obtidas por meio de um sistema composto por duas câmeras digitais, obtendo ao mesmo instante, duas imagens da mesma cena (uma na banda do visível e outra na banda do infravermelho próximo). As mesmas folhas utilizadas para

obter o valor SPAD foram coletadas para determinar o teor de N presente nas folhas. Os teores de N foliar foram distribuídos em classes baixa, satisfatória e alta. A produtividade também foi dividida em classes baixa, média e alta. Para discriminar classes de N e produtividade, foram desenvolvidos classificadores estatísticos. Para discriminar classes de N foliar, foram utilizadas todas as possíveis combinações dos oito índices de vegetação e valores SPAD coletados antes da adubação em cobertura. Para discriminar classes de produtividade, foram utilizadas todas as possíveis combinações dos oito índices de vegetação extraídos das imagens coletadas após a adubação em cobertura. Com a utilização do medidor de clorofila SPAD 502 a discriminação entre as doses de N aplicadas na semeadura foi possível nos dois experimentos estudados: no experimento 1 aos 25 DAE e no experimento 2 aos 28 DAE. O valor SPAD correlacionou-se positivamente com o teor de N nas folhas no feijoeiro, tendo a maior correlação aos 12 DAE. Nos dois experimentos, os índices de vegetação não correlacionaram com os valores de N foliar, mas com a produtividade essa correlação foi positiva e maior com o avanço dos dias após a emergência. No experimento 1 não foi possível desenvolver classificadores para discriminar as classes de N foliar, pois os valores de N foliar estavam acima do nível considerado satisfatório, incluindo todos os dados na classe alta. A utilização dos índices de vegetação como vetor de característica não foi útil na discriminação das classes de N foliar, tendo apresentado coeficiente Kappa baixo, classificados como razoável e ruim aos 20 e 28 dias após a emergência (DAE), respectivamente, no experimento 2. Quando utilizou-se o valor SPAD os resultados foram melhores, apresentando coeficiente Kappa classificados como bom e muito bom aos 20 e 28 DAE, respectivamente. Na discriminação de classes de produtividade, o maior coeficiente Kappa (44%) encontrado foi aos 64 DAE, no experimento 1, já no experimento 2 esse coeficiente Kappa foi maior (76%) aos 49 DAE. Os índices de vegetação foram eficientes na discriminação das classes de produtividade, e a combinação de mais de um índice foi importante devido ao efeito conjunto das variáveis.

ABSTRACT

TORMEN, Gislaine Pacheco, M.Sc., Universidade Federal de Viçosa, may of 2008. **Characterization of leaf nitrogen content of bean plants with techniques of machine vision.** Adviser: Francisco de Assis de Carvalho Pinto. Co-Advisers: Daniel Marçal de Queiroz and Nerilson Terra Santos.

Beans are one of the basic human nutrition components in Brazil and an important source of protein. Brazil is the major world producer and consumer, but has an average yield less than that of the USA and China. In the last years, the necessity to efficiently increase crop productivity and keep concerning with environmental issues has increased the producer interest in the use of new technologies such as precision agriculture techniques. The objective of this study was to evaluate the discrimination of leaf nitrogen (N) content classes using vegetation indices and chlorophyll meter measurements, and the discrimination of bean yield classes using the vegetation indices. The research considered two crop harvests (“dry crop” and “winter crop” of 2007). The experiment was developed in randomized block design, with treatments in factorial scheme 5x6, with three replicates, summarize 90 plots. The treatments consisted of five different sowing N fertilization rates (0, 20, 30, 40 and 50 kg ha⁻¹) and six different rates of topdressing N fertilization (0, 20, 30, 40, 60 and 80 kg ha⁻¹) on urea composite. The vegetation indices were extracted from digital images, acquired using a system composed of two digital cameras. Therefore, the system acquired two images of the same scene at the same time (one in visible and the other in a near infrared spectral bands). The same leaves used to obtain the SPAD values were collected to determine the leaf N content. The leaf N content was sorted in low, medium and high classes. The

yield was sorted in low, medium and high classes as well. In order to discriminate N and yield classes statistical classifiers were developed. To discriminate leaf N content classes, all possible combinations were used among the eight vegetation indices and SPAD values collected before topdressing fertilization. In order to discriminate yield classes, all possible combinations were used among the eight vegetation indices collected after topdressing fertilization. The chlorophyll SPAD measurements discriminated among the different rates of N applied on sowing in the two harvest seasons: in the first harvest season, at 25 day after emergence (DAE) and, in the second harvest, at 28 DAE. The SPAD value was correlated positively with leaf N content on the bean crop, having a greater correlation at 12 DAE. In the two crop harvests, the vegetation indices did not correlate with leaf N content values, but with the yield this correlation was positive and greater with the increase in days after emergence. In the first experiment, it was not possible to develop classifiers to discriminate leaf N content class, because the leaf N content values were higher than the considered tolerable levels, classifying all data into the high class. The use of the vegetation indices as characteristics vector was not useful on the leaf N content class discrimination, showing a low Kappa coefficient, classified as acceptable at 20 DAE and bad at 28 DAE, in the second experiment. When using SPAD measurements, the results improved, and Kappa coefficients were classified as good and very good at 20 and 28 DAE, respectively. Yield class discrimination obtained the greatest Kappa coefficient (44%) at 64 DAE in the first experiment, and, in the second experiment, the Kappa coefficient was greatest (76%) at 49 DAE. The vegetation indices were efficient in the discrimination of yield classes, and the combination of more than one vegetation index was important due to the variables group effect.

1. INTRODUÇÃO

O feijoeiro comum (*Phaseolus vulgaris* L.) é a espécie mais cultivada no mundo entre as demais do gênero *Phaseolus*. O Brasil é o maior produtor e maior consumidor mundial dessa espécie, responsável por 16% da produção mundial. Porém, o rendimento médio de 0,8 t ha⁻¹ é muito baixo se comparado com o dos Estados Unidos e da China, onde o rendimento médio está próximo de 2,0 t ha⁻¹ (CEPA, 2006).

Segundo Borém & Carneiro (2006), essa baixa produtividade pode ser atribuída ao fato de que o feijão, na sua maioria, ainda é produzido por agricultores que dispõem de poucos recursos tecnológicos e geralmente adubam incorretamente e não controlam pragas e doenças. A escassez ou a má distribuição das chuvas também são fatores que contribuem para esse baixo rendimento médio, pois a irrigação não é uma prática muito comum entre esses produtores. O emprego racional de fertilizantes (principalmente nitrogenados) apresenta-se como alternativa viável para amenizar o problema (Teixeira et al., 2000).

Na literatura existem diversos trabalhos com o objetivo de estudar o desempenho produtivo do feijoeiro quanto à adubação nitrogenada. Alguns resultados mostram acréscimo da produtividade da cultura com aumento das doses de nitrogênio (N) (Stone & Moreira, 2001; Carvalho et al., 2003).

O N é o elemento mais absorvido pelo feijoeiro e o seu uso geralmente tem influência significativa na produtividade. Entretanto, devido ao alto custo dos fertilizantes nitrogenados e das perdas desse nutriente no solo, torna-se de grande interesse a busca de técnicas que possam maximizar sua eficiência (Silva et al., 2006).

A necessidade de aumentar a produtividade da lavoura e reduzir os impactos ambientais tem incentivado a utilização de novas tecnologias por

parte de produtores e pesquisadores, como a utilização das técnicas de agricultura de precisão. Segundo Queiroz et al. (2000), a agricultura de precisão é a tecnologia cujo objetivo consiste em aumentar a eficiência com base no manejo diferenciado de áreas na agricultura. Para Karimi (2005), o sucesso da agricultura de precisão não depende somente da rapidez da coleta de dados no campo, mas também da análise, da interpretação dos dados coletados e do desenvolvimento de técnicas de aplicação à taxa variável.

A aplicação à taxa variável torna possível que os insumos sejam aplicados nas quantidades e locais necessários, evitando aplicações excessivas em algumas áreas do campo e insuficientes em outras. Segundo Antuniassi (2000), o conceito de aplicação à taxa variável tem sido utilizado com grande sucesso nas operações de adubação por meio do cruzamento de informações dos mapas de fertilidade e produção da cultura.

Embora um dos principais focos da agricultura de precisão seja centrado no mapeamento prévio dos parâmetros das culturas agrícolas, a aplicação à taxa variável pode ser realizada em tempo real sem o uso de mapas (Saraiva, 2000). Essa aplicação em tempo real pode ser realizada com a ajuda de sensores que adquirem informações por meio da energia eletromagnética refletida pelos objetos. Estes sensores podem fazer parte de um sistema, conhecido como sistema de visão artificial (SVA) que tem a função de automatizar processos.

Basicamente um SVA é constituído por uma câmera, uma placa de aquisição de vídeo e programas computacionais específicos de processamento de imagens para extração das informações desejadas. As informações geradas pelo SVA podem ser utilizadas na tomada de decisão para a quantidade de N a ser aplicada. Segundo Sena Jr. (2005), para desenvolver um SVA, o maior desafio ainda é o desenvolvimento de algoritmos que sejam capazes de realizar a identificação e classificação dos objetos de interesse a partir das imagens digitais nas condições agrícolas, muitas vezes adversas.

Uma forma que tem sido utilizada para avaliar a reflectância do dossel das culturas é a utilização de índices espectrais (Hansen & Schjoerring, 2003). Esses índices resultam de transformações lineares da reflectância

obtidas em duas ou mais bandas do espectro eletromagnético, mediante soma, razão, diferença, ou qualquer outra combinação entre bandas (Wiegand et al., 1991). Com o uso de sensores, Raun et al. (2002) conseguiram aumentar com sucesso a eficiência no uso do N, variando doses de N baseado em dados de NDVI obtidos em tempo real. Utilizando combinações de quatro índices espectrais, extraídos de imagens digitais, como variáveis de entrada em um classificador estatístico, Baesso et al. (2007) conseguiu avaliar o status de N nas folhas do feijoeiro cultivado em vasos.

Os sistemas de visão artificial apresentam grande potencial de utilização para coleta de dados em agricultura de precisão (Pinto et al., 2001). Embora com grande potencial de utilização, há uma carência deste tipo de sistema no mercado e os trabalhos que foram desenvolvidos em relação ao feijão são baseados em dados coletados nas plantas cultivadas em casa de vegetação. Desta maneira, o desenvolvimento de sistemas capazes de identificar o estado nutricional do dossel de uma cultura torna-se de grande interesse na área agrícola.

Este trabalho teve como objetivo geral avaliar a discriminação de classes de nitrogênio foliar, a partir de índices de vegetação e um clorofilômetro portátil, e classes de produtividade do feijoeiro, a partir de índices de vegetação.

Os objetivos específicos foram:

- Avaliar a relação das doses de N aplicadas na semeadura com os teores de N foliar e valores obtidos com o clorofilômetro portátil;
- Verificar a correlação do clorofilômetro portátil com teor de N foliar e também dos índices de vegetação com os teores de N foliar e produtividade;
- Desenvolver classificadores estatísticos para discriminar classes de N foliar utilizando índices de vegetação e clorofilômetro portátil;
- Comparar os índices de vegetação e o clorofilômetro portátil na discriminação de classes de N foliar; e
- Desenvolver classificadores estatísticos para discriminar classes de produtividade utilizando índices de vegetação.

2. REVISÃO BIBLIOGRÁFICA

2.1. Cenário da cultura do feijão no Brasil

O feijão é um dos componentes básicos da dieta alimentar da população brasileira e importante fonte de proteína. Estudos mais recentes mostram que, por possuir compostos fenólicos com ação antioxidante e alto teor de fibra, a ingestão diária de feijão é importante na prevenção de várias doenças (Abreu & Peloso, 2004).

Historicamente, o feijão é cultivado no Brasil por pequenos produtores, com baixo uso de insumos, e voltado, sobretudo, para a subsistência das famílias. Porém, nos últimos vinte anos, notou-se um crescente interesse de produtores de outras classes econômicas em cultivos de feijão em grande escala, adotando tecnologias mais avançadas, tais como irrigação, controle fitossanitário e colheita mecanizada (Wander, 2005).

Dependendo da região, o plantio de feijão no Brasil é realizado ao longo do ano, em três épocas, de tal forma que, em qualquer mês, sempre haverá produção de feijão em algum ponto do país. A primeira safra, conhecida como safra das águas, é plantada entre agosto e outubro e tem como a região Sul e o estado de São Paulo como as principais regiões produtoras. A segunda, conhecida como safra da seca, é plantada de abril a junho, sendo a maior parte dos produtores do Sul-Sudeste. E a terceira, conhecida como safra de inverno, é plantada em junho/julho nos estados de São Paulo, Minas Gerais, Goiás e oeste da Bahia (Barreiras), sempre sob sistema irrigado, atingindo alta produtividade e abastecendo o mercado entre o final da comercialização da segunda safra e o início da primeira.

Segundo CEPA (2007), dentre os principais estados produtores destacam-se o Paraná, com 21,4% da produção total, Minas Gerais (15,5%) e Bahia (9,7%).

2.2. Nitrogênio e produtividade do feijoeiro

O feijoeiro é uma planta considerada exigente em nutrientes devido ao seu ciclo curto e sistema radicular pouco profundo. O N é o nutriente mais absorvido pelo feijoeiro e de vital importância na sua produtividade. Segundo Vieira (2006), um uso adequado deste nutriente está associado à alta atividade fotossintética, a crescimento vegetativo vigoroso e a folhas verde-escuras. Porém, sua deficiência provoca baixo desenvolvimento das plantas, as folhas tornam-se verde-amareladas e poucas flores desenvolvem-se.

Segundo Andreotti et al. (2005), o N é o elemento da qualidade, fazendo parte da composição das proteínas. Portanto seu uso, quando adequado, pode otimizar as produções e os lucros e, ao mesmo tempo, minimizar possíveis efeitos negativos sobre os solos e o meio ambiente. Muitos trabalhos demonstram que o N é o nutriente absorvido em maior quantidade pelo feijoeiro. Como a fixação biológica não supre a demanda da planta em N, a adubação nitrogenada frequentemente tem proporcionado expressivos aumentos na produtividade do feijoeiro.

Teixeira et al. (2000) estudaram o efeito da adubação nitrogenada sobre a cultivar Pérola de feijão conduzido em três ensaios de campo, aplicando quatro doses de N (0, 50, 100 e 150 kg ha⁻¹) parcelados em duas vezes: 2/3 na semeadura e 1/3 em cobertura 20 dias após a emergência (DAE). Esses autores concluíram que as doses crescentes de N elevaram linearmente a produtividade do feijoeiro.

Stone & Moreira (2001), em estudo realizado durante quatro anos com a cultivar de feijão Aporé, avaliaram o efeito da adubação nitrogenada em cobertura na produtividade do feijoeiro. Foi aplicada uma dose de adubação nitrogenada em cobertura: 0, 20, 40 e 60 kg ha⁻¹, nos dois primeiros anos, e 0, 40, 80 e 120 kg ha⁻¹, nos dois últimos. Verificou-se que em todos os anos a produtividade respondeu significativamente ao aumento das doses de N.

2.3. Avaliação do estado nutricional do feijoeiro

A avaliação do estado nutricional de plantas é uma necessidade na agricultura, pois por meio dela os agricultores praticam uma adubação mais adequada. Porém, a utilização da análise foliar é um método destrutivo que requer tempo entre a tomada das amostras e a obtenção dos resultados.

Segundo Silveira (2003), se a adubação nitrogenada for subestimada, ocorre redução no rendimento de grãos e se superestimada, ocorre aumento dos custos, pelo uso desnecessário de adubo e, conseqüentemente, prejuízos ao meio ambiente. Assim, o desenvolvimento de sistemas indiretos como o clorofilômetro portátil e técnicas de sensoriamento remoto, para identificação do estado nutricional, podem ser utilizados como alternativa para tomada de decisão sobre a quantidade e o momento da aplicação do adubo nitrogenado.

2.3.1. Clorofilômetro portátil

O medidor de clorofila Minolta SPAD-502 é utilizado na quantificação da clorofila, caracterizando-se pela rapidez, simplicidade e, principalmente, por possibilitar uma avaliação não destrutiva do tecido foliar. A intensidade da cor verde da folha é indiretamente detectada pelo aparelho, mensurando a quantidade de luz dos comprimentos de onda da região do vermelho e do infravermelho próximo que é transmitida pela folha (Zotareli et al., 2002). Como o N é constituinte da molécula de clorofila, existe alta correlação entre o seu teor e a clorofila nas folhas do feijoeiro. Assim a avaliação da necessidade de N pela planta pode ser determinada pela mensuração indireta do teor de clorofila (Malavolta et al., 1997).

Furlani Júnior et al. (1996) desenvolveram um trabalho constando de dois ensaios, sendo um em solução nutritiva e outro em solo, utilizando seis doses de N. Este teve como objetivo ajustar as leituras feitas nas folhas de feijoeiro, com um clorofilômetro portátil (Minolta SPAD-501) aos níveis crescentes de N e ao seu teor nas folhas. Foram realizadas correlações das leituras do clorofilômetro com as doses aplicadas de N e com seus teores nas folhas. Essas correlações foram positivas entre as leituras e as doses de N fornecidas ($r = 0,86$), e entre as leituras e os teores de N nas folhas ($r =$

0,75), concluindo que há boas perspectivas quanto ao uso desse equipamento para detectar deficiências de N no feijoeiro.

Soratto et al. (2004) realizaram uma pesquisa com a cultivar IAC Carioca, adubada com 0, 35, 70, 140 e 210 kg ha⁻¹ de N aplicadas em cobertura aos 20 (DAE), com o objetivo de avaliar a possibilidade de uso do teor de clorofila como indicativo do teor de N nas folhas do feijoeiro. A leitura com o clorofilômetro foi realizada após o florescimento pleno, na primeira folha completamente desenvolvida, com média de dez leituras por folíolo, em cinco plantas por parcela. As folhas utilizadas foram enviadas para laboratório para análise de teor de N. Os resultados mostraram que incrementos na dose de N em cobertura provocaram aumento do teor de clorofila e que o teor de N nas folhas apresentou correlação alta e significativa com o teor de clorofila do feijoeiro, possibilitando a utilização da prática não destrutiva de medição indireta da clorofila, por meio do clorofilômetro portátil.

2.3.2. Técnicas de sensoriamento remoto

Pesquisadores vêm estudando maneiras de identificar o estado nutricional nitrogenado em diversas culturas, utilizando técnicas de sensoriamento remoto (Gopalapillai et al., 1998; Goel et al., 2003; Sena Jr., 2005; Baesso et al., 2007; Silva Jr., 2008).

De acordo com Schröder et al. (2000), parâmetros obtidos pela combinação da reflectância no vermelho (ou verde) com o infravermelho próximo podem ser bons indicadores da tonalidade de verde da cultura e conseqüentemente do teor de clorofila. Segundo Moreira (2005), o N é um dos nutrientes que participa diretamente na formação da molécula de clorofila e sua deficiência afeta as propriedades espectrais, ocasionando um aumento da reflectância na faixa do visível e uma diminuição da reflectância na faixa do infravermelho próximo.

A possibilidade de utilizar fotografias aéreas de baixo custo para caracterizar a variabilidade do estado nutricional nitrogenado da cultura do milho foi mostrada por Blackmer et al. (1996). Neste estudo foram digitalizadas fotografias aéreas usando um esquema de oito bits para gerar as contagens digitais nas cores vermelha, verde e azul no estágio de

crescimento R5 (pré-floração). As respostas das contagens digitais eram relativas ao tratamento de N em que o rendimento dos grãos foi maior. As contagens digitais do vermelho e do verde obtiveram melhores resultados que as do azul, mostrando a viabilidade de utilizar fotografias aéreas de baixo custo na variabilidade do estado nutricional nitrogenado.

Na literatura, diversos índices vegetativos já foram propostos e utilizados, explorando as diferenças na reflectância espectral do dossel das culturas. Epiphany et al. (1996) avaliaram três índices de vegetação em função de três parâmetros relevantes em sensoriamento remoto: solo, ângulos de visada e ângulos de iluminação, em experimento fatorial com feijão, em quatro estágios de desenvolvimento. Foram realizadas medidas radiométricas ao longo do ciclo da cultura, utilizando um espectrorradiômetro. Constatou-se que a influência dos parâmetros estudados sobre as bandas individuais, que compõem os índices, foi relevante na compreensão dos efeitos sobre os índices, e esses apresentaram diferença significativa quanto aos solos, nos quatro estágios de crescimento da cultura.

Hansen & Schjoerring (2003), em um experimento com a cultura do trigo de inverno, utilizaram dados de reflectância espectral em cinco estágios de crescimento com dois cultivares, três densidades de plantio e quatro níveis de nitrogênio. Foram utilizadas todas as combinações de duas bandas e realizada regressão linear com biomassa fresca, índice de área foliar, concentração de clorofila foliar, densidade de clorofila, concentração de nitrogênio foliar e densidade de nitrogênio foliar. Os autores concluíram que, no cálculo dos índices tradicionais como vermelho/infravermelho e verde/infravermelho, a utilização de bandas mais estreitas (10 nm) promoveu melhores resultados que bandas mais largas. A relação entre as variáveis estudadas e esses índices foi melhor utilizando modelo exponencial do que modelo linear.

Segundo Fontes (2006), a utilização de técnicas de sensoriamento remoto oferece maior rapidez que as análises químicas. Elas podem ser usadas em veículos, automatizando o processo de avaliação do estado nutricional nitrogenado em grandes áreas, podendo também ser utilizadas como ferramenta na agricultura de precisão.

2.4. Agricultura de precisão e visão artificial

A agricultura tem passado por uma série de transformações, tornando a atividade cada vez mais competitiva e exigindo do produtor maior nível de especialização, capacidade de gerenciamento e profissionalismo. Com isso, a agricultura de precisão apresenta-se como alternativa à agricultura convencional.

A agricultura de precisão, segundo Molin (2002), é um conjunto de tecnologias e procedimentos com o objetivo de otimizar as lavouras e sistemas de produção, tendo como elemento-chave o manejo da variabilidade da produção e dos fatores envolvidos. Segundo Stafford (2000), a agricultura de precisão necessita de um grande número de informações que só será possível com os avanços obtidos no processamento computacional. Esse mesmo autor ressalta que existe ainda a necessidade do desenvolvimento de novas tecnologias, particularmente na área de sistemas de sensoriamento antes que a agricultura de precisão seja praticada de maneira generalizada.

Entre as ferramentas utilizadas na agricultura de precisão destaca-se o sensoriamento remoto. Segundo Pires et al. (2004), um dos papéis do sensoriamento remoto na agricultura de precisão é suprir a necessidade de repetitivas informações das condições do solo, bem como os atributos da cultura, incluindo condições fisiológicas das plantas e fatores abióticos.

A pesquisa em agricultura de precisão vem sendo direcionada para o monitoramento das condições da cultura como, identificação das deficiências nutricionais, da ocorrência de pragas e doenças, na classificação e quantificação de plantas daninhas, estimativa de produção, dentre outras (Goel. et. al., 2000). Assim, a utilização de sistemas de visão artificial na agricultura pode auxiliar no monitoramento das culturas.

A visão artificial é um sistema que adquire, processa e interpreta imagens. As imagens podem ser obtidas a partir de câmeras instaladas em equipamentos agrícolas, possibilitando a tomada de decisão em tempo real pelos equipamentos (Pinto et al., 2001). Os sistemas de visão artificial normalmente incorporam classificadores que processam informações obtidas de imagens de alta resolução. Esses classificadores são

normalmente desenvolvidos com base em modelos estatísticos ou em modelos não paramétricos, tal como redes neurais.

Varella (2004) desenvolveu um classificador para aplicação em sistemas de visão artificial, com a finalidade de estimar a deficiência de nitrogênio na cultura do milho. As imagens foram obtidas nas bandas do vermelho, verde, azul e infravermelho-próximo. Essas imagens foram obtidas em três diferentes estádios fenológico da cultura com cinco tratamentos (0, 30, 60, 90 e 120 kg N ha⁻¹). O autor concluiu que os vetores de características geradas nesse estudo foram capazes de discriminar os níveis de N no primeiro estágio fenológico estudado da cultura do milho.

Orlando (2003) utilizou técnicas de visão artificial para discriminar diferentes espécies de plantas daninhas e plantas de milho, com o intuito de racionalizar o uso de herbicidas. Foram testados classificadores estatísticos e redes neurais artificiais. O autor encontrou exatidões globais de 86,5% e 80,1%, respectivamente para o classificador estatístico e para as redes neurais artificiais.

2.5. Classificadores estatísticos

Segundo Gonzalez & Woods (1992), os classificadores estatísticos normalmente se baseiam em uma abordagem probabilística, dada a aleatoriedade nas quais as classes padrões estão envolvidas. Basicamente partem da teoria geral da probabilidade e dos erros onde, com o objetivo de minimizá-los.

O classificador estatístico bayesiano é um método de classificação paramétrico que utiliza informações estatísticas dos dados para desenvolver funções discriminantes. Essas funções discriminantes são superfícies de decisão ou superfícies de separação que determinam o limite entre duas ou mais classes.

Baesso et al. (2007), trabalhando com feijão cultivado em vasos, avaliaram o uso de índices espectrais retirados de imagens digitais, para discriminar diferentes doses de N no feijoeiro. O trabalho foi conduzido em casa de vegetação, com cinco tratamentos (0, 50, 100, 150 e 200 kg de N ha⁻¹). Foram desenvolvidas funções discriminantes quadráticas, tendo como vetores de entrada as médias dos pixels de diferentes combinações dos

quatro índices espectrais testados. Três diferentes tamanhos de blocos de imagem foram testados 9 x 9; 20 x 20 e 40 x 40 pixels. Os melhores resultados foram alcançados pelos blocos de 9 x 9 e 20 x 20 pixels, apresentando classificação 94; 96 e 96% superior à classificação ao acaso para os blocos 9 x 9 pixels e 92; 94 e 94% para os blocos 20x20 pixels aos 30, 40 e 50 dias após a emergência, respectivamente.

2.6. Avaliação dos classificadores

A acurácia do classificador estatístico pode ser estimada utilizando-se o método da validação cruzada deixando uma de fora. Com esse método, $n-1$ amostras das n amostras disponíveis são utilizadas para desenvolver a função discriminante que é então aplicada à amostra deixada de fora. Esse procedimento é repetido para cada uma das n observações de treinamento. A taxa de erro na classificação de cada grupo é a proporção das amostras daquele grupo que foram classificadas incorretamente.

De acordo com SAS (1999), o critério de classificação deve ser avaliado de acordo com seu desempenho na classificação de futuras observações. A matriz de erro ou matriz de confusão é uma matriz quadrática de números que expressam a quantidade de unidades amostrais, associada a uma dada categoria durante o processo de classificação efetuado e à categoria real a que pertencem essas unidades (Congalton, 1991). Esse mesmo autor afirma que a matriz de erros é uma forma útil para representar a exatidão, uma vez que as exatidões das diferentes classes estão claramente descritas, mostrando os erros de comissão e de omissão presentes na classificação.

Com a matriz de erros, podem-se avaliar os classificadores pela exatidão global e pelo coeficiente Kappa. Segundo Congalton (1991), a exatidão global, pode ser calculada dividindo-se o total de amostras corretamente classificadas (a diagonal da matriz de erros) pelo número total de amostras na matriz. Uma desvantagem de se trabalhar apenas com este método de avaliação é o fato de a exatidão global levar em conta apenas os erros de omissão de uma classe.

Ao contrário da exatidão global, o coeficiente Kappa leva em consideração toda a matriz de erros, incluindo os erros de omissão e de

comissão. Segundo Pedreira e Santos (1999), o coeficiente Kappa é uma avaliação bem mais adequada que a exatidão global, devido ao fato de ser sensível não só à perda de acurácia global como um todo, mas também devido às variações dos erros de omissão e de comissão.

3. MATERIAL E MÉTODOS

O estudo constou de dois experimentos de campo (nas safras da seca e de inverno de 2007) na Estação Experimental, pertencente ao Departamento de Fitotecnia da Universidade Federal de Viçosa. Esta estação experimental se encontra no município de Coimbra, Minas Gerais, e está à 20°49'39" de latitude sul e 42°46'01" de longitude a oeste de Greenwich, com altitude de 710 metros.

3.1. Implantação do experimento

Inicialmente, foram realizadas análises químicas do solo para correção da fertilidade do mesmo. A correção do pH e adubação, nos sulcos de semeadura, de fósforo (P) e potássio (K) foram realizadas de acordo com a recomendação de Chagas et al. (1999) para a cultura do feijão no nível de tecnologia 4.

Posteriormente, o solo foi preparado com uma aração e duas gradagens. A cultura foi mantida sob regime de irrigação por aspersão convencional, sendo os demais tratamentos culturais e fitossanitários realizados conforme as recomendações para o feijoeiro na região.

O delineamento experimental utilizado foi o de blocos casualizados, com tratamentos distribuídos em esquema fatorial 5 x 6, com três repetições, totalizando 90 parcelas. As parcelas de 5 por 3 metros foram constituídas por seis linhas. Os tratamentos foram constituídos por cinco doses de N (0, 20, 30, 40 e 50 kg ha⁻¹) aplicadas na semeadura e seis doses de N (0, 20, 30, 40, 60 e 80 kg ha⁻¹) aplicadas em cobertura na forma de uréia, totalizando 30 tratamentos. As doses aplicadas em cobertura foram divididas

em doses únicas para as doses 20 e 30 kg ha⁻¹ e parceladas igualmente para as doses 40, 60 e 80 kg ha⁻¹.

A semeadura foi realizada em covas como auxílio de matracas. Foram utilizadas sementes de feijão da cultivar BRSMG Majestoso, pertencente ao grupo Carioca, com espaçamento de 0,50 m entre linhas e aproximadamente 15 sementes por metro de sulco. A Tabela 1 mostra as datas das semeaduras e adubações realizadas nas duas safras.

Tabela 1 – Datas da semeadura e das adubações de cobertura

Safras	Semeadura	Adubação de N em cobertura		
		Dose Única	1ª Parcela	2ª Parcela
Seca	14/03/2007	17/04/2007 (26 DAE)	12/04/2007 (21 DAE)	23/04/2007 (32 DAE)
Inverno	10/08/2007	18/09/2007 (27 DAE)	12/09/2007 (21 DAE)	25/09/2007 (34 DAE)

DAE: dias após a emergência.

A implantação do experimento e sua condução foram realizados de modo semelhante nas duas safras, mudando somente a área e a época de plantio. O primeiro experimento instalado na época da seca, no período compreendido entre março e junho de 2007, em uma área antes ocupada por plantação de milho. O segundo experimento instalado na época de inverno, no período compreendido entre agosto e novembro de 2007, em uma área sem uso agrícola por no mínimo dois anos consecutivos.

3.2. Obtenção das imagens

Para a obtenção das imagens foi utilizado um sistema composto por duas câmeras digitais distantes entre si de 13,5 cm, obtendo no mesmo instante, duas imagens da mesma cena. A Figura 1 ilustra o sistema de aquisição das imagens. Na Figura 2 é apresentado este sistema em funcionamento na área experimental.




Figura 1. Esquema representativo para aquisição das imagens.



Figura 2. Sistema de aquisição das imagens nas parcelas experimentais.

As câmeras foram acopladas a uma haste com três metros de altura, equivalente à altura de um pivô central, considerando que este sistema de aquisição poderia ser acoplado a um pivô central, automatizando a aquisição dos dados na identificação do estado nutricional de N e estimativa de produtividade do feijoeiro.

O sistema de aquisição das imagens foi o STH-DCSG-VAR/-C do fabricante Videre Design (Califórnia, EUA). Este modelo é composto por duas câmeras, uma monocromática e uma colorida. Na câmera monocromática foi acoplado um filtro óptico que limita a faixa do espectro, sensibilizando o sensor da câmera na faixa do infravermelho próximo (NIR)

no intervalo de 695 à 1050 nm. Da câmera colorida foram utilizadas as bandas do vermelho (R) e do verde (G). As faixas do espectro que sensibilizavam o sensor da câmera colorida estão apresentadas na Figura 3.




Figura 3. Espectro de sensibilidade do sensor MT9V022 às bandas vermelho (R), verde (G) e azul (B) da câmera colorida em função do comprimento de onda. Fonte: VIDERE DESIGN (2005).

As câmeras foram conectadas a um microcomputador portátil através de cabos com 10 metros de comprimento conectados em um cartão de interface digital PCMCIA IEEE 1394. Para o funcionamento das câmeras foi necessária uma alimentação externa, portanto acoplou-se uma bateria de 12 volts à placa PCMCIA card.

O padrão das lentes foi C-mount com a distância focal de 2,8 mm. As imagens foram salvas no formato BMP (Bitmap) com dimensão de 320(V) x 240(H) pixels, utilizando o software SRI's Small Vision System (SVS) fornecido pelo fabricante das câmeras. O sensor das câmeras foi o CMOS MT9V022 no formato de 1/3". Sendo assim, foram obtidas imagens que representam uma área de, aproximadamente, 3,18 x 4,87 metros com uma resolução espacial de aproximadamente 14 mm pixel⁻¹. Para eliminar as

bordaduras das parcelas, as imagens foram cortadas para representar um área de 2,0 x 2,0 m.

As características das câmeras tempo de exposição, ganho e correção do gamma, foram ajustadas para 50%, 17% e 1, respectivamente. Com exceção da correção do gamma, que é decimal, estes valores são em porcentagem e foram escolhidos baseados em testes preliminares. O ajuste do foco e a abertura da entrada de luz (diafragma) foram regulados por meio da análise da imagem formada no computador, observando o efeito do ruído (saturação do valor pixel). Estes também foram mantidos os mesmos durante todas as coletas.

As imagens foram obtidas no mesmo período, entre 10:00 e 14:00 horas, minimizando assim mudanças na reflectância da cultura. A Tabela 2 abaixo mostra as datas de coletas de dados no campo.

Tabela 2 – Datas da obtenção das imagens e coletas das folhas para obter o valor SPAD e N foliar

Experimento	Imagens	SPAD e N Foliar
1	18/04/2007 (27 DAE)	10/04/2007 (19 DAE)
	02/05/2007 (41 DAE)	16/04/2007 (25 DAE)
	25/05/2007 (64 DAE)	30/04/2007 (39 DAE)
2	10/09/2007 (19 DAE)	27/08/2007 (05 DAE)
	17/09/2007 (26 DAE)	03/09/2007 (12 DAE)
	24/09/2007 (33 DAE)	11/09/2007 (20 DAE)
	10/10/2007 (49 DAE)	19/09/2007 (28 DAE)
	17/10/2007 (56 DAE)	26/09/2007 (35 DAE)
	29/10/2007 (68 DAE)	18/10/2007 (57 DAE)

DAE: dias após a emergência.

Experimento 1: safra da seca.

Experimento 2: safra de inverno.

3.3. Estimativas do teor de clorofila foliar

Para estimar o teor de clorofila de cada parcela, foi utilizado um medidor portátil de clorofila SPAD 502. Os valores medidos pelo equipamento correspondem às medidas indiretas do teor de clorofila na folha (Costa et al., 2001).

As folhas das plantas foram posicionadas entre o emissor e o receptor do equipamento de modo que a radiação transmitida através da folha fosse convertida em sinais eletrônicos. Os valores são calculados com base na

quantidade de radiação transmitida pela folha na faixa do vermelho e do infravermelho próximo (Schepers et al., 1996). Em cada parcela, o valor SPAD foi obtido com a média da leitura aleatória de 30 valores (Figura 4) coletadas do terço médio das plantas conforme sugerido por Martinez et al. (1999) para diagnose foliar do feijoeiro. As datas das coletas dos valores SPAD estão apresentadas na Tabela 2.



Figura 4. Medidor portátil de clorofila SPAD 502.

3.4. Determinação do teor de nitrogênio foliar

As mesmas folhas utilizadas para estimar o teor de clorofila foram coletadas como amostras para determinar o teor de nitrogênio presente nas folhas. O material coletado foi identificado e depois acondicionado em sacos de papel e enviado ao Laboratório de Análise de Solos Viçosa Ltda., Viçosa - MG, para determinação do teor total de nitrogênio.

3.5. Determinação da produtividade

Para estimar a produtividade, as parcelas foram reduzidas para uma área útil de 8 m², desprezando-se 0,5 m de cada lado. A produtividade de grãos (kg ha⁻¹) foi obtida coletando as plantas de duas das quatro linhas da área útil de cada parcela, deixando-as secar ao ar (Figura 5).



Figura 5. Parcelas amarradas duas a duas com seus respectivos tratamentos.

A colheita do experimento 1 foi realizada no dia 18/06/2007. A colheita do experimento 2 foi realizada em duas vezes, nos dias 14/11/2007 e 19/11/2007, pois as parcelas não apresentavam uma maturação uniforme.

Depois da colheita foi realizada a trilha mecânica e determinada a massa dos grãos com o uso de uma balança de precisão. A umidade foi obtida pelo método padrão de estufa, $105^{\circ}\text{C} \pm 3$ por 24 horas (Brasil, 1992), com duas repetições. O valor observado foi corrigido para a umidade padrão de 12% na base úmida de acordo com a equação 1.

$$m_c = m \left(\frac{100 - U_i}{100 - U_{\text{padrão}}} \right) \quad (1)$$

Em que,

m_c = massa corrigida (kg);

U_i = umidade do feijão (%); e

$U_{\text{padrão}}$ = umidade padrão (%).

m = massa úmida (kg)

3.6. Processamento 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[®] 6.0 com o pacote de ferramentas para processamento de imagens. O código fonte dos algoritmos é apresentado nos apêndices.

Para realçar na imagem a informação a respeito do estado nutricional nitrogenado das plantas, da produtividade e atenuar a influência da variação da iluminação natural foram utilizados índices de vegetação. O processamento foi realizado utilizando-se oito índices espectrais, combinando as bandas do visível (vermelho e verde) com infravermelho próximo.

Os índices de vegetação estudados foram o NDVI (Rouse et al., 1974), GNDVI (Gitelson et al., 1996), SAVI (Huete, 1988) e WDRVI (Gitelson, 2004) de acordo com as equações 2, 3, 4 e 5, respectivamente.

$$NDVI = \frac{IV - Vm}{IV + Vm} \quad (2)$$

em que,

NDVI = índice de vegetação da diferença normalizada;

IV = valor numérico do pixel na banda do infravermelho próximo; e

Vm = valor numérico do pixel na banda do vermelho.

$$GNDVI = \frac{IV - Vd}{IV + Vd} \quad (3)$$

em que,

GNDVI = índice de vegetação da diferença de verde normalizado;

Vd = valor numérico do pixel na banda do verde.

$$SAVI = \frac{IV - Vm}{IV + Vm + L} (1 + L) \quad (4)$$

em que,

SAVI = índice de vegetação ajustador do solo;

L = constante de ajuste.

$$\text{WDRVI} = \frac{a \cdot IV - Vm}{a \cdot IV + Vm} \quad (5)$$

em que,

WDRVI = índice de vegetação de larga escala dinâmica,

a = coeficiente de ponderação, onde $a = 0,05$ a $0,2$.

Para o cálculo do SAVI foram utilizados os três valores da constante de ajuste ($L = 0,25$, $L = 0,5$ e $L = 1,0$). Para o cálculo do WDRVI foram utilizados três valores do coeficiente de ponderação ($a = 0,05$, $a = 0,1$ e $a = 0,2$).

3.7. Análise de regressão

Foi utilizada análise de regressão para verificar a existência de relação funcional entre as doses de N aplicadas na semeadura (0, 20, 30, 40 e 50 kg ha⁻¹), valores SPAD e valores de N foliar para as épocas de coleta de dados antes da adubação em cobertura.

Utilizou-se o programa computacional SAS para efetuar o ajuste de um modelo linear simples dos dados e realizou-se o teste F para a falta de ajuste e análise de variância da regressão ao nível de 5% de probabilidade. Quando o teste F para a falta de ajuste foi significativo, procedeu-se o ajuste de um modelo linear de segundo grau. Não foram testados modelos superiores ao de segundo grau, por estes não representarem o fenômeno biológico da cultura, pois, em geral, a resposta com a elevação de doses de N é no máximo quadrático.

Cada repetição dos valores SPAD e N foliar foram obtidos com a média das seis parcelas dentro do mesmo bloco que receberam as mesmas doses de N na semeadura.

3.8. Análise de correlação

Foi realizada análise de correlação do teor de N foliar com valores SPAD e com índices de vegetação para os dados coletados antes da

adubação em cobertura, por meio da correlação linear de “Pearson”. Os teores de N foliar foram correlacionados com valores SPAD e com os índices de vegetação e as correlações obtidas foram sujeitas a teste de significância a 1%.

Também verificou-se a correlação entre os índices de vegetação e produtividade para os dados coletados após a adubação em cobertura. Os índices de vegetação foram correlacionados com a produtividade e as correlações obtidas foram sujeitas ao teste de significância a 1%.

3.9. Desenvolvimento dos classificadores

Para discriminar classes de N foliar, foram utilizados os índices de vegetação e valores SPAD coletados antes da adubação em cobertura.

As classes de N foliar foram definidas com base nos valores de referência proposto por Martinez et al. (1999) para a cultura do feijão. Segundo esse autor o valor de referência varia de 3,0 a 3,5%. Neste trabalho as classes foram definidas conforme a Tabela 3.

Tabela 3. Classes de N foliar e suas correspondentes faixas

Classes de N foliar	Faixas de N foliar (%)
Baixa	< 3,0
Satisfatória	3,0 a 3,5
Alta	> 3,5

Para discriminar classes de produtividade, foram utilizados os índices de vegetação extraídos das imagens coletadas após a adubação em cobertura. As classes de produtividade foram definidas baseadas nas produtividades esperadas de acordo com níveis de tecnologia (NT) proposto por Chagas et al. (1999) para a cultura do feijão. Segundo esse autor quando se adota o NT₁ é esperada uma produtividade de até 1.200 kg ha⁻¹, para o NT₂ de 1.200 a 1.800 kg ha⁻¹, para o NT₃ de 1.800 a 2.500 kg ha⁻¹ e para o NT₄ acima de 2.500 kg ha⁻¹. Neste trabalho foram definidas três classes de produtividade (baixa, média e alta), conforme os níveis tecnológicos 2, 3 e 4, pois nesse trabalho não foi encontrada produtividade abaixo de 1.200 kg ha⁻¹ (Tabela 4)

Tabela 4. Classes de produtividade e suas correspondentes faixas de produtividade

Classes de produtividade	Faixas de produtividade (kg ha ⁻¹)
Baixa	< 1.800
Média	1.800 a 2.500
Alta	> 2.500

O vetor de características, formado pelos valores dos índices de vegetação, foi utilizado como variável de entrada de um classificador para discriminar classes de nitrogênio foliar e produtividade. Para isso, todas as possíveis combinações de índices foram testadas, totalizando 255 combinações diferentes para cada época de coleta de dados. As combinações são apresentadas na Tabela 5.

Tabela 5. Tipos de combinações de índices de vegetação e número de classificadores que serão desenvolvidos

Número de índices de vegetação combinados	Número de classificadores
1	8
2	28
3	56
4	70
5	56
6	28
7	8
8	1
Total	255

Foi testado um classificador estatístico descrito por Gonzáles & Woods (2000) (equação 6). Esse classificador foi composto por um conjunto de função discriminantes.

$$d_j(X) = \ln P(W_j) - \frac{1}{2} \ln(\det C_j) - \frac{1}{2} [(X - m_j)^T C_j^{-1} (X - m_j)] \quad (6)$$

em que,

d_j = função discriminante da classe j;

C_j = matriz de covariância da classe j;

$\det C_j$ = determinante da matriz de covariância da classe j;

X = vetor de características;
 m_j = vetor de média da classe j .
 $P(W_j)$ = probabilidade a priori da classe j ; e
 T = transposta de uma matriz.

Assumindo que as probabilidades *a priori* de ocorrência das classes são iguais, a equação anterior pode ser reescrita como:

$$d_j(X) = -\frac{1}{2} \ln[\det(C_j)] - \frac{1}{2} [(X - m_j)^T \cdot C_j^{-1} (X - m_j)] \quad (7)$$

Um vetor desconhecido X foi atribuído à classe j que apresentar maior valor da função discriminante $d_j(X)$.

3.10. Avaliação dos classificadores

O desempenho dos classificadores estatísticos foi analisado utilizando o método da validação cruzada deixando um de fora (Khattree & Naik, 2000). Nesse processo, uma observação foi separada e as funções discriminantes foram elaboradas com o restante dos dados (89 amostras), e, em seguida, a observação separada foi classificada. Esse procedimento foi repetido sucessivamente para cada uma das 90 observações, ou seja, 30 tratamentos (cinco doses de N aplicados na semeadura e seis em cobertura) e três repetições.

O erro de classificação foi estimado pela elaboração de uma matriz de erros com os resultados da classificação de cada combinação de índices. Matriz de erros é um arranjo quadrado de dimensão igual ao número de classes avaliadas, as colunas são representadas pelos dados de referência e as linhas pelos resultados da classificação. Os valores da diagonal principal representam o nível de concordância entre os conjuntos de dados. Desta matriz pode ser extraído o erro de omissão (em que o objeto não é classificado na classe à qual ele pertence) e erro de inclusão (onde o objeto é incluído em uma classe à qual ele não pertence).

Para mensurar o desempenho dos classificadores foi determinada a exatidão global de classificação e o coeficiente Kappa, descrito por Hudson & Ramm (1987). A exatidão global representa a concordância de classificação para toda a imagem de um modo geral. Seu cálculo é feito dividindo o total de unidades amostrais classificados corretamente pelo total de unidades amostrais registrado na amostra, conforme a Equação 8.

$$EG = \frac{CC}{N_t} 100 \quad (8)$$

em que,

- EG = exatidão global de classificação;
- CC = número de amostras classificadas corretamente; e
- N_t = número total de amostras.

O índice kappa, diferentemente da exatidão global, utiliza todos os dados da matriz de erro na sua fórmula, conforme a Equação 9.

$$\hat{K} = \frac{n \sum_{i=1}^c a_{ii} - \sum_{i=1}^c a_{ie} a_{ei}}{n^2 - \sum_{i=1}^c a_{ie} a_{ei}} \quad (9)$$

em que,

- \hat{K} = estimativa do coeficiente kappa;
- a_{ii} = valor da linha i coluna i da diagonal da matriz de erros;
- a_{ie} = valor total da linha i;
- a_{ei} = valor total da coluna j;
- n = número total de amostras; e
- c = número total de classes.

Kappa igual a zero significa que o acerto obtido pelo classificador é igual ao acerto por acaso. Valores positivos de Kappa ocorrem quando o acerto for maior que o acaso, enquanto os negativos ocorrem quando o acerto é pior do que uma classificação por acaso.

Em cada época de obtenção das imagens no campo, foi selecionada a melhor combinação de índices, por meio do maior coeficiente Kappa entre as combinações de índices testadas. Na comparação entre os classificadores utilizou-se o teste Z para testar a diferença entre dois coeficientes kappa independentes ao nível de significância de 5%, utilizando a equação 10.

$$Z = \frac{\hat{K}_1 - \hat{K}_2}{\sqrt{\text{var}(\hat{K}_1) + \text{var}(\hat{K}_2)}} \quad (10)$$

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; e

A variância para grandes amostras do coeficiente Kappa foi determinada pelas equações 11 a 15 (Bishop et al., 1975 citados por Hudson & Ramm, 1987).

$$\text{var}(\hat{K}) = \frac{1}{n} \left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4} \right] \quad (11)$$

em que,

$$\theta_1 = \frac{1}{n} \sum_{i=1}^c a_{ii} \quad (12)$$

$$\theta_2 = \frac{1}{n^2} \sum_{i=1}^c (a_{ie} a_{ei}) \quad (13)$$

$$\theta_3 = \frac{1}{n^2} \sum_{i=1}^c a_{ii} (a_{ie} a_{ei}) \quad (14)$$

$$\theta_4 = \frac{1}{n^3} \sum_{i=1}^c \sum_{j=1}^c a_{ij} (a_{je} a_{ej})^2 \quad (15)$$

Se o valor Z calculado para o teste for maior que o valor Z tabelado, diz-se que o resultado foi significativo e rejeita-se a hipótese nula ($H_0:K1=K2$), concluindo-se que os dois classificadores são estatisticamente diferentes. O valor Z tabelado ao nível de 5% de probabilidade é igual a 1,96.

4. RESULTADO E DISCUSSÃO

4.1. Análise das imagens adquiridas ao longo dos dias após a emergência

As Figuras 6, 7 e 8 ilustram a evolução da cultura ao longo dos dias após a emergência no experimento 1, aos 27, 41 e 64 DAE, respectivamente. As imagens apresentadas, tanto do experimento 1 como do experimento 2, foram recortadas para representar um área de 2,0 x 2,0 metros, no intuito de eliminar as bordaduras das parcelas. Todas as imagens mostradas são da mesma parcela que receberam as maiores doses de N na semeadura (50 kg ha^{-1}) e em cobertura (80 kg ha^{-1}) do bloco 1.




Figura 6. Imagens coletadas aos 27 DAE. a) imagem colorida; b) imagem infravermelha.




Figura 7. Imagens coletadas aos 41 DAE. a) imagem colorida; b) imagem infravermelha.






Figura 8. Imagens coletadas aos 64 DAE. a) imagem colorida; b) imagem infravermelha.

Observa-se nas três figuras acima que as imagens coloridas ficaram escuras, o ajuste do foco e a abertura da entrada de luz (diafragma) foram regulados por meio da análise da imagem formada no computador. O ajuste do foco e a abertura da entrada de luz foram regulados na primeira coleta e mantidos constantes durante toda o experimento. Aos 27 DAE, observa-se que é possível visualizar solo nas entre linhas (Figura 6.a). Já aos 41 e 64 DAE a cobertura vegetal predomina (Figura 7.a e Figura 8.a).

As Figuras 9, 10, 11, 12, 13 e 14 ilustram a evolução da cultura ao longo dos dias após a emergência no experimento 2, aos 19, 26, 33, 49, 56 e 68 DAE, respectivamente.




a




b

Figura 9. Imagens coletadas aos 19 DAE. a) imagem colorida; b) imagem infravermelha.




a




b

Figura 10. Imagens coletadas aos 26 DAE. a) imagem colorida; b) imagem infravermelha.




a




b

Figura 11. Imagens coletadas aos 33 DAE. a) imagem colorida; b) imagem infravermelha.




a



b

Figura 12. Imagens coletadas aos 49 DAE. a) imagem colorida; b) imagem infravermelha.




a



b

Figura 13. Imagens coletadas aos 56 DAE. a) imagem colorida; b) imagem infravermelha.



a



b

Figura 14. Imagens coletadas aos 68 DAE. a) imagem colorida; b) imagem infravermelha.

Diferentemente do experimento 1, no experimento 2, as seis imagens anteriores ficaram mais claras. Como na experimento 1, o ajuste do foco e a abertura da entrada de luz (diafragma) foram regulados por meio da análise da imagem formada no computador, na primeira coleta e mantidos os mesmos durante toda o experimento. Nas três primeiras coletas (19, 26 e 33 DAE), era possível visualizar o solo. Aos 68 DAE nota-se que algumas folhas já estavam amareladas. Nesta época, o feijoeiro já se encontra na última etapa da sua fase reprodutiva (maturação) (Santos & Gavilanes, 2006).

4.2. Análise de regressão das variáveis SPAD e N foliar em relação às doses de N aplicadas na sementeira

4.2.1. Relação entre valores de N foliar e doses de N aplicadas na sementeira

A evolução dos valores de N foliar para as cinco doses de N aplicadas na sementeira é ilustrada na Figura 15, para experimento 1, e Figura 16, para o s experimento 2.




Figura 15. Evolução dos valores médios de N foliar, aos 19 e 25 DAE no experimento 1, para as doses de N aplicado na sementeira.




Figura 16. Evolução dos valores médios de N foliar, aos 05, 12, 20 e 28 DAE no experimento 2, para as doses de N aplicado na semeadura.

No experimento 1, houve uma tendência de diminuição na média dos valores de N foliar entre 19 e 25 DAE. Aos 19 DAE, observa-se uma variação na média dos valores de N foliar em relação às doses de N aplicados na semeadura. Aos 25 DAE esses valores tiveram pouca variação, permanecendo praticamente constantes em relação às doses de N aplicadas na semeadura.

A média dos valores de N foliar, aos 19 e 25 DAE, ficaram acima da faixa de valores satisfatória, segundo Martinez et al. (1999). Para esses autores a faixa de suficiência ou teores adequados para o teor de nitrogênio foliar é de 3,0 a 3,5% para amostras colhidas do terço mediano das plantas na época do florescimento. Esse experimento foi conduzido logo após a colheita do milho que estava implantado na área. Normalmente a cultura do milho recebe de 100 a 200 kg ha⁻¹ de N em cobertura, para que a cultura atinja uma produtividade alta. Acredita-se que essas altas doses de N possam ter influenciado na fertilidade do solo. Já o segundo experimento foi conduzido em solo sem uso agrícola por no mínimo dois anos consecutivos. Nessa área, os valores dos macronutrientes P (1,3 mg dm⁻³) e K (26 mg dm⁻³) tiveram uma classificação baixa, segundo Alvarez et al. (1999). Portanto, os valores apresentados de P e K, no experimento 1, indicam uma superioridade na fertilidade do solo para este experimento.

No experimento 2, aos 5 e 28 DAE, observa-se que houve pouca variação na média dos valores de N foliar em relação às doses de N aplicados na sementeira, indicando uma pequena distinção entre as doses de N aplicadas na sementeira para estas datas. Como observado no experimento 1, ocorreu uma tendência na diminuição ao longo tempo dos valores médios de N foliar. Segundo Fontes (2006), as concentrações de nutrientes em um determinado tecido variam de acordo com a idade da planta. Em geral, a concentração de N nas folhas decresce com o aumento da idade da planta.

Os resultados da análise de regressão com o teste F para falta de ajustamento dos modelos lineares de primeiro grau ajustados entre as doses de N aplicadas na sementeira e os valores de N foliar aos 19 e 25 DAE, experimento 1 são apresentados na Tabela 6.

Tabela 6. Resultados da análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre valores de N foliar e doses de N aplicados na sementeira aos 19 e 25 DAE para o experimento 1

Épocas estudadas	Teste F	
	Falta de Ajuste	Regressão
19 DAE	0,16 ^{ns}	18,98 ^{**}
25 DAE	0,08 ^{ns}	0,53 ^{ns}

^{**} significativo ao nível de 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade; N foliar: análise do teor de nitrogênio nas folhas.

A hipótese H0 do teste para falta de ajustamento é a de que a mesma não é significativa. A hipótese foi aceita para o modelo linear de primeiro grau obtido com os valores de N foliar nas duas épocas analisadas, indicando que o modelo ajustou-se bem para explicar a variação dos teores de N foliar observados em função das doses de N aplicadas na sementeira. Uma vez que o teste F para falta de ajustamento não foi significativo para os valores de N foliar coletados aos 19 DAE, a regressão obtida foi submetida à análise de variância.

A Figura 17 ilustra o modelo ajustado de primeiro grau e seu respectivo coeficiente de determinação juntamente com o diagrama de dispersão dos valores de N foliar em função das doses de N aplicadas na sementeira, aos 19 DAE, para o experimento 1.




Figura 17. Modelo linear de primeiro grau ajustado para os valores de N foliar com as doses de nitrogênio aplicadas na sementeira aos 19 DAE para o experimento 1.

Observa-se que houve aumento nos valores médios de N foliar com o aumento das doses de N aplicadas na sementeira.

Os resultados da análise de regressão com o teste F para falta de ajustamento dos modelos lineares de primeiro grau ajustados entre as doses de N aplicadas na sementeira e os valores de N foliar aos 05, 12, 20 e 28 DAE, experimento 2 são apresentados na Tabela 7.

Tabela 7. Resultados da análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre valores de N foliar e doses de N aplicados na sementeira aos 05, 12, 20 e 28 DAE para o experimento 2

Épocas estudadas	Teste F	
	Falta de Ajuste	Regressão
05 DAE	0,16 ^{ns}	18,88**
12 DAE	6,54**	-----
20 DAE	0,13 ^{ns}	27,02**
28 DAE	0,44 ^{ns}	2,98 ^{ns}

** significativo ao nível de 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade; N foliar: análise do teor de nitrogênio nas folhas.

Dentre os modelos lineares de primeiro grau testados entre doses de N aplicadas na sementeira e valores de N foliar, o teste F para a falta de ajustamento, com exceção aos 12 DAE, apresentou-se não significativo ao nível de 1% de probabilidade. Nas demais épocas, 05, 20 e 28 DAE, os

modelos lineares de primeiro grau ajustaram-se bem aos dados. Porém aos 28 DAE, para a regressão não foi significativo.

As Figuras 18 e 19 ilustram o modelo ajustado de primeiro grau e seu respectivo coeficiente de determinação juntamente com o diagrama de dispersão dos valores de N foliar em função das doses de N aplicadas na semeadura, aos 05 e 20 DAE, para o experimento 2, respectivamente.




Figura 18. Modelo linear de primeiro grau ajustado para os valores de N foliar com as doses de nitrogênio aplicadas na semeadura aos 05 DAE para o experimento 2.




Figura 19. Modelo linear de primeiro grau ajustado para os valores de N foliar com as doses de nitrogênio aplicadas na semeadura aos 20 DAE para o experimento 2.

A falta de ajustamento foi significativa ao nível de 1% de probabilidade para o modelo linear de primeiro grau ajustado aos 12 DAE, assim procedeu-se o ajuste de modelos lineares de segundo grau entre doses de N aplicadas na sementeira e os valores N foliar (Tabela 8).

Tabela 8. Resultados da análise de variância do teste F para falta de ajustamento do modelo linear de segundo grau entre valores de N foliar e doses de N aplicados na sementeira aos 12 DAE para o experimento 2

Épocas estudadas	Teste F	
	Falta de Ajuste	Regressão
12 DAE	1,77 ^{ns}	160,16**

** significativo ao nível de 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade; N foliar: análise do teor de nitrogênio nas folhas.

A Figura 20 ilustra o modelo ajustado de segundo grau e seu respectivo coeficiente de determinação juntamente com o diagrama de dispersão dos valores de N foliar em função das doses de N aplicadas na sementeira, aos 12 DAE, para o experimento 2.

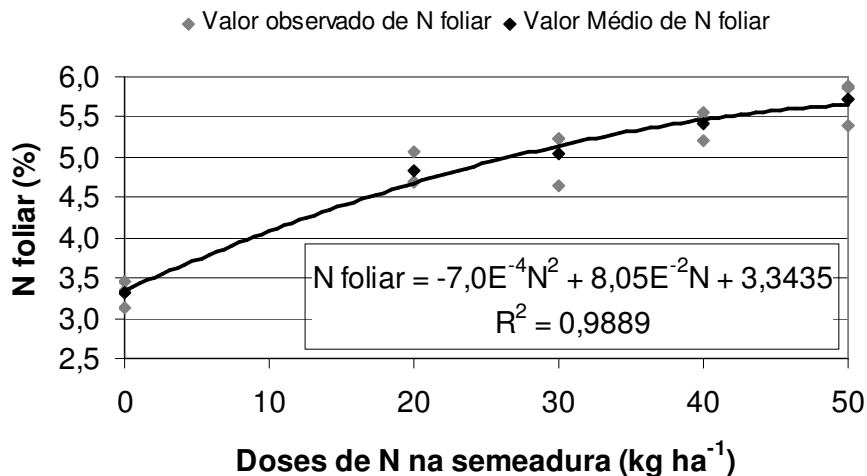


Figura 20. Modelo linear de segundo grau ajustado para os valores de N foliar com as doses de nitrogênio aplicadas na sementeira aos 12 DAE para o experimento 2.

Portanto é possível concluir, com base nos modelos ilustrados nas Figuras 17, 18 e 19, que a cultura respondeu significativamente as doses de N aplicadas antes da adubação em cobertura.

4.3.2. Relação entre valores SPAD e doses de N aplicados na semeadura

A evolução dos valores de N foliar para as cinco doses de N aplicadas na semeadura é ilustrada na Figura 21, para o experimento 1, e Figura 22, para o experimento 2.

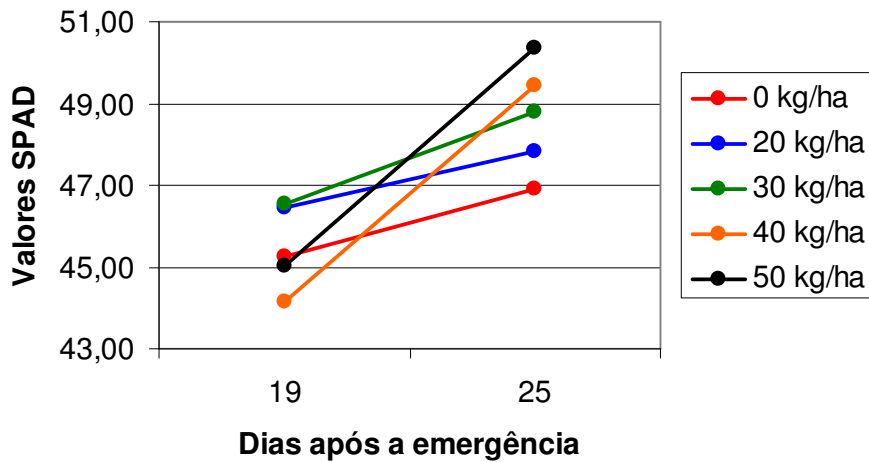


Figura 21. Evolução dos valores médios de SPAD, aos 19 e 25 DAE no experimento 1, para as doses de N aplicados na semeadura.




Figura 22. Evolução dos valores médios de SPAD, aos 05, 12, 20 e 28 DAE no experimento 2, para as doses de N aplicados na semeadura.

No experimento 1, os 19 DAE, observa-se que as médias dos valores SPAD foram próximas. Aos 25 DAE, a média dos valores SPAD teve uma

tendência em aumentar com o acréscimo das doses de N aplicadas na semeadura, comportamento diferente do encontrado na Figura 15, onde a média dos valores de N foliar tiveram pouca variação permanecendo praticamente constantes em relação às doses de N aplicadas na semeadura. Essa diferença entre o comportamento do N foliar e valores SPAD deve-se ao fato do teor de clorofila ser influenciado por outros fatores além do N. Segundo Chapman & Barreto (1997), 50 a 70% do N total das folhas é integrante de enzimas associadas aos cloroplastos, demonstrando que apesar da sua importância, o mesmo, não é o único responsável pela composição da clorofila.

No experimento 2, aos 5 DAE, observa-se que as médias dos valores SPAD foram próximas. Aos 12, 20 e 28 DAE, a média dos valores SPAD teve uma tendência em aumentar com o aumento das doses de N aplicadas na semeadura, principalmente das parcelas que não receberam adubação para as que foram adubadas.

Os resultados da análise de regressão com o teste F para falta de ajustamento dos modelos lineares de primeiro grau ajustados entre as doses de N aplicadas na semeadura e os valores SPAD aos 19 e 25 DAE, experimento 1 são apresentados na Tabela 9.

Tabela 9. Resultados da análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre valores de SPAD e doses de N aplicados na semeadura aos 19 e 25 DAE para o experimento 1

Épocas estudadas	Teste F	
	Falta de Ajuste	Regressão
19 DAE	3,06 ^{ns}	0,38 ^{ns}
25 DAE	0,08 ^{ns}	25,41 ^{**}

** significativo ao nível de 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade; N foliar: análise do teor de nitrogênio nas folhas.

Nas duas datas estudadas no experimento 1, os modelos lineares de primeiro grau apresentaram-se não significativos ao nível de 5% de probabilidade no teste para a falta de ajustamento, indicando um bom ajuste dos modelos aos dados. O teste F da regressão foi significativo apenas aos 25 DAE para o modelo linear de primeiro grau ajustado dos valores SPAD ao

nível de 5% de significância. Isso indica a existência de uma relação funcional entre essas variáveis.

A Figura 23 ilustra o modelo ajustado e seu respectivo coeficiente de determinação juntamente com o diagrama de dispersão dos valores SPAD em função das doses de N aplicadas na sementeira aos 25 para o experimento 1.




Figura 23. Modelo linear de primeiro grau ajustado para os valores SPAD com as doses de nitrogênio aplicadas na sementeira aos 25 DAE para o experimento 1.

Da mesma forma que a observada aos 19 DAE, na relação entre N foliar e doses de N, observa-se que houve uma tendência linear e crescente de aumento nos valores médios de SPAD com o aumento das doses de N aplicadas na sementeira.

Os resultados da análise de regressão com o teste F para falta de ajustamento dos modelos lineares de primeiro grau ajustados entre as doses de N aplicadas na sementeira e os valores SPAD aos 05, 12, 20 e 28 DAE, experimento 2 são apresentados na Tabela 10.

Aos 05 e 28 DAE, o teste F, os modelos lineares de primeiro grau apresentaram-se não significativos ao nível de 5% de probabilidade no teste para a falta de ajustamento, indicando um bom ajuste dos modelos aos dados. Portanto, procedeu-se à análise de variância dos modelos de regressão obtidos, onde o teste F da regressão foi significativo para os dois

modelos (5 e 28 DAE) ao nível de significância. Aos 12 e 20 DAE, os modelos apresentaram não significativo para a falta de ajustamento.

Tabela 10. Resultados da análise de variância do teste F para falta de ajustamento do modelo linear de primeiro grau entre valores de SPAD e doses de N aplicados na sementeira aos 05, 12, 20 e 28 DAE para o experimento 2

Épocas estudadas	Teste F	
	Falta de Ajuste	Regressão
05 DAE	2,11 ^{ns}	12,70**
12 DAE	32,04**	----
20 DAE	4,86**	----
28 DAE	0,33 ^{ns}	93,81**

** significativo ao nível de 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade; N foliar: análise do teor de nitrogênio nas folhas.

As Figuras 24 e 25 ilustram os modelos ajustados e seus respectivos coeficientes de determinação juntamente com os diagramas de dispersão dos valores SPAD em função das doses de N aplicadas na sementeira aos 05 e 28 DAE, experimento 2, respectivamente.




Figura 24. Modelo linear de primeiro grau ajustado para os valores SPAD com as doses de nitrogênio aplicadas na sementeira aos 05 DAE para o experimento 2.




Figura 25. Modelo linear de primeiro grau ajustado para os valores SPAD com as doses de nitrogênio aplicadas na sementeira aos 28 DAE para o experimento 2.

Nas duas datas houve uma tendência linear e crescente de aumento nos valores SPAD com o aumento da doses de N aplicadas na sementeira. Porém, verifica-se que o coeficiente da regressão aos 28 DAE foi maior que aos 05 DAE. Isso indica que com o desenvolvimento das plantas a variação do teor de clorofila nas plantas apresenta maior incremento para cada unidade de N aplicado.

A falta de ajustamento foi significativa ao nível de 1% de probabilidade para os modelos lineares de primeiro grau ajustados aos 12 e 20 DAE, assim procedeu-se o ajuste de modelos lineares de segundo grau. Os resultados da análise de variância da regressão com o teste para falta de ajustamento dos modelos lineares de segundo grau ajustados entre doses de N aplicadas na sementeira e valores SPAD, para o experimento 2, aos 12 e 20 DAE são apresentados na Tabela 11.

Tabela 11. Resultados da análise de variância do teste F para falta de ajustamento do modelo linear de segundo grau entre valores de N foliar e doses de N aplicados na sementeira aos 12 e 20 DAE para o experimento 2

Épocas estudadas	Teste F	
	Falta de Ajuste	Regressão
12 DAE	3,22**	585,30**
20 DAE	0,62 ^{ns}	180,31**

** significativo ao nível de 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade; N foliar: análise do teor de nitrogênio nas folhas.

Aos 12 e 20 DAE, para os modelos lineares de segundo grau ajustados, a falta de ajustamento foi não significativa ao nível de 5% probabilidade somente aos 20 DAE. O teste F da regressão, para este modelo revelou o efeito significativo das doses de N aplicadas na sementeira sobre os valores SPAD, mostrando-se significativo ao nível de 1% de probabilidade.

As Figuras 26 e 27 ilustram os modelos ajustados de segundo grau e seus respectivos coeficientes de determinação juntamente com os diagramas de dispersão dos valores SPAD em função das doses de N aplicadas na sementeira aos 12 e 20 DAE, experimento 2, respectivamente.




Figura 26. Modelo linear de segundo grau ajustado para os valores SPAD com as doses de nitrogênio aplicadas na sementeira aos 12 DAE para o experimento 2.




Figura 27. Modelo linear de segundo grau ajustado para os valores SPAD com as doses de nitrogênio aplicadas na sementeira aos 20 DAE para o experimento 2.

Aos 25 DAE, do experimento 1, e aos 28 DAE, do experimento 2, os modelos ajustados apresentaram-se satisfatórios, verificando a existência de relação funcional linear entre as doses de N aplicadas na sementeira e os valores SPAD.

4.3. Análise de correlação

4.3.1. Correlação entre os valores de N foliar e valores SPAD

Na Tabela 12 são apresentados os valores dos coeficientes de correlação do N foliar com valores SPAD, em todas as épocas de coleta de dados nos o experimentos 1 e 2.

No experimento 1, foram realizadas três coletas de dados no campo, aos 19, 25 e 39 DAE, mas apenas na segunda, aos 25 DAE, a correlação entre SPAD e N foliar não foi significativa a 1%. Aos 39 DAE o coeficiente de correlação foi de 0,66. Resultados semelhantes foram encontrados por Furlani Júnior et al. (1996), que encontraram uma correlação positiva entre as leituras do aparelho SPAD, aos 40 DAE, e teores de N nas folhas do feijoeiro ($r = 0,75$).

Tabela 12. Coeficientes de correlação entre os teores de N foliar e os valores SPAD em cada uma das épocas de coleta de dados

Experimentos	Épocas	Coeficiente de correlação
1	19 DAE	-0,34**
	25 DAE	-0,20 ^{ns}
	39 DAE	0,66**
2	05 DAE	0,26 ^{ns}
	12 DAE	0,85**
	20 DAE	0,75**
	28 DAE	0,43**
	35 DAE	0,40**
	57 DAE	0,27**

** correlação significativa a 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade; N foliar: análise do teor de nitrogênio nas folhas; valor SPAD: variável obtida pelo teor de clorofila SPAD; DAE: dias após a emergência.

No experimento 2, foram realizadas seis coletas de dados no campo, aos 05, 12, 20, 28, 35 e 57 DAE e apenas aos 05 DAE apresentou correlação não significativa. O N foliar, aos 5 DAE (Figura 16), tendeu a apresentar os valores mais altos entre as três coletas antes da adubação em cobertura e menor variação em relação às doses aplicadas. Essa baixa variação deve-se ao fato da planta ainda não ter respondido à adução nitrogenada e que o alto valor de N foliar pode ter ocorrido devido ao resíduo de N no solo. Aos 12 DAE, o coeficiente de correlação foi o mais alto (0,85). Resultados parecidos foram encontrados por Furlani Júnior et al. (1996) e Baesso (2005), que encontraram uma correlação positiva entre as leituras do aparelho SPAD e os teores de N nas folhas do feijoeiro, com coeficientes de correlação de 0,75 e 0,72, respectivamente. Porém esses autores encontraram essa correlação entre 40 e 50 DAE. Para Rosolem (1996), a adubação nitrogenada deve ser realizada de modo que propicie boa nutrição da planta na época em que ainda é possível aumentar o número de vagens por planta, ou seja, até o início do florescimento por volta dos 20 a 30 DAE.

Assim, a alta correlação entre o teor de N foliar e valores SPAD nas folhas do feijoeiro é de grande importância para a diagnose precoce de nitrogênio. Isto possibilita o uso do clorofilômetro portátil, por ser um aparelho de baixo custo, ter maior praticidade e por garantir tomada de decisões em tempo hábil, para possíveis adubações de N em cobertura, sem o comprometimento da produção.

4.3.2. Correlação entre os índices de vegetação e os valores de N foliar

No experimento 1, foi realizada apenas uma coleta de imagens antes da adubação em cobertura, aos 27 DAE. No experimento 2, foram realizadas duas coletas de imagens antes da adubação em cobertura, aos 19 e 26 DAE. Foi realizada a correlação dos índices com os valores de N foliares obtidos na data mais próxima à coleta das imagens. No experimento 1, os índices de vegetação obtidos das imagens coletadas aos 27 DAE, foram correlacionados com os valores de N foliar coletados aos 25 DAE. No experimento 2, os índices de vegetação obtidos das imagens coletadas aos 19 e 26 DAE, foram correlacionados com os valores de N foliar coletados aos 20 e 28 DAE, respectivamente. Na Tabela 13 são apresentadas as correlações dos índices de vegetação estudados com o N foliar, para dados coletados antes da adubação em cobertura.

As correlações entre os teores de N foliar com os índices de vegetação não apresentaram resultados significativos, ao nível de 1% de probabilidade, para nenhuma das épocas de coleta de dados. A presença do solo ainda predominava nessas épocas de coleta de dados. Segundo Meneses & Madeira Netto (2001) a radiância refletida na região do infravermelho próximo, depende tanto da quantidade de folha existentes, quanto da sua distribuição e arranjo no dossel. Resultados diferentes foram encontrados por Silva Jr. et al. (2008), que estudando a correlação entre índices de vegetação e N foliar na forrageira, encontraram coeficiente de correlação acima de 83%, entre o GNDVI e N foliar, sendo que este se mostrou mais eficiente do que o NDVI e o SAVI nas três épocas estudadas.

Tabela 13. Correlação dos índices de vegetação com doses aplicadas na semeadura e com N foliar, para o experimento 1 e 2.

Índices de vegetação	N foliar		
	Experimento 1	Experimento 2	
	25 DAE	20 DAE	28 DAE
NDVI	-0,06 ^{ns}	0,13 ^{ns}	-0,09 ^{ns}
GNDVI	-0,05 ^{ns}	0,13 ^{ns}	-0,09 ^{ns}
SAVI _{0,25}	-0,06 ^{ns}	0,13 ^{ns}	-0,09 ^{ns}
SAVI _{0,5}	-0,06 ^{ns}	0,13 ^{ns}	-0,09 ^{ns}
SAVI _{1,0}	-0,06 ^{ns}	0,13 ^{ns}	-0,09 ^{ns}
WRDVI _{0,05}	0,02 ^{ns}	0,16 ^{ns}	-0,06 ^{ns}
WRDVI _{0,1}	-0,01 ^{ns}	0,16 ^{ns}	-0,07 ^{ns}
WRDVI _{0,2}	-0,03 ^{ns}	0,15 ^{ns}	-0,07 ^{ns}

** correlação significativa a 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade. NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença do verde normalizado; SAVI: índice de vegetação do ajuste do solo; WRDVI: índice de vegetação da larga escala dinâmica.

Nas duas datas havia presença de solo exposto nas entrelinhas (Figuras 9 e 10), portanto eram esperadas respostas diferentes, principalmente nos índices que utilizam combinações de bandas diferentes. Segundo Epiphanyo & Huete (1995), o NDVI é mais sensível ao vermelho que ao infravermelho e uma maior presença de solo causa um aumento da reflectância no vermelho fazendo com que o NDVI apresente valores mais baixos, já que o vermelho é subtraído do numerador ($IV - Vm$) na equação 2. Para Gitelson et al. (1996), o GNDVI tem uma escala dinâmica mais larga do que o NDVI e é, na média, ao menos cinco vezes mais sensível à concentração de clorofila. Segundo Huete (1988), o SAVI foi proposto para amenizar essa influência do solo, baseando-se no princípio de que a curva de vegetação tende a aproximar-se da curva de solo para baixas densidades de vegetação ($L=1$), passando por uma mistura de respostas espectrais para densidades médias ($L=0,5$) e quase nenhuma influência do solo para densidades altas de vegetação ($L=0,25$).

O valor de um pixel sofre influência de vários fatores, como tipo de sensor utilizado, tipo de cena a ser imageada e iluminação. No presente trabalho, a resposta dos valores dos pixels pode ter sido influenciada pela presença de solo, exposto nas entrelinhas na fase inicial de desenvolvimento da cultura, pela falta de calibração das câmeras e pela iluminação. Como já mencionado anteriormente, as imagens foram obtidas entre 10 e 14 horas

em condições de céu aberto. Porém a intensidade da radiação incidente não pode ser controlada, já que a mesma quando penetra na atmosfera sofre atenuações causadas por reflexão, espalhamento e absorção pelos constituintes atmosféricos (gases e água), por partículas dispersas e nuvens (Moreira, 2005). Portanto, acredita-se que o comportamento semelhante dos oito índices de vegetação extraídos das imagens coletadas ao longo dos DAE, Figuras 28 e 29, foram influenciados pela combinação de fatores como a iluminação, presença de solo e falta de calibração das câmeras, ocasionando em índices de vegetação altamente correlacionados.

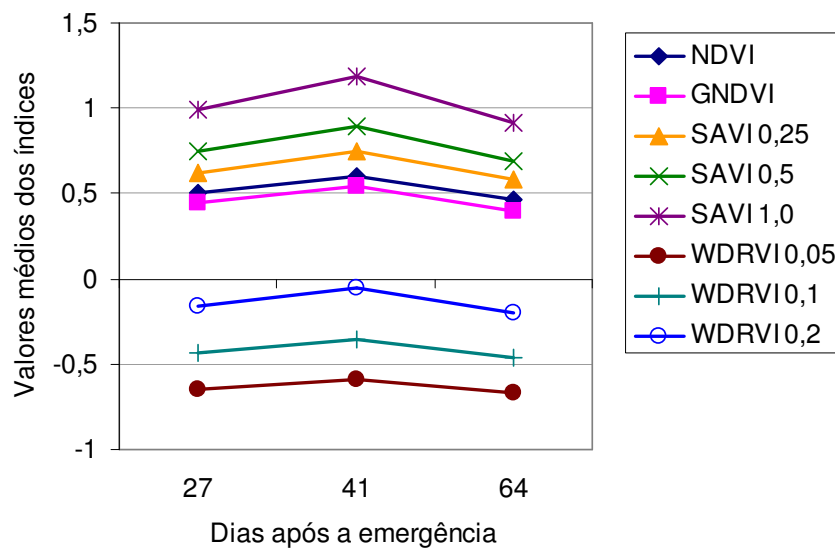


Figura 28. Valores médios dos índices de vegetação (IV). NDVI: IV da diferença normalizada; GNDVI: IV da diferença do verde normalizado; SAVI: IV do ajuste do solo; WRDVI: IV da larga escala dinâmica, aos 27, 41 e 64 DAE (dias após a emergência) no experimento 1.

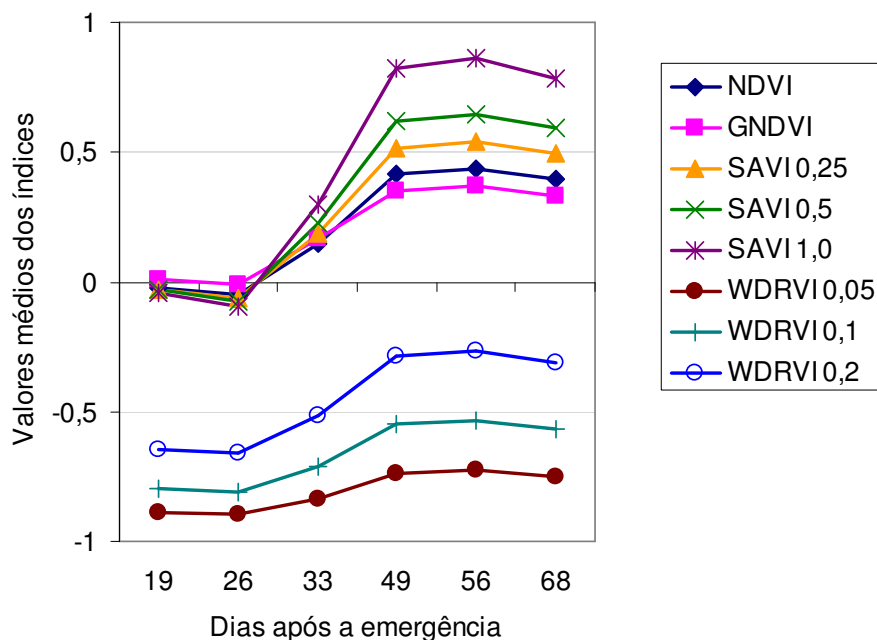


Figura 29. Valores médios dos índices de vegetação NDVI: IV da diferença normalizado; GNDVI: IV da diferença do verde normalizado; SAVI: IV do ajuste do solo; WRDVI: IV da larga escala dinâmica, aos 19, 26, 33, 49, 56 e 68 DAE (dias após a emergência) no experimento 2

Os coeficientes de correlação entre os índices de vegetação são apresentados nas Tabelas 14 a 16 para o experimento 1 e nas Tabelas 17 a 22 para o experimento 2.

Tabela 14. Matriz de correlação entre os índices de vegetação estudados aos 27 DAE no experimento 1

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	0,99**						
SAVI _{0,25}	1,00**	0,99**					
SAVI _{0,5}	0,86**	0,88**	0,86**				
SAVI _{1,0}	0,79**	0,81**	0,79**	0,99**			
WRDVI _{0,05}	0,90**	0,91**	0,90**	0,80**	0,73**		
WRDVI _{0,1}	0,96**	0,96**	0,96**	0,84**	0,77**	0,99**	
WRDVI _{0,2}	0,98**	0,98**	0,98**	0,86**	0,78**	0,97**	0,99**

Tabela 15. Matriz de correlação entre os índices de vegetação estudados aos 41 DAE no experimento 1

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	0,99**						
SAVI _{0,25}	1,00**	0,99**					
SAVI _{2,0,5}	0,48**	0,52**	0,48**				
SAVI _{1,0}	0,43**	0,47**	0,43**	1,00**			
WRDVI _{0,05}	0,50**	0,51**	0,49**	0,30**	0,28**		
WRDVI _{0,1}	0,74**	0,74**	0,73**	0,41**	0,37**	0,95**	
WRDVI _{0,2}	0,90**	0,90**	0,89**	0,46**	0,42**	0,83**	0,96

Tabela 16. Matriz de correlação entre os índices de vegetação estudados aos 64 DAE no experimento 1

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	1,00**						
SAVI _{0,25}	0,91**	0,90**					
SAVI _{2,0,5}	0,78**	0,79**	0,84**				
SAVI _{1,0}	0,72**	0,73**	0,77**	0,99**			
WRDVI _{0,05}	0,86**	0,86**	0,80**	0,71**	0,66**		
WRDVI _{0,1}	0,95**	0,95**	0,87**	0,77**	0,71**	0,98**	
WRDVI _{0,2}	0,98**	0,98**	0,90**	0,79**	0,73**	0,94**	0,99**

Tabela 17. Matriz de correlação entre os índices de vegetação estudados aos 19 DAE no experimento 2

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	0,99**						
SAVI _{0,25}	1,00**	0,99**					
SAVI _{1,0}	0,99**	0,97**	0,99**				
SAVI _{2,0}	0,98**	0,96**	0,98**	1,00**			
WRDVI _{0,05}	0,99**	0,97**	0,99**	0,98**	0,97**		
WRDVI _{0,1}	0,99**	0,97**	0,99**	0,98**	0,98**	1,00**	
WRDVI _{0,2}	1,00**	0,98**	1,00**	0,99**	0,98**	1,00**	1,00**

Tabela 18. Matriz de correlação entre os índices de vegetação estudados aos 26 DAE no experimento 2

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	0,99**						
SAVI _{0,25}	1,00**	0,99**					
SAVI _{2,0,5}	0,99**	0,98**	0,99**				
SAVI _{1,0}	0,97**	0,97**	0,97**	1,00**			
WRDVI _{0,05}	0,99**	0,97**	0,99**	0,97**	0,96**		
WRDVI _{0,1}	0,99**	0,97**	0,99**	0,98**	0,96**	1,00**	
WRDVI _{0,2}	0,99**	0,98**	0,99**	0,98**	0,97**	1,00**	1,00**

Tabela 19. Matriz de correlação entre os índices de vegetação estudados aos 33 DAE no experimento 2

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	1,00**						
SAVI _{0,25}	1,00**	1,00**					
SAVI _{2,0,5}	1,00**	0,99**	1,00**				
SAVI _{1,0}	0,99**	0,99**	0,99**	1,00**			
WRDVI _{0,05}	0,99**	0,98**	0,99**	0,99**	0,99**		
WRDVI _{0,1}	0,99**	0,99**	0,99**	0,99**	0,99**	1,00**	
WRDVI _{0,2}	1,00**	0,99**	1,00**	0,99**	0,99**	1,00**	1,00**

Tabela 20. Matriz de correlação entre os índices de vegetação estudados aos 49 DAE no experimento 2

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	1,00**						
SAVI _{0,25}	1,00**	1,00**					
SAVI _{2,0,5}	0,96**	0,96**	0,96**				
SAVI _{1,0}	0,93**	0,93**	0,93**	1,00**			
WRDVI _{0,05}	0,97**	0,98**	0,97**	0,94**	0,92**		
WRDVI _{0,1}	0,98**	0,99**	0,98**	0,95**	0,92**	1,00**	
WRDVI _{0,2}	0,99**	1,00**	0,99**	0,96**	0,93**	0,99**	1,00**

Tabela 21. Matriz de correlação entre os índices de vegetação estudados aos 56 DAE no experimento 2

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	0,99**						
SAVI _{0,25}	1,00**	0,99**					
SAVI _{2,0,5}	0,96**	0,95**	0,96**				
SAVI _{1,0}	0,93**	0,93**	0,93**	1,00**			
WRDVI _{0,05}	0,98**	0,99**	0,98**	0,95**	0,92**		
WRDVI _{0,1}	0,99**	1,00**	0,99**	0,95**	0,92**	1,00**	
WRDVI _{0,2}	0,99**	1,00**	0,99**	0,96**	0,93**	1,00**	1,00**

Tabela 22. Matriz de correlação entre os índices de vegetação estudados aos 68 DAE no experimento 2

	NDVI	GNDVI	SAVI _{0,25}	SAVI _{0,5}	SAVI _{1,0}	WRDVI _{0,05}	WRDVI _{0,1}
GNDVI	0,99**						
SAVI _{0,25}	1,00**	0,99**					
SAVI _{2,0,5}	0,95**	0,93**	0,95**				
SAVI _{1,0}	0,91**	0,89**	0,91**	0,99**			
WRDVI _{0,05}	0,98**	0,99**	0,98**	0,93**	0,89**		
WRDVI _{0,1}	0,99**	1,00**	0,99**	0,93**	0,89**	1,00**	
WRDVI _{0,2}	0,99**	1,00**	0,99**	0,94**	0,90**	1,00**	1,00**

4.3.3. Correlação entre índice de vegetação e produtividade

Nas Tabelas 23 e 24 são apresentadas as produtividades médias (kg ha⁻¹) do feijoeiro corrigida para a umidade padrão de 13%.

Tabela 23. Produtividade média (kg ha⁻¹) de grãos do feijoeiro em relação às doses de N (kg ha⁻¹) aplicadas para o experimento 1

N na Semeadura	N em Cobertura					
	0	20	30	40	60	80
0	1895,57	1958,75	2165,84	2165,50	2408,76	2853,08
20	2396,51	2049,06	2174,05	2384,15	2122,57	2026,56
30	2337,99	2240,91	2439,27	2469,74	2778,65	2780,28
40	2063,77	2506,98	1801,73	2640,95	2417,53	2318,63
50	2440,45	2196,48	2165,67	2350,13	1731,02	2628,89

Tabela 24. Produtividade (kg ha⁻¹) de grãos do feijoeiro em relação às doses de N (kg ha⁻¹) aplicadas para o experimento 2

N na Semeadura	N em Cobertura					
	0	20	30	40	60	80
0	1195,94	1519,59	1425,28	2385,17	2170,41	2883,79
20	2644,76	1367,18	2257,77	2219,41	3030,74	3094,85
30	1304,06	2372,30	2238,78	2333,23	2644,76	2765,97
40	2367,29	2330,41	2413,78	2757,71	3575,87	3408,97
50	2204,84	2388,99	2624,64	3103,29	2971,14	3840,07

No experimento 1, a produtividade mínima foi 1.731,02 kg ha⁻¹, para as doses de N aplicadas, 50 kg ha⁻¹ na sementeira e 60 kg ha⁻¹ em cobertura, e a produtividade máxima foi de 2.853,08 kg ha⁻¹, para as doses de N aplicadas, 0 kg ha⁻¹ na sementeira e 80 kg ha⁻¹ em cobertura. A produtividade do experimento 1, foi afetada pela ocorrência do mofo-branco em algumas parcelas do experimento, principalmente nas que receberam as maiores doses. Segundo Oliveira (2005), uma lavoura de feijão pode sofrer em média perdas de 30% na produção com a ocorrência desta doença. Mesmo com a ocorrência desta doença a produtividade média foi de 2.296,98 kg ha⁻¹.

No experimento 2, a produtividade mínima foi 1.195,94 kg ha⁻¹ para as menores doses N aplicadas, ou seja, para as parcelas que não receberam adubação, e a produtividade máxima foi de 3.840,07 kg ha⁻¹ para as maiores doses de N aplicadas, 50 kg ha⁻¹ na sementeira e 80 kg ha⁻¹ em cobertura. A produtividade média nesse experimento foi de 2.461,37 kg ha⁻¹, maior que a média nacional (930,0 kg ha⁻¹) e a de Minas Gerais (2.302,0 kg ha⁻¹) na safra de inverno 2007 (Conab, 2007/2008). Resultados semelhantes foram encontrados por Kikuti et al. (2005), que obteve uma produtividade média de 1.863,0 kg ha⁻¹ e produtividade máxima com a doses de N de 140 kg ha⁻¹.

No experimento 2, a máxima eficiência foi obtida com as doses de N maiores do que as recomendadas para a cultura do feijão em Minas Gerais. Considerando o nível de tecnologia empregado e somente o resultado obtido com o emprego das maiores doses de N, a produtividade média obtida foi coerente com a prevista por Chagas *et al.* (1999), para o nível 4 que foi acima de 2.500 kg ha⁻¹ de grãos. Na Tabela 25 são apresentados os valores dos coeficientes de correlação dos índices de vegetação com a produtividade para os dois experimentos.

Tabela 25. Correlação entre índices de vegetação e produtividade para os experimentos 1 e 2

Índices	Produtividade					
	Experimento 1		Experimento 2			
	41 DAE	64 DAE	33 DAE	49 DAE	56 DAE	68 DAE
NDVI	-0,05 ^{ns}	0,53**	0,69**	0,78**	0,81**	0,84**
GNDVI	-0,02 ^{ns}	0,52**	0,70**	0,79**	0,83**	0,85**
SAVI _{0,25}	-0,06 ^{ns}	0,54**	0,69**	0,78**	0,81**	0,84**
SAVI _{0,5}	-0,06 ^{ns}	0,54**	0,69**	0,78**	0,81**	0,84**
SAVI _{1,0}	-0,06 ^{ns}	0,54**	0,69**	0,78**	0,81**	0,84**
WRDVI _{0,05}	0,10 ^{ns}	0,23 ^{ns}	0,70**	0,77**	0,84**	0,87**
WRDVI _{0,1}	0,06 ^{ns}	0,36**	0,70**	0,78**	0,84**	0,86**
WRDVI _{0,2}	0,02 ^{ns}	0,44**	0,70**	0,79**	0,83**	0,86**

** correlação significativa a 1% de probabilidade; ^{ns}: não significativo ao nível de 5% de probabilidade. NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença do verde normalizado; SAVI: índice de vegetação do ajuste do solo; WRDVI: índice de vegetação da larga escala dinâmica.

Para o experimento 1 foram realizadas duas coletas de imagens após a adubação em cobertura, aos 41 e 64 DAE. Apenas a segunda coleta, aos 64 DAE, teve correlação significativa a 1% entre os índices NDVI, GNDVI, SAVI_{0,25}, SAVI_{0,5}, SAVI_{1,0}, WRDVI_{0,1} e WRDVI_{0,2} e a produtividade. O maior coeficiente de correlação foi 0,54 para os SAVI_{0,25}, SAVI_{0,5} e SAVI_{1,0}, seguidos por NDVI e GNDVI que obtiveram coeficientes de correlação de 0,53 e 0,52, respectivamente. Se comparado com o segundo experimento esses coeficientes de correlação foram baixos, onde uma possível causa possa ter sido a ocorrência do mofo-branco na cultura.

No experimento 2, todos os índices de vegetação foram altamente correlacionados com a produtividade, para as quatro épocas estudadas após a adubação em cobertura (33, 49, 56 e 68 DAE), aumentando com o avanço dos dias. Em todas as épocas estudadas os coeficientes de correlação

foram significativos a 1%, porém a época mais próxima da colheita (68 DAE) foi a que obteve os maiores coeficientes de correlação.

Pontes et al. (2005), trabalhando com índice de vegetação para diferenciação de produção de cana-de-açúcar, mostraram que existe correlação entre o índice NDVI e a produtividade da cultura de cana-de-açúcar, onde essa correlação é mais evidente no pico do ciclo vegetativo da cultura, após o período de chuvas.

Nos dois experimentos, não houve diferença entre os oito índices de vegetação estudados e a produtividade. Da mesma forma, quando se realizou a análise de correlação entre os índices e o N foliar, acredita-se que o comportamento semelhante dos oito índices de vegetação extraídos das imagens coletadas ao longo dos DAE, possa ter sido influenciado pela falta de calibração da câmera e pela iluminação.

4.4. Discriminação de classes de N foliar utilizando índices de vegetação

No experimento 1 os valores de N foliar, aos 25 DAE, se apresentaram acima dos valores considerados satisfatórios para a cultura do feijão que é de 3,0 a 3,5%. O menor valor de N foliar para esta data foi de 3,8%, agrupando todos os dados na classe alta. Como mencionado anteriormente, a fertilidade do solo neste caso pode ter influenciado nos altos valores de N foliar. Portanto, para este experimento, não foi possível desenvolver um classificador para identificar as classes de N foliar com o uso dos índices de vegetação. Os melhores classificadores para as duas épocas estudadas no experimento 2 são apresentados na Tabela 26.

Tabela 26. Melhores classificadores selecionados a partir do maior coeficiente Kappa aos 20 e 28 DAE do experimento 2, utilizando como vetor de entrada os índices de vegetação

Época	Combinação de índices de vegetação	Exatidão global	Coeficiente Kappa	
20 DAE	GNDVI; SAVI _{1,0} ; WDRVI _{0,05}	0,61	0,26*	a
28 DAE	SAVI _{0,25} ; SAVI _{0,5} ; SAVI _{1,0}	0,46	0,19*	a

* Diferente de zero pelo teste Z ao nível de 5% de probabilidade.

Os coeficientes kappa seguidos de uma mesma letra não diferiram pelo teste Z a 5% de probabilidade.

NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença do verde normalizado; SAVI: índice de vegetação do ajuste do solo; WDRVI: índice de vegetação da larga escala dinâmica.

Os coeficientes Kappa, dos classificadores desenvolvidos com as combinações dos índices de vegetação, das duas épocas estudadas foram estatisticamente diferentes de zero, pelo teste Z, ao nível de 5% de probabilidade. Com isso obteve uma classificação melhor que uma classificação ao acaso. Porém os classificadores aos 20 e 28 DAE apresentaram um desempenho razoável e ruim, respectivamente, segundo os critérios utilizados por Landis & Koch (1977) na avaliação dos valores obtidos de Kappa. No item 4.3.2 foi observado que as correlações entre os teores de N foliar com os índices de vegetação não apresentou resultado significativo, ao nível de 1% de probabilidade, assim a falta de correlação entre essas variáveis pode ter influenciado nos baixos valores dos coeficientes Kappa. As matrizes de erros dos classificadores para as duas épocas estudadas são apresentadas na Tabela 27 e 28.

Tabela 27. Matriz de erro obtida com os valores das combinações dos índices de vegetação aos 20 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	satisfatória	alta	
baixa	4	4	9	76
satisfatória	1	8	11	60
alta	1	9	43	19
Erros de omissão (%)	33	62	32	Exatidão global = 61 %

Tabela 28. Matriz de erro obtida com os valores das combinações dos índices de vegetação aos 28 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	satisfatória	alta	
baixa	14	8	8	53
satisfatória	12	13	9	62
alta	7	5	14	46
Erros de omissão (%)	58	50	55	Exatidão global = 46 %

Aos 20 DAE, observa-se que o maior erro de omissão foi para a classe satisfatória. Analisando os dados, menos da metade das amostras, 8 de 21, foram atribuídas à classe satisfatória. Isto significa que amostras, que na realidade pertenciam à classe satisfatória tiveram os valores das combinações dos índices de vegetação semelhantes aos da classe baixa e alta. Aos 28 DAE, o maior erro de omissão foi para classe baixa, ou seja,

58% das amostras foram classificadas fora das classes a que elas realmente pertenciam.

Nas duas épocas analisadas, a utilização dos índices de vegetação como vetor de característica não foi útil na discriminação das classes de N foliar, tendo apresentado índice Kappa baixo e erros de omissão e inclusão altos.

4.5. Discriminação das classes de N foliar utilizando o medidor de clorofila SPAD 502

Como no item acima, não foi possível desenvolver um classificador para discriminar classes de N foliar no experimento 1, devido os valores de N foliar estarem acima dos níveis satisfatórios para a cultura do feijão.

Os classificadores das duas épocas estudadas no experimento 2 são apresentados na Tabela 29.

Tabela 29. Valores da exatidão global e coeficiente Kappa aos 20 e 28 DAE do experimento 2 utilizando como vetor de entrada os valores SPAD

Época	Exatidão global	Coeficiente Kappa	
20 DAE	0,73	0,45*	a
28 DAE	0,83	0,75*	b

* Diferente de zero pelo teste Z ao nível de 5% de probabilidade.

Os coeficientes kappa seguidos de uma mesma letra não diferiram pelo teste Z a 5% de probabilidade.

Os coeficientes Kappa, dos classificadores desenvolvidos com valores SPAD, das duas épocas estudadas foram estatisticamente diferentes de zero, pelo teste Z, ao nível de 5% de probabilidade. Os valores dos coeficientes Kappa, nas duas épocas, foram melhores que uma classificação ao acaso. Apesar da correlação entre valores SPAD e N foliar aos 20 DAE (75%) ter sido maior que aos 28 DAE (43%), nesta data o coeficiente Kappa foi maior e diferente estatisticamente do coeficiente Kappa obtido aos 20 DAE. Os classificadores aos 20 e 28 DAE apresentaram um desempenho bom e muito bom, respectivamente, segundo Landis & Koch (1977). As matrizes de erros dos classificadores para as duas épocas estudadas são apresentadas na Tabela 30 e 31.

Tabela 30. Matriz de erro obtida com os valores de SPAD aos 20 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	satisfatória	alta	
baixa	4	11	4	86
satisfatória	0	6	3	33
alta	2	4	56	10
Erros de omissão (%)	33	71	11	Exatidão global = 73 %

Tabela 31. Matriz de erro obtida com os valores de SPAD aos 28 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	satisfatória	alta	
baixa	28	0	0	0
satisfatória	4	26	11	37
alta	0	0	21	0
Erros de omissão (%)	13	0	34	Exatidão global = 83 %

Mesmo tendo uma classificação considerada boa, aos 20 DAE, os erros de omissão, na classe satisfatória, e inclusão, na classe baixa, foram altos. O que não aconteceu aos 28 DAE, onde nessa época não houve nenhum erro de omissão, na classe média, e nenhum erro de inclusão nas classes baixa e alta, justificando, assim, uma classificação muito boa realizada pelo algoritmo.

Com isso, o uso das leituras do clorofilômetro, como vetor de entrada no classificador, foi eficiente na discriminação das classes de N foliar aos 28 DAE. Possibilitando a diagnose precoce de N, de uma forma não destrutiva, rápida e eficaz, para possíveis recomendações de adubações de N em cobertura.

4.6. Comparação entre os índices de vegetação e o clorofilômetro portátil na discriminação de classes de N foliar

Os coeficientes Kappa dos classificadores desenvolvidos aos 20 e 28 DAE para valores de índices de vegetação e para os valores SPAD são comparados na Tabela 32.

Tabela 32. Resultado do desempenho de classificação com as melhores combinações de índices de vegetação e com os valores SPAD

DAE	Índices de vegetação	Valores SPAD
20	0,26 a	0,45 a
28	0,19 a	0,75 b

Os coeficientes kappa seguidos de uma mesma letra não diferem na linha pelo teste Z a 5% de probabilidade. Combinação de índices aos 20 DAE (GNDVI; SAVI_{1,0}; WDRVI_{0,05}) e aos 28 DAE (SAVI_{0,25}; SAVI_{0,5}; SAVI_{1,0}).

Aos 28 DAE o resultado da classificação, utilizando como vetor de entrada a combinação dos índices de vegetação, foi estatisticamente diferente daquela realizada com os valores de SPAD. O maior valor de Kappa observado foi aos 28 DAE utilizando os valores de SPAD como vetor de entrada. Segundo Meneses & Madeira Netto (2001) a radiância refletida na região do infravermelho próximo, depende tanto da quantidade de folha existentes, quanto da sua distribuição e arranjo no dossel.

O baixo índice de área foliar dificulta a discriminação de diferentes classes de N foliar, principalmente quando utiliza a banda do infravermelho próximo que, segundo Meneses & Madeira Netto (2001), a radiância refletida nesta banda, depende tanto da quantidade de folha existentes, quanto da sua distribuição e arranjo no dossel. O mesmo não acontece com os valores de SPAD que não depende somente da intensidade da cor verde da folha, obtida por meio da quantidade de luz de comprimentos de onda na região do vermelho e do infravermelho próximo transmitidas pela folha.

4.7. Desenvolvimento e avaliação dos classificadores na discriminação de classes de produtividade

Os melhores classificadores de produtividade para duas épocas estudadas no experimento 1 são apresentados na Tabela 33.

Tabela 33. Melhores classificadores selecionados a partir do maior coeficiente Kappa, aos 41 e 64 DAE do experimento 1, utilizando como vetor de entrada os índices de vegetação

Época	Combinação de índices de vegetação	Exatidão global	Coefficiente Kappa
41 DAE	NDVI; GNDVI; SAVI _{0,25} ; SAVI _{0,5}	0,42	0,14
41 DAE	NDVI; GNDVI; SAVI _{0,25} ; SAVI _{1,0}	0,42	0,14
64 DAE	WDRVI _{0,05} ; WDRVI _{0,2}	0,63	0,44*

* Diferente de zero pelo teste Z ao nível de 5% de probabilidade.

NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença do verde normalizado; SAVI: índice de vegetação do ajuste do solo; WDRVI: índice de vegetação da larga escala dinâmica.

O coeficiente Kappa do classificador desenvolvido aos 41 DAE foi estatisticamente igual a zero, pelo teste Z, a 5% de probabilidade. Isso equivale dizer que essa classificação é estatisticamente igual a uma classificação ao acaso. Já aos 64 DAE, o coeficiente Kappa foi estatisticamente diferente de zero, pelo teste Z, a 5% de probabilidade, obtendo uma classificação melhor que uma classificação ao acaso.

No experimento 1, aos 41 e 64 DAE, os classificadores apresentaram, segundo critérios propostos por Landis & Koch (1977) para os valores dos índice kappa, um desempenho ruim e bom, respectivamente. Na análise de correlação entre índices de vegetação e produtividade (item 4.2.3), aos 41 DAE, foi observada a falta de correlação significativa a 1%, podendo, assim, justificar o desempenho ruim dos classificadores nesta época. Aos 64 DAE essa correlação foi significativa, e para alguns índices de vegetação os coeficientes de correlação foram maiores que 50%, justificando o desempenho do classificador nesta época ser melhor que aos 41 DAE. Para isso foram combinados apenas dois dos oito índices de vegetação disponível ($WDRVI_{0,05}$; $WDRVI_{0,2}$), como vetor de entrada no classificador.

As matrizes de erros dos classificadores para as duas épocas estudadas, no experimento 1, são apresentadas nas Tabelas 34 e 35. Os dois classificadores selecionados aos 41 DAE apresentaram matrizes de erros iguais.

Tabela 34. Matriz de erro obtida com os valores dos índices de vegetação aos 41 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	média	alta	
baixa	10	10	11	68
média	8	15	10	55
alta	5	8	13	50
Erros de omissão (%)	57	55	62	Exatidão global = 42 %

Tabela 35. Matriz de erro obtida com os valores dos índices de vegetação aos 64 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	média	alta	
baixa	18	7	2	33
média	4	13	6	43
alta	1	13	26	35
Erros de omissão (%)	22	61	34	Exatidão global = 63 %

Aos 41 DAE, conforme indicado pelo valor o coeficiente Kappa, a classificação não foi satisfatória, pois os erros de omissão e comissão foram altos. Verifica-se que embora o coeficiente Kappa aos 64 DAE tenha sido diferente de zero e recebido uma classificação boa, os erros de omissão e comissão também foram altos. Acredita-se que a ocorrência do mofo-branco pode ter contribuído nos resultados dos classificadores. Portanto, para este experimento, a utilização dos índices de vegetação como vetor de característica não foi útil na discriminação das classes de produtividade.

Os melhores classificadores para as quatro épocas estudadas no experimento 2 são apresentados na Tabela 3.

Tabela 36. Melhores classificadores selecionados a partir do maior coeficiente Kappa, aos 33, 49, 56 e 68 DAE do experimento 2, utilizando como vetor de entrada os índices de vegetação

Época	Combinação de índices de vegetação	Exatidão global	Coeficiente Kappa	
49 DAE	NDVI; SAVI _{0,25} ; SAVI _{1,0} ; WDRVI _{0,2}	0,84	0,76*	a
56 DAE	NDVI; GNDVI; SAVI _{0,25} ; SAVI _{1,0} ; WDRVI _{0,1}	0,82	0,72*	a b
56 DAE	NDVI; GNDVI; SAVI _{0,25} ; SAVI _{0,5} ; WDRVI _{0,1}	0,82	0,72*	a b
68 DAE	GNDVI; SAVI _{1,0} ; WDRVI _{0,1} ; WDRVI _{0,2}	0,79	0,68*	a b
68 DAE	GNDVI; SAVI _{0,5} ; WDRVI _{0,1} ; WDRVI _{0,2}	0,79	0,68*	a b
33 DAE	NDVI; GNDVI; SAVI _{0,5} ; SAVI _{1,0} ; WDRVI _{0,1}	0,72	0,58*	b

* Diferente de zero pelo teste Z ao nível de 5% de probabilidade.

Os coeficientes kappa seguidos de uma mesma letra não diferiram pelo teste Z a 5% de probabilidade. NDVI: índice de vegetação da diferença normalizado; GNDVI: índice de vegetação da diferença do verde normalizado; SAVI: índice de vegetação do ajuste do solo; WDRVI: índice de vegetação da larga escala dinâmica.

Nas quatro épocas estudadas, os coeficientes Kappa, dos classificadores desenvolvidos com os índices de vegetação, foram estatisticamente diferentes de zero, pelo teste Z, a de 5% de probabilidade.

Com isso obteve uma classificação melhor que uma classificação ao acaso. Segundo critérios propostos por Landis & Koch (1977) para os valores dos índice Kappa, aos 33 DAE o classificador apresentou um desempenho bom e aos 49, 56 e 68 DAE os classificadores apresentaram um desempenho muito bom. O coeficiente Kappa aos 33 DAE diferiu do coeficiente Kappa aos 49 DAE pelo teste Z ao nível de 5% de probabilidade. O maior coeficiente Kappa foi aos 49 DAE (76%), utilizando quatro dos oito índices de vegetação. No item 4.3.3, foi verificada a correlação entre os oito índices de vegetação e produtividade, e para as quatro épocas estudadas essas duas variáveis foram altamente correlacionadas, aumentando ao longo do desenvolvimento da cultura. Como os coeficientes Kappa não diferiram estatisticamente entre si aos 49, 56 e 68 DAE, e todos os classificadores apresentaram um desempenho muito bom, qualquer uma das três épocas analisada poderia ser utilizada na discriminação de classes de produtividade.

As matrizes de erros dos classificadores para as quatro épocas estudadas, no experimento 2, são apresentadas nas Tabelas 37 a 40. Os dois classificadores selecionados aos 56 e 68 DAE apresentaram matrizes de erros iguais.

Tabela 37. Matriz de erro obtida com os valores dos índices de vegetação aos 33 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	média	alta	
baixa	16	6	1	30
média	5	19	10	44
alta	0	3	30	9
Erros de omissão (%)	24	32	27	Exatidão global = 72 %

Tabela 38. Matriz de erro obtida com os valores dos índices de vegetação aos 49 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	média	alta	
baixa	17	4	0	19
média	4	22	4	27
alta	0	2	37	5
Erros de omissão (%)	19	21	9	Exatidão global = 84 %

Tabela 39. Matriz de erro obtida com os valores dos índices de vegetação aos 56 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	média	alta	
baixa	19	5	0	21
média	2	19	5	27
alta	0	4	36	10
Erros de omissão (%)	9	32	12	Exatidão global = 82 %

Tabela 40. Matriz de erro obtida com os valores dos índices de vegetação aos 68 DAE

Valor estimado	Classes de Produtividade			Erros de inclusão (%)
	baixa	média	alta	
baixa	15	5	0	25
média	6	19	8	42
alta	0	4	33	11
Erros de omissão (%)	29	32	20	Exatidão global = 79 %

Acredita-se que aos 33 DAE a cultura ainda não havia respondido totalmente à primeira parcela e a dose única de N aplicado em cobertura, o que pode ter contribuído para uma classificação pior que as demais. Aos 56 e 68 DAE, o classificador discriminou muito bem a classe baixa da classe alta, pois nenhuma observação da classe baixa foi classificada como da classe alta e vice-versa. Conclusão similar é válida aos 49 DAE, porém com erros de omissão e inclusão menores em relação aos outros dias, que garantiu uma melhor classificação em relação ao coeficiente Kappa (76%).

O desenvolvimento de sistemas capazes de identificar a produtividade de uma cultura é de grande importância, pois por meio deste podem ser gerados mapas de produtividade, considerados por muitos pesquisadores como sendo uma parte essencial da agricultura de precisão. Os mapas de produtividade podem indicar a localização de áreas críticas em termos de rentabilidade, auxiliando na identificação dos fatores que estão limitando a produtividade.

4.8. Avaliação da combinação dos índices de vegetação

O número de índices de vegetação combinados e sua frequência nos classificadores cujos coeficientes Kappa não diferiram do maior valor

observado e foram maior que zero são apresentados na Tabela 41 (experimento 1) e Tabela 42 (experimento 2).

No primeiro experimento não foi utilizado as imagens coletas aos 27 DAE, pois o N foliar nesta época estava acima dos níveis considerados satisfatório. Nos dois experimentos o número de classificadores selecionados foram altos. Aos 49 DAE, foi a época que selecionou o menor número de classificadores (99) dentre todas as épocas estudadas. No experimento 1, aos 64 DAE, classificadores univariados não foram selecionados.

Tabela 41. Número de índices de vegetação combinados e sua frequência nos classificadores no qual os coeficientes Kappa não deferiram do maior valor observado nas três épocas de aquisição de imagens no experimento 1

Número de índices combinados	Frequência de Ocorrência	
	41 DAE	64 DAE
1	3	0
2	19	12
3	52	44
4	67	67
5	50	56
6	23	28
7	8	8
8	1	1
Total de classificadores	223	216

Tabela 42. Número de índices de vegetação combinados e sua frequência nos classificadores no qual os coeficientes Kappa não deferiram do maior valor observado nas seis épocas de aquisição de imagens no experimento 2

Número de índices combinados	Frequência de Ocorrência					
	20 DAE	28 DAE	33 DAE	49 DAE	56 DAE	68 DAE
1	8	4	1	0	5	8
2	19	26	10	0	12	28
3	46	47	42	6	22	54
4	65	40	64	26	60	69
5	55	53	43	34	52	56
6	28	28	26	24	28	28
7	4	7	8	8	8	8
8	0	1	1	1	1	1
Total de classificadores	225	206	195	99	188	252

No experimento 2, aos 49 DAE, não foram selecionados classificadores univariados e nem classificadores que utilizam a combinação de dois índices de vegetação. Com exceção dos índices coletados aos 20, as demais épocas incluíram a combinação de oito índices de vegetação entre os melhores classificadores. Sena Jr. (2005) encontrou grande número de classificadores que não diferiram do maior valor de Kappa obtido, utilizando todas as possíveis combinações de nove índices. Com isso ele concluiu que a utilização de mais de um índice é importante, devido ao efeito conjunto das variáveis. De modo geral os maiores coeficientes Kappa dos classificadores selecionados, foram os que utilizaram mais de um índice combinados.

As Figuras 29 e 30 ilustram as freqüência de ocorrência dos coeficientes Kappa observados entre os classificadores selecionados aos 41 e 64 DAE (experimento 1), respectivamente.




Figura 29. Freqüência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 41 DAE, experimento 1.




Figura 30. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 64 DAE, experimento 1.

Aos 41 DAE a faixa dos coeficientes Kappa selecionados foi de 0 a 0,14. Já aos 64 DAE a faixa dos coeficientes kappa dos classificadores selecionados foi de 0,25 a 0,45, mostrando-se mais favorável à classificação do aos 41 DAE para o experimento 1.

As Figuras 31, 32, 33, 34, 35 e 36 ilustram as frequências de ocorrência dos coeficientes Kappa observados entre os classificadores selecionados aos 19, 26, 33, 49, 56 e 68 DAE (sexperimento 2), respectivamente.




Figura 31. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 19 DAE, experimento 2.




Figura 32. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 26 DAE, experimento 2.




Figura 33. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 33 DAE, experimento 2.




Figura 34. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 49 DAE, experimento 2.




Figura 35. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 56 DAE, experimento 2.




Figura 36. Frequência de ocorrência dos coeficientes kappa entre os melhores classificadores selecionados aos 68 DAE, experimento 2.

As Figuras 31 e 32 ilustram a freqüência de ocorrência dos coeficientes Kappa nos classificadores desenvolvidos para discriminar classes de N foliar, por meio de índices de vegetação. Aos 20 DAE a faixa dos coeficientes kappa selecionados foi de 0,04 a 0,26. Enquanto aos 28 DAE a faixa dos coeficientes kappa dos classificadores selecionados foi de 0 a 0,19.

As Figuras 34, 35, 36 e 37 ilustram a freqüência de ocorrência dos coeficientes Kappa nos classificadores desenvolvidos para discriminar classes de produtividade, por meio de índices de vegetação. Em todas as quatro épocas estudadas os valores dos coeficientes Kappa foram acima de zero, ou seja, os classificadores se comportaram melhor que uma classificação ao acaso, mostrando, assim, que os classificadores nesse experimento foram mais eficientes do que no experimento 1.

5. CONCLUSÕES

Este trabalho teve como objetivo geral avaliar a discriminação de classes de nitrogênio foliar, a partir de índices de vegetação e medidor de clorofila SPAD 502, e classes de produtividade do feijoeiro, a partir de índices de vegetação. Foram feitos dois experimentos em épocas diferentes (“seca” e “inverno” de 2007) com uso de irrigação por aspersão convencional. O delineamento experimental utilizado foi o de blocos casualizados, com tratamentos distribuídos em esquema fatorial 5 x 6, com três repetições, totalizando 90 parcelas. Os tratamentos foram constituídos por cinco doses de nitrogênio (N) (0, 20, 30, 40 e 50 kg ha⁻¹) aplicadas na semeadura e seis doses de N (0, 20, 30, 40, 60 e 80 kg ha⁻¹) aplicadas em cobertura, totalizando 30 tratamentos. Foram obtidas imagens em diferentes fases do desenvolvimento da cultura. O teor de clorofila nas folhas foi estimado utilizando-se um medidor portátil de clorofila e o teor de N foliar foi determinado em amostras por meio de análise laboratorial. Avaliou-se a relação funcional entre as doses de N aplicadas na semeadura, os valores SPAD e os valores de N foliar. Avaliou-se a correlação do valor SPAD com teor de N foliar e dos índices de vegetação com o teor de N foliar e produtividade. Os resultados obtidos permitiram as seguintes conclusões:

- Com a utilização do medidor de clorofila SPAD 502 a discriminação entre as doses de N aplicadas na semeadura foi possível nos dois experimentos estudadas. No experimento 1 aos 25 DAE e no experimento 2 aos 28 DAE.
- O valor SPAD correlacionou-se positivamente com o teor de N nas folhas no feijoeiro. O uso do medidor portátil SPAD 502 pode ser indicado para identificar N foliar nas folhas do feijoeiro no início do desenvolvimento da cultura.

- Nos dois experimentos, os índices de vegetação estudados, extraídos de imagens digitais, não correlacionaram com os valores de N foliar.
- Nos dois experimentos, os índices de vegetação correlacionaram positivamente com a produtividade do feijoeiro. No experimento 2 (“inverno”) a correlação foi maior com o avanço dos dias após a emergência.
- A utilização dos índices de vegetação não foi útil na discriminação das classes de N foliar.
- Na discriminação das classes de N foliar, os classificadores desenvolvidos com valores SPAD obtiveram melhores resultados que os desenvolvidos com os índices de vegetação.
- Os índices de vegetação conseguiram discriminar as classes de produtividade.
- A combinação de mais de um índice de vegetação influenciou de forma positiva nos valores dos índices Kappa.

6. REFERÊNCIAS BIBLIOGRÁFICAS

ABREU, A. F. B; PELOSO, M. J. D. **Cultivares de Feijoeiro Comum para o estado de Minas Gerais**. Santo Antônio de Goiás –Go: Embrapa Arroz e Feijão, 2004. 4p. (Circular técnica 65, 2004).

ALVAREZ, V.H.; RIBEIRO, A.C. Calagem. In: RIBEIRO, A.C.; GUIMARÃES, P.T.G; ALVAREZ V., V.H. (Ed.) **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**, 5ª aproximação. Comissão de Fertilidade do Solo do Estado de Minas Gerais. Viçosa: CFSEMG, 1999. cap. 8, p. 43-66.

ANDREOTTI, M.; NAVA, I. A.; WIMMER, L. N.; GUIMARÃES, V. F.; FURLANI, E. J. Fontes de nitrogênio e modos de adubação em cobertura sobre a produtividade de feijão (*Phaseolus vulgaris* L.) na "safra das águas". **Acta Sci. Agron.**, Maringá, V. 27, n. 4, p.595-602, 2005.

ANTUNIASSI, U. R.; GADANHA, C. D. J. Aplicação localizada de produtos fitossanitários. In: BORÉM, A.; GIUDICE, M. P.; QUEIROZ, D. M.; MANTOVANI, E. C.; FERREIRA, L. R.; VALLE, F. X. R.; GOMIDE, R. L. (Ed.) **Agricultura de Precisão**. Viçosa: UFV, p.181-202, 2000.

BAESSO, M. M.; PINTO, F. A. C.; QUEIROZ, D. M.; VIEIRA, L. B.; ALVES, E. A. Determinação do "status" nutricional de nitrogênio no feijoeiro utilizando imagens digitais coloridas. **Eng. Agríc.**, Jaboticabal, V. 27, n. 2, p. 520-528, 2007.

BAESSO, M. M., **Análise do estatus do nitrogênio no feijoeiro utilizado imagens digitais**. 2005. 64f. Dissertação (Mestrado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa. 2005.

BLACKMER, T. M.; SCHEPERS, J. S.; VAEVEL, G. E.; MAYER, G. E. Analysis os aerial photography for nitrogen stress within corn fields. **Agronomy Journal**, v.88, p. 729-733, 1996.

BORÉM, A.; CARNEIRO, J. E. S. A Cultura. In: VIEIRA, C.; PAULA JÚNIOR, T. J. de; BORÉM, A. (Ed.). **Feijão**, 2. ed. Viçosa: Atual, Ed. Universidade Federal de Viçosa, cap. 1, p. 13-18, 2006.

BRASIL. **Ministério da Agricultura e reforma Agrária. Regras para análises de sementes**. Brasília: CLAV/DNDV/SNAD/MA, 365p, 1992.

CARVALHO, M. A. C.; FURLANI JÚNIOR, E.; ARF, O.; SÁ, M. E. de; PAULINO, H. B.; BUZZETTI, S. Doses e épocas de aplicação de nitrogênio e teores foliares deste nutriente e de clorofila em feijoeiro. **Revista Brasileira de Ciência do Solo**, v.27, p.445-450, 2003.

CENTRO DE SOCIOECONOMIA E PLANEJAMENTO AGRÍCOLA (CEPA). **Síntese Anual da Agricultura em Santa Catarina**. Florianópolis: Instituto CEPA/SC, 2006.

CENTRO DE SOCIOECONOMIA E PLANEJAMENTO AGRÍCOLA (CEPA). **Síntese Anual da Agricultura em Santa Catarina**. Florianópolis: Instituto CEPA/SC, 2007.

CHAGAS, J. M.; BRAGA, J. M.; VIEIRA, C.; SALGADO, L. T.; JUNQUEIRA NETO, A.; ARAÚJO, G. A. A.; ANDRADE, M. J. B. LANA, R. M. Q.; RIBEIRO, A. C. Feijão. In: RIBEIRO, A. C.; GUIMARÃES, P. T. G.; ALVAREZ V., V.H. (Ed.) **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**, 5ª aproximação. Comissão de Fertilidade do Solo do Estado de Minas Gerais. Viçosa: CFSEMG, cap. 18, p. 306-307, 1999.

CHAPMAN, S. C. & BARRETO, H. J. Using a chlorophyll meter to estimate specific leaf nitrogen of tropical maize during vegetative growth. **Agronomy Journal**, v.89, p.557-562, 1997.

CONAB, Ministério da Agricultura, pecuária e Abastecimento. Safra 2007/2008 6ª Levantamento de Grãos Março/2008. Disponível em: <http://www.conab.gov.br/>, acesso em 25 de março de 2008.

CONGALTON, R. G. A review of assessing the accuracy of classifications of remotely sensed data. **Remote sensing thematic accuracy assessment: A compendium**, n 37, p.35-46, 1991.

COSTA, C.; DWYER, L. M.; DUTILLEUL, P.; STEWART, D. W.; MA, B. L.; SMITH, D. L. Inter-relationships of applied nitrogen, spad, and yield of leafy and non-leafy maize genotypes. **Journal of Plant Nutrition**, v. 24, n. 8, p.1173 - 1194, 2001.

EPIPHANIO, J. C. N.; GLERIANE, J. M.; FORMAGGIO, A. R.; RURDOFF, B. F. T. Índice de vegetação no sensoriamento remoto da cultura do feijão. **Pesquisa agropecuária brasileira**, Brasília, v.31, n.06, p.445-454, 1996.

EPIPHANIO, J. C. N. ; HUETE, A. R. . Influence of Sun and sensor geometry on the relationship between vegetation indices and fapar in alfalfa. **Remote Sensing of Environment**, v. 51, p. 351-360, 1995.

FONTES, P. C. A. **Diagnóstico do estado nutricional das planta**. Viçosa: Universidade Federal de Viçosa, 3 ed., 122p, 2006.

FURLANI JÚNIOR, E.; NAKAGAWA, J.; BULHÕES, L. J.; MOREIRA, J. A. A.; GRASSI FILHO, H. Correlação entre leituras de clorofila e níveis de nitrogênio aplicados em feijoeiro. **Bragantia**, Campinas, v. 55, n. 1, p. 171-175, 1996.

GITELSON, A. A. Wide Dynamic Range Vegetation Index for remote quantification of biophysical characteristics of vegetation. **Journal Plant Physiology**, n. 161, p. 165-173, set. 2004.

GITELSON, A. A.; KAUFMAN, Y. J.; MERZLYAK, M. N. Use of a green channel in remote sensing of global vegetation from EOS-MODIS. **Remote Sensing of Environment**, v.58, p.289-298, 1996.

GOEL, P. K.; PRASHER, S. O.; PATEL, R. M. ; DITOMMASO, A.; SMITH, D. L. Airborne optical remote sensing for detection of weed investation in site specific management of field crops. **ASAE Annual international Meeting**, Milwaukee, WI. Paper nº 003056, 13p, 2000.

GOEL, P. K.; PRASHER, S. O.; PATEL, R. M. ; LANDRY, J. A.; BONNELL, R. B.; VIAU, A. A. Classification of hyperspectral data by decision trees and artificial neural networks to identify weed stress and nitrogen status of corn. **Computers and Electronics in Agriculture**, v. 39, n. 2, p. 67-93, 2003.

GOPALAPILLAI, S.; TIAN, L.; BEAL, J. Detection of nitrogen stress in corn using digital aerial imagery. In: **ASAE Annual International Meeting**, Orlando. Paper nº 98-3030, 1998.

GONZALES, R. C.; WOODS, R. E. **Processamento de imagens digitais**. Editora Edgard Blücher Ltda, São Paulo. 509p, 2000.

HANSEN, P. M.; SCHJOERRING, J. K. Reflectance measurement of canopy biomass and nitrogen status in wheat crops using normalized difference vegetation indices and partial least squares regression. **Remote sensing of environment**, New York, n.86, p.542–553, 2003.

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

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v. 25, p. 295-309, ago. 1988.

KARIMI, Y.; PRASHER, S. O.; PATEL, R. M.; KIM, S. H. Application of support vector machine technology for weed and nitrogen stress detection in corn. **Computers and Electronics in Agriculture**, v. 51, p. 99-109, 2005.

KHATTREE, R.; NAIK, D. N. **Multivariate data reduction and discrimination with SAS software**. Cary: SAS Institute, 574 p, 2000.

KIKUTI, H.; ANDRADE, M. J. B.; CARVALHO, J. G.; MORAIS, A. R. Nitrogênio e fósforo em feijão (*Phaseolus vulgaris* L.) variedade cultivada BRS MG Talismã. **Acta Sci. Agron.**, Maringá, V. 27, n. 3, p.415-422, 2005.

LANDIS, J.R.; KOCH, G.G. The measurement of observer agreement for categorical data. **Biometrics**, v. 33, n. 1, p. 159-174, 1977.

MALAVOLTA, E., VITTI, G.C., OLIVEIRA, S.A. **Avaliação do estado nutricional das plantas: princípios e aplicações**. Piracicaba : POTAFÓS, p. 319, 1997.

MARTINEZ, H.E.P.; CARVALHO, J.G. de; SOUZA, R.B. de. Diagnose Foliar. In: RIBEIRO, A.C.; GUIMARÃES, P.T.G; ALVAREZ V., V.H. (Ed.) **Recomendações para o uso de corretivos e fertilizantes em Minas Gerais**, 5ª aproximação. Comissão de Fertilidade do Solo do Estado de Minas Gerais. Viçosa: CFSEMG, 1999. cap. 17, p. 144-168.

MENESES, P. R.; MADEIRA NETTO, J. S. **Sensoriamento remoto - reflectância dos alvos naturais**. Brasília: EMBRAPA, 262p, 2001.

MOLIN, J. P. **Tendências da agricultura de precisão no Brasil**. In: Congresso Brasileiro de agricultura de precisão – Piracicaba, SP – ESALQ/USP, 2004.

MOREIRA, M. A.; **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. Viçosa: Universidade Federal de Viçosa, 320p, 2005.

OLIVEIRA, S. H. F; Manejo do mofo branco. **Revista DBO Agrotecnologia**, n. 4, 2005.

ORLANDO, R. C. **Sistema de visão artificial para discriminação entre plantas daninhas e milho**. Viçosa, MG: UFV, 2003. (dissertação doutorado).

PEDREIRA, B. C. C. G.; SANTOS R. F. dos. Avaliação das escalas de 1:25.000 e 1:100.000 em mapeamentos orientados a planejamentos ambientais. **Caderno de Informações Georreferenciadas**. v.1, n.3, 1999.

PINTO, F. A. C; SENA Jr, D. G.; QUEIROZ, D. M.; GOMIDE, R. L. Visão artificial na agricultura de precisão. In: BALASTREIRE L.A. **Avanços na Agricultura de Precisão no Brasil no período 1999-2001**. ESALQ/USP, Piracicaba, p.309-316, 2001.

PIRES, J. L. F.; CUNHA, G. R.; PASINATO, A.; FRANÇA, S. ; RAMBO, L. **Discutindo agricultura de precisão – Aspectos Gerais**. Embrapa (Documento online 42), 2004.

PONTES, P. P. B.; ROCHA, J. V.; LAMPARELLI, R. A. C. **Análise temporal de índices de vegetação como subsídio à previsão de safras de cana-de-açúcar**. Simpósio Brasileiro de sensoriamento remoto, Goiânia, p.2017-224, 2005.

QUEIROZ, D. M.; DIAS, G. P.; MANTOVANI, E. C. Agricultura de precisão na produção de grãos. In: BORÉM, A.; GIUDICE, M. P.; QUEIROZ, D. M.; MANTOVANI, E. C.; FERREIRA, L. R.; VALLE, F. X. R.; GOMIDE, R. L. (Ed.) **Agricultura de Precisão**. Viçosa: UFV, p.1-41, 2000.

RAUN, W. R.; SOLIE, J. B.; JOHNSON, G. V.; STONE, M. L.; MULLEN, R. W.; FREEMAN, K. W.; THOMASON, W. E.; LUKINA, V. Improving nitrogen use efficiency in cereal grain production with optical sensing and variable rate application. **Agronomy Journal**. v.94, p.815-820, 2002.

ROSOLEM, C. A. Calagem e adubação mineral. In: ARAÚJO, R. S.; RAVA, C. A.; STONE, L. F.; ZIMMERMANN, M.J.O. (Coords.). **Cultura do feijoeiro comum no Brasil**. Piracicaba: Potafós, p.353-390, 1996..

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W.; HARLAN, J. C. **Monitoring the vernal advancement of retrogradation (greenwave effect) of natural vegetation**. NASA/GSFC, Type III, Final Report, Greenbelt, MD, 371 p, 1974.

SANTOS, J. B.; GAVILANES, M. L. Botânica. In: VIEIRA, C.; PAULA JÚNIOR, T. J. de; BORÉM, A. (Ed.). **Feijão**, 2. ed. Viçosa: Atual, Ed. Universidade Federal de Viçosa, cap. 1, p. 13-18, 2006.

SARAIVA, A. M.; CUGNASCA, C. E.; HIRAKAWA, A. R. Aplicação em taxa variável de fertilizantes e sementes. In: BORÉM, A.; GIUDICE, M. P.; QUEIROZ, D. M.; MANTOVANI, E. C.; FERREIRA, L. R.; VALLE, F. X. R.; GOMIDE, R. L. (Ed.) **Agricultura de Precisão**. Viçosa: Universidade Federal de Viçosa, p.109-145, 2000.

SAS Institute. **SAS Online Doc**. Version 8, SAS Institute Inc., Cary, USA, 1999.

SCHEPERS, J. S.; BLACKMER, T. M.; WILHELM, W. W.; RESENDE, M. Transmittance and reflectance measurements of corn leaves from plants with different nitrogen and water supply. **Journal of Plant Physiology**, v. 148, p. 523 - 529, 1996.

SCHRÖDER, J.J.; NEETESON, J.J.; OENEMA, O.; STRUIK, P.C. Does the crop or the soil indicate how to save nitrogen in maize production? Reviewing the state of the art. **Field crops research**, Amsterdam, n.66, p.151-164, 2000

SENA Jr., D. G. **Utilização de técnicas de visão artificial para ajuste da adubação nitrogenada em trigo**. 2005. 160f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa. 2005.

SILVA, T. R. B.; LEMOS L. B.; TAVARES C. A. Produtividade e característica tecnológica de grãos em feijoeiro adubado com nitrogênio e molibdênio. **Pesquisa Agropecuária Brasileira**, v. 41, n. 5, p. 739-745, maio, 2006.

SILVA JÚNIOR, M. C; PINTO, F. A. C.; FONSECA, D. M.; QUEIROZ, D. M.; MACIEL, B. F. Detecção do efeito da adubação nitrogenada em *Brachiaria decumbens* Stapf. utilizando um sistema de sensoriamento remoto. **R. Bras. Zootec.**, v.37, n.3, p.411-419, 2008.

SILVEIRA, P.M.; BRAZ, A.J.B.P.; DIDONET, A.D. Uso do clorofilômetro como indicador da necessidade de adubação nitrogenada em cobertura no feijoeiro. **Pesquisa Agropecuária Brasileira**, Brasília, v. 38, n. 9, p. 1083-1087, set. 2003.

SORATTO, R. P.; CARVALHO, M. A. C.; ARF, O. Teor de clorofila e produtividade do feijoeiro em razão da adubação nitrogenada. **Pesquisa Agropecuária Brasileira**, Brasília, v. 39, n. 9, p. 895-901, 2004.

STAFFORD, J.V. Implementing precision agriculture in the 21st century. **Journal of Agricultural Engineering Research**, v.76, n.3, p.26 -275, 2000.

STONE, L.F.; MOREIRA, J.A.A. Resposta do feijoeiro ao nitrogênio em cobertura, sob diferentes lâminas de irrigação e preparos do solo. **Pesquisa Agropecuária Brasileira**, v.36, n. 3, p.473-481, março, 2001.

TEIXEIRA, I. R.; ANDRADE, M. S. B.; CARVALHO, J. G., MORAIS; A. R., Corrêa J. B. D. Resposta do feijoeiro comum (*Phaseolus vulgaris* L.cv. Pérola) a diferentes densidades de semeadura e doses de nitrogênio. **Ciência e Agrotecnologia**, v. 24, n. 2, p. 399-408, abr./jun., 2000.

VARELLA, C. A. A. **Estimativa da produtividade e do estresse nutricional da cultura do milho usando imagens digitais**. 2004. 407f. Tese (Doutorado em Engenharia Agrícola) – Universidade Federal de Viçosa, Viçosa. 2004.

VIDERE DESIGN. STH-DCSG-VAR/-C Stereo Head User`s Manual. Califórnia, EUA, 27 p. 2005.

VIEIRA, C. Adubação Mineral e Calagem. In: VIEIRA, C.; PAULA JÚNIOR, T.J. de; BORÉM, A. (Ed.). **Feijão**, 2. ed. Viçosa: Atual, Ed. Universidade Federal de Viçosa, cap. 6, p. 115-142, 2006.

WANDER, A. E. **Cultivo do Feijão Irrigado na Região Noroeste de Minas Gerais**. Santo Antônio de Goiás –Go: Embrapa Arroz e Feijão, dezembro/2005. 2005.

7. APÊNDICES

Apêndice A

Código-fonte do algoritmo implementado no MATLAB, para recortar as imagens para representar uma área de 2 x 2 metros.

```
% ROTINA PARA CORTE DE IMAGENS
% GISLAINE PACHECO TORMEN

clear; clc;

% copie e cole o diretorio de interesse
cd('D:\Gislaine\Gislaine\UFV\Mestrado\IMAGENS_GIZA\Imagens_29_10_07')
B=3; %Bloco

N=[0 20 30 40 60 80]; %doses de N em cobertura
for i=N %numeros de amostras
    l=strcat('0_',num2str(i),'_',num2str(B),'-Q.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('0_',num2str(i),'_',num2str(B),'-RGB.bmp');
    imwrite(I2,RGB)
end
for i=N %numeros de amostras
    l=strcat('20_',num2str(i),'_',num2str(B),'-Q.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('20_',num2str(i),'_',num2str(B),'-RGB.bmp');
    imwrite(I2,RGB)
end
for i=N %numeros de amostras
    l=strcat('30_',num2str(i),'_',num2str(B),'-Q.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('30_',num2str(i),'_',num2str(B),'-RGB.bmp');
    imwrite(I2,RGB)
end
for i=N %numeros de amostras
    l=strcat('40_',num2str(i),'_',num2str(B),'-Q.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('40_',num2str(i),'_',num2str(B),'-RGB.bmp');
    imwrite(I2,RGB)
end
```

```

for i=N %numeros de amostras
    l=strcat('50_',num2str(i),'_',num2str(B),'-Q.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('50_',num2str(i),'_',num2str(B),'-RGB.bmp');
    imwrite(I2,RGB)
end

for i=N %numeros de amostras
    l=strcat('0_',num2str(i),'_',num2str(B),'-L.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('0_',num2str(i),'_',num2str(B),'-IR.bmp');
    imwrite(I2,RGB)
end

for i=N %numeros de amostras
    l=strcat('20_',num2str(i),'_',num2str(B),'-L.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('20_',num2str(i),'_',num2str(B),'-IR.bmp');
    imwrite(I2,RGB)
end

for i=N %numeros de amostras
    l=strcat('30_',num2str(i),'_',num2str(B),'-L.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('30_',num2str(i),'_',num2str(B),'-IR.bmp');
    imwrite(I2,RGB)
end

for i=N %numeros de amostras
    l=strcat('40_',num2str(i),'_',num2str(B),'-L.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('40_',num2str(i),'_',num2str(B),'-IR.bmp');
    imwrite(I2,RGB)
end

for i=N %numeros de amostras
    l=strcat('50_',num2str(i),'_',num2str(B),'-L.bmp');
    I1=imread(I);
    I2=I1(88:232,48:192,:);
    RGB=strcat('50_',num2str(i),'_',num2str(B),'-IR.bmp');
    imwrite(I2,RGB)
end

```

Apêndice B

Código-fonte do algoritmo implementado no MATLAB, para calcular aos índices de vegetação extraídos das imagens recortadas.

```
% CALCULO DOS INDICES DOS RECORTES
% GISLAINE PCHECO TORMEN
% NDVI, GNDVI, SAVI E WDRVI

clear; clc;
cd ('D:\usuarios\GISLAINE\Mestrado\Projeto\Indices\Safra 2\Imagens_10_09_07')
B=3; % Bloco

N=[0 20 30 40 60 80];

for i=N %numeros de amostras
    IRGB=strcat('0_',num2str(i),'_',num2str(B),'-RGB.bmp');
    IIR=strcat('0_',num2str(i),'_',num2str(B),'-IR.bmp');
    I1=imread(IRGB);I2=imread(IIR);
    ni=(double(I2));r=(double(I1(:,1)));g=(double(I1(:,2)));

    NDVI=((ni-r)./(ni+r));GNDVI=((ni-g)./(ni+g));SAVI1=((ni-r)./(ni+r+0.25))*1.25;SAVI2=((ni-r)./(ni+r+0.5))*1.5;SAVI3=((ni-r)./(ni+r+1))*2;WDRVI1=(0.05*ni-r)./(0.05*ni+r);WDRVI2=(0.1*ni-r)./(0.1*ni+r);WDRVI3=(0.2*ni-r)./(0.2*ni+r);

    NDVI_M=mean(mean(NDVI));GNDVI_M=mean(mean(GNDVI));SAVI1_M=mean(mean(SAVI1));SAVI2_M=mean(mean(SAVI2));SAVI3_M=mean(mean(SAVI3));WDRVI1_M=mean(mean(WDRVI1));WDRVI2_M=mean(mean(WDRVI2));WDRVI3_M=mean(mean(WDRVI3));
    if i==0;
        ii=1;
    elseif i==20;
        ii=2;
    elseif i==30;
        ii=3;
    elseif i==40;
        ii=4;
    elseif i==60;
        ii=5;
    else i==80;
        ii=6;
    end
    resp0(1,ii)=NDVI_M;
    resp0(2,ii)=GNDVI_M;
    resp0(3,ii)=SAVI1_M;
    resp0(4,ii)=SAVI2_M;
    resp0(5,ii)=SAVI3_M;
    resp0(6,ii)=WDRVI1_M;
    resp0(7,ii)=WDRVI2_M;
    resp0(8,ii)=WDRVI3_M;

end

for i=N %numeros de amostras
    IRGB=strcat('20_',num2str(i),'_',num2str(B),'-RGB.bmp');
    IIR=strcat('20_',num2str(i),'_',num2str(B),'-IR.bmp');
    I1=imread(IRGB);I2=imread(IIR);
    ni=(double(I2));r=(double(I1(:,1)));g=(double(I1(:,2)));
```

```

NDVI=((ni-r)/(ni+r));GNDVI=((ni-g)/(ni+g));SAVI1=((ni-r)/(ni+r+0.25))*1.25;SAVI2((((ni-
r)/(ni+r+0.5))*1.5);SAVI3((((ni-r)/(ni+r+1))*2);WDRVI1=(0.05*ni-
r)/(0.05*ni+r);WDRVI2=(0.1*ni-r)/(0.1*ni+r);WDRVI3=(0.2*ni-r)/(0.2*ni+r);

```

```

NDVI_M=mean(mean(NDVI));GNDVI_M=mean(mean(GNDVI));SAVI1_M=mean(mean(SAVI
1));SAVI2_M=mean(mean(SAVI2));SAVI3_M=mean(mean(SAVI3));WDRVI1_M=mean(mea
n(WDRVI1));WDRVI2_M=mean(mean(WDRVI2));WDRVI3_M=mean(mean(WDRVI3));

```

```

if i==0;
    ii=1;
elseif i==20;
    ii=2;
elseif i==30;
    ii=3;
elseif i==40;
    ii=4;
elseif i==60;
    ii=5;
else i==80;
    ii=6;
end
resp20(1,ii)=NDVI_M;
resp20(2,ii)=GNDVI_M;
resp20(3,ii)=SAVI1_M;
resp20(4,ii)=SAVI2_M;
resp20(5,ii)=SAVI3_M;
resp20(6,ii)=WDRVI1_M;
resp20(7,ii)=WDRVI2_M;
resp20(8,ii)=WDRVI3_M;
end

```

```

for i=N %numeros de amostras
    IRGB=strcat('30_',num2str(i),'_',num2str(B),'-RGB.bmp');
    IIR=strcat('30_',num2str(i),'_',num2str(B),'-IR.bmp');
    I1=imread(IRGB);I2=imread(IIR);
    ni=(double(I2));r=(double(I1(:, :, 1)));g=(double(I1(:, :, 2)));

```

```

NDVI=((ni-r)/(ni+r));GNDVI=((ni-g)/(ni+g));SAVI1((((ni-r)/(ni+r+0.25))*1.25);SAVI2((((ni-
r)/(ni+r+0.5))*1.5);SAVI3((((ni-r)/(ni+r+1))*2);WDRVI1=(0.05*ni-
r)/(0.05*ni+r);WDRVI2=(0.1*ni-r)/(0.1*ni+r);WDRVI3=(0.2*ni-r)/(0.2*ni+r);

```

```

NDVI_M=mean(mean(NDVI));GNDVI_M=mean(mean(GNDVI));SAVI1_M=mean(mean(SAVI
1));SAVI2_M=mean(mean(SAVI2));SAVI3_M=mean(mean(SAVI3));WDRVI1_M=mean(mea
n(WDRVI1));WDRVI2_M=mean(mean(WDRVI2));WDRVI3_M=mean(mean(WDRVI3));

```

```

if i==0;
    ii=1;
elseif i==20;
    ii=2;
elseif i==30;
    ii=3;
elseif i==40;
    ii=4;
elseif i==60;
    ii=5;
else i==80;
    ii=6;
end
resp30(1,ii)=NDVI_M;
resp30(2,ii)=GNDVI_M;
resp30(3,ii)=SAVI1_M;
resp30(4,ii)=SAVI2_M;

```

```

    resp30(5,ii)=SAVI3_M;
    resp30(6,ii)=WDRVI1_M;
    resp30(7,ii)=WDRVI2_M;
    resp30(8,ii)=WDRVI3_M;
end

for i=N %numeros de amostras
    IRGB=strcat('40_',num2str(i),'_',num2str(B),'-RGB.bmp');
    IIR=strcat('40_',num2str(i),'_',num2str(B),'-IR.bmp');
    I1=imread(IRGB);I2=imread(IIR);
    ni=(double(I2));r=(double(I1(:,:,1)));g=(double(I1(:,:,2)));

    NDVI=((ni-r)./(ni+r));GNDVI=((ni-g)./(ni+g));SAVI1=(((ni-r)./(ni+r+0.25))*1.25);SAVI2=(((ni-
r)./(ni+r+0.5))*1.5);SAVI3=(((ni-r)./(ni+r+1))*2);WDRVI1=(0.05*ni-
r)./(0.05*ni+r);WDRVI2=(0.1*ni-r)./(0.1*ni+r);WDRVI3=(0.2*ni-r)./(0.2*ni+r);

    NDVI_M=mean(mean(NDVI));GNDVI_M=mean(mean(GNDVI));SAVI1_M=mean(mean(SAVI
1));SAVI2_M=mean(mean(SAVI2));SAVI3_M=mean(mean(SAVI3));WDRVI1_M=mean(mea
n(WDRVI1));WDRVI2_M=mean(mean(WDRVI2));WDRVI3_M=mean(mean(WDRVI3));
    if i==0;
        ii=1;
    elseif i==20;
        ii=2;
    elseif i==30;
        ii=3;
    elseif i==40;
        ii=4;
    elseif i==60;
        ii=5;
    else i==80;
        ii=6;
    end
    resp40(1,ii)=NDVI_M;
    resp40(2,ii)=GNDVI_M;
    resp40(3,ii)=SAVI1_M;
    resp40(4,ii)=SAVI2_M;
    resp40(5,ii)=SAVI3_M;
    resp40(6,ii)=WDRVI1_M;
    resp40(7,ii)=WDRVI2_M;
    resp40(8,ii)=WDRVI3_M;
end

for i=N %numeros de amostras
    IRGB=strcat('50_',num2str(i),'_',num2str(B),'-RGB.bmp');
    IIR=strcat('50_',num2str(i),'_',num2str(B),'-IR.bmp');
    I1=imread(IRGB);I2=imread(IIR);
    ni=(double(I2));r=(double(I1(:,:,1)));g=(double(I1(:,:,2)));

    NDVI=((ni-r)./(ni+r));GNDVI=((ni-g)./(ni+g));SAVI1=(((ni-r)./(ni+r+0.25))*1.25);SAVI2=(((ni-
r)./(ni+r+0.5))*1.5);SAVI3=(((ni-r)./(ni+r+1))*2);WDRVI1=(0.05*ni-
r)./(0.05*ni+r);WDRVI2=(0.1*ni-r)./(0.1*ni+r);WDRVI3=(0.2*ni-r)./(0.2*ni+r);

    NDVI_M=mean(mean(NDVI));GNDVI_M=mean(mean(GNDVI));SAVI1_M=mean(mean(SAVI
1));SAVI2_M=mean(mean(SAVI2));SAVI3_M=mean(mean(SAVI3));WDRVI1_M=mean(mea
n(WDRVI1));WDRVI2_M=mean(mean(WDRVI2));WDRVI3_M=mean(mean(WDRVI3));
    if i==0;
        ii=1;
    elseif i==20;
        ii=2;
    elseif i==30;

```

```

        ii=3;
    elseif i==40;
        ii=4;
    elseif i==60;
        ii=5;
    else i==80;
        ii=6;
    end
    resp50(1,ii)=NDVI_M;
    resp50(2,ii)=GNDVI_M;
    resp50(3,ii)=SAVI1_M;
    resp50(4,ii)=SAVI2_M;
    resp50(5,ii)=SAVI3_M;
    resp50(6,ii)=WDRVI1_M;
    resp50(7,ii)=WDRVI2_M;
    resp50(8,ii)=WDRVI3_M;
end

```

```

resp=[resp0 resp20 resp30 resp40 resp50]
wk1write ('i_B3.wk1',resp);

```

```

ni=(((ni-min(min(ni)))/(max(max(ni))-min(min(ni))))*255); % Reescalando (0 255)

```

Apêndice C

Código-fonte do algoritmo implementado no MATLAB para elaborar e avaliar classificadores estatísticos com os valores de índices de vegetação como vetor de entrada.

```
% ALGORITMO PARA ELABORAÇÃO E AVALIAÇÃO DE CLASSIFICADOR ESTATÍSTICO
% VALIDAÇÃO CRUZADA
% CALCULA COMBINAÇÃO DE ÍNDICES DE VEGETAÇÃO
% GISLAINE PACHECO TORMEN
% 3 CLASSES
% ADAPTADO DE SENA Jr. (2005)

clear
clc
% carrega os dados
[nomearq,caminho] = uigetfile('*.*txt','Selecione dados de origem');
dados=dlmread(strcat(caminho,nomearq));
parc=dados(:,1);
mat=dados(:,2:size(dados,2));
% calcula as combinacoes
indices=size(mat,2);
v=[1:indices];
% inicializa a matriz resultados do kappa
res_kappa=zeros(1,size(v,2)+2);
% inicializa o contador de combinacoes
tot_comb=0;
for n=1:indices;
    comb=combnk(v,n);
    disp(n)
    % monta a matriz com a combinacao da vez
    for i=1:size(comb,1)
        comb_vez=comb(i,:);
        tot_comb=tot_comb+1;
        for k=1:size(comb_vez,2)
            p=comb_vez(k);
            mat_vez(:,k)=mat(:,p);
        end
        mat_erro=zeros(3,3);
        % calcula dados para elaboracao do classificador
        for nc=1:size(mat_vez,1)
```

```

conta_1=1;
conta_2=1;
conta_3=1;
for c=1:size(mat_vez,1)
    if c ~= nc
        if parc(c,1)==1;
            mat_1(conta_1,:)=mat_vez(c,:);
            conta_1=conta_1+1;
        elseif parc(c,1)==2;
            mat_2(conta_2,:)=mat_vez(c,:);
            conta_2=conta_2+1;
        elseif parc(c,1)==3;
            mat_3(conta_3,:)=mat_vez(c,:);
            conta_3=conta_3+1;
        end
    end
end % c=1:size(mat_vez,1)
% calcula media e matriz de covariancia
med_1=mean(mat_1);
med_2=mean(mat_2);
med_3=mean(mat_3);
cov_1=cov(mat_1);
cov_2=cov(mat_2);
cov_3=cov(mat_3);
Sc=(conta_1-1)*cov_1 + (conta_2-1)*cov_2 + (conta_3-1)*cov_3 ;
Sc=Sc/((conta_1-1) + (conta_2-1) + (conta_3-1) );
% calcula os "d's"
d1=-0.5*(mat_vez(nc,:)'-med_1')*inv(Sc)*(mat_vez(nc,:)'-med_1')-0.5*log(det(Sc));
d2=-0.5*(mat_vez(nc,:)'-med_2')*inv(Sc)*(mat_vez(nc,:)'-med_2')-0.5*log(det(Sc));
d3=-0.5*(mat_vez(nc,:)'-med_3')*inv(Sc)*(mat_vez(nc,:)'-med_3')-0.5*log(det(Sc));
% "escolhe" o maior "d"
[dmax,classe]=max([d1;d2;d3]);
% monta a matriz de erros
if parc(nc,1)==1 & classe==1
    mat_erro(1,1)=mat_erro(1,1)+1;
elseif parc(nc,1)==1 & classe==2
    mat_erro(1,2)=mat_erro(1,2)+1;
elseif parc(nc,1)==1 & classe==3
    mat_erro(1,3)=mat_erro(1,3)+1;
elseif parc(nc,1)==2 & classe==1

```

```

        mat_erro(2,1)=mat_erro(2,1)+1;
    elseif parc(nc,1)==2 & classe==2
        mat_erro(2,2)=mat_erro(2,2)+1;
    elseif parc(nc,1)==2 & classe==3
        mat_erro(2,3)=mat_erro(2,3)+1;
    elseif parc(nc,1)==3 & classe==1
        mat_erro(3,1)=mat_erro(3,1)+1;
    elseif parc(nc,1)==3 & classe==2
        mat_erro(3,2)=mat_erro(3,2)+1;
    elseif parc(nc,1)==3 & classe==3
        mat_erro(3,3)=mat_erro(3,3)+1;
    end
    % limpa as matrizes da validacao cruzada
    clear mat_1 mat_2 mat_3
end % nc=1:size(mat_vez,1)
[kappa,var_kappa]=kappa_certo(mat_erro);
% armazena kappa e var_kappa
res_kappa(tot_comb,1:size(comb_vez,2))=comb_vez;
res_kappa(tot_comb,10)=trace(mat_erro)/sum(sum(mat_erro));
res_kappa(tot_comb,11)=kappa;
res_kappa(tot_comb,12)=var_kappa;
res_kappa(tot_comb,13:15)=mat_erro(1,1:3);
res_kappa(tot_comb,16:18)=mat_erro(2,1:3);
res_kappa(tot_comb,19:21)=mat_erro(3,1:3);
% passa para a proxima combinacao
clear mat_vez
end % i=1:size(comb,1)
end % n=1:indices;
%
nome_salva=(strcat('res_md',nomearq(size(nomearq,2)-8:size(nomearq,2))))
dlmwrite(nome_salva,res_kappa,'\t');
dlmwrite(nome_salva,res_kappa,'\t');

```

Apêndice D

Código-fonte do algoritmo implementado no MATLAB para cálculo do coeficiente Kappa e variância do Kappa.

```
% ALGORITMO PARA CALCULAR INDICE KAPPA
% GISLAINE PACHECO TORMEN
% ADAPTADO DE SENA Jr. (2005)

function [khat,var_k] = kappa_certo(me)
% exatidao global
eg=trace(me)/sum(me(:));
%
exp_a=sum(me,1)*sum(me,2)/sum(sum(sum(me,2)*sum(me,1)));
khat=(eg-exp_a)/(1-exp_a);
%
n=sum(sum(me));
%
mp=sum(me,2)*sum(me,1);
teta1=eg;
teta2=exp_a;
% teta 3= somatorio(me(ii)*(linha_marg(i)+col_marg(i))/n*n
somat3=0;
mg_li=sum(me,2)';
mg_co=sum(me,1);
soma_mg=mg_li+mg_co;
for i=1:size(me)
somat3=somat3+me(i,i)*(soma_mg(1,i));
end
teta3=somat3/n^2;
% teta4=somatorio(me(i,j)*(linha_marg(i)+col_marg(i))^2)/n^3
somat4=0;
for j=1:size(me,1)
for i=1:size(me)
somat4=somat4+me(i,j)*(mg_li(1,j)+mg_co(1,i))^2;
end
end
teta4=somat4/n^3;
% calcula variancia kappa
%
parc1=teta1*(1-teta1)/(1-teta2)^2;
parc2=2*(1-teta1)*(2*teta1*teta2-teta3)/(1-teta2)^3;
parc3=(1-teta1)^2*(teta4-4*teta2^2)/(1-teta2)^4;
var_k=(parc1+parc2+parc3)/n;
```

Apêndice E

Resultado das análises de solos para os dois experimentos (“seca” e “Inverno” de 2007). As análises do experimento 1 foi efetuado no laboratório de análise de solos de Viçosa Ltda na cidade de Viçosa - MG. As análises do experimento 2 foi efetuado no laboratório de análise de solos da Universidade Federal de Viçosa (Departamento de solos).

Resultados Analíticos – experimento 1 (“seca”)

Ref. Lab	Referência do Cliente	pH		P	K	Na	Ca ²⁺	Mg ²⁺	Al ³⁺	H + Al
		H ₂ O		mg/dm ³			cmolc/dm ³			
174	Amostra 00 -20 cm	4,8		10,8	43		0,7	0,4	0,5	3,63

SB	CTC (t)	CTC (T)	V	m	ISNa	MO	P-rem	Zn	Fe	Mn	Cu	B	S
cmolc/dm ³			%			dag/kg	Mg/L	mg/dm ³					
1,21	1,71	4,84	25	29		1,5	21,2	17,1	116,6	48	2,9	0,33	

Resultados Analíticos – experimento 2 (“inverno”)

Ref. Lab	Referência do Cliente	pH		P	K	Na	Ca ²⁺	Mg ²⁺	Al ³⁺	H + Al
		H ₂ O		mg/dm ³			cmolc/dm ³			
3955	Amostra 1	5,30		1,3	26		0,88	0,26	0,05	3,33

SB	CTC (t)	CTC (T)	V	m	ISNa	MO	P-rem	Zn	Fe	Mn	Cu	B	S
cmolc/dm ³			%			dag/kg	Mg/L	mg/dm ³					
1,21	1,26	4,51	26,8	4,0			25,6						

pH em água, KCl e CaCl₂ – Relação 1:2,5

P – Na – K – Fe – Zn – Mn – Cu – Extrator Mehlich 1

Ca – Mg – Al - Extrator: KCl mol/L

H + Al - Extrator Acetato de cálcio 0,5 mol/L – pH 7,0

B – Extrator água quente

S – Extrator – Fosfato monocálcico em ácido acético

SB = Soma de Bases Trocáveis

CTC (T) - (Capacidade de troca Catiônica a pH 7,0)

CTC (t) - (Capacidade de troca Catiônica Efetiva)

V = Índice de saturação de Bases

m = Índice de Saturação do Alumínio

ISNa - Índice de Saturação de Sódio

Mat. Org. (MO) = C.Org x 1,724 – Walkley – Black

P – rem = Fósforo Remanescente

Resultados de Análise Granulométricos – experimento 1 (“seca”)

Ref. Lab	Referencia do Cliente	Areia Grossa	Areia Fina	Silte	Argila	Classe Textural
1290	3942	9	9	17	65	Muito Argilosa

Resultados de Análise Granulométricos – experimento 2 (“inverno”)

Ref. Lab	Referencia do Cliente	Areia Grossa	Areia Fina	Silte	Argila	Classe Textural
1291	3955	6	2	18	74	Muito Argilosa